



Universidade de Brasília

Instituto de Ciências Exatas  
Departamento de Ciência da Computação

# Posicionamento dinâmico e eficiente de Estações Base LTE Móveis em cenários de desastre baseado em Algoritmo Evolucionário

Giordano Süffert Monteiro

Monografia apresentada como requisito parcial  
para conclusão do Curso de Engenharia da Computação

Orientador

Prof. Dr. Marcelo Antonio Marotta

Brasília  
2023



Universidade de Brasília

Instituto de Ciências Exatas  
Departamento de Ciência da Computação

# **Posicionamento dinâmico e eficiente de Estações Base LTE Móveis em cenários de desastre baseado em Algoritmo Evolucionário**

Giordano Süffert Monteiro

Monografia apresentada como requisito parcial  
para conclusão do Curso de Engenharia da Computação

Prof. Dr. Marcelo Antonio Marotta (Orientador)  
CIC/UnB

Prof. Dr. Lucas Bondan  
Rede Nacional de Ensino e Pesquisa

Prof. Dr. Thiago De Paulo Faleiros  
CIC/UnB

Prof. Dr. João Luiz Azevedo de Carvalho  
Coordenador do Curso de Engenharia da Computação

Brasília, 23 de janeiro de 2023

# Dedicatória

Dedico este trabalho aos meus pais, por sempre me apoiarem, não só durante toda minha trajetória acadêmica, mas também no meu desenvolvimento como pessoa e como profissional.

# Agradecimentos

Agradeço profundamente ao meu orientador, o Prof. Dr. Marcelo A. Marotta, por ter usado parte do seu tempo para me fazer crescer academicamente e auxiliar neste trabalho. À equipe dos professores que me ajudam desde o projeto de pesquisa do CCOpMv, Prof. Dr. Lucas Bondan, Prof. Dr. Geraldo P. Rocha Filho e Prof. Dr. Marcos F. Caetano, pelos ensinamentos e opiniões que contribuíram para essa pesquisa. Agradeço ao meu colega Juliano B. Pereira por ter participado do projeto de pesquisa do CCOpMv junto comigo e assim permitido que este trabalho chegasse às proporções que chegou hoje. A todos os meus familiares e amigos que acreditaram em mim e me apoiaram durante essa jornada.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES), por meio do Acesso ao Portal de Periódicos.

# Resumo

Este trabalho explora o problema de posicionamento de antenas móveis ao longo do tempo, aplicado a um cenário de desastre. Este tipo de problema é estudado em diversas ocasiões, em que a tecnologia utilizada e características geográficas do cenário causam um grande impacto na sua solução. Uma situação de desastre exemplifica bem esses impactos, de forma a necessitar de uma nova infraestrutura de comunicação independente para auxiliar operações de Comando e Controle que serão realizadas pelas tropas, como buscas e resgates. Suprir as necessidades desse tipo de cenário pede por dinamismo no tempo e no espaço, o que justifica a adoção do modelo do Centro de Coordenação de Operações Móveis (CCOpMv), criado pelo Exército Brasileiro. Esse modelo apresenta o 4G LTE dentre suas tecnologias e é composto por diversas viaturas, nas quais podem ser instalados eNodeBs de potência reduzida, facilitando assim o deslocamento das antenas no cenário. O elevado custo de cada um desses veículos faz com que seja necessário tentar minimizar sua quantidade. Para realizar essa minimização no problema de posicionamento de antenas móveis ao longo do tempo, o cenário é modelado e em seguida é proposta uma solução meta-heurística chamada *Predictive GA Deployer* (PGD), capaz de adaptar a instalação dessas antenas às necessidades dos usuários de forma dinâmica. Para comparação, também foi desenvolvida um algoritmo exato *Additive ILP Deployer* (AID) que necessita de toda a informação temporal do cenário de antemão. Essas soluções foram avaliadas por meio de simulações utilizando a plataforma OMNeT++, em que foram utilizadas situações com restrições de QoS diferentes. Os resultados da avaliação mostram que o número de antenas utilizadas pelo PGD e pelo AID foi diferenciável, de forma que o número de antenas do PGD se distancia mais do resultado ótimo quanto maior é o requisito de QoS. Ao mesmo tempo, o PGD se mostrou adequado para ser utilizado em cenários mais realistas, com uma restrição de QoS baixa, visto que não necessita da mesma completude de informações temporais que o AID.

**Palavras-chave:** Problema de posicionamento de antenas, Algoritmos de otimização, Minimização da quantidade de antenas, Rede em ambiente de desastre, Rede 4G LTE, Algoritmo genético aninhado, Estações base sobre rodas

# Abstract

This work explores the problem of positioning antennas on wheels over time, applied to a disaster scenario. This type of problem is studied in multiple occasions when the technology used and the geographic features of the setting make a big impact on its solution. A disaster situation exemplifies these impacts well, since it requires a new independent communication infrastructure to support Command and Control operations that will be carried out by the troops, such as searches and rescues. Meeting the needs of this type of scenario asks for dynamism in time and space, which justifies the adoption of the Mobile Operations Coordination Center (CCOpMv) model, created by the Brazilian Army. This model presents 4G LTE among its technologies and is composed of several vehicles in which can be installed eNodeBs with reduced power, facilitating the antenna displacement in the scenario. The high cost of each one of these vehicles makes it necessary to try to minimize the amount used. To do this minimization in the problem of positioning antennas on wheels over time, the scenario was modeled and a meta-heuristic solution, called Predictive GA Deployer (PGD), was proposed, since it is capable to dynamically install the antennas according to the users necessity. To compare, an exact algorithm called ILP Deployer (AID), that needs all the scenario temporal information beforehand, was also implemented. These solutions were evaluated through simulations using the OMNeT++ platform, in which situations with different shortQoS restrictions were used. The evaluation results show that the number of the antennas that were used by the PGD and the AID was differentiable, so that the number of the PGD antennas gets farther away from the optimal result the higher the QoS is. At the same time, the PGD has proven to be suitable for use in more realistic scenarios with a low QoS restriction, since it doesn't need the same completeness of temporal information as the AID.

**Keywords:** Antenna positioning problem, Optimization algorithms, Minimization of the number of antennas, Network in disaster environment, 4G LTE network, Nested genetic algorithm, Base stations on wheels

# Sumário

<b>1</b>	<b>Introdução</b>	<b>1</b>
<b>2</b>	<b>Contextualização</b>	<b>4</b>
2.1	Situações de desastre	4
2.2	CCOpMv	6
2.3	LTE	7
2.4	Algoritmos de Otimização	9
2.4.1	ILP	9
2.4.2	AG	10
<b>3</b>	<b>Trabalhos Relacionados</b>	<b>13</b>
<b>4</b>	<b>Modelagem e Definição do Problema</b>	<b>17</b>
4.1	Modelagem	17
4.2	Definição do Problema	20
<b>5</b>	<b>Soluções Propostas</b>	<b>24</b>
5.1	PGD	24
5.1.1	GA Externo	25
5.1.2	GA Interno	29
5.2	AID	32
<b>6</b>	<b>Avaliação e Resultados</b>	<b>33</b>
6.1	Cenário	33
6.2	Ferramentas de Simulação	33
6.2.1	OMNeT++	34
6.2.2	INET	34
6.2.3	Simu5G	35
6.3	Configurações	35
6.4	Análise dos Resultados	39

<b>7 Conclusões</b>	<b>44</b>
7.1 Contribuições	45
7.2 Trabalhos Futuros	45
<b>Referências</b>	<b>46</b>
<b>Anexo</b>	<b>48</b>
<b>I Implementação do PGD</b>	<b>49</b>



# Lista de Figuras

2.1	Arquitetura do CCOpMv . . . . .	6
2.2	Arquitetura de rede LTE . . . . .	8
2.3	Representação da população de um algoritmo genético . . . . .	10
2.4	Fluxograma de um algoritmo genético genérico . . . . .	11
2.5	Método de cruzamento de k pontos para k=2 . . . . .	12
2.6	Mutação por inversão . . . . .	12
4.1	Distribuição de usuários em uma faixa de tempo $t$ . . . . .	19
5.1	Fluxograma do PGD para uma faixa de tempo $t$ . . . . .	25
5.2	Construção da pontuação de <i>fitness</i> do GA Externo . . . . .	27
5.3	Fluxograma da função Mutação de Antenas . . . . .	28
5.4	Fluxograma do PGD com foco no cálculo da <i>fitness</i> . . . . .	30
6.1	Exemplo de cenário no simulador para $t = 0$ . . . . .	36
6.2	Exemplo de cenário no simulador para $t = 10$ . . . . .	37
6.3	Média do número de eNodeBs em cada simulação . . . . .	40
6.4	CDF do SNR médio recebido por cada UE . . . . .	40
6.5	CDF do <i>throughput</i> recebido por cada UE . . . . .	41

# Lista de Tabelas

4.1	Notação utilizada nesta obra. . . . .	18
6.1	Parâmetros utilizados nas simulações. . . . .	39
6.2	Tempos de Execução para o PGD. . . . .	43

# Lista de Abreviaturas e Siglas

**3G** *Third Generation of Mobile Phone Technology.*

**3GPP** *3rd Generation Partnership Project.*

**4G** *Fourth Generation of Mobile Phone Technology.*

**5G** *Fifth Generation of Mobile Phone Technology.*

**AG** *Algoritmo Genético.*

**AID** *Additive ILP Deployer.*

**BS** *Base Station.*

**C/I** *Carrier-to-Interference Ratio.*

**CCOpMv** *Centro de Coordenação de Operações Móveis.*

**CDF** *Cumulative Distribution Function.*

**CMM** *Communication Management Module.*

**CV** *Coeficiente de Variação.*

**DP** *Desvio Padrão.*

**E-UTRAN** *Evolved UMTS Terrestrial Radio Access Network.*

**eNodeB** *Evolved NodeB.*

**EPC** *Evolved Packet Core.*

**GA** *Genetic Algorithm.*

**gNodeB** *Next Generation NodeB.*

**IDE** *Integrated Development Environment.*

**ILP** *Integer Linear Programming.*

**LTE** *Long Term Evolution.*

**MILP** *Mixed Integer Linear Programming.*

**MME** *Mobility Management Entity.*

**MTU** *Maximum Transmission Unit.*

**NA** *Nó de Acesso.*

**NR** *New Radio.*

**OMNeT++** *Objective Modular Network Testbed in C++.*

**PCRF** *Policy and Charging Rules Function.*

**PGD** *Predictive GA Deployer.*

**PGW** *Packet Data Network Gateway.*

**QoS** *Quality of Service.*

**SGW** *Serving-Gateway.*

**SNR** *Signal to Noise Ratio.*

**TID** *Traditional ILP Deployer.*

**UAV** *Unmanned Aerial Vehicles.*

**UE** *User Equipment.*

# Capítulo 1

## Introdução

O planejamento de uma rede e o posicionamento de suas antenas são problemas estudados desde as primeiras tecnologias de comunicação sem fio e continuam sendo um desafio na implantação de redes com tecnologias mais atuais, como o *5G New Radio* e o *Long Term Evolution* (LTE). Sendo influenciada pela tecnologia utilizada, distribuição geográfica de seus usuários, limitações físicas do terreno, além de outros diversos fatores, a rede gerada deve fornecer uma cobertura do serviço dentro dos requisitos a serem estabelecidos. Seu principal objetivo é minimizar o custo de implantação e expansão de uma rede ao determinar a quantidade e localização de suas estações base (*Base Stations* - BSs).

Desastres naturais ou não naturais são resultados de eventos que causam danos materiais, humanos ou ambientais, como modificar o cenário geográfico, deixar pessoas em perigo e destruir a infraestrutura local de comunicação. Desta forma, são mobilizadas tropas para prestarem assistência no local, sendo necessária a instalação de uma nova infraestrutura de comunicação para auxiliar as operações de Comando e Controle que serão realizadas, como buscas e resgates. A fim de suprir a demanda, a rede precisa ser capaz de aumentar sua área de cobertura e a quantidade máxima de usuários conectados. Com isso em mente, uma possível solução é a utilização de BSs montadas em veículos, visto que possibilitam uma rápida instalação de novas antenas sem depender de uma infraestrutura de comunicação já existente no local.

Essa implantação dinâmica de BSs, que obedece a demanda de comunicação em novas áreas, gera um gasto cada vez maior com a instalação, manutenção e uso desses equipamentos. No contexto de urgência, também é necessário que o tempo para a instalação de uma nova BS seja curto. Como solução, é comum a utilização de uma rede distribuída, com a instalação de diversas BSs com potência e áreas de coberturas reduzidas a fim de aproximá-las dos usuários e permitir seu transporte e instalação em veículos, em contrapartida à utilização de poucas BSs fixas com uma potência maior.

Para tentar lidar com situações que exigem o planejamento de redes, foram realizados

diversos estudos publicados na literatura. Alguns deles focam no posicionamento de BSs ou simplesmente de antenas, sem dar atenção ao número total de antenas e à movimentação dos usuários [1, 2]. Já para os que se preocupam com a movimentação dos usuários, são visto exemplos em que foram utilizados algoritmos meta-heurísticos como *Gray Wolf Optimizer* e *Particle Swarm Optimizer* [3], buscando um posicionamento de BSs próximo ao ótimo com a consideração de eliminar ao final aquelas redundantes.

Neste trabalho, explora-se um cenário de desastre com base no projeto Centro de Coordenação de Operações Móveis (CCOpMv), um modelo do Exército Brasileiro que propõe a criação de uma infraestrutura de comunicações visto a necessidade do desdobramento planejado de tropas no decorrer do tempo. As BSs dessa rede são representadas por veículos militares capazes de abrigar diversos tipos de tecnologias de comunicação. Visando este objetivo, é escolhida a tecnologia *Fourth Generation of Mobile Phone Technology* (4G) LTE para criar essa infraestrutura sob demanda, de forma que suas estações rádio base, chamadas de Evolved NodeBs (eNodeBs), tem uma potência reduzida e são agora montadas em veículos, ou seja, são móveis. No CCOpMv existem dois tipos diferentes de veículos: (i) um nó principal fixo (CMM) e (ii) um conjunto de nós de acesso móveis (NAs). Todos eles apresentam a capacidade de operar de forma independente, caso necessário, além de um alto custo de criação e operação.

No problema de posicionamento de antenas, é possível utilizar o valor da relação entre sinal e ruído (*Signal to Noise Ratio* - SNR), utilizado em [1, 2], como métrica para medir a qualidade do serviço mínima que deve ser fornecida a todos os usuários do cenário. Uma BS apresenta também uma quantidade máxima de usuário que ela é capaz de servir, além de querer se conectar a outras por meio de uma conexão de *backhaul* para permitir a troca de informações. Assim, a rede instalada deve ser capaz de permitir o uso das aplicações necessárias com uma qualidade mínima a todo momento, sem saturar o local com veículos desnecessários, visto que o custo de uma missão também é um fator essencial para determinar sua viabilidade.

Esse problema de otimização, por ser um problema linear, pode ser facilmente resolvido utilizando algoritmos exatos que retornam a solução ótima, como utilizando Programação Inteira Linear (*Integer Linear Programming* - ILP), em que os deslocamentos de todos os usuários ao longo do tempo são conhecidos de antemão. Porém, em um cenário real de desastre não é possível ter esse tipo de informação de antecipadamente, já que os usuários se adaptam constantemente à situação em que se encontram.

Dessa forma, é necessário o estudo de soluções capazes de ajustar o posicionamento de antenas ao longo do tempo levando em consideração a movimentação e necessidade dos usuários. Propõe-se então a aplicação meta-heurística *Predictive GA Deployer* (PGD), formada por algoritmos evolucionários, para que resolva o problema em questão sob de-

manda e realize a minimização do número de eNodeBs, utilizando somente as informações atuais do cenário. Adicionalmente, também é proposto o algoritmo exato *Additive ILP Deployer* (AID), gerado a partir das restrições estabelecidas e baseado em ILP, para ser comparado com a solução meta-heurística PGD. Por fim, os resultados de ambos os algoritmos são avaliados por meio de diversas simulações de eventos discretos na plataforma OMNeT++ [4].

O restante do trabalho está organizado da seguinte maneira. O Capítulo 2 descreve e explica diversos conceitos e tecnologias utilizados nesse trabalho, como desastres, CCOpMv, redes LTE e algoritmos de otimização. O Capítulo 3 apresenta trabalhos relacionados encontrados na literatura que buscam resolver o problema de alocação de antenas em diferentes contextos. Em seguida, o Capítulo 4 descreve como foi realizada a modelagem do cenário e a definição do problema a ser resolvido. O Capítulo 5, por sua vez, apresenta as soluções propostas. Assim, Capítulo 6 define as especificidades do cenário considerado, informa as ferramentas de simulações utilizadas para realizar a avaliação dessas soluções e mostra os resultados obtidos. Por fim, o Capítulo 7 apresenta as conclusões e possíveis trabalhos futuros.

# Capítulo 2

## Contextualização

Este capítulo apresenta os tópicos de conhecimento necessários para uma melhor compreensão dos principais pontos que contextualizam este trabalho. Será explicado quais são as características de situações classificadas como desastre e o seu possível impacto na infraestrutura de comunicações local. Além disso, é apresentada a infraestrutura do Centro de Coordenação de Operações Móveis (CCOpMv) que define as soluções tecnológicas utilizadas. Em seguida, serão percorridos diferentes tipos de algoritmos de otimização e detalhados aqueles utilizados nas soluções propostas neste trabalho. Por fim, os componentes de uma rede LTE serão explicitados.

### 2.1 Situações de desastre

Um desastre é a consequência de eventos adversos sobre um cenário vulnerável, de forma a provocar danos e prejuízos mensuráveis, sejam eles humanos, materiais e/ou ambientais. De acordo com o Manual de Planejamento em Defesa Civil [5], os desastres podem ser classificados quanto a sua intensidade, evolução ou origem.

Quanto a intensidade, os desastres são classificados em quatro níveis:

1. Desastres de pequeno porte ou intensidade, também chamados de acidentes;
2. Desastres de médio porte ou intensidade;
3. Desastres de grande porte ou intensidade;
4. Desastres de muito grande porte ou intensidade.

Os danos materiais podem ser danificados ou destruídos. Eles são divididos em dois níveis de prioridade:

- **Prioridade I:**



- Instalações públicas de saúde;
- Unidades habitacionais de população de baixa renda;
- Instalações públicas de ensino;
- Obras de infra-estrutura pública;
- Outras instalações públicas prestadoras de serviços essenciais;
- Instalações comunitárias.

• **Prioridade II:**

- Instalações particulares de saúde;
- Instalações particulares de ensino;
- Instalações rurais, industriais, comerciais e de prestação de serviços;
- Residências das classes mais favorecidas.

Dentre os possíveis prejuízos resultantes de uma circunstância de desastre, está o mau ou não funcionamento da geração e distribuição de energia e de infraestruturas de comunicações locais. Além disso, um desastre natural, por exemplo, nem sempre ocorre em áreas de fácil acesso e com infraestrutura suficiente preexistente. Assim, é necessário estabelecer uma nova infraestrutura de comunicação para que seja possível a coordenação de possíveis resgates, entregas de suprimentos, etc.

Esta mobilização de recursos é realizada por um Centro de Comando e Controle, que irá definir como será o uso tanto dos recursos humanos (tropas) quanto de recursos materiais, visto que aqueles já existentes foram são as tropas que devem ser alocadas no espaço e no tempo, e os equipamentos necessários para a instalação de uma infraestrutura de comunicação independente.

Neste trabalho consideraremos situações de desastre em que os danos materiais observados foram de Prioridade I, como danos à infraestruturas de comunicação pública e instalações públicas de serviços emergenciais voltadas para esse tipo de situação, e danos de Prioridade II como a destruição de serviços privados de comunicação. Dessa forma, o cenário analisado considera uma situação de desastre de Nível 4 (desastres de muito grande porte ou intensidade) em que os danos causados são muito importantes e os prejuízos consequentes são muito volumosos, havendo então a necessidade de assistência substancial da defesa civil.

Um exemplo desta categoria de desastre é o rompimento da barragem da Vale em Brumadinho, no dia 25 de janeiro de 2019, que provocou a destruição de cerca de 200 hectares de vegetação nativa e áreas de proteção, além da perda de 270 vidas humanas [6]. Seus impactos sociais foram a destruição de estruturas públicas e privadas, restrição

de usos possíveis para as águas, entre outros. Já seus impactos ao meio ambiente foram principalmente a destruição de grande parte da vida aquática e os impactos negativos na vida terrestre. Visto a escala do desastre, fez-se necessário o auxílio de tropas não só municipais e estaduais mas também federais e internacionais.

## 2.2 CCOpMv

O Centro de Coordenação de Operações Móveis (CCOpMv) é um projeto estratégico que está em desenvolvimento pelo Exército Brasileiro para possibilitar que diferentes serviços e tecnologias estejam disponíveis para tropas em uma situação que necessite da implementação dessa infraestrutura. Ele é composto por caminhões equipados por diversos tipos de tecnologia, como 4G LTE, rádio HF, VHF e UHF, sendo capaz de criar uma nova infraestrutura de redes e comunicação independente de qualquer serviço local.




Figura 2.1: Arquitetura do CCOpMv

Existem dois diferentes tipos de veículos: um nó principal fixo, chamado de *Communication Management Module* (CMM), e um conjunto de nós de acesso (NA) móveis, como pode ser visto na Figura 2.1. O CMM atua como a conexão externa de grande capacidade à Internet ou serviços de forma geral, além de atuar como um ponto de convergência às tropas do cenário. Já no caso dos NAs, devem ser transportados os equipamentos ne-

cessários para a implantação dessa infraestrutura e para que, caso necessário, consigam operar de maneira independente de outros veículos.

Os NAs devem ser capazes de se comunicar com outros veículos próximos formando um *backhaul* para trocar informações. Dentre as possíveis formas de comunicação para esse criar *backhaul*, existem cabos de fibra óptica ou rádios micro-ondas. No contexto do trabalho, considera-se que essa comunicação seria feita por meio de rádios micro-ondas que apresentam um alcance de 2 km sem linha de visão, visto que esta é uma opção disponível ao utilizar esses veículos.

Neste trabalho a rede LTE foi a tecnologia escolhida para suprir as necessidades dos usuários do cenário, visto que é capaz de fornecer diversos serviços necessários em situações de desastre, como *Voice over IP* (VoIP) e videoconferências. Dessa forma, os NAs serão considerados como eNodeBs móveis, podendo se conectar com o núcleo da rede por meio do nó principal fixo ou de forma independente.

## 2.3 LTE

O *Long Term Evolution* é um padrão para comunicações banda larga sem fio para terminais portáteis, que ganhou o nome de 4G LTE. O padrão é desenvolvido pelo *3rd Generation Partnership Project* (3GPP), provendo um aumento de capacidade e velocidade quando comparado com o padrão do 3G.

A arquitetura de uma rede LTE, apresentada na Figura 2.2, é composta por duas partes principais: (i) a rede de acesso, chamada de *Evolved UMTS Terrestrial Radio Access Network* (E-UTRAN) e (ii) o núcleo da rede, chamado de *Evolved Packet Core* (EPC) [7].

A E-UTRAN, área de foco deste trabalho, é composta por estações rádio base chamadas de *Evolved NodeBs* (eNodeBs), responsáveis por realizar a comunicação com os equipamentos de usuário (UEs). Esses eNodeBs são capazes de realizar o gerenciamento de recursos, a compressão e proteção de dados, o roteamento e a garantia de uma qualidade de serviço (QoS) para as aplicações oferecidas [7, 8]. Dessa forma, a arquitetura da rede se simplifica já que não há necessidade de um controlador de acesso adicional separado das BSs.

Os eNodeBs podem ser classificados quanto ao seu poder de transmissão. Um eNodeB comum apresenta, de acordo com o 3GPP [9], uma potência de transmissão de 46 dBm para um portador de 10 MHz, podendo ser referenciado como um eNodeB para uma *macrocell*. Já para situações em que são necessárias potências menores são atribuídos outros nomes para essas células. Um exemplo é uma *microcell* onde ocorre uma concentração de

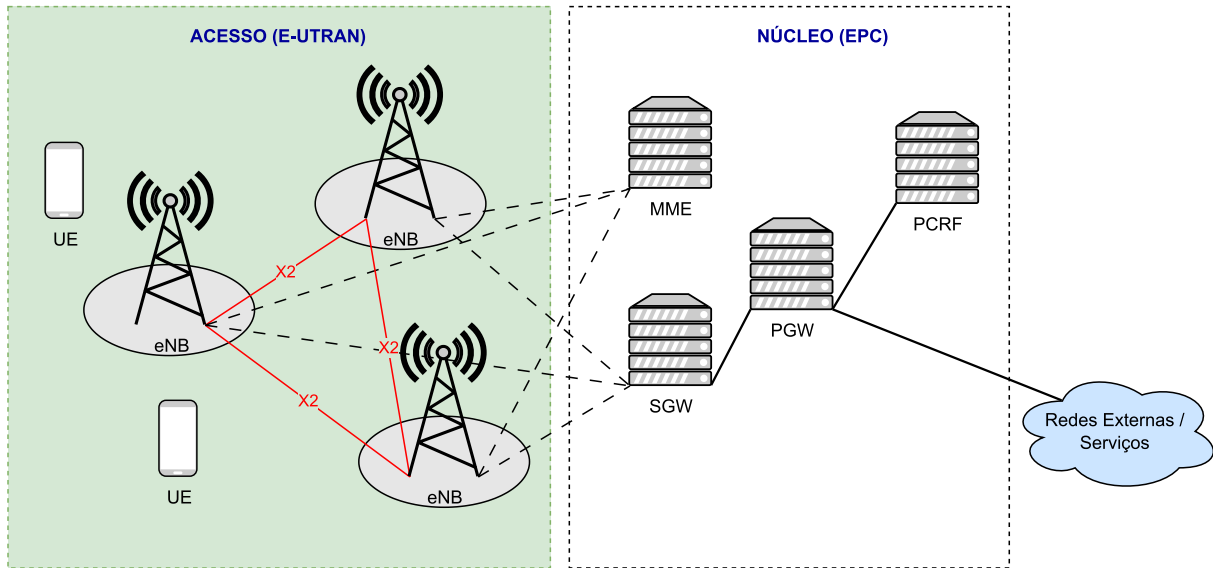


Figura 2.2: Arquitetura de rede LTE

usuários, sendo utilizados eNodeBs com potências de transmissão mais baixas, como 30 dBm.

O canal de rádio utilizado pelos eNodeBs, muitas vezes chamado de *carrier* ou portador, apresenta uma frequência e largura de banda definidas. A largura de banda determina os limites superiores e inferiores a partir da frequência principal que serão utilizados.

Por fim, uma operação que ocorre entre diferentes eNodeBs é o processo de *handover* de um UE. Neste processo, o UE já conectado à rede avalia o nível de sinal recebido de todos os eNodeBs de forma que, caso exista um eNodeB com um sinal melhor, é inicializado um processo do *handover* para que o UE se conecte a ele. Assim, é necessário que os eNodeBs se comuniquem entre si, havendo diversas formas para que isso ocorra dentro do LTE. Uma delas é o uso de uma nova interface que surgiu com os eNodeBs chamada de X2, em que a comunicação é feita diretamente entre eles, sem necessidade de passar pelo EPC [7].

O *Evolved Packet Core* (EPC) é composto, no mínimo, pelas seguintes entidades lógicas: (i) a Entidade de Gerenciamento de Mobilidade (MME), (ii) o *Serving-Gateway* (SGW), (iii) o *Packet Data Network Gateway* (PGW) e (iv) a Função de Política e Regras de Cobrança (PCRF), que se comunicam entre si, podendo estar ou não no mesmo equipamento físico [8, 10]. As funções de cada uma delas estão descritas abaixo:

- **MME:** gerencia a mobilidade dos usuários, ou seja, faz o rastreamento deles na rede, além de realizar a sinalização, o que inclui a autenticação e autorização desses usuários;
- **SGW:** responsável pelo roteamento e encaminhamento dos pacotes de dados de usuários;

- **PGW**: realiza a conexão entre a rede LTE e redes externas de pacotes de dados, como a Internet ou servidores de aplicações, atuando como a entrada e saída do tráfego da rede;
- **PCRF**: suporta serviços de detecção de fluxo de dados, política de fiscalização e cobrança baseada em fluxo.

## 2.4 Algoritmos de Otimização

A otimização é o problema de identificar a melhor solução dentre todas as soluções possíveis. Normalmente esse tipo de problema é descrito de forma a ser necessário maximizar ou minimizar certos valores, obedecendo um conjunto de restrições impostas sobre o cenário analisado. Para resolvê-los existem diferentes tipos de algoritmos com diversas classificações. Algumas elas são:

- **Exato**: é um algoritmo que é sempre capaz de encontrar a solução ótima para um problema, caso encontre uma;
- **Heurístico**: é um algoritmo capaz de gerar uma solução aparentemente boa para um problema específico mas sem garantir que ela será a ótima;
- **Meta-heurístico**: é um algoritmo que atua como uma *framework*, independente de problemas, que provê uma estratégia para desenvolver algoritmos heurísticos de otimização [11].

Em troca de um resultado não ótimo, os algoritmos heurísticos e meta-heurísticos possibilitam a solução de problemas mais complexos que não podem ser resolvidos por algoritmos exatos, além de poder ter outras vantagens, como um tempo de execução menor ou a possibilidade de fazer quase ou nenhuma suposição sobre o problema.

Em seguida são explicados dois exemplos de algoritmos em mais detalhes: (i) o exato ILP e o meta-heurístico Algoritmo Genético (AG), que serão utilizados neste trabalho.

### 2.4.1 ILP

Um problema *Integer Linear Programming* (ILP) é um programa matemático de otimização e/ou viabilidade em que o problema apresenta variáveis inteiras e suas restrições são lineares, sendo possível ser descrito como uma função linear. Ele é utilizado em casos em as variáveis representam quantidades que só podem ser inteiras ou decisões que devem ter o valor 0 ou 1. Além disso, quando alguma dessas variáveis não é discreta, o programa passa a ser chamado de *Mixed Integer Linear Programming* (MILP).

## 2.4.2 AG

Um Algoritmo Genético (AG) é um algoritmo meta-heurístico que apresenta um funcionamento inspirado pelo processo de seleção natural, fazendo parte de uma classe de algoritmos maior chamada algoritmos evolucionários. A fim de buscar uma solução satisfatória do problema em questão, o algoritmo simula a existência de uma população em que os indivíduos mais aptos passam suas características adiante e geram uma nova geração melhor do que a anterior.




Figura 2.3: Representação da população de um algoritmo genético

Como exemplificado na Figura 2.3, um AG é composto por uma população de indivíduos (cromossomos) em que cada um representa uma possível solução para o problema. Um cromossomo é formado por uma sequência de genes que apresentam um valor próprio. Normalmente um gene pode possuir um valor 0 ou 1, indicando a presença ou não da característica representada por ele. Porém, já existem implementações de AGs adaptados para aceitar um conjunto ou intervalo de números como o valor de um gene. A Figura 2.4 apresenta o fluxograma do comportamento genérico de algoritmo genético.

Visto que cada cromossomo apresenta uma sequência de genes, cada qual com um valor, é possível calcular o **grau de aptidão** de cada um deles, determinando o quão boa é a solução representada. A forma com que essa pontuação é calculada depende do que se pretende otimizar, restrições do cenário, impacto de determinados fatores no resultado, entre outros. Assim, a definição de uma função *fitness* que determina o grau de aptidão é de grande influência na qualidade dos resultados gerados pelo algoritmo.

Possuindo os valores de aptidão de cada indivíduo de uma população, é realizada uma **seleção** a fim de escolher aqueles que irão gerar a próxima geração. O método de seleção muitas vezes utiliza esses valores de aptidão no seu processo de decisão. Existem diversos algoritmos conhecidos, cada qual com diferentes pressões de seleção, como roleta (*roulette wheel*), classificação (*rank*) e estado estável (*steady state*) [12].

A técnica de seleção de roleta consiste em uma escolha randômica de indivíduos na qual a probabilidade de escolha de cada um é proporcional ao seu grau de aptidão. Por exemplo, caso um indivíduo tenha uma pontuação equivalente à metade da pontuação total da população, ele terá 50% de chance de ser escolhido. O método de seleção de




Figura 2.4: Fluxograma de um algoritmo genético genérico

classificação, por sua vez, não determina a probabilidade de escolha baseada diretamente no valor da pontuação de aptidão, mas sim na sua classificação comparando às pontuações do resto da população.

Já a seleção de estado estável (*steady state selection*) simplesmente seleciona alguns dos indivíduos com as melhores pontuações e removidos somente aqueles que apresentaram as piores pontuações, ao invés de substituir toda a população pelos novos indivíduos que serão gerados. Dessa forma é possível manter indivíduos além dos de melhor pontuação para gerar uma população diversa.

Após o processo de seleção, é realizado o **cruzamento** (*crossover*) a fim de representar o acasalamento entre indivíduos. O resultado desse cruzamento será novos indivíduos gerados a partir dos genes dos cromossomos selecionados, que irão substituir totalmente ou parcialmente a população atual. Existem diversos métodos de cruzamento, como o de um ponto (*one point*), o de k pontos (*k points*) e o uniforme [13].

No cruzamento de um ponto, um ponto na sequência de genes é escolhido de forma que, em um cenário com dois indivíduos parentes selecionados, os genes de depois desse ponto de um deles são substituídos pelos genes do outro, e vice-versa. O cruzamento de k pontos, exemplificado na Figura 2.5, é uma generalização do cruzamento de um ponto para qualquer número inteiro positivo de pontos, operando de forma a trocar os segmentos gerados pelos k pontos entre parentes alternadamente. Diferentemente, o método uniforme




Figura 2.5: Método de cruzamento de k pontos para k=2

gera novos indivíduos ao escolher um gene por vez, que pode ser de qualquer um dos parentes com mesma probabilidade.

Por fim, após a criação desse novo conjunto de indivíduos, é simulado o processo de **mutação** dos genes dos cromossomos, em que eles apresentam uma determinada chance de alterarem o seu valor, mantendo assim a diversidade na população. Alguns dos métodos de mutação são a inversão (*inversion*), a troca (*swap*) e a mistura (*scramble*) [14].



Figura 2.6: Mutação por inversão

A mutação por inversão define que, caso um gene seja selecionado para sofrer mutação, o seu valor será invertido, como demonstrado na Figura 2.6. No caso da mutação por troca, o valor de dois genes aleatórios são trocados. Já na mutação por mistura, um conjunto de genes selecionados terão sua ordem misturada, ou seja, terão seus valores embaralhados entre eles.

Ao final da mutação, é finalmente gerada uma nova população, ou seja, uma nova geração de soluções. Assim, esse processo de cálculo do grau de aptidão, seleção, cruzamento e mutação é repetido até seja alcançada uma **condição de parada**. Essa condição pode ser esperar até que seja encontrado um indivíduo com uma pontuação suficientemente alta ou pode ser um número máximo de gerações a serem criadas, selecionando o indivíduo da população final com o maior grau de aptidão como o resultado do algoritmo.

Vale apontar que os métodos utilizados nos processos de seleção, cruzamento e mutação, assim como a função *fitness*, podem ser escolhidos e adaptados para se adequarem melhor ao problema que deve ser resolvido e seu cenário.



# Capítulo 3

## Trabalhos Relacionados

Este capítulo apresenta artigos relevantes para resolver o problema de posicionamento de antenas em diversos contextos. Existem soluções tanto para tecnologias de comunicação sem fio de forma geral quanto para cenários que utilizando a tecnologia 4G LTE especificamente. Além disso, foi explorado em trabalhos mais recentes a possibilidade de movimentação dessas BSs e a consideração de concentrações de usuários.

Yang et al. [1] trabalham com a ideia de otimizar a localização de uma quantidade predeterminada de antena instaladas de forma circular para poder servir usuários distribuídos uniformemente no cenário. É possível observar uma abordagem para usuários distribuídos de uma maneira mais realística em [2], em que Zhang and Dai utilizam um algoritmo com gradiente estocástico para identificar concentrações de usuários e determinar a disposição das antenas de um *Distributed Antenna System* a fim de prover um melhor serviço. Porém, esses trabalhos ainda não exploram de maneira explícita a movimentação dos usuários no decorrer do tempo ou uma minimização do número de antenas utilizadas, além de tratar especificamente de antenas e não de BSs.

Ghazzai et al. [3] analisam a performance de dois métodos meta-heurísticos, o *Gray Wolf Optimizer* e o algoritmo de Otimização por Enxame de Partículas (*Particle Swarm Optimization*), como técnicas utilizadas para determinar a localização ótima de um conjunto de antenas dada uma distribuição de usuários na região em questão. Os algoritmos tiveram como fatores determinantes a taxa de dados máxima provida por cada antena, a quantidade máxima de estações base necessária e o raio de de serviço dessas estações, de forma a se adaptar dependendo da densidade de usuários em cada região e removendo antenas redundantes no final da análise. Assim, o artigo realiza um bom trabalho em demonstrar a possibilidade do uso de algoritmos meta-heurísticos para realizar um planejamento da implantação de estações base em um cenário com uma distribuição de usuários heterogênea, mesmo que não trabalhe considerando mudanças no cenário com o passar do tempo.

Jauhri et al. [15] fazem uma comparação entre o uso de algoritmos de busca estocástica diferentes para determinar as posições das antenas no cenário. Alguns desses algoritmos foram o *Annealing*, modelando o comportamento termodinâmico do sistema, e o algoritmo genético, também utilizado neste trabalho, mas aqui levado em consideração resultados de um software de modelagem de antenas para a avaliação das suas hipóteses e um número pré-determinado de antenas no cenário. Vale apontar que, para determinar o melhor posicionamento, o foco é dado sobre o padrão de radiação das antenas, minimizando o *Free-space path loss* e o *Mutual Coupling*, sem levar em consideração a passagem de tempo ou a disponibilidade e qualidade do serviço do ponto de vista dos usuários.

Sabouni et al. [16] propõem que sejam implementadas as chamadas *Self Organizing Networks* (SON) a fim de permitir uma adaptação dinâmica e automática da rede a diversas situações, condição também presente neste trabalho. Os algoritmos SON funcionam de forma a ligar e desligar eNodeBs conforme a necessidade dos usuários utilizando a infraestrutura já instalada, sendo possível utilizá-los em uma rede heterogênea centralizada ou em uma rede descentralizada sem Macro eNodeBs. Seu fator diferencial é a consideração da variação na quantidade e movimentação dos usuários no decorrer do tempo e a redução da quantidade de antenas ligadas em um determinado momento, se assemelhando com a nossa proposta na consideração do tempo em seu algoritmo, além de avaliar os resultados por meio de simulações.

Idris et al. [17] realizam um estudo sobre o planejamento de uma rede de aparelhos celulares LTE. Dessa forma, buscaram definir um processo de planejamento dessa rede capaz de determinar uma solução custo-efetiva e ótima, ou seja, que diminua o número de equipamentos utilizados, que responda às necessidades para análise de tráfego e consiga a capacidade ótima da rede. Esse processo consiste em dividir o cenário em *clusters* com diferentes concentrações de usuários, identificar o tipo de cenário de *pathloss* que será utilizado por cada antena e utilizar outros diversos parâmetros da rede gerados através de simulações como SNR, *throughput* e qualidade do sinal, para complementar a análise. Essa análise tem como diferencial os diferentes dados utilizados porém não considera a possibilidade de movimentação dos usuários ao longo do tempo.

No quesito da utilização de antenas móveis, Nemer et al. [18] trabalham com veículos aéreos não-tripulados (UAVs) que possuem antenas que funcionam como estações sem fio, a fim de prover uma área de cobertura melhor para usuários terrestres. Assim, é utilizada uma abordagem autônoma de tomada de decisão baseada em teoria de jogos para maximizar a área de cobertura e minimizar o custo energético dos UAVs. Também utilizando BSs aéreas, Wu et al. [19] apresentam um trabalho que utiliza essas BSs para suprir uma demanda súbita ou não disponível de uma rede terrestre de forma rápida e efetiva. Como solução para o problema de planejar a melhor localização para uma BS

aérea, é utilizado um modelo de aprendizagem por reforço profundo, capaz de retornar um resultado otimizado e de alta eficiência espectral, desde que seja treinado por experiências já registradas. Ambos esses trabalhos que utilizam antenas móveis apresentam interessantes soluções para o planejamento do posicionamento delas, mesmo não considerando a passagem de tempo em seus modelos.

Qutqut et al. [20] propõem uma estratégia de posicionamento dinâmico de BSs de menor potência, normalmente utilizada em locais fechados, no ao livre para complementar uma infraestrutura já existente. Assim, o trabalho define dois objetivos: minimizar o custo de entrega de dados e a minimização do uso da rede já existente. Esse problema de otimização é formulado como um *mixed integer linear program* MILP que determina as localizações ótimas de instalação de antenas dentre os *hotspots* existentes. Para solucioná-lo, foram desenvolvidos dois algoritmos gulosos, um para cada objetivo definido. Também com um foco em cenários com *hotspots* e na utilização de BSs de menor potência, Zhang et al. [21] fazem uma análise da alocação automática apropriada de BS de 5G neste tipo de ambiente urbano utilizando uma abordagem de programação dinâmica baseada em vetores, utilizando restrições de cobertura e custo. Mesmo com objetivos e cenários bem definidos, essas soluções não consideram a movimentação dos usuários no decorrer do tempo, e sim que as concentrações de usuários serão mantidas.

Essas soluções encontradas na literatura fazem referência a uma grande gama de tipos de cenários diferentes, sendo eles urbanos ou rurais. Além disso, fica evidente a necessidade da definição de um objetivo nesse tipo de problema de alocação de antenas, seja ele a entrega de um QoS mínimo, a maximização da área de cobertura, a minimização de custos, etc. Porém, a minimização do número de antenas, mesmo que esteja relacionada ao custo da rede e a área de cobertura, não é tratada diretamente pela grande parte dos algoritmos utilizados, realizando no máximo a retirada de antenas redundantes no final. Além disso, somente um dos trabalhos observados considera a movimentação dos usuários no decorrer do tempo em seu problema, porém sem influenciar no número de BS necessárias. Nos outros trabalhos, essa passagem do tempo não foi analisada, de forma a, ou considerar que uma certa distribuição ou densidade de usuários não se modificaria, ou simplesmente ignorando essa possibilidade ao utilizar um cenário mais realista.

Para cobrir essa lacuna observada na literatura, é necessária um nova solução que considere características de um cenário de desastre, ou seja, a modificação do cenário no decorrer do tempo e uma adição dinâmica de eNodeBs de forma a aumentar o número de antenas instaladas conforme a necessidade e movimentação dos usuários. Dessa forma, este trabalho propõe um algoritmo meta-heurístico PGD capaz de gerar soluções para o problema sem necessitar de todas as informações temporais sobre ele de uma só vez sob demanda, de forma que ele possa ser comparado com outros algoritmos, como um

algoritmo exato que gera uma solução ótima para o mesmo cenário.

# Capítulo 4

## Modelagem e Definição do Problema

Visando solucionar o problema de alocação eficiente de BSs para a criação de uma nova infraestrutura de comunicações em um cenário de desastre, este trabalho utiliza como base as BSs e tecnologias do projeto do Centro de Coordenação de Operações Móveis (CCOpMv). Assim é utilizada a tecnologia 4G LTE e suas BSs, eNodeBs, montadas em veículos para dar mobilidade a esses equipamentos, como pode ser visto no exemplo da figura 2.1, sendo esses veículos capazes de operar independentemente um dos outros e se comunicando entre si por meio de conexões de *backhaul*.

### 4.1 Modelagem

Considerando um cenário de desastre, faz-se necessário o envio de tropas e a instalação de uma nova infraestrutura de comunicações de acordo com a necessidade e movimentação desses usuários no decorrer do tempo. Geograficamente, esse cenário é mapeado em um conjunto de setores  $\mathcal{M} = \{1, 2, \dots, M\}$ , em que  $M$  é o cardinal desse conjunto e cada setor é denotado por um identificador  $m \in \mathcal{M}$ . Esses setores podem ter o formato e tamanho desejados, com a única restrição de não se sobreporem. Para este trabalho, considera-se um cenário retangular de tamanhos horizontal e vertical fixos  $I, J \in \mathbb{R}$  da ordem de quilômetros, permitindo a definição de setores quadrados. Cada setor  $m$  pode ser ou não capaz de possibilitar a instalação de uma estação base. Isso ocorre pois algumas localizações podem ser inacessíveis por meio de veículos terrestres ou apresentar riscos à pessoas ou equipamentos, como por exemplo um setor que inclui um rio ou no qual ocorreu um desabamento de terra. Para que esses tipos de quadros sejam considerados, cria-se uma máscara binária  $\mathcal{H}_M$  em que cada elemento  $h_m \in \{0, 1\}$  que indica a capacidade de um setor de receber uma antena ( $h_m = 1$ ) ou não ( $h_m = 0$ ).

O cenário pode ter diversos tipos de usuários, como moradores ou tropas de resgate que irão popular diferentes setores. Esses usuários podem chegar e sair de um setor  $m$

Tabela 4.1: Notação utilizada nesta obra.

Notação	Descrição
$\mathcal{M}$	Conjunto de setores geográficos
$m$	Identificador $\in \mathcal{M}$ de um setor
$\mathcal{T}$	Conjunto de faixas de tempo
$t$	Identificador $\in \mathcal{T}$ de uma faixa de tempo
$\mathcal{H}$	Máscara binária de viabilidade de instalação dos setores
$h_m$	Viabilidade de instalação $\in \mathcal{H}$ de uma BS em $m$
$\mathcal{U}$	Matriz da quantidade de UEs
$u_{tm}$	Quantidade de UEs $\in \mathcal{U}$ em $m$ no tempo $t$
$\mathcal{S}$	Matriz de estimativa de SNR
$s_{mn}$	Valor SNR estimado $\in$ para uma BS em $m$ e UEs em $n$
$\varepsilon(m, n)$	Função de SNR aproximado entre uma BS em $m$ e UEs em $n$
$D$	Matriz das distâncias entre setores
$d_{mn}$	Distância $\in D$ em os setores $m$ e $n$
$\psi(m, n)$	Função de distância entre os setores $m$ e $n$
$\phi$	Valor de SNR mínimo que deve ser entregue aos UEs
$\gamma$	Número máximo de UEs conectados suportado por cada BS
$\psi$	Maior distância possível para estabelecimento de <i>backhaul</i>
$x_{tm}$	Variável de decisão $\in \mathcal{X}$ da instalação de uma BS em $m$ no tempo $t$
$y_{tmn}$	Variável de decisão $\in \mathcal{Y}$ da conexão entre a BS em $m$ e UEs em $n$ no tempo $t$
$\mathcal{X}$	Matriz solução com o posicionamento das BSs
$\mathcal{Y}$	Matriz solução com as conexões entre UEs e BSs

ou da própria rede ao longo do tempo livremente, além de se locomover entre diferente setores. Dessa forma, para representar a mobilidade dos usuários ao longo do tempo, realiza-se a discretização de um intervalo de tempo finito em um conjunto de faixas de tempo  $\mathcal{T} = \{1, 2, \dots, T\}$ , em que cada faixa de tempo é representada por um identificador  $t \in \mathcal{T}$ , podendo retratar uma duração fixa de horas ou minutos ou indicar eventos específicos, como no caso de eventos periódicos que causam modificações significativas no cenário. Neste trabalho, para fins de simplificação, considera-se que cada faixa de tempo corresponde a uma hora, permitindo uma configuração mais facilitada de um cenário de uma duração inteira de horas e de uma movimentação que muda a cada hora. Além disso, utilizando esse tipo de representação, é possível criar uma matriz  $\mathcal{U}_{T \times M}$  em que cada elemento  $u_{tm} \in \mathbb{Z}^+$  demonstra a mudança no número de usuários da rede em um setor  $m$  ao longo de uma faixa de tempo  $t$ . Um exemplo dos dados dessa matriz para uma faixa de tempo específica pode ser visualizada na Figura 4.1, através de um cenário com 10 x 10 setores no qual os setores em vermelho possuem usuários.

Visto que todo setor pode ter uma antena e, conseqüentemente, aumentar a área de cobertura da rede, é possível estimar a razão sinal-ruído (SNR) para todos os possíveis

$U_{tij}$	1	2	3	4	5	6	7	8	9	10
1										
2							13	11	8	
3						7	6	23	4	
4						3	9	3	11	
5						2	5			
6	7	10	3							
7	11	19	4							
8	8	6	9							
9										
10										

Figura 4.1: Distribuição de usuários em uma faixa de tempo  $t$

pares  $m$  e  $n$  de setores, e gerar assim a matriz  $\mathcal{S}_{M \times M}$ . Cada elemento  $s_{mn} = \varepsilon(m, n)$  dessa matriz é o valor de uma aproximação do SNR computada através da função  $\varepsilon(m, n)$  que representa o modelo do canal da rede. Por exemplo, neste trabalho, o SNR aproximado foi modelado de acordo com:

$$\varepsilon(m, n) = \frac{P_m G_{mn} H_{mn}}{\sigma_{mn}} \quad (4.1)$$

onde  $P_m$  é a potência de transmissão da antena de um eNodeB móvel instalado no setor  $m$ , o  $G_{mn}$  é o produto dos ganhos do transmissor (eNodeB) e do receptor (UE) dos setores  $m$  e  $n$  respectivamente, e o  $H_{mn}$  representa causas de atenuação do sinal causada pela perda de propagação (*pathloss*) e outros efeitos relativos ao meio de propagação. Por fim,  $\sigma$  é constituído por todos os ruídos e outros efeitos, como o ruído térmico, *shadowing*, *fading*, figura de ruído, etc.

Como o modelo considera a contagem de tempo de minutos até horas, o estimador de SNR é completamente baseado na distância entre os elementos da rede e em outros componentes utilizados em simulações ou derivados de modelos empíricos, como a perda de propagação do cenário *Urban Micro* sem linha de visão (NLOS) do 3GPP [9, Anexo B.1.2.1]. Então, para que seja possível computar os diversos efeitos e componentes de canais considerados, a distância entre todos os setores é calculada através da confecção de uma matriz  $D_{M \times M}$  com elementos  $d_{mn} = \psi(m, n)$ , onde a função  $\psi(m, n)$  pode ser

definida por alguma fórmula de distância e  $d_{mn} \in \mathbb{R}^+$ , como por exemplo, a distância Euclidiana entre os centros geométricos de dois setores  $m$  e  $n$ .

Adicionalmente, também são definidos requisitos relevantes que devem ser alcançados pela rede de comunicação que será instalada. Um deles é a entrega de uma qualidade de serviço mínima, medida através do SNR estimado, que será entregue aos possíveis usuários de um setor como  $\phi \in \mathbb{R}^+$ , fazendo com que seja sempre possível que os usuários em uma situação de desastre, em que a perda de comunicação pode ser vital, tenham sempre acesso ao serviço necessário. Outro requisito estabelecido é que, após parar em um setor específico, o eNodeB móvel deve permanecer parado no mesmo local por uma quantidade de faixas de tempo mínima  $\delta \in \mathbb{Z}^+$  antes que possa se mover novamente para outro local, sendo ele resquício da possibilidade de que eNodeBs instalados poderiam mudar de localização no decorrer do tempo e não é utilizado neste trabalho. Cada eNodeB móvel também apresenta uma quantidade máxima de usuários  $\gamma$  aos quais suas antenas podem se conectar, visto que são limitadas. Além disso, um eNodeB móvel deve tentar se conectar com pelo menos um outro eNodeB por meio de um *backhaul* para que possam trocar informações relevantes. Para que esse *backhaul* exista e seja mantido, é necessário que haja uma distância mínima entre os veículos, sendo ela expressada em metros como  $\psi \in \mathbb{R}^+$  e determinada pela tecnologia utilizada.

Por fim, em relação ao nó fixo (CMM) da arquitetura do CCOpMv, por atuar como a conexão externa da nova infraestrutura à Internet, ele pode ser colocado em locais em que ainda existe alguma forma de conectividade a fim de utilizar conexões de maior capacidade ou comunicação via satélite para ganhar acesso a locais estratégicos. Devido à sua maior capacidade de comunicação e ser um ponto de convergência de tropas, é preferencial que outros veículos, neste caso os NAs, se conectem ao CMM para ter acesso à Internet, mesmo com esses veículos também possuindo esse acesso de forma independente caso necessário. Assim, o eNodeB do nó fixo será sempre a primeira BS a ser instalada e quase nunca irá mudar de posição após o início de uma missão.

Através da modelagem realizada do cenário, suas definições e requisitos da rede, torna-se possível definir o problema de posicionamento de antenas móveis terrestres no decorrer do tempo para prover uma infraestrutura de comunicação em casos de desastres, como será descrito em seguida.

## 4.2 Definição do Problema

Como o primeiro passo a fim de definir o problema em questão, serão definidas as variáveis de decisão existentes. O posicionamento dos veículos com as BSs deve ser condizente com



o cenário e assim deve ser definido no espaço e no tempo. A variável terrestre móvel  $x_{tm}$  é então determinada como:

$$x_{tm} = \begin{cases} 1; & \text{se um veículo está instalado em } m \text{ na faixa de tempo } t \\ 0; & \text{caso contrário} \end{cases} \quad (4.2)$$

Quando um veículo é posicionado em um setor, ele já é capaz de aumentar a área de cobertura de comunicação e se conectar com usuários de outros setores. A fim de simplificar essas conexões, assume-se que todos os usuários de um setor estarão conectados à mesma BS. Assim, criada-se uma segunda variável que representa as conexões entre setores com BSs e os setores com usuários servidos, de forma que:

$$y_{tmn} = \begin{cases} 1; & \text{se um veículo instalado no setor } m \text{ na faixa de tempo } t \text{ está} \\ & \text{servindo os usuários do setor } n \\ 0; & \text{caso contrário} \end{cases} \quad (4.3)$$

Com as variáveis estabelecidas, é buscado minimizar o número de veículos no problema de posicionamento de BSs móveis ao longo do tempo, visto que cada viatura apresenta um grande custo de produção e manutenção. Assim, a função objetivo é então definida como:

$$\begin{aligned} \min \quad & \sum_{t \in \mathcal{T}} \sum_{m \in \mathcal{M}} x_{tm} \\ \text{r.a.} \quad & [4.5 - 4.10] \end{aligned} \quad (4.4)$$

Essa função está sujeita às seguintes 6 restrições estabelecidas:

#### A. Requisitos QoS devem ser alcançados:

No cenário, um SNR mínimo  $\phi$  por setor deve ser oferecido para sustentar a conectividade. Neste caso, para cada faixa de tempo  $t$ , todos os setores  $n$  com ao menos um usuário devem ser servidos.

$$y_{tmn}\phi \leq s_{mn} \quad \forall t \in \mathcal{T}; \forall m \in \mathcal{M}; \forall n \in \mathcal{M} \mid u_{tn} > 0. \quad (4.5)$$

É possível perceber que, ao definimos que um SNR deve ser menor ou igual ao mínimo, a restrição permite com que a variável de conectividade seja zerada sem tornar o problema inviável.

**B. Veículos terrestres são capazes de suportar somente um número limitado de usuários:**

Os veículos do CCOpMv suportam um número limitado de usuários conectados ( $\gamma$ ) visto que o equipamento é restringido pelas suas baterias e não é capaz de operar por grandes períodos de tempo.

$$\sum_{n \in \mathcal{M}} y_{tmn} u_{tn} \leq \gamma; \quad \forall t \in \mathcal{T}; \forall m \in \mathcal{M}. \quad (4.6)$$

**C. Um setor  $n$  só deve estar conectado à uma única estação base de um setor  $m$ :**

Os equipamentos de usuários apresentam a necessidade e capacidade de se conectarem a somente uma antena de uma BS por vez.

$$\sum_{m \in \mathcal{M}} y_{tmn} = 1; \quad \{\forall t \in \mathcal{T}; \forall n \in \mathcal{M} \mid u_{tn} \neq 0\}. \quad (4.7)$$

**D. Após instalada, uma estação base não pode ser removida:**

Um veículo contendo uma BS se instala em um determinado setor  $m$  e permanece neste local até o final da operação realizada no cenário.

$$\begin{aligned} x_{(t-1)m} - x_{tm} &\leq 0; \\ \forall m \in \mathcal{M}; \forall n \in \mathcal{M}; \{\forall t \in \mathcal{T} \mid t > 0\}. \end{aligned} \quad (4.8)$$

**E. Conexões com  $n$  só são realizadas se uma estação base existir em  $m$ :**

Só deve ser possível para um equipamento de usuário localizado em um setor  $n$  se conectar a um setor  $m$  caso exista uma BS nesse setor para realizar conexão.

$$y_{tmn} - x_{tm} \begin{cases} \leq 0; \forall t \in \mathcal{T}; \{\forall m \in \mathcal{M}; \forall n \in \mathcal{M}; | m \neq n\} \\ = 0; \forall t \in \mathcal{T}; \{\forall m \in \mathcal{M}; \forall n \in \mathcal{M}; | m = n\} \end{cases} \quad (4.9)$$

É possível perceber que, de acordo com essa restrição, se existirem usuários no mesmo setor  $m$  de uma BS instalada, esses usuários devem se conectar à esse setor. Foi assim definido pois ela proverá um sinal melhor do que outras estações base de outros setores.

#### F. Uma estação base deve estar conectada ao *backhaul*:

Dado uma tecnologia utilizada para conexões entre os veículos da arquitetura do CCOpMv, existe um alcance máximo  $\psi$  no qual uma conexão pode ser estabelecida. Dessa forma, a fim de possibilitar a troca de informação entre estações base, faz necessário que um setor  $m$  que abriga uma BS deve estar a uma distância de até no máximo  $\psi$  de outro setor que também contém uma BS.

$$x_{tm} - \sum_{n \in \mathcal{M} \mid n \neq m; d_{mn} \leq \psi} x_{tn} \leq 0 \quad (4.10)$$

$$\forall t \in \mathcal{T}; \forall m \in \mathcal{M}.$$

Com o problema definido na equação 4.5, é possível desenvolver propostas de solução que buscam esse objetivo de minimizar o número de BSs móveis. O problema definido é um problema linear inteiro misto, que pode ser resolvido através do uso de solucionadores de programação linear, como OR-Tools<sup>1</sup>. Para ser solucionado em um solucionador, esse problema deve apresentar todos os deslocamentos dos usuários ao longo do tempo. Entretanto, em um caso real, esses deslocamentos não são conhecidos de antemão. Dessa forma, mecanismos meta-heurísticos como o Algoritmo Genético, devem ser explorados e propostos, como apresentados no capítulo a seguir.

---

<sup>1</sup>Google - Operations Research Tools (OR-Tools). <https://developers.google.com/optimization>[Último Acesso em 27/01/2023]

# Capítulo 5

## Soluções Propostas

Normalmente, em um contexto de desdobramento de tropas, não é correto assumir que já são conhecidos os comandos que serão dados ou o posicionamento dos usuários, visto que são resultados de uma constante adaptação à situação. Dessa forma, este trabalho propõe o uso de dois algoritmos: (i) o *Predictive GA Deployer* (PGD), um algoritmo meta-heurístico, e (ii) o *Additive ILP Deployer* (AID), um algoritmo exato. No contexto do CCOpMv, eles devem estar disponíveis em um servidor de aplicações que se comunica com a rede LTE, de forma que para o veículo CMM esse servidor deve ser mais robusto que aqueles nos NAs, já que os veículos tem como preferência utilizar as aplicações através do CMM.

Para solucionar o problema de posicionamento de antenas móveis terrestres ao longo do tempo, esses algoritmos necessitam de diversos dados do cenário, como o número de setores existentes ( $M$ ), a localização dos usuários no decorrer do tempo ( $\mathcal{U}_{tm}$ ), a distância  $d_{mn}$  e estimativa de SNR  $s_{mn}$  para cada par  $m$  e  $n$  de setores do cenário. Além disso, é necessário determinar alguns valores que serão utilizados nas restrições do problema, como o número máximo de usuários suportados por antena ( $\gamma$ ), a distância mínima para que seja estabelecido o *backhaul* entre as BSs ( $\psi$ ), o valor mínimo de SNR ( $\phi$ ) a ser considerado e o local das antenas existentes na ultima faixa de tempo, incluindo o CMM ( $\xi$ ) que é posicionado no início da missão.

### 5.1 PGD

O PGD é composto de algoritmos genéticos aninhados para determinar o posicionamento das antenas e suas conexões de uma maneira dinâmica, em que, para cada faixa de tempo, serão apenas consideradas as localizações dos usuários determinadas pelo último comando dado às tropas, sem haver necessidade de já saber a configuração futura das tropas antes da ordem ser dada.

O algoritmo é composto por duas partes principais: (i) o GA Externo e (II) GA Externo. O algoritmo genético externo (GA Externo) é responsável por tentar gerar a melhor distribuição de antenas possível no cenário, que possibilite um arranjo de conexões válido e assim obedeça a todas as restrições do problema. Já o algoritmo genético interno (GA Interno), consiste em tentar gerar esse arranjo de conexões válido entre as BSs e os UEs, para que o resultado seja utilizado na função *fitness* do algoritmo genético externo.

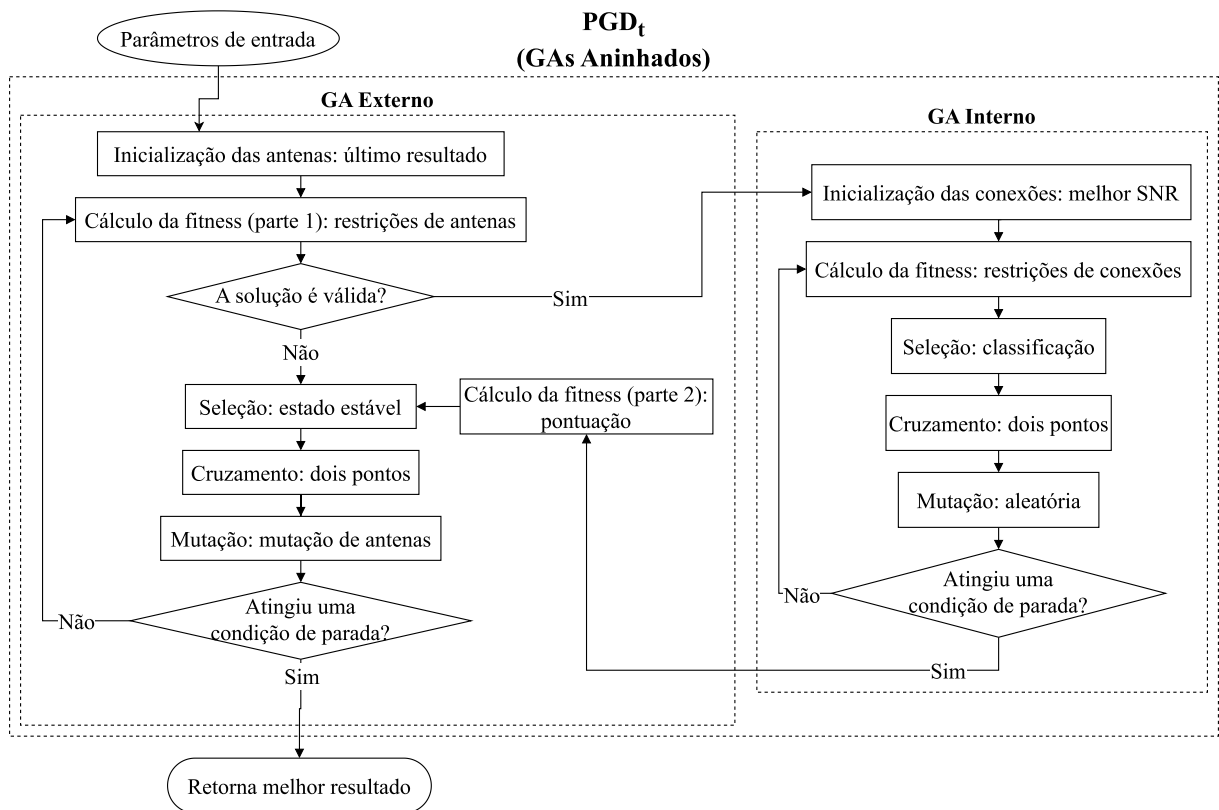


Figura 5.1: Fluxograma do PGD para uma faixa de tempo  $t$

O fluxo de execu o da solu o proposta, para cada faixa de tempo  $t$ , segue o fluxograma ilustrado na Figura 5.1.   poss vel perceber que o GA Externo possui, dentro da sua fun o *fitness*, o GA Interno, caracterizando um algoritmo gen tico aninhado.

Vale destacar que foi utilizada uma abordagem elitista de uma forma geral no GA Externo e no GA Interno, em que   determinado um n mero de indiv duos de maior pontua o que n o ser o modificados nas etapas de cruzamento ou muta o. Em seguida, as duas partes do algoritmo ser o explicadas em mais detalhes.

### 5.1.1 GA Externo

A fim de representar a localiza o de antenas no cen rio, os cromossomos do GA Externo foram modelados como uma sequ ncia de valores bin rios de tamanho  $M$ , em que a

posição do gene na sequência determina o seu setor no cenário. Assim, cada gene de um cromossomo representa uma variável  $x_m$ , ou seja, indica se uma antena está instalada ou não em cada setor do cenário no início da faixa de tempo considerada.

A população de cada geração do GA Externo será composta por 100 indivíduos, quantidade padrão do software utilizado e comumente utilizada na literatura, cada um representando uma tentativa de solução para o problema. Para a **população inicial** do cenário, os indivíduos são todos iguais, contendo apenas a posição do CMM. Já para a população inicial das próximas faixas de tempo, são utilizados 100 indivíduos com o melhor resultado encontrado na faixa de tempo anterior, visto que isso auxilia no cumprimento da restrição (4.9).

### **Função *fitness*:**

A função *fitness* utilizada pelo GA Externo, que atribui um grau de aptidão a uma solução, de forma que um maior grau indica uma melhor aptidão, pode ser descrita como sendo composta por duas partes. Na sua primeira parte é verificado se a solução obedece às restrições (4.9) e (4.11), pois elas dependem somente do posicionamento das antenas no cenário. Se a solução não obedecer a alguma dessas duas restrições, a função *fitness* termina e retorna o valor zero. Caso a solução esteja de acordo com essas restrições, é executado o GA Interno, passando as informações da solução/cromossomo que está sendo avaliada, para que ele tente determinar uma configuração de conexões entre as antenas e os usuários que obedeça as outras restrições do problema. Se o GA Interno for incapaz de encontrar uma solução de conexões válida, a função *fitness* retorna um valor zero. Porém, se encontrada uma solução válida, as conexões escolhidas são retornadas ao GA Externo, de forma que essas conexões sejam utilizadas no restante da função e que elas sejam salvas e fiquem associadas ao cromossomo avaliado, fazendo com que a partir dele seja possível obter tanto os valores de  $x_m$  como também de  $y_{mn}$ .

Já na segunda parte da função *fitness*, dada uma solução que obedece todos os requisitos do problema e já apresenta suas conexões entre antenas e usuários definidas, é calculado o seu valor de aptidão. Esse valor é gerado a partir da combinação de outras quatro pontuações diferentes: (i) o escore do número de antenas, (ii) o escore de área de cobertura, (iii) o escore de excentricidade e (iv) o escore de erro, em ordem importância.

1. O escore do número de antenas ( $E_1$ ) é responsável pela minimização do número de antenas utilizadas, sendo representado pela quantidade de setores do cenário sem antenas.
2. O escore de área de cobertura ( $E_2$ ) é a quantidade de setores do cenário com a possibilidade de ter uma conexão com um SNR maior que o mínimo ( $\phi$ ).

3. O escore de excentricidade ( $E_3$ ) é dado pela diferença entre a maior distância possível ao centro do cenário e a média da distância do setor central aos setores com antenas. Dessa forma, um conjunto de antenas mais próxima do centro resultará em um escore mais alto.
4. O escore de erro ( $E_4$ ) é computado através da raiz quadrada do erro médio quadrático (RMSE) entre o valor de SNR recebido pelos usuários e o mínimo ( $\phi$ ). Quanto mais próximos são os valores estimados de  $\phi$ , menor o RMSE. Para fazer o score aumentar em vez de diminuir quando computado um RMSE menor, foi definido um valor máximo de resultado como  $v = 3 * \phi$ , ou seja, três vezes o valor do SNR mínimo. Com isso, o escore foi definido como a normalização do valor da diferença entre  $v$  e o valor de RMSE computado, para que ele fique entre 0 e  $1 - 10^{-9}$  e nunca seja igual a 1.




Figura 5.2: Construção da pontuação de *fitness* do GA Externo

Agora, para combinar esses escores em uma única pontuação, dividimos um número real em quatro partes como pode ser observado na Figura 5.2. O escore de erro apresenta a menor prioridade na pontuação final, sendo utilizado como sua parte não inteira. Começando pela casa das unidades, o escore de excentricidade é escrito em um intervalo de casas decimais suficientes para representar a maior distância possível até o centro do cenário. Para o segundo escore de maior impacto, o de área de cobertura, é disponibilizada a mesma quantidade de algarismos que o número total de setores no cenário ( $M$ ) logo após os intervalos de  $E_3$ . Por fim, visto que minimizar a quantidade de antenas é o principal objetivo do otimizador, o escore do número de antenas preenche as casas decimais de maior ordem da pontuação, sendo assim a medida mais importante. Organizando o grau de aptidão dessa forma, os diferentes escores não influenciam uns nos outros.

### Seleção e Cruzamento:

Após a determinação do grau de aptidão de todos os indivíduos, é realizada a seleção dos parentes. O método de seleção utilizado no GA Externo foi o estado estável, no qual foram selecionados 4 pais para realizarem o cruzamento e que os resultados irão substituir somente os indivíduos com os piores resultados da população. Em seguida, é realizada o

cruzamento com probabilidade de 80% de substituir um antigo cromossomo. O método utilizado é o cruzamento de dois pontos, ilustrado na Figura 2.5 para um caso de dois parentes, em que um parente troca de forma alternada os pedaços divididos com outro parente.

Vale lembrar que devido à estratégia elitista, os 4 melhores indivíduos se mantêm inalterados até a próxima geração, sem serem substituídos pelo cruzamento ou modificados pela mutação, que será explicada a seguir.

### Mutação:

No caso do método da mutação utilizado pelo GA Externo, foi implementado um algoritmo próprio, Mutação de Antenas, para tomar vantagem das características e comportamentos do cenário, como definido na Figura 5.3. A mutação ocorre com uma chance de 20% em cada gene de um indivíduo da população. A Mutação de Antenas primeiramente verifica se na geração anterior o indivíduo na mesma posição que o atual era uma solução válida ou não. No caso de não ter sido uma solução válida, mesmo que já tenha sido modificado na etapa do cruzamento, o gene alvo da mutação terá seu valor modificado. Como no GA Externo os genes só podem ter os valores 0 ou 1, a mutação inverterá o valor. Analisando com mais cuidado, como o cenário sempre se inicializa com um número pequeno de antenas iniciais, simples mutações de inversão com 20% de chance tendem a causar um grande aumento na quantidade de antenas, já que a grande maioria dos valores é 0.

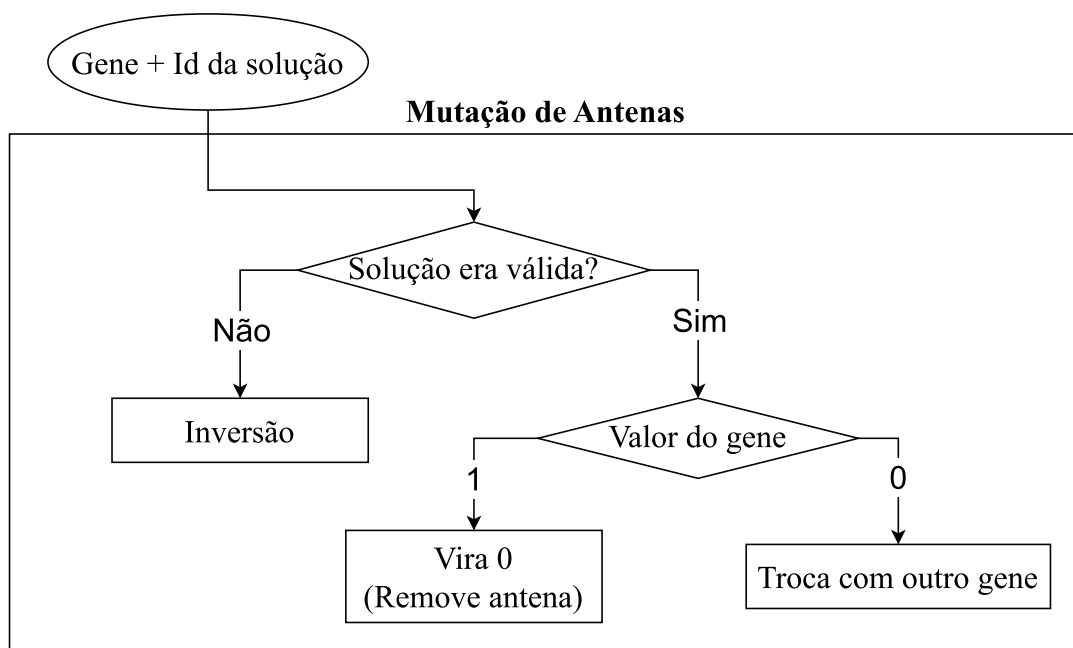


Figura 5.3: Fluxograma da função Mutação de Antenas



No caso do indivíduo ter sido uma solução válida na geração anterior, caso o gene alvo da mutação indique a existência de uma antena, ou seja, tenha o valor 1, esse valor é simplesmente invertido. Isso ocorre pois, dada a existência de uma solução já válida, deve-se buscar soluções com um número menor de antenas visto que indivíduos com mais antenas terão um grau de aptidão pior que a já existente, minimizando assim o número de antenas no cenário. Vale apontar também que, neste caso, mesmo que o indivíduo em questão tenha sido alterado durante a etapa do cruzamento, devido à política elitista do algoritmo, é garantido que existirá na geração atual uma solução de pontuação igual ou melhor do que a do indivíduo da última geração que foi analisado.

Por fim, caso um outro gene deste mesmo cromossomo seja alvo de mutação mas apresente dessa vez um valor 0, ou seja, não exista uma antena instalada no setor que representa, ocorrerá uma mutação por troca, em que o gene em questão trocará seu valor pelo de outro gene do mesmo cromossomo. Dessa forma, não são acrescentadas antenas no cenário de forma desnecessária. Elas são então movidas para outros setores no caso do gene ter o valor trocado ou nada será modificado.

### **Condições de parada:**

Após o processo de mutação, é finalmente gerada uma nova geração de indivíduos e verificadas as condições de parada do algoritmo. No GA Externo, as condições de parada são a execução do algoritmo até a centésima geração ou a criação de novas gerações 30 vezes seguidas sem alteração no grau de aptidão mais alto da população, valores definidos após observar o desempenho do algoritmo na prática.

Quando nenhuma dessas condições são cumpridas, o processo é executado novamente porém com uma nova população inicial de cromossomos, calculando suas pontuações de aptidão, realizando o cruzamento e etc. Essa sequência de eventos continua acontecendo até que alguma das condições de parada seja cumprida, finalizando também o PGD. Neste caso, o cromossomo com a maior pontuação de aptidão da última geração e sua configuração de conexões são os valores para  $x_m$  e  $y_m n$  de um faixa de tempo  $t$ .

Caso exista uma faixa de tempo seguinte para a qual terá que ser definido um novo posicionamento de antenas e conexões, a solução do tempo  $t$  será utilizada para criar a geração inicial da execução do PGD para o tempo  $t + 1$ , auxiliando o cumprimento da restrição (4.9).

### **5.1.2 GA Interno**

Por meio da Figura 5.4 é possível observar melhor como os cromossomos do GA Externo interagem com o GA Interno, podendo ser executado até 100 vezes dentro de uma única

geração do GA Externo. Assim, surge a necessidade de procurar fazer com que o GA Interno seja o mais simples e objetivo possível, para não tornar o algoritmo otimizador extremamente lento.

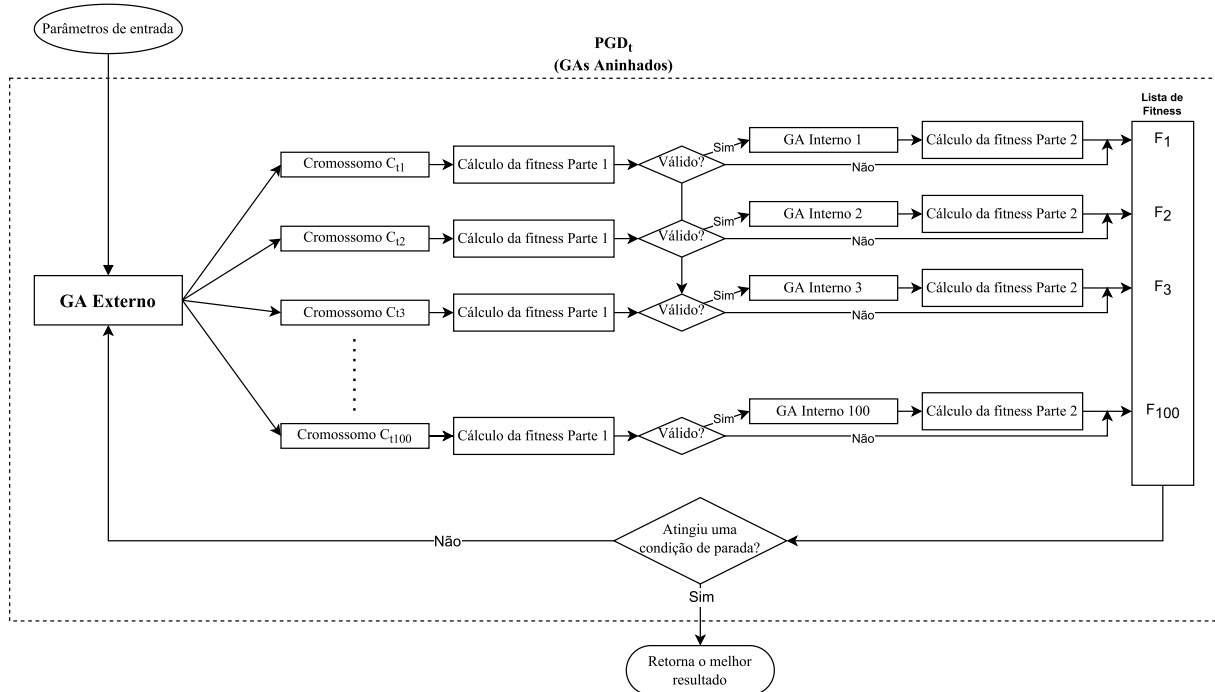


Figura 5.4: Fluxograma do PGD com foco no cálculo da *fitness*

Com isso em mente, o GA Interno só é executado caso as restrições implementadas no GA Externo sejam obedecidas, removendo assim suas execuções que são indiferentes para o resultado final. É possível também definir um tamanho diferente aos seus indivíduos a cada execução, visto que cada cromossomo é modelado para representar somente os setores do cenário que abrigam usuários ativos, reduzindo a quantidade de genes na grande maioria dos casos. Os possíveis valores carregados por esses genes são os números dos setores disponíveis para conexão, ou seja, que possuem antenas instaladas. Isso só é factível pois o PGD executa o GA Interno somente quando existe uma solução de posicionamento de antenas sendo avaliada. Assim, é possível reduzir a quantidade de informação necessária para executar o GA Interno e ainda assim representar corretamente a variável  $y_m n$ .

A **população inicial** do GA Interno, composta por 100 indivíduos, também é definida de forma a melhorar seu desempenho no cenário, em que os valores dos indivíduos iniciais dizem respeito às melhores conexões que podem ser realizadas de acordo com a matriz  $\mathcal{S}_{M \times M}$  que contém os valores de SNR estimados para cada par de setores do cenário.

### **Função *fitness*:**

O cálculo do grau de aptidão dos indivíduos dessa população é restrita ao cumprimento (1) ou não (0) das restrições que envolvem conexões ((4.5), (4.6), (4.7) e (4.9)). O GA Interno também apresenta uma abordagem elitista, em que os dois indivíduos com uma melhor pontuação não são substituídos pelo método do cruzamento ou recebem mutações. Dessa forma, uma vez encontrada uma solução válida, de valor 1, o algoritmo terminará com pelo menos uma solução válida.

### **Seleção, cruzamento e mutação:**

Seguindo o fluxo de execução do GA Interno, ilustrado na figura 5.1, a seleção dos parentes, utiliza o método de classificação que, neste caso, apresenta a vantagem de possibilitar a seleção de cromossomos com valor de aptidão zero, já que pode ocorrer de uma geração não apresentar nenhuma solução válida. Depois, é executado o algoritmo de cruzamento de dois pontos com 80% de chance de substituir um indivíduo, assim como no GA Externo, seguido do algoritmo de mutação randômica que, com uma chance de 20%, muda o valor de um gene para outro aleatório dentre os seus valores possíveis.

### **Condição de parada:**

Por fim, é gerada uma nova geração que só atinge a condição de parada se for a décima geração criada, sendo esse um valor reduzido pois a inicialização faz com que um resultado possível seja encontrado rapidamente e nos testes realizados, 10 gerações foi suficiente, fazendo com que o algoritmo em si tenha uma menor complexidade, já que o GA Interno é executado diversas vezes dentro do GA Externo. Dessa forma, caso vários indivíduos de valor de aptidão 1 estejam disponíveis no final da execução do GA Interno, a solução escolhida será o primeiro deles, sem filtrá-los por meio de outra métrica, por exemplo. Vale apontar também que uma melhor escolha de conexões afetaria somente o escore  $E_4$  da função *fitness* do GA Externo, que apresenta a menor prioridade dentre as métricas utilizadas.

Pseudocódigos do algoritmo *Predictive GA Deployer* (PGD) podem ser encontrados no Anexo I deste trabalho. Sua implementação foi realizada utilizando a linguagem de programação Python com o auxílio da biblioteca Pygad [22].

## 5.2 AID

O *Additive ILP Deployer* (AID) utiliza *Integer Linear Programming* (ILP) para minimizar o número de antenas do cenário e assim conseguir a solução ótima de um cenário. Para que isso seja possível, o algoritmo necessita de acesso a todas as informações geradas na modelagem do cenário, assumindo conhecer padrão futuro de movimentação dos usuários além da ordem atual, para que de uma só vez seja computada a solução ótima para todo o cenário antes mesmo que ele comece.

Esse algoritmo exato é implementado ao utilizar as mesmas variáveis binárias  $x_{tm}$  e  $y_{tmn}$  do problema como suas variáveis, sendo elas definidas como matrizes binárias de tamanho  $T \times M$  e  $T \times M \times M$ , respectivamente. Ele utiliza o método *Branch and cut* the otimização combinatória para resolver ILPs. Assim, para atuar como entrada desse algoritmo, primeiramente é definida uma restrição para que a antena inicial do cenário seja instalada e nunca seja removida, representando um comportamento característico do CCOpMv. Em seguida, são implementadas as restrições do problema definidas neste trabalho (4.5 a 4.11).

Por fim, a função objetivo para minimizar o número de antenas (4.5) é definida, possibilitando com que o método *Branch and cut* seja executado com essas informações e uma solução é computada caso seja possível. Caso não exista uma solução válida, não é retornado um resultado. A implementação foi facilitada pelo uso do solver CBC-MIP do módulo de Python ORTools [23], escolhido no lugar de outros possíveis algoritmos pois o módulo é gratuito e desenvolvido pelo Google, além de que a linguagem de programação Python é utilizada para a criação dos outros algoritmos e a configuração automatizada das simulações realizadas neste trabalho.

# Capítulo 6

## Avaliação e Resultados

Neste capítulo os algoritmos propostos *Predictive GA Deployer* (PGD) e *Additive ILP Deployer* (AID) são avaliados por meio de resultados de simulações. Assim, especificidades do cenário a ser analisado e parâmetros das restrições do problema são definidos, seguido de explicações sobre o simulador utilizado, OMNeT++[4], e sobre as configurações utilizadas. Por fim, os resultados obtidos são ilustrados e analisados.

### 6.1 Cenário

O cenário considerado nesta avaliação representa uma região geográfica de  $4km \times 4km$ , tamanho aproximado da região em que ocorreu o desastre da barragem de Brumadinho [6], sendo mapeado em  $M = 100$  setores quadrados com 400m de lado. Ele tem uma duração de 12 horas, para representar a duração de uma missão real em seu período de alta intensidade, que é dividida em  $T = 12$  faixas de tempo de 1h cada, para facilitar a representação na hora da simulação em que deve ser realizada a mudança de posicionamento de usuários e de suas conexões. Definimos o alcance máximo de uma conexão de *backhaul* como  $\psi = 2km$ , visto que a tecnologia de rádio micro-ondas presente no CCOpMv apresenta esse alcance. Além disso, os eNodeBs terão um número máximo de usuário conectados  $\gamma = 40$ , visto que o 3GPP define um máximo de 60 usuários para casos de com antenas de 46dBm de potência de transmissão[9, Anexo A.2.1.1.2], então reduzimos esse valor pois nossas antenas são de menor potência (30dBm). Para fins de simplicidade, este trabalho considera que todos os setores podem receber antenas.

### 6.2 Ferramentas de Simulação

Para a realização de simulações, foi utilizado o simulador de eventos discretos OMNeT++ [4] como software base, o *framework* INET [24] para implementar redes sem fio e o *fra-*

*mework* Simu5G [25] que introduz os componentes necessários para a construção de redes 4G LTE e 5G. Essas ferramentas são detalhadas a seguir.

### 6.2.1 OMNeT++

O simulador de eventos discretos gratuito *Objective Modular Network Testbed in C++* (OMNeT++) é uma *framework* de C++ extensível, modular e baseada em componentes voltada para a construção de simuladores de redes. Ela é uma ferramenta gratuita que disponibiliza seu próprio ambiente de desenvolvimento (*Integrated Development Environment* - IDE).

Utilizando a linguagem de programação C++, ele é capaz de definir o comportamento de componentes, além de criar sua topologia em linguagem NED, como por exemplo, as portas que serão utilizadas para comunicação entre componentes ou entre componentes e atributos internos de um outro componente. Assim, esses componentes mais básicos, chamados de módulos, são utilizados para criar componentes cada vez maiores e mais complexos, permitindo com que a arquitetura da ferramenta seja altamente customizável e expansível.

O OMNeT++ também permite que seja definido um arquivo com diversas configurações que serão utilizadas em uma simulação, como a rede escolhida, as conexões existentes, aplicações, etc. Essa simulação pode ser executada utilizando a interface gráfica Qtenv disponibilizada na IDE para fins de análise, demonstração e depuração. Já para executar grandes quantidades de simulações, em que o interesse está no resultado gerado, é utilizado o Cmdenv que roda somente pelo terminal.

Por fim, uma simulação retorna os dados especificados na configuração, como os dados das camadas físicas e de aplicação, sendo possível avaliar a qualidade de um serviço, o fluxo de pacotes, etc.

### 6.2.2 INET

O INET é um framework desenvolvido para o OMNeT++ que disponibiliza modelos para redes com fio ou sem fio. Dentre esse modelos, se destacam protocolos, uma camada física detalhada e novas aplicações. Diversos outros *frameworks* utilizam o INET como base para estender suas funções. O Simu5G, também utilizado neste trabalho, depende dos módulos definidos no INET, assim como o SimuLTE [26], para implementar de redes LTE 4G, e o Veins [27] para a implementar redes veiculares.

### 6.2.3 Simu5G

O Simu5G é um modelo de simulação de plano de usuário do novo rádio 5G (5G NR) para INET e OMNeT++. Ele é escrito em C++ e apresenta a qualidade de ser completamente customizável através de uma interface simples, possibilitando a implementação de novos módulos.

Por incorporar todos os modelos do INET, o *framework* é capaz de simular tanto redes LTE quanto redes 5G, de forma a prover conectividade entre as duas. Além disso, ele disponibiliza macro ou micro *eNodeBs* e *gNodeBs* (estação base do 5G) fixas, suporte para *handover* e coordenação de interferência entre células.

Os equipamentos de usuários (*User Equipments* - UEs) apresentam várias opções diferentes de mobilidade, suportando interferência e *handover*. As antenas utilizadas pelas BSs, por sua vez, podem ser setorizadas ou omnidirecionais.

As camadas de protocolos implementadas seguem os padrões do 3GPP tanto para LTE quanto para 5G, onde a camada física é modelada por meio de um modelo de canal realístico e customizável. Por exemplo, as opções de cenário para o canal estão entre aquelas definidas pelo 3GPP [9], como o "URBAN\_MICROCELL" e "URBAN\_MACROCELL". Além disso, escalonamento de recursos suporta *Carrier Aggregation*[28] e várias tecnologias.

Neste trabalho focaremos mais nas suas funcionalidades e módulos de 4G LTE. Esse *framework* nos possibilita utilizar *eNodeBs* e UEs voltados para a simulação de redes 4G, além de acrescentar os módulos necessários para a definição de um EPC, com parâmetros e estatísticas voltados a esse tipo de comunicação. Também é possível implementar novos módulos com diferentes funcionalidades caso surja a necessidade de extrair informações adicionais sobre um instante da simulação, de definir um novo padrão de movimentação para os usuários, etc.

Vale destacar também que o Simu5G é capaz de rodar uma emulação de rede, integrando uma rede 5G ou LTE criada no software a redes e aplicações reais. Além disso, como o *framework* é de código aberto, suas simulações podem ser compartilhadas de forma a ser possível replicá-las utilizando uma mesma configuração.

## 6.3 Configurações

Para a realização das simulações, foi utilizado o simulador de eventos OMNeT++ [4], além de suas *frameworks* INET [24] e Simu5G [25]. Ele disponibiliza a plataforma para realização de simulações, enquanto o INET é responsável por permitir a simulação de redes sem fio e o Simu5G fornece os modelos dos equipamentos necessários para simular

uma rede LTE, como pode ser visto na Figura 6.1. Assim, os elementos da rede LTE do cenário foram representados da seguinte forma:

- **UE** - modelo de UE do Simu5G
- **BS móvel** - modelo de eNodeB do Simu5G
- **EPC** - modelo de SGW do Simu5G que cumpre as funções necessárias do EPC na simulação
- **Serviços** - modelos de roteador e servidor do INET, em que o servidor pode rodar um aplicação

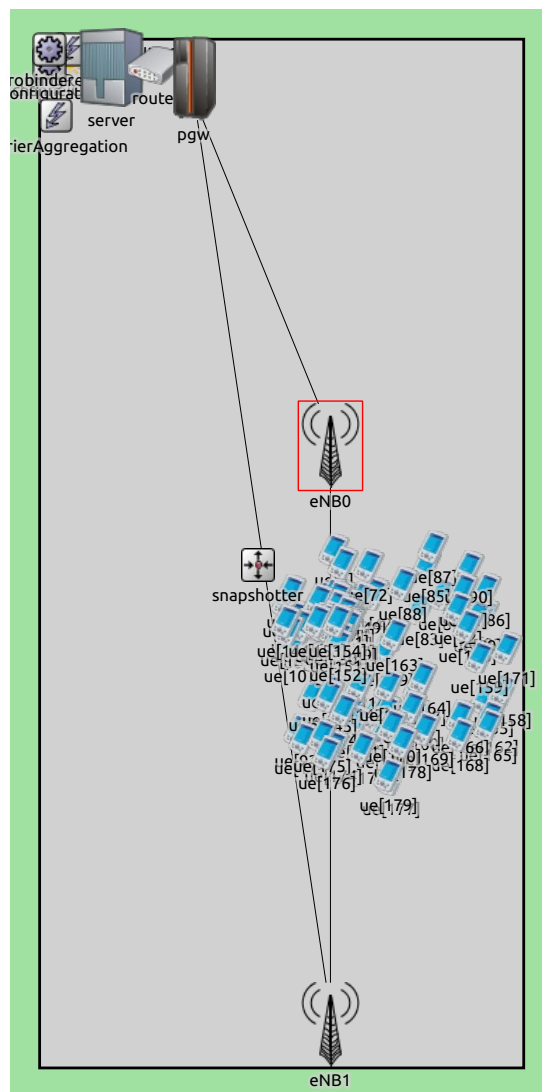


Figura 6.1: Exemplo de cenário no simulador para  $t = 0$



Para de replicar o modelo do cenário no simulador são necessárias algumas adaptações, pois o cenário modelado faz uma discretização do tempo e do espaço. O tamanho do modelo é obedecido porém ele não foi discretizado, visto que é possível utilizar o padrão de movimentação e inserção de UEs para criar uma simulação mais interessante do que uma em que eles ficassem parados durante uma faixa de tempo inteira. Já para o caso do tempo, a sua discretização foi representada pela divisão do tempo total do cenário em pequenas  $T$  simulações, de forma que elas terão a mesma configuração apresentada na Tabela 6.1 porém com UEs e eNodeBs que diferem em quantidade, localização e conexões entre eles. Para que as simulações sejam executadas em um tempo hábil, a faixa de tempo de 1h de duração é representada no simulador como 1s, realizando as adaptações necessárias, como modificar a velocidade de movimentação dos UEs, que deve fazer com que eles percorram em um segundo a mesma distância que percorriam em uma hora.

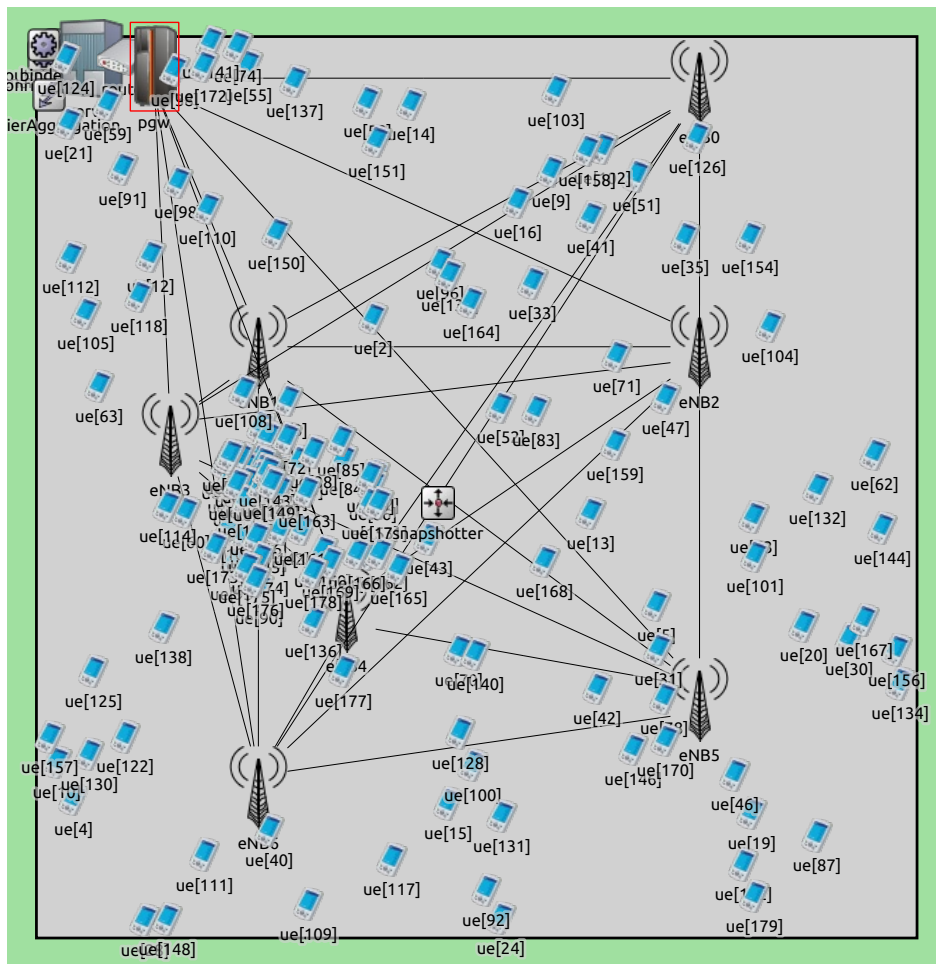


Figura 6.2: Exemplo de cenário no simulador para  $t = 10$

Visto que o comportamento dos usuários, definido por ordens dadas às tropas, é conhecido antes de uma faixa de tempo ocorrer de fato, o comportamento dos usuários é

definido antes da computação das soluções, sendo utilizado como parâmetro tanto nos algoritmos otimizadores quanto na simulação. O posicionamento inicial toma como base o modelo de rede heterogênea com concentrações de usuários do 3GPP [9, Anexo A.2.1.1.2], em que os usuários apresentam 66% de chance de iniciar o cenário em uma concentração ao invés de ser distribuído aleatoriamente na célula, como mostrado na Figura 6.1. A movimentação desses usuários foi definida ao atribuímos valores para suas velocidades e direções. A velocidade de cada UE, em km/h, é modificada no início de cada faixa de tempo e tem seu valor escolhido através de uma distribuição normal de média 3[9] e desvio padrão 1. Esse valor é então usado como km/s, sem realizar a conversão, para se adaptar à nova representação de uma faixa de tempo que dura 1 segundo ao invés de 1 hora na simulação. Já a direção é definida no início da atividade do UE de forma aleatória e se modifica somente caso um usuário chegue nos limites do cenário, de forma a mantê-lo dentro da área analisada. Com esse padrão de movimentação, quanto mais para o final do cenário, mais aleatória é a disposição dos usuários, como é retratado na Figura 6.2.

Além disso, a quantidade de usuários conectados se modifica no decorrer do cenário, acontecendo um aumento até a metade de sua duração seguido de uma diminuição, utilizando valores gerados através de uma distribuição de *Poisson* (6.1) com  $\lambda = 30$  para definir a quantidade de usuários adicionados ou removidos a cada faixa de tempo. Dessa forma, cerca de 180 usuários estão presentes no período de maior atividade do cenário.

$$f(k; \lambda) = \frac{\lambda^k e^{-\lambda}}{k!}, \quad (6.1)$$

Através da distribuição de antenas e da configuração das conexões geradas como resultado da solução que será avaliada por meio da simulação, é definida a rede LTE que será utilizada e o arranjo de conexões dos UEs com os eNodeBs. Além dessas informações, a Tabela 6.1 apresenta outros parâmetros utilizados pelas simulações. Algumas das configurações do canal utilizado são também utilizadas no cálculo do SNR estimado (equação (4.1)), como o cenário de *pathloss*, a potência de transmissão e ganho do eNodeB, e o ganho do UE.

O canal utilizado apresenta 0.7GHz de frequência, diferente do que é sugerido pelo 3GPP [9], por esse ser o padrão do Exército Brasileiro para esse tipo de operação militar. A aplicação, por sua vez, foi escolhida com o propósito de tentar levar a capacidade da rede ao limite e assim possibilitar uma simulação em que o posicionamento das antenas é ainda mais importante para o QoS da aplicação. Os seus pacotes foram definidos do tamanho da unidade de transmissão máxima (*Maximum Transmission Units* - MTUs) de uma rede LTE.

Mesmo que sejam executadas aplicações *uplink* e *downlink* nas simulações, será avaliado somente o QoS da aplicação *downlink*, visto que esse é o foco do cenário. Por fim,

Tabela 6.1: Parâmetros utilizados nas simulações.

Parâmetro	Valor
Dimensões	4 km x 4 km
Potência de transmissão do eNodeB	30 dBm
Ganho do eNodeB	5 dBi
Ganho do UE	-1 dBi
Tipo de antena do eNodeB	omnidirecional
Frequência do canal	0.7 GHz
Largura de banda do canal	20 MHz
Canal com interferência de transmissão	Não
Canal com <i>Fading</i>	Sim
Canal com <i>Shadowing</i>	Sim
<i>Shadowing</i> $\alpha$	4
<i>Handover</i>	Não
Escalonador	MAXCI
Cenário de <i>pathloss</i>	NLOS Urban Micro[9, Anexo B.1.2.1]
Aplicação	<i>Streaming</i> de Vídeo UDP
MTU	1428 B
Tamanho do pacote da aplicação	1428 B
Taxa de dados da aplicação	10 Mbps

vale apontar que o escalonador MAXCI utilizado tem como objetivo maximizar o valor do *Carrier-to-Interference Ratio* (C/I), ou seja, o SNR médio do cenário. A seguir são avaliadas as soluções propostas com base nos resultados obtidos utilizando as seguintes versões das ferramentas de simulação: OMNeT++ 5.6.2, INET-Framework 4.2.2 e Simu5G 1.1.0.

## 6.4 Análise dos Resultados

Para a avaliação das soluções de otimização *Predictive GA Deployer* (PGD) e *Additive ILP Deployer* (AID), foram realizadas simulações de seus resultados para 10 situações de mobilidade diferentes, utilizando também um terceiro algoritmo, *Traditional ILP Deployer* (TID), como base de comparação. Esse algoritmo representa um caso de péssimo QoS, definindo um posicionamento fixo não otimizado no decorrer do tempo para os eNodeBs, levando em conta somente a disposição inicial dos usuários sem se adaptar às mudanças que ocorrerão no cenário. Além disso, para cada uma dessas situações, foram utilizados três problemas com diferentes exigências de QoS: (i) 5dB, (ii) 10dB ou (iii) 15dB de SNR mínimo, totalizando 30 cenários simulados para cada algoritmo otimizador.

A Figura 6.3 informa a quantidade média de veículos/eNodeBs alocados por cada otimizador para cada um dos diferentes valores de SNR mínimos considerados. Como esperado, o algoritmo AID apresenta uma quantidade baixa de antenas, visto que elas




Figura 6.3: Média do número de eNodeBs em cada simulação

não aumentam com o aumento na quantidade de usuários no decorrer do cenário. O que não ocorre com o PGD, visto a sua quantidade elevada de antenas, demonstrando que houve uma tentativa de adaptação. Porém, comparando o algoritmo meta-heurístico PGD com o algoritmo exato AID, fica evidente que as soluções são diferenciáveis quanto o número de antenas, com um comportamento em que quanto maior a exigência de QoS do problema, maior é a diferença entre os resultados. Isso demonstra que falta precisão no posicionamento das antenas por parte do algoritmo PGD, o que acarreta na necessidade de uma grande quantidade de antenas e em grandes variações desse número em diferentes cenários, mesmo que com as mesmas restrições, como pode ser observado pelo tamanho do desvio padrão da sua média para o caso de 15dB.




Figura 6.4: CDF do SNR médio recebido por cada UE

A Figura 6.4, por sua vez, representa a função de probabilidade acumulada (CDF) do

SNR médio recebido por cada UE de cada um dos 30 cenários de cada algoritmo, sendo possível ver o quão bem cada solução se saiu no quesito de QoS. Para fins de visualização, quando um UE tentou utilizar a aplicação mas não foi capaz de se conectar ao eNodeB, foi atribuído um valor de -10dB para seu SNR, justificando assim os valores negativos vistos nesse gráfico. Como os valores de ambos os algoritmos PGD e AID tiveram um SNR melhor que TID em todos os três casos de problemas, é evidente que o aumento no número de suas antenas gerou um aumento no QoS como o esperado. Vale apontar também que a grande quantidade de usuários não conectados existentes nos casos de TID existe pelo fato do cenário eventualmente ter mais usuários do que o limite máximo de 40 usuários por antena.

Comparando agora o PGD com o AID quanto ao valor de SNR entregue aos usuários, é possível observar observar que, para problemas em que seu valor é de 5dB, o PGD apresentou uma melhor performance, em que aproximadamente 40% de seus usuários apresentaram um SNR maior que 20, pois ele possui uma quantidade maior de antenas. Porém, em relação à métrica de QoS requisitada, ambos os algoritmos obtiveram uma ótima performance, em que em torno de 95% de seus usuários tiveram um SNR de 5dB ou maior. Para os casos de SNR mínimo de 10dB, as duas soluções ficaram muito próximas, também com cerca de 95% de seus usuários com valores maiores ou iguais ao mínimo definido. O mesmo não aconteceu para um SNR mínimo de 15dB, visto que somente cerca de 82% dos UEs de PGD obtiveram um SNR maior ou igual a 15dB, ao contrário do AID que teve um valor de aproximadamente 92%.




Figura 6.5: CDF do *throughput* recebido por cada UE

Por fim, observando a Figura 6.5, que representa a CDF da taxa de transferência (*throughput*) dos usuários, é possível extrair informações que complementam o que foi observado na Figura 6.4. Primeiramente, é possível identificar com mais clareza que houve

uma quantidade significativa de usuários que não se receberam pacotes da aplicação. Isso ocorreu devido ao fato de que as aplicações utilizadas por cada um dos UEs saturavam facilmente o canal, visto que cada aplicação tem uma taxa de dados de 10Mbps e o canal tem uma largura de banda de 10MHz. Com o canal saturado, como o escalonador MAXCI prioriza os usuários de maior SNR, aqueles com uma qualidade de sinal pior não foram capazes de se comunicar. Isso também explica o PGD apresentar a melhor performance, pois como apresenta maior quantidade de antenas, conseqüentemente tem uma média menor de usuários para cada uma delas. É importante apontar também que a taxa de transferência deixa claro que o PGD conseguiu servir a aplicação melhor que o AID em termos de *throughput*, sendo seus valores de SNR na Figura 6.4 uma provável consequência do número exacerbado de antenas colocadas no cenário.

Comparando os resultados em relação aos valores de SNR mínimo utilizados, o comportamento observado foi o esperado, em que para cada um dos algoritmos, os casos de maior exigência de QoS tiveram maiores valores de SNR e taxa de transferência.

Pode-se considerar que o algoritmo PGD não otimiza de forma suficiente a nossa função objetivo (4.5) ao ser comparado com as soluções ótimas de AID. Assim, em casos em que o comportamento do cenário no tempo é conhecido previamente, o uso do PGD é desaconselhado, como em situações de treinamento de tropas, em que o futuro posicionamento das antenas pode ser definido no início da atividade e espera-se que as tropas sigam um padrão de movimentação pré-estabelecido.

Porém, como o PGD apresenta a capacidade de informar seus resultados para cada faixa de tempo sob demanda, baseando-se somente nas ordens atuais, ele se pode mostrar mais útil que o algoritmo exato AID em alguns casos. Isso porque a diferença no número de antenas, para valores baixos de SNR mínimo, ainda não é muito grande (menor que 3 no caso do de 5dB) e porque é comum que as operações em cenários de desastre decidam as suas ações com base no que acontece no decorrer do tempo, sem saber no início do cenário como vai ser o comportamento dos usuários após a primeira ordem dada, o que impossibilita o uso do algoritmo AID.

Considerando cenários reais, o algoritmo PGD seria recomendado para ser aplicado em casos como na tragédia que assolou o litoral norte de São Paulo/Brasil no dia 19 de fevereiro de 2023, em que fortes chuvas causou inundações e deslizamentos na região, deixando 40 mortos, 1730 desalojados e 766 desabrigados [29]. Nesse caso, também foram causados diversos danos materiais às infraestruturas existentes, sendo necessário o estabelecimento de novas infraestruturas e o envio de missões de resgate e busca pelas pessoas afetadas. Assim, o PGD permitira que essa nova infraestrutura fosse criada dinamicamente de forma a ser montada adicionando novos veículos de acordo com a locomoção das tropas aos locais mais prioritários que são analisados no decorrer da missão.

Tabela 6.2: Tempos de Execução para o PGD.

SNR Mínimo (dB)	Média (min)	DP (min)	CV
5	20.37	3.30	0.162
10	23.07	3.86	0.167
15	30.43	5.60	0.184

O algoritmo base TID, por sua vez, apresentou menos de 40% de usuários acima do requisito de QoS nos casos de SNR mínimo 5dB e 10dB, e somente 20% nos casos de 15dB. Dessa foram, as propostas de solução PGD e AID demonstram também a importância da utilização de algoritmos que levam em consideração o comportamento futuro de um cenário dinâmico como o aqui considerado.

Por fim, um outro aspecto importante a ser considerado quanto ao uso do PGD em casos reais é o tempo de execução do algoritmo, sendo necessário um servidor de aplicações potente o suficiente para gerar um resultado em tempo hábil para ser utilizado. Uma exemplificação desses dados pode ser observada na Tabela 6.2, em que são informados os tempos de execução do algoritmo PGD para os casos aqui analisados utilizando um Máquina Virtual local do tipo *Oracle VM VirtualBox* [30], com cada 4 instâncias de execução do algoritmo tendo acesso a 4 núcleos de processamento da arquitetura Intel Core i5-7400, 5 GB de RAM e 50 GB de HDD.

É possível perceber que o tempo de execução aumenta quanto maior o requisito de QoS, assim como o Desvio Padrão (DP) e o Coeficiente de Variação (CV). Esse comportamento é esperado, visto que existem menos possíveis resultados que obedecem uma restrição mais exigente. Além disso, em todos os casos foi observado um CV um pouco maior que 15%, indicando que a carga de trabalho foi não heterogênea entre os casos de um mesmo requisito de QoS. Em contrapartida, o valor do tempo de execução foi alto, considerando que a melhor média observada foi de 20 minutos, o que é um terço do tempo de 1h que cada faixa de tempo representa, demonstrando a possível necessidade do uso de um equipamento mais robusto do que o testado neste trabalho.

# Capítulo 7

## Conclusões

Este trabalho teve como objetivo explorar possíveis soluções para o problema de alocação de antenas móveis ao longo do tempo, mais especificamente, BSs. Isso pois o cenário no qual esse problema foi analisado é representado por um área de desastre que teve suas infraestruturas de comunicação desabilitadas ou eram inexistentes. Assim, foi vista a necessidade de criação de uma rede de comunicação que pudesse se adaptar de forma dinâmica e eficiente.

Com isso em mente, foi utilizada a arquitetura do Centro de Coordenação de Operações Móveis (CCOpMv), projetado para dar apoio ao Exército Brasileiro ao instalar uma rede de comunicação independente utilizando seus veículos que contêm diversas tecnologias de comunicação, como o 4G LTE. Assim, definimos um cenário no qual seriam escolhidas as localizações para esses eNodeBs montados em veículos utilizando o SNR como medida de QoS. Porém, como o custo desses veículos é muito alto, foi definido o objetivo de otimização de minimizar a quantidade de veículos/BSs. Assim, o cenário foi modelado de forma discreta, possibilitando a definição do problema, por meio da criação de suas variáveis, de suas restrições sobre a localização e conexões das BSs e de sua função objetivo.

Para solucionar esse problema, foram propostos dois algoritmos de otimização: (i) *Predictive GA Deployer* (PGD), meta-heurístico, e (ii) *Additive ILP Deployer* (AID), exato. Eles foram então avaliados por meio da observação dos resultados de simulações realizadas com problemas de diferentes valores de QoS, utilizando a ferramenta OMNeT++. Adicionalmente, foi analisado um outro algoritmo não otimizador no tempo, *Traditional ILP Deployer* (TID), para servir de base de comparação às soluções propostas.

Os resultados demonstraram que ambas as soluções propostas estão se adaptando ao cenário no decorrer do tempo. O AID é capaz de apresentar resultados superiores ao PGD, porém necessita do conhecimento futuro de toda a duração do cenário antes de realizar qualquer computação. Foi possível observar também que, quanto maior o valor da restrição de QoS, maior é a diferença entre o resultado do PGD e o ótimo, podendo



saturar o cenário de veículos. Porém, em um cenário adaptativo mais realístico no se sabe somente a ordem atual de movimentação das tropas, o PGD se provou ser uma solução adequada para quando as restrições de QoS não forem muito elevadas.

## 7.1 Contribuições

Como contribuição do trabalho, foi realizada a modelagem de um cenário de desastre e a definição matemática para um problema de posicionamento de antenas nesse contexto. Foram criados também dois algoritmos de otimização: um algoritmo meta-heurístico PGD e um algoritmo exato AID, baseados nesse cenário. Adicionalmente, todas as implementações realizadas para que a execução desse trabalho fosse possível, incluindo a modelagem do cenário, a implementação das soluções e a criação das configurações necessárias para a realização de diversas simulações, estão disponíveis em um repositório<sup>1</sup> online.

## 7.2 Trabalhos Futuros

Para a enriquecer o trabalho realizado, sugere-se comparar as soluções aqui utilizadas com outras já implementadas na literatura e utilizá-las em um cenário em que certas posições não estão disponíveis ou em um cenário baseado em uma operação real. Além disso, tendo em vista as deficiências existentes na solução PGD, tentar realizar um ajuste de seus hiper-parâmetros utilizando outros algoritmos ou realizar mudanças nas suas funções pode fazer com que ele gere resultados mais precisos.

Adicionalmente, o cenário e o problema aqui definidos e trabalhados podem ser evoluídos de forma a considerarem parâmetros de QoS para conexões *uplink* além de *downlink*. Por fim, novas soluções podem ser propostas para tentar prever certos dados do cenário, como a interferência, movimentação dos usuários, etc.

---

<sup>1</sup><https://github.com/GiordanoSM/LTE-Scenarios-Simulation/>

# Referências

- [1] Ang Yang, Yindi Jing, Chengwen Xing, Zesong Fei, and Jingming Kuang. Performance Analysis and Location Optimization for Massive MIMO Systems With Circularly Distributed Antennas. *IEEE Transactions on Wireless Communications*, 14(10):5659–5671, October 2015. ISSN 1558-2248. doi: 10.1109/TWC.2015.2441057. 2, 13
- [2] Yue Zhang and Lin Dai. On the Optimal Placement of Base Station Antennas for Distributed Antenna Systems. *IEEE Communications Letters*, 24(12):2878–2882, December 2020. ISSN 1558-2558. doi: 10.1109/LCOMM.2020.3020373. 2, 13
- [3] Hakim Ghazzai, Elias Yaacoub, and Mohamed-Slim Alouini. Optimized LTE Cell Planning for Multiple User Density Subareas Using Meta-Heuristic Algorithms. In *2014 IEEE 80th Vehicular Technology Conference (VTC2014-Fall)*, September 2014. doi: 10.1109/VTCFall.2014.6966100. ISSN: 1090-3038. 2, 13
- [4] OMNeT++. "OMNeT++ Discrete Event Simulator". <https://omnetpp.org/>, 2001. [Acesso em: 12/01/2023]. 3, 33, 35
- [5] Antônio Luiz Coimbra de Castro. Manual de Planejamento em Defesa Civil Volume I. <http://www.defesacivil.mg.gov.br/images/documentos/Defesa%20Civil/manuais/Manual-PLANEJAMENTO-1.pdf>. [Acesso em: 17/01/2023]. 4
- [6] Marcus Vinicius Polignano and Rodrigo Silva Lemos. Rompimento da barragem da Vale em Brumadinho: impactos socioambientais na Bacia do Rio Paraopeba. *Ciência e Cultura*, 72(2):37–43, April 2020. ISSN 0009-6725. doi: 10.21800/2317-66602020000200011. Publisher: Sociedade Brasileira para o Progresso da Ciência. 5, 33
- [7] Maxwell. 2. Tecnologia LTE (Long Term Evolution) - Maxwell. [https://www.maxwell.vrac.puc-rio.br/18484/18484\\_3.PDF](https://www.maxwell.vrac.puc-rio.br/18484/18484_3.PDF). [Acesso em: 23/01/2023]. 7, 8
- [8] Motorola. Long Term Evolution (LTE): A Technical Overview. [https://www.3g4g.co.uk/Lte/LTE\\_WP\\_0706\\_Motorola.pdf](https://www.3g4g.co.uk/Lte/LTE_WP_0706_Motorola.pdf), 2007. [Acesso em: 17/01/2023]. 7, 8
- [9] 3GPP. 3GPP TR 36.814 - Further Advancements for E-UTRA Physical Layer Aspects. 9(3):1–104, 2010. doi: ts\_136211v090100p. URL [https://www.3gpp.org/ftp/Specs/archive/36\\_series/36.814/36814-900.zip](https://www.3gpp.org/ftp/Specs/archive/36_series/36.814/36814-900.zip). 7, 19, 33, 35, 38, 39
- [10] Introduction to Evolved Packet Core. [https://www.3g4g.co.uk/Lte/LTE\\_WP\\_0903\\_AlcatelLucent.pdf](https://www.3g4g.co.uk/Lte/LTE_WP_0903_AlcatelLucent.pdf), author = Alcatel-Lucent. [Acesso em: 17/01/2023]. 8

- [11] Fred Glover and Kenneth Sörensen. Metaheuristics. *Scholarpedia*, 10(4):6532, April 2015. ISSN 1941-6016. doi: 10.4249/scholarpedia.6532. [Acesso em: 22/01/2023]. 9
- [12] Wikipedia. Selection (genetic algorithm). [https://en.wikipedia.org/wiki/Selection\\_\(genetic\\_algorithm\)](https://en.wikipedia.org/wiki/Selection_(genetic_algorithm)), . [Acesso em: 23/01/2023]. 10
- [13] Wikipedia. Crossover (genetic algorithm). [https://en.wikipedia.org/wiki/Crossover\\_\(genetic\\_algorithm\)](https://en.wikipedia.org/wiki/Crossover_(genetic_algorithm)), . [Acesso em: 23/01/2023]. 11
- [14] Wikipedia. Mutation (genetic algorithm). [https://en.wikipedia.org/wiki/Mutation\\_\(genetic\\_algorithm\)](https://en.wikipedia.org/wiki/Mutation_(genetic_algorithm)), . [Acesso em: 23/01/2023]. 12
- [15] Abhinav Jauhri, Jason D. Lohn, and Derek S. Linden. A comparison of antenna placement algorithms. In *Proceedings of the Companion Publication of the 2014 Annual Conference on Genetic and Evolutionary Computation, GECCO Comp '14*, pages 1223–1230, New York, NY, USA, July 2014. Association for Computing Machinery. ISBN 978-1-4503-2881-4. doi: 10.1145/2598394.2605446. 14
- [16] Rami Sabouni, Roshdy M. Hafez, and Marc St-Hilaire. Adaptive coverage for high data rate LTE networks. pages 303–307, February 2014. doi: 10.1109/ICCNC.2014.6785350. 14
- [17] Ahmad Idris, Suci Rahmatia, and M. Ismail. 4G LTE Cellular Network Coverage Planning and Simulation on Mandalay Area with Propagation Model Cost-Hatta. In *2021 9th International Conference on Information and Communication Technology (ICoICT)*, pages 280–285, August 2021. doi: 10.1109/ICoICT52021.2021.9527455. 14
- [18] Ibrahim A. Nemer, Tarek R. Sheltami, and Ashraf S. Mahmoud. A game theoretic approach of deployment a multiple UAVs for optimal coverage. *Transportation Research Part A: Policy and Practice*, 140:215–230, October 2020. ISSN 0965-8564. doi: 10.1016/j.tra.2020.08.004. URL <https://www.sciencedirect.com/science/article/pii/S0965856420306881>. 14
- [19] Jiahui Wu, Peng Yu, Lei Feng, Fanqin Zhou, Wenjing Li, and Xuesong Qiu. 3D Aerial Base Station Position Planning based on Deep Q-Network for Capacity Enhancement. In *2019 IFIP/IEEE Symposium on Integrated Network and Service Management (IM)*, pages 482–487, April 2019. ISSN: 1573-0077. 14
- [20] Mahmoud H. Qutqut, Hatem Abou-zeid, Hossam S. Hassanein, A. M. Rashwan, and Fadi M. Al-Turjman. Dynamic small cell placement strategies for LTE Heterogeneous Networks. In *2014 IEEE Symposium on Computers and Communications (ISCC)*, pages 1–6, June 2014. doi: 10.1109/ISCC.2014.6912536. ISSN: 1530-1346. 15
- [21] Jianming Zhang, Deru Zhang, and Juanjuan Sun. A Vector-Based Dynamic Programming Approach for Small Cell Placement in Dense Urban. In *2022 IEEE 33rd Annual International Symposium on Personal, Indoor and Mobile Radio Communications (PIMRC)*, pages 1227–1232, September 2022. doi: 10.1109/PIMRC54779.2022.9977974. ISSN: 2166-9589. 15

- [22] pygad: PyGAD: A Python 3 Library for Building the Genetic Algorithm and Training Machine Learning Algorithms (Keras & PyTorch). <https://github.com/ahmedfgad/GeneticAlgorithmPython>, . [Acesso em: 23/01/2023]. 31
- [23] ortools: Google OR-Tools python libraries and modules. <https://developers.google.com/optimization/>, . [Acesso em: 23/01/2023]. 32
- [24] INET. "INET Framework - INET Framework". <https://inet.omnetpp.org/>. [Acesso em: 12/01/2023]. 33, 35
- [25] Simu5G. "Simu5G - 5G New Radio User Plane Simulator for OMNeT++ and INET". <http://simu5g.org/>, 2020. [Acesso em: 12/01/2023]. 34, 35
- [26] SimuLTE. "SimuLTE - LTE User Plane Simulator for OMNeT++ and INET". <https://simulte.com/>, 2015. [Acesso em: 12/01/2023]. 34
- [27] Veins. "veins - The open source vehicular network simulation framework". <https://veins.car2x.org>, 2006. [Acesso em: 12/01/2023]. 34
- [28] 3GPP. Carrier Aggregation explained. <https://www.3gpp.org/technologies/101-carrier-aggregation-explained>, 2022. [Acesso em: 16/01/2023]. 35
- [29] BBC. Litoral de SP foi atingido por 'evento extremo', com recorde de chuvas e elevação do mar. <https://www.bbc.com/portuguese/articles/c3gj49n6jwno>, February 2023. [Acesso em: 02/03/2023]. 42
- [30] Oracle. Oracle VM VirtualBox). <https://www.virtualbox.org/>. [Acesso em: 05/03/2023]. 43

# Anexo I

## Implementação do PGD

---

**Algoritmo 1:** Mutação de Antenas (MutaçãoAntenas)

---

**Entrada:** gene, id da solução

**Saída:** novo gene

**Inicialização:**

pontuação\_indivíduo\_antigo  $\leftarrow$  pontuação de aptidão do indivíduo da última geração com mesmo id da solução;

indivíduo\_atual  $\leftarrow$  {indivíduo a qual esse gene pertence};

**if** *pontuação\_indivíduo\_antigo* > 0 **then**

**if** *gene* = 1 **then**

        | novo\_gene  $\leftarrow$  0;

**else**

        | novo\_gene  $\leftarrow$  outro gene de indivíduo\_atual;

**end**

**else**

    | novo\_gene  $\leftarrow$  *inversodegene*;

**end**

**return** *novo\_gene*

---

---

**Algoritmo 2:** *Predictive GA Deployer* (PGD) para um tempo  $t$ 

---

**Entrada:**  $M, \mathcal{U}_t, D, \mathcal{S}, \xi, \psi, \phi, \gamma$  e  $\mathcal{X}_{t-1}$  {se  $t - 1 \in \mathcal{T}$ }

**Saída:**  $\mathcal{X}_t, \mathcal{Y}_t$

**Inicialização:**

*Seleção*  $\leftarrow$  estado estável ;

*Cruzamento*  $\leftarrow$  dois pontos ;

número\_pais  $\leftarrow$  4

gerações  $\leftarrow$  100

elitismo  $\leftarrow$  4 ;

probabilidade\_mutação  $\leftarrow$  0.20

probabilidade\_cruzamento  $\leftarrow$  0.80

**if**  $t - 1 \in \mathcal{T}$  **then**

    População inicial com indivíduos com antenas da solução do tempo anterior

$\mathcal{X}_{t-1}$ ;

**else**

    População inicial com indivíduos com a antena inicial  $\xi$ ;

**end**

**for** geração = 1 a gerações **do**

**for** indivíduo em população **do**

        pontuação, conexões  $\leftarrow$  **FitGAExterno**(indivíduo);

**end**

    Execute a **seleção** de indivíduos que serão os pais da próxima geração;

    Execute o **cruzamento** entre os pais e gere novos descendentes com probabilidade *probabilidade\_cruzamento*, considerando o *elitismo*;

    Execute a **mutação** de genes com probabilidade *probabilidade\_mutação* (MutaçãoAntenas), considerando o *elitismo*;

**if** melhor indivíduo não muda a 30 gerações **then**

$\mathcal{X}_t \leftarrow$  melhor indivíduo

$\mathcal{Y}_t \leftarrow$  conexões do melhor indivíduo

**return**  $\mathcal{X}_t, \mathcal{Y}_t$

**else**

        Atualize o melhor indivíduo de acordo com as pontuações;

        Atualize os indivíduos da próxima geração;

**end**

**end**

$\mathcal{X}_t \leftarrow$  melhor indivíduo

$\mathcal{Y}_t \leftarrow$  conexões do melhor indivíduo

**return**  $\mathcal{X}_t, \mathcal{Y}_t$

---

---

**Algoritmo 3:** Fitness do GA Externo (FitGAExterno)

---

**Entrada:** indivíduo,  $\phi$ ,  $\gamma$ ,  $D$ ,  $\mathcal{S}$ ,  $\mathcal{U}_t$ ,  $\xi$ ,  $M$

**Saída:** pontuação de aptidão

**Inicialização:**

melhores\_conexões  $\leftarrow$  {melhores conexões possíveis de acordo com  $\mathcal{S}$ };

Verifique as Restrições 4.9 e 4.11;

conexões  $\leftarrow$  **GAInterno**(melhores\_conexões);

Pontuação de antenas  $\leftarrow$  número de genes - número de antenas;

Pontuação de cobertura  $\leftarrow$  número de setores servidos com  $SNR < \phi$ ;

Pontuação de excentricidade  $\leftarrow$  média das distâncias das antenas ao centro;

Pontuação de erro  $\leftarrow$  raiz do erro quadrático médio limitada a  $3 * \phi$  e normalizada entre 0 e  $1 - 10^{-9}$ ;

**pontuação**  $\leftarrow$  combinação das quatro pontuações como ilustrado na Figura 5.2;

Salve as **conexões** consideradas.

**return** *pontuação*

---

---

**Algoritmo 4:** Ga Interno (GAInterno)

---

**Entrada:** conexões iniciais,  $\phi$ ,  $\gamma$ ,  $M$ ,  $\mathcal{U}_t$

**Saída:** conexões

**Inicialização:**

*Seleção*  $\leftarrow$  estado estável;

*Cruzamento*  $\leftarrow$  dois pontos;

*Mutação*  $\leftarrow$  aleatória;

*Fitness*  $\leftarrow$  Restrições 4.5 a 4.9 e 4.9;

número\_pais  $\leftarrow$  4

gerações  $\leftarrow$  10

elitismo  $\leftarrow$  2 ;

probabilidade\_mutação  $\leftarrow$  0.20

probabilidade\_cruzamento  $\leftarrow$  0.80

Gere a população inicial binária de acordo com  $\mathcal{X}_{t-1}$  ou  $\xi$ ;

**for** *geração* = 1 a *gerações* **do**

**for** *indivíduo em população* **do**

        | pontuação  $\leftarrow$  **Fitness**;

**end**

    Execute a **seleção** de indivíduos que serão os pais da próxima geração;

    Execute o **cruzamento** entre os pais e gere novos descendentes com probabilidade *probabilidade\_cruzamento*, considerando o *elitismo*;

    Execute a **mutação** de genes com probabilidade *probabilidade\_mutação*, considerando o *elitismo*;

    Atualize o melhor indivíduo de acordo com as pontuações;

    Atualize os indivíduos da próxima geração;

**end**

**return** *melhor indivíduo*

---