



Instituto Federal da Bahia

Programa de Pós-Graduação em Engenharia de Sistemas e Produtos

**ALOCAÇÃO OTIMIZADA DE ESTAÇÕES  
RÁDIO BASE PARA SISTEMAS DE  
RADIOCOMUNICAÇÃO PROFISSIONAIS  
UTILIZANDO ALGORITMO BASEADO EM  
ENXAME DE PARTÍCULAS.**

Ubiraci Alves Muniz Barretto

DISSERTAÇÃO DE MESTRADO

Salvador  
2023



UBIRACI ALVES MUNIZ BARRETTO

**ALOCÇÃO OTIMIZADA DE ESTAÇÕES RÁDIO BASE PARA  
SISTEMAS DE RADIOCOMUNICAÇÃO PROFISSIONAIS  
UTILIZANDO ALGORITMO BASEADO EM ENXAME DE  
PARTÍCULAS.**

Esta Dissertação de Mestrado foi apresentada ao Programa de Pós-Graduação em Engenharia de Sistemas e Produtos da Instituto Federal da Bahia, como requisito parcial para obtenção do grau de Mestre em Engenharia de Sistemas e Produtos.

Orientador: Prof. Dr. Fabrício Gerônimo Simões Silva

Salvador  
2023

FICHA CATALOGRÁFICA ELABORADA PELO SISTEMA DE BIBLIOTECAS DO IFBA, COM OS  
DADOS FORNECIDOS PELO(A) AUTOR(A)

B273a Barretto, Ubiraci Alves Muniz

Alocação otimizada de estações rádio base para sistemas de radiocomunicação profissionais utilizando algoritmo baseado em enxame de partículas / Ubiraci Alves Muniz Barretto. - orientador: Fabricio Gerônimo Simões Silva -- Salvador, 2023.

86 p.

Dissertação (Programa de Pós-Graduação em Engenharia de Sistemas de Produtos) -- Instituto Federal da Bahia, Salvador, 2023.

1. Radiocomunicação. 2. Estação rádio base. 3. Enxame de partícula. I.Silva, Fabricio Gerônimo Simões, orient. III. TÍTULO.

CDD/CDU 654.16



**INSTITUTO FEDERAL DA BAHIA**  
**PRÓ-REITORIA DE PESQUISA, PÓS-GRADUAÇÃO E INOVAÇÃO**

**PROGRAMA DE PÓS-GRADUAÇÃO EM  
ENGENHARIA DE SISTEMAS E PRODUTOS –  
PPGESP**

**ALOCAÇÃO OTIMIZADA DE ESTAÇÕES RÁDIO BASE PARA SISTEMAS  
DE RADIOCOMUNICAÇÃO PROFISSIONAIS UTILIZANDO ALGORITMO  
BASEADO EM ENXAME DE PARTÍCULAS**

**UBIRACI ALVES MUNIZ BARRETO**

Produto(s) Gerado(s): **Dissertação;**

Orientador: Prof. Dr. Fabrício Gerônimo Simões Silva

Banca examinadora:

---

Prof. Dr. Fabrício Gerônimo Simões Silva  
Orientador – Instituto Federal da Bahia (IFBA)

---

Prof. Dr. José Mário Araújo  
Membro Interno – Instituto Federal da Bahia (IFBA)

---

Prof. Dr. Karcus Day Rosário Assis  
Membro Externo – Universidade Federal da Bahia (UFBA)

---

Prof. Dr. Antonio César de Castro Lima  
Membro Externo – Universidade Federal da Bahia (UFBA)

Trabalho de Conclusão de Curso aprovado pela banca examinadora em 20/09/2023.



Documento assinado eletronicamente por **FABRICIO GERONIMO SIMOES SILVA,**  
**Docente Colaborador(a),** em 20/09/2023, às 17:57, conforme decreto nº 8.539/2015.



Documento assinado eletronicamente por **JOSE MARIO ARAUJO, Professor Titular**, em 20/09/2023, às 18:40, conforme decreto nº 8.539/2015.

---



Documento assinado eletronicamente por **Antonio Cezar de Castro Lima, Usuário Externo**, em 20/09/2023, às 19:30, conforme decreto nº 8.539/2015.

---



Documento assinado eletronicamente por **Karcus Day Rosário Assis, Usuário Externo**, em 20/09/2023, às 19:49, conforme decreto nº 8.539/2015.

---



A autenticidade do documento pode ser conferida no site [http://sei.ifba.edu.br/sei/controlador\\_externo.php?acao=documento\\_conferir&acao\\_origem=documento\\_conferir&id\\_orgao\\_acesso\\_externo=0](http://sei.ifba.edu.br/sei/controlador_externo.php?acao=documento_conferir&acao_origem=documento_conferir&id_orgao_acesso_externo=0) informando o código verificador **3114067** e o código CRC **33C6FA08**.

---

*Dedico esse trabalho a minha esposa Michele Barretto e filho Arthur Barretto pelos momentos em que estive ausente para me dedicar a realização desta pesquisa. Aos meus pais por todo esforço realizado para que a educação fosse uma prioridade na minha vida. E ao meu irmão Ubiratan Barretto pelas palavras de incentivo.*



## AGRADECIMENTOS

Inicialmente, um agradecimento especial ao meu orientador, Professor Dr. Fabrício Simões, por todo esforço, paciência e dedicação empreendido para conclusão deste trabalho. Inclusive, por todos os ensinamentos e discussões realizadas para que esta pesquisa alcançasse resultados que em princípio não eram esperados. Tenho certeza que sem sua orientação não seria possível chegar até aqui.

Um agradecimento também especial ao Capitão PM Alan Damasceno pelo apoio incondicional na elaboração do algoritmo em Python, realizado muitas vezes aos domingos.

Fico grato aos Professores Drs. José Mário Araújo, Karcus Rosário Assis e Antonio César de Castro Lima que aceitaram o convite para participar da minha Banca Examinadora e realizaram importantes contribuições para melhoria desta dissertação.

Agradeço aos colegas da Superintendência de Telecomunicações da SSP/BA, pelas inúmeras palavras de incentivo durante a reta final do curso e um agradecimento especial ao Major PM Travessa, Superintendente, que me disponibilizou o tempo necessário para conclusão deste trabalho.

Por fim, um especial agradecimento a todos os docentes e discentes do PPGESP por toda contribuição a minha formação pessoal e acadêmica.



*Tente (tente!)  
E não diga que a vitória está perdida  
Se é de batalhas que se vive a vida  
Tente outra vez  
(Raul Seixas)*

---





## RESUMO

Um grande desafio na melhoria da eficiência na implementação de redes de radiocomunicação para Segurança Pública e Defesa é a obtenção de um posicionamento ótimo para a Estação Rádio Base. Devido ao número de variáveis necessárias para análise destas posições, este problema é reconhecido na literatura como de alta complexidade computacional. Normalmente, para realização dos estudos, são utilizadas ferramentas de predição da propagação de rádio. No entanto, estas soluções dependem geralmente da experiência e intuição do projetista para definição da melhor localização para as Estações Rádio Base. Neste trabalho, é apresentada uma solução alternativa baseada no método meta- heurístico conhecido como otimização por enxame de partículas, em que uma função *fitness* é otimizada considerando de forma ponderada cobertura e economia. O modelo de propagação de Longley - Rice foi utilizado a partir de um comparativo com medições realizadas em campo. Para uma região de estudo de  $1806 \text{ km}^2$ , o desempenho do algoritmo mostrou bons resultados, quando considerada a modelagem utilizada, com possibilidade de alocação de quatro Estações Rádio Base com percentuais superiores a 90% de cobertura.

**Palavras-chave:** Radiocomunicação, Estação Rádio Base, Enxame de partícula.



## ABSTRACT

A great challenge in the implementation of radiocommunication networks for Public Safety and Defense is obtaining an optimal positioning for the Radio Base Stations (RBSs). due to the number of variables needed to analyze these positions, this problem is recognized in the literature as of high computational complexity. Normally, to carry out the studies, only radio propagation forecasting tools were used. However, these solutions usually depend on the experience and intuition of the designer to define the best location for the ERBs. In this work, we are presenting an alternative solution based on the heuristic method, known as particle swarm optimization, in which a function fitness is optimized considering weighted form, coverage and economy. The model of Longley - Rice propagation was used based on a comparison with medications performed in field. For a study region of 1,806 km<sup>2</sup>, the performance of the algorithm showed good results, when taken into account the modeling used, with the possibility of allocation of four ERBs with percentages greater than 90

**Keywords:** Radio communication, Base Radio Station, Genetic Algorithm.



# SUMÁRIO

<b>Capítulo 1—Introdução</b>	26
<b>Capítulo 2—Referencial Teórico</b>	31
2.1 Modelos de Propagação . . . . .	31
2.1.1 Propagação no Espaço Livre . . . . .	31
2.1.2 Modelo de Lee . . . . .	32
2.1.3 Modelo de Longley Rice . . . . .	34
2.1.4 Modelo de Okumura Hata . . . . .	37
2.2 Otimização . . . . .	38
2.3 Computação Natural . . . . .	44
2.3.1 Inteligência de Enxame . . . . .	44
2.3.2 Enxame de Partículas . . . . .	45
<b>Capítulo 3—Proposta: Descrição e Método</b>	53
3.1 Definição do Modelo de Propagação . . . . .	54
3.2 Região de Estudo . . . . .	56
3.3 Algoritmo PSO . . . . .	57
<b>Capítulo 4—Resultados</b>	61
4.1 Comparativo com medidas de campo . . . . .	61
4.1.1 Modelo de Hata . . . . .	65
4.1.2 Modelo de Lee . . . . .	65
4.1.3 Modelo de Longley - Rice . . . . .	67
4.2 Comparação entre os Modelos de Propagação . . . . .	68
4.3 Resultados do Algoritmo por Enxame de Partículas . . . . .	71
<b>Capítulo 5—Conclusão</b>	79



## LISTA DE FIGURAS

2.1	Ponto de interseção e decaimento da atenuação . . . . .	33
2.2	Obtenção do $\gamma_i$ . . . . .	36
2.3	Classificação dos problemas de otimização. . . . .	40
2.4	Exemplificação da capacidade das formigas em encontrar o menor caminho: (a) ponte inicialmente fechada; (b) distribuição inicial das formigas; (c) distribuição ao logo do tempo. . . . .	46
2.5	O vetor de posição sendo atualizado em uma iteração . . . . .	49
2.6	Fluxograma do PSO . . . . .	51
3.1	Fluxograma do algoritmo implementado. . . . .	55
3.2	Região de estudo . . . . .	56
3.3	Região de estudo com pontos de recepção . . . . .	57
4.1	Interface para medições em campo . . . . .	62
4.2	Resultado das medições no município de Itaparica. . . . .	62
4.3	Exemplo de <i>frame</i> . . . . .	63
4.4	Obtenção do ponto de elevação - Altimetria. . . . .	63
4.5	Local e visualização da torre. . . . .	64
4.6	Cálculo da distância. . . . .	64
4.7	Gráfico - Medidas em campo x Modelo Hata . . . . .	66
4.8	Gráfico - Medidas em Campo x Modelo Lee. . . . .	68
4.9	Gráfico - Medidas em Campo x Modelo Rice. . . . .	69
4.10	Gráfico - Comparativo Geral . . . . .	69
4.11	Resultado da <i>fitness</i> para a otimização 6 e $\alpha = 0,7$ . . . . .	72
4.12	Resultado da <i>fitness</i> para a otimização 7 e $\alpha = 0,7$ . . . . .	72
4.13	Posicionamento das ERBs no mapa para a otimização 6 e $\alpha = 0,7$ . . . . .	73
4.14	Posicionamento das ERBs no mapa para a otimização 7 e $\alpha = 0,7$ . . . . .	74
4.15	Resultado da <i>fitness</i> para otimização 8 e $\alpha = 0,9$ . . . . .	75
4.16	Posicionamento das ERBs no mapa para otimização 8 e $\alpha = 0,9$ . . . . .	76
4.17	Resultado da <i>fitness</i> para otimização 1 e $\alpha = 0,9$ . . . . .	77
4.18	Posicionamento das ERBs no mapa para otimização 8 e $\alpha = 0,9$ . . . . .	78





## LISTA DE TABELAS

2.1	Valores estimados para a irregularidade do terreno . . . . .	35
2.2	Relação entre as faixas de frequência aplicadas para os modelos . . . . .	38
4.1	Parâmetros/Valores dos modelos. . . . .	65
4.2	Comparação entre as medições em campo e o modelo Hata . . . . .	66
4.3	Comparação entre as medições em campo e o modelo Lee . . . . .	67
4.4	Comparação entre as medições em campo e o modelo Rice . . . . .	70
4.5	Detalhamento do Erro médio e Desvio Padrão . . . . .	70
4.6	Parâmetros de operação do PSO . . . . .	71
4.7	Parâmetros de operação do PSO. . . . .	74
4.8	Comparativo com trabalhos relacionados. . . . .	76



## LISTA DE SIGLAS

<b>ERB</b> Estação Rádio Base . . . . .	26
<b>ERBs</b> Estações Rádio Base . . . . .	26
<b>PSO</b> Otimização por Enxame de Partículas . . . . .	27
<b>GA</b> Algoritmo Genético . . . . .	27
<b>RFID</b> Identificação por Rádio Frequência . . . . .	27
<b>BRKGA</b> Algoritmos Genéticos de Chave Aleatória Enviesados . . . . .	28
<b>LTE</b> Evolução a Longo Prazo . . . . .	28
<b>DRMPSO</b> Otimização de Enxame de Partículas Multiobjetivo de Faixa Dividida . . . . .	28
<b>FPO</b> Otimização por Polinização de Flores . . . . .	29
<b>ABG</b> Alpha, Beta e Gama . . . . .	29
<b>CI</b> <i>Close in</i> . . . . .	29
<b>RF</b> Radio Frequência . . . . .	32
<b>ITM</b> Modelo de Terreno Irregular . . . . .	34
<b>API</b> Interface de Programação de Aplicativos . . . . .	54
<b>ANATEL</b> Agência Nacional de Telecomunicações . . . . .	54
<b>ETSI</b> Instituto Europeu de Padrões de Telecomunicações . . . . .	58
<b>TETRA</b> Rádio Troncalizado Terrestre . . . . .	58
<b>BER</b> Taxa de Erro de Bit . . . . .	62



## LISTA DE SÍMBOLOS

$a$	Fator de correção
$a_0$	Fator de ajuste do modelo
$d$	Distância entre antenas
$f$	Frequência de Operação
$f_0$	Frequência de referência
$G_R$	Ganho da antena de recepção
$G_T$	Ganho da antena de transmissão
$G_{Rp}$	Ganho padrão da antena de recepção
$G_{Tp}$	Ganho padrão da antena de transmissão
$h_1$	Altura da antena da estação base
$h_2$	Altura da antena da estação móvel
$h_{1p}$	Altura padrão da antena da estação base
$h_{2p}$	Altura padrão da antena da estação móvel
$L_0$	Atenuação no espaço livre
$L_{ref}$	Somatório de atenuações
$n$	Fator de ajuste da frequência
$P_O$	Potência medida a 1,6 Km do ponto de transmissão
$P_R$	Potência do sinal recebido
$P_T$	Potência do sinal transmitido
$P_{Tp}$	Potência padrão do sinal transmitido
$r$	Distância entre a estação base e a estação móvel
$r_0$	Distância entre a estação base e o ponto a 1,6 Km

$\delta_L$	Desvio de localização
$\delta_t$	Desvio de tempo
$\gamma$	Taxa de variação da atenuação com a distância
$\gamma_L$	Variável de mudança localização
$\gamma_s$	Variável de mudança do cenário
$\gamma_t$	Variável de tempo
$\lambda$	Comprimento de onda

## Capítulo

# 1

## INTRODUÇÃO

A implantação de sistemas de telecomunicações, principalmente aqueles voltados às aplicações de radiocomunicação para Segurança Pública e Defesa, exigem altos investimentos e significativo tempo de execução dependendo da dimensão da área a ser coberta. Estas implantações são realizadas através da análise de cobertura de radiofrequência, que se baseia em modelos de perda por propagação (ou de percurso) para prever a distribuição do campo eletromagnético ao redor de uma antena transmissora e, conseqüentemente, avaliar distâncias máximas de alcance do sistema. A exatidão das predições geradas por esses modelos depende dos dados disponíveis sobre o sistema e a região de análise (DIAS, 2018).

Segundo Junior (2015), para as Instituições de Segurança Pública e Defesa, as dificuldades surgem no momento do mapeamento completo da rede, ou ainda nos casos de expansão ou de novos projetos, pois sem ferramentas adequadas, a tendência é obter resultados pouco satisfatórios ou incorretos sobre o sistema de radiocomunicação a ser utilizado.

Uma forma de tornar mais eficaz a aplicação desta análise, é a utilização de *softwares* que realizam um estudo preditivo da radiopropagação do sinal. A utilização destas ferramentas computacionais permite uma visualização antecipada dos resultados de cobertura, o que torna-se uma vantagem no planejamento de redes, pois podem revelar problemas que só seriam percebidos no momento da instalação dos equipamentos de transmissão e recepção. (JUNIOR, 2015).

Entretanto, ainda assim, esta avaliação torna-se intuitiva, visto que a localização das Estações Rádio Base (ERBs) escolhidas para o estudo pode não ser a mais eficaz na região de cobertura pretendida o que pode levar a resultados ineficientes, como a instalação de uma quantidade maior de ERBs do que a necessária gerando investimentos prescindíveis.

Como as ferramentas de estudo disponíveis no mercado não verificam dentro da região de cobertura pretendida a melhor coordenada para instalação da Estação Rádio Base (ERB), resta ao projetista analisar, através da sua experiência, as posições que possam apresentar os melhores resultados realizando caso a caso o estudo destas. O problema é que este formato, não garante a escolha da melhor localização (latitude e longitude). Isso ocorre, porque o problema de posicionamento de ERBs, envolve uma grande quantidade de parâmetros, tornando-se complexa a busca de uma solução de forma determinística.

Desta maneira, uma forma de otimizar a implantação de sistemas de radiocomunicação, no que se refere ao problema de melhor posicionamento da ERB, é a utilização de métodos baseados em heurísticas.

Em uma série de problemas que envolve otimização combinatório, tendo como exemplo clássico o problema do caixeiro viajante, métodos heurísticos possibilitam que através de modelos estatísticos e a partir de soluções iniciais aleatórias seja possível a obtenção de soluções ótimas. Entre estes modelos destacam-se Algoritmos Imunoinspirados (SIA), Algoritmos Genéticos (GA) e Inteligência de Enxame.

Nos seus trabalhos, por exemplo, Lieska, Laitinen e Lahteenmaki (1998), Han et al. (2001), Alenoghena, Emagbetere e Aibinu (2013), Suriya e Porter (2014), Ouamri (2017), Costa (2016), Amorim1 et al. (2019) e Antunes et al. (2021) utilizaram Algoritmo Genético (GA) para otimização do posicionamento de ERBs enquanto as pesquisas de Yangyang et al. (2004), Talau (2010), Monshi e Islam (2012), Pereira (2014) e Filho (2019) utilizaram o método de Otimização por Enxame de Partículas (PSO).

Em Lieska, Laitinen e Lahteenmaki (1998) foi realizada uma análise utilizando GA visando resolver o problema de otimização no posicionamento de ERB's para obtenção da máxima cobertura. Ressaltou que o GA mantém uma população de soluções potenciais (com bom desempenho) enquanto outros métodos processam um único ponto. Modelou o problema considerando uma região fictícia cartesiana visando maximizar a área total de cobertura onde a energia recebida era maior que -60 dBm.

Em Han et al. (2001), uma nova representação para descrever o posicionamento de estações base com números reais e introdução de novos operadores genéticos foi adotada. Na sua proposta é descrito não apenas os locais das estações base, mas também o quantitativo delas. Aplicou o algoritmo num problema de otimização considerando eficiência na cobertura e viabilidade econômica, e testou em um ambiente de densidade de tráfego não homogênea. Concluiu, através do resultado da simulação, que é possível encontrar soluções quase ótimas com o algoritmo.

Em seu trabalho, Alenoghena, Emagbetere e Aibinu (2013) utilizou um algoritmo baseado GA para otimizar o posicionamento de ERB levando em consideração a sua vizinhança. A proposta levava em consideração a regulamentação local quanto às exigências de distanciamento da ERB em relação a escolas, hospitais, igrejas e outras edificações. Através da utilização de uma área retangular simulada e a atribuição de pesos conforme os limites legais para cada distância, simulou a otimização do posicionamento da ERB. Obteve como resultado 100% de eficiência concluindo que o GA pode ser utilizado para otimização no posicionamento de ERB.

Já em sua pesquisa Suriya e Porter (2014), propôs um modelo de otimização utilizando GA para o posicionamento de leitores de Identificação por Rádio Frequência (RFID) em uma instalação de grande escala. Para tal, realizou duas simulações envolvendo uma instalação de 30 x 30 m, utilizando coordenadas cartesianas, com 99 etiquetas RFID colocadas aleatoriamente. Na primeira, utilizou apenas 10 leitores comparando os resultados com os obtidos em pesquisas anteriores. A segunda buscou encontrar o número ideal e localização de leitores para as 99 tags RFID. Concluiu que o GA conseguiu obter com eficiência e rapidez os melhores resultados para o quantitativo e posicionamento dos leitores de RFID na instalação.

Costa (2016), propôs um modelo utilizando um algoritmo genético modificado (algoritmo memético) para obtenção do posicionamento ótimo para ERBs. Utilizou o modelo Cost 231



- Hata e frequências na faixa de 700 MHz e 2.5 GHz para o padrão de Evolução a Longo Prazo (LTE) com estudo realizado para o município de Palmas-TO. Concluiu que o algoritmo memético apresentou bons resultados no que diz respeito a alocação de ERBs, pois das 30 possíveis combinações em 29 delas a cobertura da área de estudo foi de mais de 80% dos pontos de demanda, estando, portanto, dentro do exigido pela ANATEL para áreas urbanas.

Em pesquisa publicada, Valavanis et al. (2014) desenvolveu uma metodologia de otimização baseada em GA tendo como objetivo identificar de forma estocástica a solução ótima que atenda aos requisitos das operadoras de telefonia em termos de cobertura e capacidade em uma determinada área, com o mínimo de ERB e consequentemente de custo. Na sua metodologia, desenvolveu um sistema de LTE que funciona para uma topologia de rede que considera, explicitamente, estruturas de células mistas (macro, micro), nós de retransmissão e locais de demanda de tráfego não uniformes. Os resultados demonstraram um desempenho bem sucedido do método proposto.

Em Ouamri (2017) também foi utilizado GA para otimizar o posicionamento de ERBs. Considerou as coordenadas do local  $(x, y)$ , transmissão de potência, altura e inclinação como parâmetros de projeto. Cobertura, interferência e custo foram definidas na função objeto, enquanto *Handover*, demanda de tráfego e sobreposição foram considerados como restrições. Utilizou o modelo de Hata para cálculo das perdas no caminho e levou como suposição uma região plana. O algoritmo apresentou uma avaliação de desempenho com 97% dos usuários sendo cobertos com sinal de boa qualidade.

Em Amorim1 et al. (2019) foi resolvido o problema de posicionamento de ERB utilizando a meta-heurística *Biased Random - Key Genetic Algorithms* (Algoritmos Genéticos de Chave Aleatória Enviesados (BRKGA)) visando otimizar, de forma ponderada, um balanço entre cobertura e custo de serviço. Na sua pesquisa, realizou vários testes para provar a eficácia da solução proposta, onde o BRKGA apresentou valores distantes 1,4%, em média, da cobertura ótima, resultados superiores em termos de execução e cobertura de área frente aos métodos adotados pela literatura.

Também utilizando GA, Antunes et al. (2021) realizou um estudo visando verificar a viabilidade de um algoritmo de otimização exato e outro meta-heurístico, utilizando GA, para obter a melhor cobertura possível ao menor custo no emprego de ERBs móveis em comunicações críticas militares. Utilizou como ambiente de estudo um modelo baseado na tragédia de Brumadinho. Concluiu que o algoritmo baseado em GA era superior ao exato para situações com alta carga de trabalho, além de entregar soluções ótimas em menor tempo computacional.

Já utilizando o PSO, Yangyang et al. (2004) utilizou o Otimização de Enxame de Partículas Multiobjetivo de Faixa Dividida (DRMPSO) para o melhor posicionamento de ERBs considerando cobertura e eficiência econômica. Considerou o conjunto ótimo de Pareto para avaliação dos resultados do algoritmo e o método de propagação no espaço livre para uma região simulada. Os resultados de simulação mostraram que a abordagem proposta é eficiente e eficaz, especialmente para projetos de redes em larga escala.

Uma pesquisa realizada por Hassan, Cohanim e Weck (2005) teve como objetivo realizar uma avaliação comparativa entre o GA e o PSO. Destacou, que os métodos se assemelham no sentido que ambos possuem abordagens de pesquisa baseadas na população e que ambas dependem do compartilhamento de informações entre os membros da população para melhorar seus processos de pesquisa usando uma combinação determinística com regras probabilísticas. Para

os estudos comparativos, realizou a otimização de oito problemas através de várias execuções com PSO e GA. Concluiu que, embora o PSO e o GA obtenham soluções de alta qualidade, com índices de qualidade de 99% ou mais com um nível de confiança de 99% para a maioria dos problemas de teste, o esforço computacional exigido pelo PSO para encontrar soluções de alta qualidade é menor do que o esforço exigido pelo GA para encontrar a mesma alta qualidade de soluções.

Em seu trabalho, Talau (2010) apresentou uma abordagem para resolver a otimização do posicionamento de ERB's em um ambiente interno, visando atender um conjunto de usuários, com um número mínimo de estações. Utilizou o modelo de otimização por enxame de partículas binárias simulando quatro regiões de estudo. Considerou para os estudos a propagação no espaço livre com frequência de operação em 1,8 GHz. Comparou os resultados do PSO binário com soluções ótimas encontradas por um algoritmo de pesquisa exaustivo. Os resultados computacionais sugeriram que o algoritmo PSO fornece uma abordagem bastante eficiente para obter soluções ótimas com pequeno esforço computacional.

De forma semelhante, Monshi e Islam (2012) utilizou o PSO para otimização no posicionamento de ERBs levando em consideração uma função de otimização multiobjeto para cobertura e eficiência econômica. Considerando uma região simulada utilizou o método de propagação de Hata e parâmetros de potência, altura e energia efetiva irradiada para os cálculos do algoritmo. Obteve respostas otimizadas para um conjunto de simulações variando-se os parâmetros do PSO.

Pereira (2014), baseado-se na fórmula de capacidade de Shannon e o índice de justiça de Jain, avaliou o desempenho do PSO sugerido para dois conjuntos de pontos de demanda de tráfego, correspondendo a uma estimativa do tráfego médio e de pico, respectivamente, para uma região metropolitana. Realizou os estudos com 8, 32, 128 e 256 partículas para posicionamento das ERBs, sugerindo pontos ideais para colocação das mesmas encontrada pelo PSO. De forma semelhante a Talau (2010), considerou para os cálculos a propagação no espaço livre e frequência de 2GHz. Seus resultados demonstraram uma melhoria de 17% com um aumento no número de estações menor do que 10%.

Por fim, Filho (2019) propôs uma otimização do posicionamento de múltiplas *small cells*, utilizando os métodos de otimização PSO e Otimização por Polinização de Flores (FPO). Tomando como referência um ambiente urbanizado, utilizou dois modelos de propagação, Alpha, Beta e Gama (ABG) e *Close in* (CI), simulados em diferentes faixas de frequência: 3,5 GHz, 10 GHz, 24 GHz, 28 GHz, 60 GHz e 73 GHz. Os resultados mostraram que os algoritmos posicionaram de maneira eficiente as *small cells*, sendo que o PSO exige um menor tempo de processamento, mas com uma maior quantidade de iterações quando comparado aos resultados do FPO.

Segundo Thevenot (2020), o PSO compartilha muitas semelhanças com GA. O sistema é inicializado com uma população de soluções aleatórias e busca soluções ótimas através da atualização de gerações. No entanto, ao contrário do GA, o PSO não tem operadores de evolução, como *crossover* e mutação. A diferença está na forma como as gerações são atualizadas. Foi demonstrado também que o PSO pode ter melhores resultados de forma mais rápida e econômica em comparação com outros métodos. Ainda apresenta a vantagem de possuir poucos parâmetros que são de simples entendimento. Além disso, para os mesmos parâmetros, o PSO funciona em uma grande variedade de tarefas, o que o torna um algoritmo muito flexível.

Diante do exposto, o objetivo deste trabalho é desenvolver um algoritmo que utilizando o método PSO seja capaz de otimizar o posicionamento de ERBs em um sistema de radiocomunicação voltado para a Segurança Pública operando no intervalo entre 144 - 450 MHz, considerando aspectos técnicos e econômicos e utilizando no estudo um ambiente geográfico real através das operações sendo realizadas com as coordenadas geográficas em formato decimal. Como objetivos específicos, é possível listar:

- Definir o modelo de predição de radiopropagação mais adequado ao problema a partir de medições realizadas em campo;
- Implementar uma rotina baseada em computação bio-inspirada, através do método PSO, usando linguagem de programação *Python*;
- Avaliar o desempenho do método de otimização a partir das soluções obtidas e do tempo de processamento;

Além da Introdução, o trabalho é organizado como se segue: No Capítulo 02 é detalhada a fundamentação teórica necessária para o desenvolvimento da pesquisa. No Capítulo 03 são apresentadas as principais etapas de elaboração deste trabalho. Em seguida, no Capítulo 04, os resultados obtidos são apresentados e discutidos. E por fim, na Conclusão, é abordado um resumo das principais realizações deste trabalho.

## REFERENCIAL TEÓRICO

Com intuito de obter os melhores resultados de cobertura na implantação de sistemas de radiocomunicação, são utilizados *softwares* para predição da cobertura. Como já citado, estas aplicações utilizam métodos matemáticos desenvolvidos a partir de estudos determinísticos ou empíricos.

Os métodos determinísticos são modelos teóricos que se baseiam em formulações matemáticas, fundamentadas em princípios físicos exatos, no qual leva-se em consideração todo o meio de propagação das ondas eletromagnéticas, desde a topografia do terreno até as construções, ou seja, tudo que pode afetar a propagação do sinal (MOREIRA, 2017). Estes modelos podem ser utilizados para qualquer ambiente, mas na prática exigem grande esforço computacional, pois utilizam algoritmos complexos o que requer maior memória e capacidade de processamento dos dados. Dentre os modelos determinísticos, destacam-se o modelo de Diferenças Finitas no Tempo, o modelo de Traçado de Raios e o modelo utilizando equações parabólicas (GOMES, 2015).

No entanto, os modelos empíricos são mais funcionais por apresentarem baixo custo computacional. São utilizados na predição de cobertura dos mais variados cenários, como por exemplo, em ambientes rurais, suburbanos e urbanos (LEMOS, 2016). Também são encontradas aplicações desses modelos em ambiente do tipo *indoor*.

Neste sentido, como o alvo deste trabalho é o desenvolvimento de um algoritmo de baixo custo para estudos voltados a implantação de sistemas de radiocomunicação críticos, especificamente para Segurança Pública, neste capítulo são abordados alguns dos principais modelos empíricos de propagação.

### 2.1 MODELOS DE PROPAGAÇÃO

Nesta seção, são detalhados alguns exemplos de modelos empíricos como a propagação no Espaço Livre, modelo Log-Distância, Lee, Longley-Rice e Okumura-Hata.

#### 2.1.1 Propagação no Espaço Livre

A propagação no espaço livre é estudada em ambientes onde a propagação de ondas de rádio entre a antena transmissora e receptora de um determinado sistema de comunicações está livre

de todos os objetos que possam interagir de alguma forma com a onda eletromagnética (LEMOS, 2016). Para obter os valores de potência recebida no espaço livre é utilizada a Equação 2.1 de *Friis*.

$$P_R = P_T G_T G_R \left( \frac{\lambda}{4\pi d} \right)^2 \quad (2.1)$$

No espaço livre a propagação da onda ocorre em linha reta, sem efeitos de difração ou reflexão (LEMOS, 2016). Conforme Yacoub (1993), uma forma de mensurar os estudos de rádio propagação é através da perda de trajetória  $L$  dada pela Equação 2.2

$$L = \frac{P_R}{P_T} = \left( \frac{\lambda}{4\pi d} \right)^2, \quad (2.2)$$

considerando antenas isotrópicas, isto é, com  $G_T = G_R = 1$ .

Em decibéis, a perda de trajetória  $L$  é dada por

$$L_{(dB)} = 10 \log \left( \frac{\lambda}{4\pi d} \right)^2 \quad (2.3)$$

Consequentemente, a equação de *Friis*, em decibéis, passa a ser

$$L_{(dB)} = 20 \log(\lambda) - 20 \log(4\pi) - 20 \log(d) \quad (2.4)$$

Sabendo que  $\lambda = \frac{c}{f}$ , que a frequência é dada em MHz e distâncias em km, obtém-se

$$L_{(dB)} = 20 \log(c) - 20 \log(f) - 21,98 - 20 \log(d) \quad (2.5)$$

Por fim, a equação de *Friis* passa a ser dada por

$$L_{(dB)} = 32,44 + 20 \log(d_{km}) + 20 \log(f_{MHz}) \quad (2.6)$$

Embora a equação de transmissão de *Friis* seja simples, não considera fatores geográficos da região, como por exemplo, o relevo. Por isso, é necessário abordar outras ferramentas de predição de propagação do sinal.

### 2.1.2 Modelo de Lee


O modelo de Lee proposto em 1985 foi obtido a partir de dados experimentais. Nele, verificou-se a taxa de atenuação do nível do sinal em função da distância, conforme as variações da topografia e da morfologia do terreno. É um modelo muito utilizado em projetos de Radio Frequência (RF) de telefonia móvel, principalmente na faixa de frequência de 950 MHz, e é adequado para faixas entre 150 e 2400 MHz (JUNIOR, 2015).

O modelo baseou-se em exaustivas medições de sinal em algumas cidades com características diferentes, com o objetivo de se encontrar parâmetros de ajuste a serem incorporados na expressão, permitindo com isso adequar a aplicação do modelo a outras regiões morfologicamente semelhantes (ELIAS, 2005). O modelo é definido pela Equação 2.7.

$$P_R = P_0 - \gamma \log\left(\frac{r}{r_0}\right) - n \log\left(\frac{f}{f_0}\right) + a_0 \quad (2.7)$$

O modelo de Lee tem como um dos seus principais fundamentos a utilização de um ponto de intersecção num raio de 1,6 km da estação - base. O valor do decaimento associado ao valor neste ponto é utilizado para prever o nível de sinal de cada ponto ao longo de uma radial. Estes valores podem ser usados para previsões em áreas similares sem ser necessário refazer as medidas (PEREIRA, 2007). Segundo Lee (1989), a razão em se adotar a potência a partir de 1.6 km (uma milha) do ponto de transmissão é que dentro de uma região circular, com centro na ERB em questão e raio com valor descrito, existe pouca influência dos elementos morfológicos no aumento da atenuação do sinal recebido.

A potência de recepção no ponto de intersecção  $P_0$  e o decaimento da atenuação  $\gamma$  em função da distância são obtidos a partir da verificação dos dados apresentados na Figura 2.1, caso não seja possível a obtenção do valor em campo, considerando-se as características do tipo de ambiente de estudo.



**Figura 2.1** Ponto de intersecção e decaimento da atenuação  
Fonte: (PATRIOTA, 2011)

Conforme descrito por Lee (1989), o fator  $n$  é obtido dentro da faixa definida na Equação 2.8.

$$20dB/década \leq n \leq 30dB/década \quad (2.8)$$

Sendo válida para frequências que vão de 30 a 2000 MHz e distâncias que variam de 1 a 30 Km. Para sistemas operando em regiões urbanas, com frequências superiores a 450 MHz,  $n = 30$  dB/década tem sido geralmente adotado, mostrando boa aproximação da realidade.

O fator  $a_0$  tem como objetivo ajustar a previsão a partir da definição dos parâmetros reais da ERB e do terminal móvel. O ajuste é efetuado considerando níveis de potência de transmissão, altura dos centros de emissão das antenas da ERB e do terminal móvel e ganhos das antenas da ERB e do terminal móvel (PEREIRA, 2007), conforme Equação 2.9

$$a_0 = 10\log\left(\frac{P_T}{P_{Tp}}\right) + 20\log\left(\frac{h_1}{h_{1p}}\right) + 10\log\left(\frac{h_2}{h_{2p}}\right) + (G_T - G_{Tp}) + (G_R - G_{Rp}) \quad (2.9)$$

Os valores padrão para o modelo de Lee são:

- $P_{Tp} = 10$  W;
- $h_{1p} = 30$  m;
- $h_{2p} = 3$  m;
- $G_{Tp} = 6$  dBd;
- $G_{Rp} = 0$  dBd.

### 2.1.3 Modelo de Longley Rice

O modelo Longley-Rice ou Modelo de Terreno Irregular (ITM) é utilizado em estudos de propagação para faixas de frequência entre 20 MHz a 20 GHz, uma ampla variedade de altura e distância de antenas, onde a característica do terreno tem significativa relevância. O modelo apresenta resultados de predição com baixo custo computacional e satisfatório quando comparado a outros modelos tradicionais (AMARAL, 2012).

Ele trabalha com dois modos diferentes a partir do perfil do terreno: Quando os parâmetros inerentes do caminho são facilmente determinados, a previsão é denominada de previsão modo ponto a ponto, ou seja, ambos os terminais se encontram em locais específicos conhecidos. Nesse caso, o problema é basicamente estimar a potência de recepção. Caso o perfil do terreno não esteja disponível, o método de Longley-Rice apresenta técnicas para estimar os parâmetros específicos, e essa previsão é denominada previsão modo de área. Para isso, foram atribuídas variáveis aleatórias, relacionadas as condições de tempo, localização e situação que a estação móvel está sujeita (AMARAL, 2012).

Além da frequência, altura e distância entre as antenas, o modelo também possui como variáveis de entrada as irregularidades no terreno ( $\Delta h$ ), constante de aterramento elétrico (permissividade e condutividade do solo), refratividade da superfície, clima, critério de localização e nível de confiança. Devido a complexidade de parâmetros, foi elaborado para uso computacional. Maior detalhamento dos valores destas variáveis, desenvolvimento e métodos de aplicação são encontrados em (HUFFORD; LONGLEY; KISSICK, 1982).

No modelo, o sinal recebido pela estação móvel é resultante do sinal transmitido somado às atenuações do espaço livre (Equação 2.6) e de referência  $L_{ref}$ . Conforme a Equação 2.10:

$$P_r = P_t + L + L_{ref} \quad (2.10)$$

A atenuação de referência é dada pela Equação 2.11, onde estão definidos os efeitos aleatórios de situação, localização e tempo.

$$L_{ref} = L_0 - \gamma_s + \delta_L \gamma_L + \delta_t \gamma_t \quad (2.11)$$

Para as situações em que a localização da estação móvel não é conhecida, a variável  $\gamma_L$  é obtida pela expressão:

$$\gamma_L = \frac{10k\Delta h(d)}{k\Delta h(d) + 13}, k = 2\pi f \quad (2.12)$$

Sendo  $k$  a frequência angular e  $\Delta h(d)$  o parâmetro que caracteriza a irregularidade do terreno. Embora a variância relacionada com a localização da estação dependa da irregularidade do terreno  $\Delta h$  em função de sua posição  $d$ , alguns valores são tabelados para este cálculo, conforme Tabela 2.1:

**Tabela 2.1** Valores estimados para a irregularidade do terreno

<b>Tipo de Terreno</b>	$\Delta h(d)$
Água	0 - 50
Planície	30
Serras	80 a 150
Montanhas	150 a 300
Picos e Cordilheiras	300 a 700

Fonte: (AMARAL, 2012)

Para as situações onde a localização da estação receptora é conhecida, caracterizando um estudo ponto a ponto, considera-se  $\gamma_L = 0$  (AMARAL, 2012).



Os efeitos da variação do cenário  $\gamma_s$  são definidos a partir de uma distância de referência ( $D = 100\text{km}$ ) e a distância efetiva entre as estações ( $d_e$ )

$$\gamma_s = 5 + 3 \exp\left(\frac{-d_e}{D}\right) \quad (2.13)$$

Por fim, a variável aleatória  $\gamma_t$  é obtida através da consulta a Figura 2.2 para a distância ( $d$ ) entre as estações e os correspondentes valores para atenuação em cada clima (AMARAL, 2012).




Figura 2.2 Obtenção do  $\gamma_t$   
Fonte:(AMARAL, 2012)

Os desvios  $\delta_L$  e  $\delta_t$  são adimensionais, sempre positivos e com valor médio unitário (JUNIOR, 2015).

### 2.1.4 Modelo de Okumura Hata

O modelo de Okumura foi desenvolvido a partir de testes em cidades japonesas e foi publicado em 1968. É válido para faixa de frequências entre 150 e 1920MHz, distâncias de 30 a 100km e altura de antenas variando de 30m a 100m (JUNIOR, 2015).

O referido modelo apresenta resultados mais adequados e próximos da realidade do que apenas o cálculo da atenuação no espaço livre. Ele foi desenvolvido a partir de testes realizados em larga escala com várias estações, transmitindo em várias bandas, numa grande variedade de ambientes de propagação, tentando explorar os fatores fundamentais que influenciam a propagação desde a morfologia do terreno à existência de edifícios, orientação de ruas, existência de superfícies abertas e superfícies aquáticas (GOES, 2017).

Assim, Okumura propôs uma família de curvas que relacionam a atenuação média e a frequência de operação (ELIAS, 2005). A partir destas curvas, a expressão 2.14 permite calcular a potência média teórica recebida por um móvel:

$$P_r = P_0 - L_p \quad (2.14)$$

No qual  $P_r$  é a potência média recebida pelo móvel em ambiente urbano e  $P_0$  é a potência que seria recebida pelo móvel através da propagação no espaço livre, dada por:

$$P_0 = P_t - L \quad (2.15)$$

e  $L_p$  a atenuação de percurso média desenvolvida por Hata para possibilitar a implementação computacional das curvas de Okumura.

O modelo é definido pela Equação 2.16

$$L_{purbano} = 69,55 + 26,16 \log(f) - 13,82 \log(h_1) + (44,9 - 6,55h_2) \log(d) - a(h_2) \quad (2.16)$$

O fator de correção  $a(h_2)$  pode ser obtido a partir da Equação 2.17 quando a região de estudo for um ambiente com pouca urbanização.

$$a(h_2) = (1,11 \log(f) - 0,7)h_2 - (1,56 \log(f) - 0,8) \quad (2.17)$$

Para ambientes com muita urbanização, Equações 2.18 e 2.19

$$a(h_2) = 8,29 \log^2(1,54a(h_2)) - 1,1(dB) \text{ para frequência } < 300MHz \text{ e} \quad (2.18)$$

$$a(h_2) = 3,2 \log^2(11,75a(h_2)) - 4,97(dB) \text{ para frequência } \geq 300MHz \quad (2.19)$$

Em seu trabalho de pesquisa Moreira (2017), apresentou uma análise comparativa da potência de sinal recebida de medidas realizadas na cidade de Natal/RN com os valores teóricos obtidos por meio de simulações de alguns modelos clássicos de propagação como: Espaço livre, Reflexão, Percurso Médio e Okumura-Hata. Foi observado que o modelo de Okumura-Hata se aproximou bastante dos valores medidos.

Além disso, o modelo Okumura-Hata-Cost-231 é um dos métodos mais empregados para cálculo da perda média de propagação em áreas urbanas, apesar de não estar na faixa de frequência de aplicação deste trabalho, pois o modelo COST-231 é uma extensão do modelo de Okumura-Hata para frequências até 2 GHz (JUNIOR, 2015).

Quanto a definição do modelo uma importante questão deve ser observada: a frequência de operação. Sistemas de radiocomunicação para Segurança Pública operam nas faixas de frequência inferiores a 700 MHz. Desta forma, o modelo escolhido deverá ter aplicação nestas faixas de frequência.

Na Tabela 4.5 é apresentado um resumo das faixas de frequência para os modelos de Lee, Longley-Rice e Okumura Hata.

**Tabela 2.2** Relação entre as faixas de frequência aplicadas para os modelos

<b>Modelo</b>	<b>Faixa de Frequência</b>
Lee	150 - 2400MHz
Longley - Rice	20 - 20000MHz
Okumura Hata	150 - 1920MHz

Fonte: Autor, 2021

Diante disto, como operam na faixa de frequência desejável, estes modelos foram comparados considerando erro médio e desvio padrão a partir de medições realizadas em campo. O objetivo é identificar qual modelo mais se aproxima das características da região estudada.

## 2.2 OTIMIZAÇÃO

Das atividades cotidianas até as complexas pesquisas científicas é comum a busca pela solução de problemas a partir de uma técnica chamada de Otimização. Segundo Olivieri (2004) e Takahashi (2007) a otimização é um conjunto de métodos ou procedimentos capazes de determinar as melhores configurações para minimizar ou maximizar uma determinada função, chamada de função objetivo, sujeita ou não a uma série de restrições, com intuito de se obter

os melhores resultados ou recursos possíveis.

Desta forma, para resolver problemas utilizando os métodos de otimização é necessário, primeiramente, entendê-lo corretamente e em seguida definir a função objetivo, suas possíveis restrições, bem como as variáveis de decisão. As variáveis de decisão são as incógnitas a serem determinadas capazes de maximizar ou minimizar uma função objetivo. As restrições são os limites aplicados aos valores das variáveis de decisão. Podem ser expressas em equações e/ou inequações que traduzem um limite físico à solução do problema.

Para Carvalho (2014), dependendo da escolha das variáveis de projeto, função objetivo e restrições, vários tipos de problemas de otimização podem ser criados. A partir disso, destaca-se duas importantes classificações para os algoritmos que utilizam técnicas de otimização, conforme Figura 2.3:

1. Uma referente as características da função objetivo e suas restrições;
2. A outra quanto a natureza dos dados e variáveis de entrada.

Na primeira, uma otimização pode ser classificada como programação linear ou não linear. Nas lineares, a função objetivo e suas restrições podem ser representadas como equações matemáticas lineares das variáveis do projeto. Já as não lineares, a função objetivo e/ou suas restrições são funções não lineares das variáveis envolvidas (OLIVIERI, 2004). No que se refere a natureza dos dados e suas variáveis de entrada, o método utilizado no algoritmo de otimização pode ser determinístico ou probabilístico.

No método determinístico a função objetivo é dada por uma função matemática devendo esta ser contínua e diferenciável no espaço de busca (BASTOS, 2004). Dessa forma, conforme Bastos (2004) e Junior (2012), este tipo de problema pode ser representado da seguinte forma:

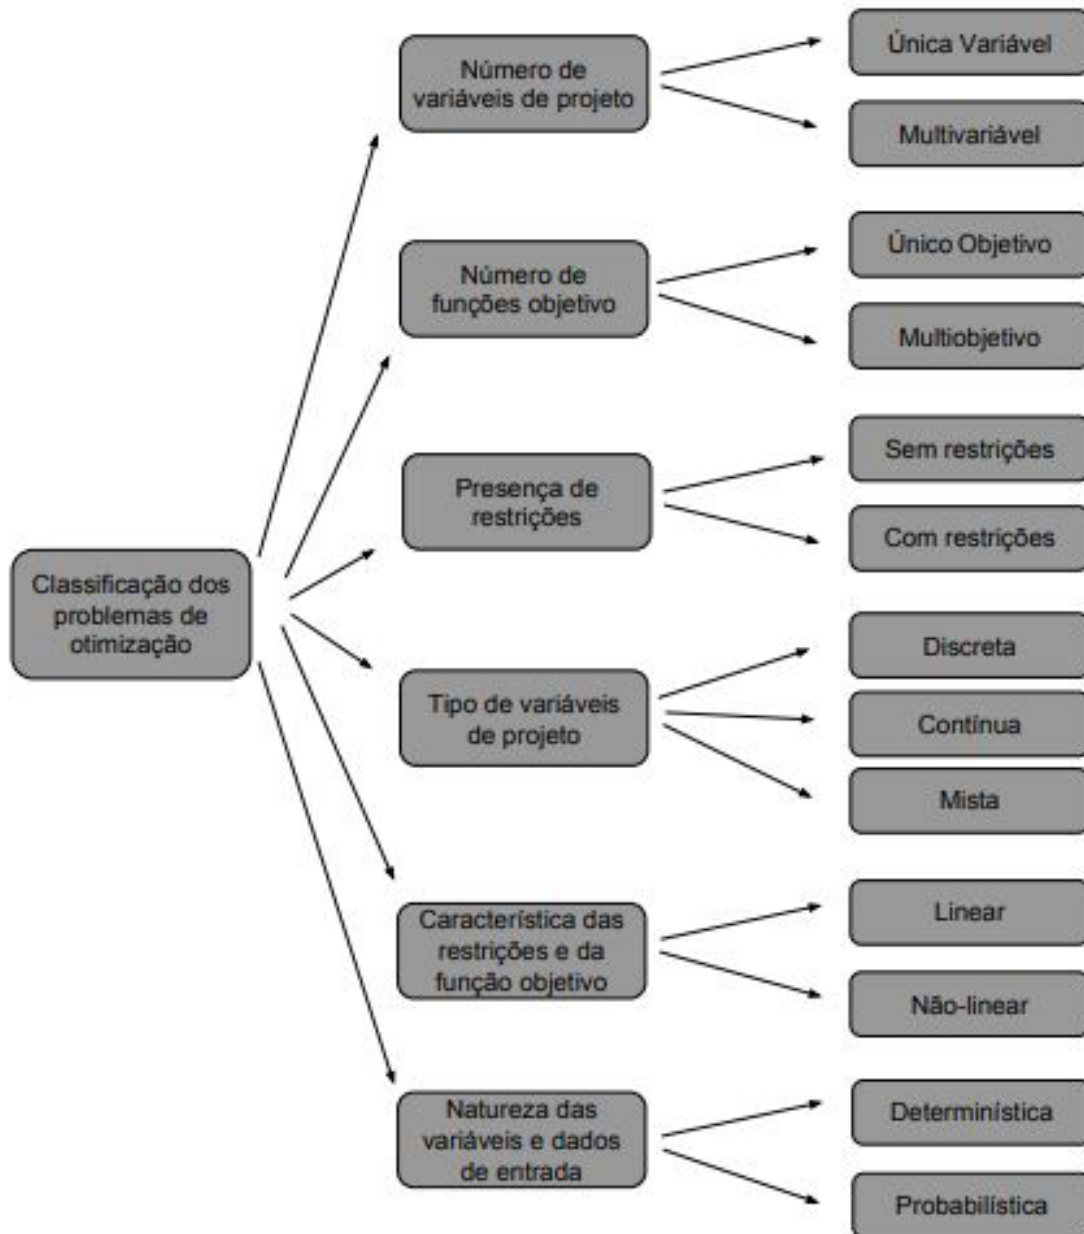
Maximizar ou minimizar:

$$f(x_1, x_2, x_3, \dots, x_n), \quad (2.20)$$

Satisfazendo

$$\begin{aligned} g_1(x_1, x_2, \dots, x_n) [ <=> ] b_1 \\ & \vdots \\ g_m(x_1, x_2, \dots, x_n) [ <=> ] b_m \end{aligned} \quad (2.21)$$

em que  $(x_1, x_2, \dots, x_n)$  são as variáveis de decisão,  $f(x_1, x_2, x_3, \dots, x_n)$  é a função objetivo e  $g_1, g_2, \dots, g_m$  as restrições.



**Figura 2.3** Classificação dos problemas de otimização.  
Fonte:(CARVALHO, 2014)

Em geral, os métodos determinísticos são baseados nos cálculos das derivadas de primeira ordem ou parciais de segunda ordem. Nestes casos, a procura do ponto ótimo usa as coordenadas do ponto corrente ( $x_k$ ) como ponto de partida para a próxima iteração ( $k + 1$ ) (OLIVIERI, 2004). A resolução de problemas sem restrições consiste em se aplicar, de forma iterativa, a Equação 2.22

$$X_{k+1} = X_k + \lambda_k d_k, \quad (2.22)$$

Um exemplo de aplicação muito comum desta iteração em modelos determinísticos é o método do gradiente. Neste método, o algoritmo tem como objetivo identificar a inclinação da função em um ponto inicial, seguindo então em direção ao objetivo (máximo ou mínimo da função), por meio de incrementos ou decrementos proporcionais ao gradiente da função (LUZIA, 2010).

Para determinar se o candidato  $(x_1, x_2, \dots, x_n)$  é a solução ótima, em geral, analisa-se o gradiente da função objetivo. Um gradiente nulo indica que a função atingiu o seu máximo ou mínimo (LUZIA, 2010).

Segundo Saramago (2009), os métodos determinísticos possuem uma grande vantagem, devido ao reduzido número de avaliações da função objetivo, o que faz com que tenham convergência rápida. Em virtude disto, apresentam baixo custo computacional.

Por conta desta rapidez na convergência e, conseqüentemente, baixo custo computacional, para Brandão (2010) e Secchi (2018), o método determinístico do tipo gradiente é o melhor a ser utilizado na solução de problemas, caso seja possível a sua aplicação. Ainda para Secchi (2018), se for possível empregar um método tipo gradiente para resolver o problema, ele sem dúvida será o algoritmo mais eficiente, já que incorpora muito mais informação sobre o espaço de busca.

Entretanto, algumas situações podem inviabilizar a sua utilização, como por exemplo:

- A função objetivo  $f(x)$  não é contínua;
- A função é multimodal, isto é, tem vários máximos ou mínimos locais;
- Não é possível escrever uma função objetivo  $f(x)$  diferenciável.

Para solução nestas situações, uma possibilidade é a utilização de métodos alternativos. Tratado mais adiante, o método alternativo freqüentemente utilizado é o conhecido como método heurístico de otimização.

Alguns dos problemas mais comuns limitados a obtenção da solução por métodos determinísticos são os de otimização combinatória. Nestes problemas, apesar do conjunto das

possíveis soluções ser finito, testar todas possibilidades é inviável devido a extensão do espaço de busca.

Um exemplo clássico de problema de otimização combinatória é o do caixeiro viajante. Neste problema, imagina-se que um vendedor precise visitar um certo número de cidades e depois retornar para casa. O objetivo do algoritmo é determinar a sequência ótima de cidades a percorrer, de forma que a distância percorrida seja mínima. Considerando isso, o nível de complexidade para determinar a quantidade de rotas possíveis esta diretamente ligado ao valor de  $n$  que representa a quantidade de cidades. Dado que o número de rotas é estabelecido de maneira fatorial com  $(n - 1)!/2$ , a quantidade cresce exponencialmente a partir dos valores de  $n$ . Segundo Ertel (2023), apesar da descrição simples, o problema do caixeiro viajante pertence a classe de problemas NP-difícil, isto é, não possui solução em tempo polinomial.

Para Secchi (2018), a grande dificuldade dos problemas combinatoriais, como o do caixeiro viajante, é que como a quantidade de possíveis soluções cresce com velocidade fatorial, o processamento computacional torna-se incapaz de enumerar todas as possíveis soluções do problema.

Assim, para estas situações, se faz necessário a utilização de métodos alternativos para solução dos problemas. O mais comum destes métodos são advindos da otimização probabilística ou estocástica.

A otimização estocástica é a classe geral de algoritmos e técnicas que empregam algum grau de aleatoriedade para encontrar soluções ótimas (ou a mais ótima possível) para problemas difíceis. As metaheurísticas são as mais gerais desses tipos de algoritmos, e são aplicadas a uma ampla gama de problemas (LONES, 2011). Contudo, deve ser observado, conforme Secchi (2018), que estes métodos devem ser empregados quando tudo o mais não funciona. Isto ocorre, devido ao fato destes métodos, em geral, exigirem grande esforço computacional e tempo de processamento superiores para resolver o mesmo problema que um método que empregue derivadas.

Segundo Lones (2011), as metaheurísticas são algoritmos usados para encontrar respostas para problemas quando se possui poucas informações, por exemplo: quando não se sabe que solução parece ótima, quando não se sabe como encontrá-la de uma maneira baseada em princípios, têm-se pouca informação heurística para continuar e a busca por força bruta está fora de questão porque o espaço é muito grande. Mas, caso se tenha uma solução candidata para o problema, esta poderá ser testada e avaliada no que tange a sua qualidade.

Ainda para o autor, uma forma de pensar a metaheurística é com o algoritmo de otimização conhecido como *Hill-Climbing*, que pode se traduzir nos seguintes passos:

1. Começar com um conjunto de comportamento aleatório.

2. Em seguida, faça uma pequena modificação aleatória e experimente a nova versão.
3. Se a nova versão é melhor, descarte a antiga. Caso contrário, descarte a nova versão.
4. Agora faça outra modificação pequena e aleatória na versão atual. Se esta versão mais recente for melhor, descarte a versão atual, caso contrário, descarte a versão mais recente.
5. Repita o quanto possível.

Um exemplo de problema de otimização combinatória, objeto desta pesquisa, é o de alocação de ERBs. Segundo Hao (2001), este problema pode ser informalmente descrito como: Dado um lista de locais candidatos para posicionamento das ERBs e uma distribuição geográfica discretizada (área de trabalho caracterizada por um conjunto de pontos com informações relacionadas à estimativa de potência recebida, o objetivo é selecionar algumas ERBs entre as posições disponíveis.

Todas essas decisões devem satisfazer um conjunto de variáveis (níveis de potência recebida, distância mínima entre as ERBs, altura das antenas) e otimizar um conjunto de objetivos (número de ERBs utilizadas, níveis de cobertura, nível de interferência entre ERBs). Neste caso, é possível verificar que se trata de um problema com inúmeras possibilidades de combinação (OLIVEIRA; MACULAN, 2015).

O problema de posicionamento de ERBs ocorre com bastante frequência nos mais diversos segmentos de telecomunicações como operadoras de telefonia celular, transmissoras de rádio e televisão e redes de radiocomunicação privadas. A melhor definição no posicionamento das estações em um projeto resultam em impactos significativos nos resultados de cobertura e nos valores investidos. E este é um grande problema, pois nem sempre a melhor solução do ponto de vista técnico atende os requisitos econômicos, ou vice-versa. A solução ótima seria aquela que permitisse equilibrar os requisitos técnicos (maior nível de cobertura, por exemplo) com as restrições econômicas.

Diante do exposto e tomando como base as definições da Figura 2.3, o problema de alocação de ERBs para esta pesquisa é modelado como multivariável, multiobjeto, com restrições, de variável discreta e probabilística. Sendo um típico problema para aplicação de métodos heurísticos.

Assim, como os métodos heurísticos constituem uma busca contínua e empírica, com vários ótimos locais, cujo resultado é o melhor que se pode encontrar sob determinadas condições, uma possível estratégia para solução do problema de alocação de ERBs e a utilização dos métodos baseados na natureza.

A natureza é um exemplo de otimização ideal, porque cada uma das características ou fenômenos da natureza sempre encontra a estratégia ideal para resolver problemas, a partir



da interação complexa entre organismos vivos, que variam de microrganismos a seres humanos, para equilibrar o ecossistema, manter a diversidade e a estimular a adaptação (ISABELA, 2012).

Este modelo, conhecido como computação natural será melhor detalhado na próxima seção.

## 2.3 COMPUTAÇÃO NATURAL

Atualmente é muito evidente o impacto da ciência da computação no cotidiano das relações e atividades humanas. As atividades agrícolas, pecuária e de meteorologia, por exemplo, são setores das Ciências Naturais que se desenvolveram rapidamente em função das novas tecnologias agregadas a estes setores.

Entretanto, não só as Ciências Naturais têm se aproveitado dos estudos computacionais para acelerar o seu processo de desenvolvimento, a Ciência da Computação também tem se utilizado da natureza para desenvolver novos métodos e algoritmos. Com base nesta ideia, um novo ramo da Ciência da Computação, conhecida como Computação Natural, vem sendo alvo de pesquisas com um vasto campo de aplicação.

Segundo Maclennan (2004), a Computação Natural é a computação inspirada na natureza. Já para Castro (2007), a computação natural é o elo entre as Ciências Naturais e a Ciência da Computação. Refere-se a todo e qualquer sistema computacional desenvolvido com inspiração ou utilização de algum mecanismo natural ou biológico no processamento da informação.

Observar o comportamento de animais, como formigas, abelhas, aves e peixes, por exemplo, tem sido utilizado no desenvolvimento de diversos tipos de algoritmo para um grande número de aplicações. Além disso, há modelos de algoritmos desenvolvidos baseados nas leis da evolução natural de Charles Darwin ou no sistema imunológico dos animais. O objetivo é obter soluções para problemas que não poderiam ser resolvidos satisfatoriamente por métodos tradicionais (CASTRO; JOSÉ; ZUBEN, 2000).

Entre estes métodos, destaca-se a Computação Bioinspirada, objeto de estudo deste trabalho, que inclui todas as estratégias desenvolvidas a partir de algum mecanismo natural. Exemplos de computação bioinspirada, estão os algoritmos evolucionários (Algoritmos Genéticos), sistemas imunológicos artificiais (Sistemas Imunológicos Artificiais) e inteligência de enxame (Otimização por Enxame de Partículas).

### 2.3.1 Inteligência de Enxame

Apesar de serem considerados seres irracionais, alguns animais apresentam significativos níveis de inteligência quando observado o seu comportamento coletivo. Exemplo muito conhecido é

verificado entre as abelhas e formigas. Entretanto, peixes, aves e uma série de outros animais apresentam uma inteligência coletiva, principalmente na busca por alimentos.

Segundo Serapiao (2009), as técnicas baseadas no comportamento coletivo de sistemas com níveis de organização como os citados, são conhecidas como inteligência de enxames. Esta inteligência aparenta ter como base a ocorrência de alguma comunicação entre os indivíduos, que além da sua própria experiência, estão submetidos também a influência no comportamento dos demais indivíduos do grupo.

Apesar de não existir qualquer nível de controle central que oriente a cada indivíduo como deva se comportar, as interações locais entre os indivíduos do grupo geralmente levam ao surgimento de um comportamento coletivo tendo como principal objetivo a resolução de algum problema (SERAPIAO, 2009).

Cinco princípios básicos para sistemas de inteligência de enxame são sugeridos por Millonas (1993) :

- Proximidade - os agentes devem ser capazes de interagir;
- Qualidade - os agentes devem ser capazes de avaliar seus comportamentos;
- Diversidade - permite ao sistema reagir a situações inesperadas;
- Estabilidade - nem todas as variações ambientais devem afetar o comportamento de um agente;
- Adaptabilidade - capacidade de adequação as variações ambientais.

Algumas das técnicas mais conhecidas de Inteligência de Enxames são a otimização por colônia de formigas, otimização por enxame de partículas, algoritmos de coleta de alimentos por bactérias e algoritmos de colônia de abelhas.

Como alvo dos estudos deste trabalho, o algoritmo baseado em enxame de partículas é mais detalhado na próxima seção.

### **2.3.2 Enxame de Partículas**

De forma geral, a Otimização por Enxame de Partículas (PSO) é baseado na ideia de que a adaptação dos indivíduos decorre da sua experiência individual, mas principalmente na comparação da sua experiência com as dos demais indivíduos do grupo.


Segundo Castro (2007), o modelo fundamenta-se no processo que compreende um componente de menor nível correspondente ao real comportamento dos indivíduos, e um componente

de maior nível na formação de padrões entre indivíduos. Portanto, cada indivíduo dentro de uma população tem sua própria experiência, identificando suas qualidades, e como seres sociais, eles também têm algum conhecimento sobre o desempenho de outros indivíduos vizinhos.

Essas duas características de informação são definidas por Serapiao (2009) como uma aprendizagem individual e outra social. Portanto, a probabilidade de que um determinado indivíduo tome uma certa decisão terá como base seu desempenho no passado e do desempenho de alguns de seus vizinhos.

Neste caso, para solução de algum problema (localização de alimento, por exemplo), o indivíduo realiza uma avaliação de si e compara os seus resultados com os obtidos, individualmente, pelos integrantes mais próximos dentro do grupo. Caso ele identifique dentre os vizinhos algum com resultado superior ao seu ele passa a adotar aquele comportamento. Logo, a tendência é que todo grupo passe a adotar o comportamento do indivíduo que tenha obtido o melhor resultado.

Um exemplo clássico para ilustrar tal comportamento é o apresentado por Goedert, Filho e Blanco (2017), onde destaca o comportamento das formigas, que deixam trilhas de uma substância denominada feromônio para que as próximas possam encontrar o alimento mais rapidamente. Em seguida, cada formiga percorre e reforça a trilha liberando mais feromônio. Na Figura 2.4 é ilustrado este comportamento.



**Figura 2.4** Exemplificação da capacidade das formigas em encontrar o menor caminho: (a) ponte inicialmente fechada; (b) distribuição inicial das formigas; (c) distribuição ao longo do tempo.

Fonte: (GOEDERT; FILHO; BLANCO, 2017)

Além da busca por alimentos, a fuga de predadores e a busca por parceiros são outros fatores motivadores ao desenvolvimento da inteligência coletiva. Para Bell e Oommen (2015), o conhecimento cognitivo desenvolvido pelo indivíduo devido às suas experiências passadas e o social devido à comunicação realizada dentro do grupo, é o que possibilita o desenvolvimento desta inteligência coletiva.

Para Castro (2007), portanto, os indivíduos são capazes de avaliar, comparar e imitar uma série de situações possíveis que o ambiente lhes oferece. Estes indivíduos são vistos como pontos em um espaço de busca e sua mudança ao longo do tempo é representada através de movimentos. Neste caso, cada indivíduo, também chamado de partícula, é uma possível solução do problema. O enxame de partículas corresponde aos múltiplos indivíduos da população.

A modelagem matemática para o PSO tem como objetivo, para um problema de otimização, encontrar uma partícula (ou indivíduo) representado por um vetor

$$X = [x_1, x_2, x_3, x_4, \dots, x_n] \quad (2.23)$$

que minimiza ou maximiza uma determinada função objetivo  $F(X)$ . O vetor  $X$ , conhecido como vetor de posição, representa um modelo que possui  $n$  dimensões, no qual  $n$  representa o número de variáveis que podem ser determinadas em um problema. Por exemplo, a latitude e a longitude de uma ERB,  $n=2$ . A partir da função  $F(X)$  é avaliada a qualidade da posição  $X$ , isto é, a qualidade da solução associada a um determinado indivíduo do grupo. (ALMEIDA; LEITE, 2019).

Considerando um enxame com  $P$  partículas, existe um vetor de posição

$$X_i^t = (x_{i1}, x_{i2}, x_{i3}, x_{i4} \dots x_{in})^t, \quad (2.24)$$

e um vetor de velocidade

$$V_i^t = (v_{i1}, v_{i2}, v_{i3}, v_{i4} \dots v_{in})^t \quad (2.25)$$

em uma iteração  $t$  para cada uma das partículas  $i = 1, 2, \dots, P$ . Esses vetores são atualizados através da quantidade  $j$  de dimensões da posição da partículas de acordo com as Equações 2.26 e 2.27

$$V_{ij}^{t+1} = wV_{ij}^t + \underbrace{c_1 r_1^t (pbest_{ij} - X_{ij}^t)}_{\text{intelig. individual}} + \underbrace{c_2 r_2^t (gbest_j - X_{ij}^t)}_{\text{intelig. coletiva}}, \quad (2.26)$$

$$X_{ij}^{t+1} = X_{ij}^t + V_{ij}^{t+1}, \quad (2.27)$$

no qual  $i = 1, 2, \dots, P$  e  $j = 1, 2, \dots, n$  (ALMEIDA; LEITE, 2019).

O parâmetro  $w$  é a constante de peso de inércia. Ele é importante para equilibrar a busca. Para valores mais altos, o algoritmo faz uma busca global no espaço de soluções. Valores menores, busca local, ou seja, exploração das áreas mais promissoras (BERNARDES, 2013).

O produto de  $w$  com a velocidade anterior da partícula define a relação pela qual a veloci-

dade anterior da partícula é atualizada para a nova velocidade. Desta forma, se  $w = 1$ , a nova velocidade da partícula sofre grande influência da velocidade anterior, realizando uma maior exploração do espaço de busca. Adotando-se valores de  $0 < w < 1$ , a influência da velocidade anterior é reduzida e, com menor velocidade, a partícula tende a realizar uma exploração mais local.

Conforme os resultados das pesquisas de Venkateshaiah e Arumugam (2010), Shigang, Zhou e Wang (2013) e Cekus e Skrobek (2018) uma definição conveniente é variar os valores de  $w$  reduzindo-o a medida que o número de iterações cresce, permitindo que o algoritmo migre de uma exploração global para uma busca mais local. Neste caso, a relação é dada pela Equação 2.28

$$W = W_{max} - \left( \frac{W_{max} - W_{min}}{iter_{max}} \right) iter, \quad (2.28)$$

O termo representando inteligência individual, segundo termo da Equação 2.26, é calculado por meio da diferença entre a melhor posição da própria partícula  $pbest_{ij}$ , e sua posição atual  $X_{ij}^t$ . Pode-se notar que a ideia por trás deste termo é que conforme a partícula fica mais distante da posição  $pbest_{ij}$ , a diferença  $(pbest_{ij} - X_{ij}^t)$  deve aumentar; portanto, esse termo aumenta, atraindo a partícula para sua melhor posição. O parâmetro de cognição individual  $c_1$  é uma constante positiva que pesa a importância das próprias experiências anteriores da partícula. O outro parâmetro que compõe o produto do segundo termo é  $r_1$ , e este é um parâmetro de valor aleatório com intervalo entre 0 e 1. Este parâmetro aleatório evita convergências a um ótimo local (ALMEIDA; LEITE, 2019).

Finalmente, o terceiro termo é o de aprendizagem social (inteligência coletiva). Por causa disso, todas as partículas no enxame são capazes de compartilhar a informação do melhor ponto alcançado  $gbest_j$  independentemente de qual partícula o encontrou. Assim, a diferença  $(gbest_j - X_{ij}^t)$  atua como uma atração para as partículas para o melhor ponto encontrado em alguma iteração. Da mesma forma,  $c_2$  é um parâmetro de aprendizagem social que pondera a importância do aprendizado global do enxame (ALMEIDA; LEITE, 2019). O parâmetro  $r_2$  possui as mesmas características de  $r_1$ .


De acordo com Castro (2007), inicialmente, adota-se a soma das duas constantes de aceleração através da relação  $c_1 + c_2 > 4$ , geralmente sendo adotadas ambas iguais a 2,05.

Uma vez que a velocidade da  $i$ -ésima partícula é calculada, a sua posição  $X_{ij}^{t+1}$  na próxima iteração  $t + 1$  é estabelecida como uma influência da posição antiga  $X_{ij}^t$  e da velocidade  $V_{ij}^{t+1}$ , conforme Equação 2.27 (SERAPIAO, 2009). Desta forma, uma partícula  $P$  irá se mover em uma determinada direção que é função da sua posição atual  $X_{ij}^t$ , velocidade  $V_{ij}$ , da posição que levou ao seu melhor desempenho até o momento ( $pbest_{ij}$ ), e do melhor desempenho global do

sistema até o momento ( $gbest_j$ ) (SERAPIAO, 2009).

Com o intuito de limitar a mudança na posição de uma partícula de modo a não extrapolar o espaço de busca, dois valores  $v_{min}$  e  $v_{max}$  são definidos, garantindo assim que as partículas oscilem dentro de alguns limites predefinidos (CASTRO, 2007).

A Figura 2.5, exemplifica a atualização na posição de uma partícula em uma iteração, com relação a um problema em duas dimensões ( $x_1$  e  $x_2$ ).



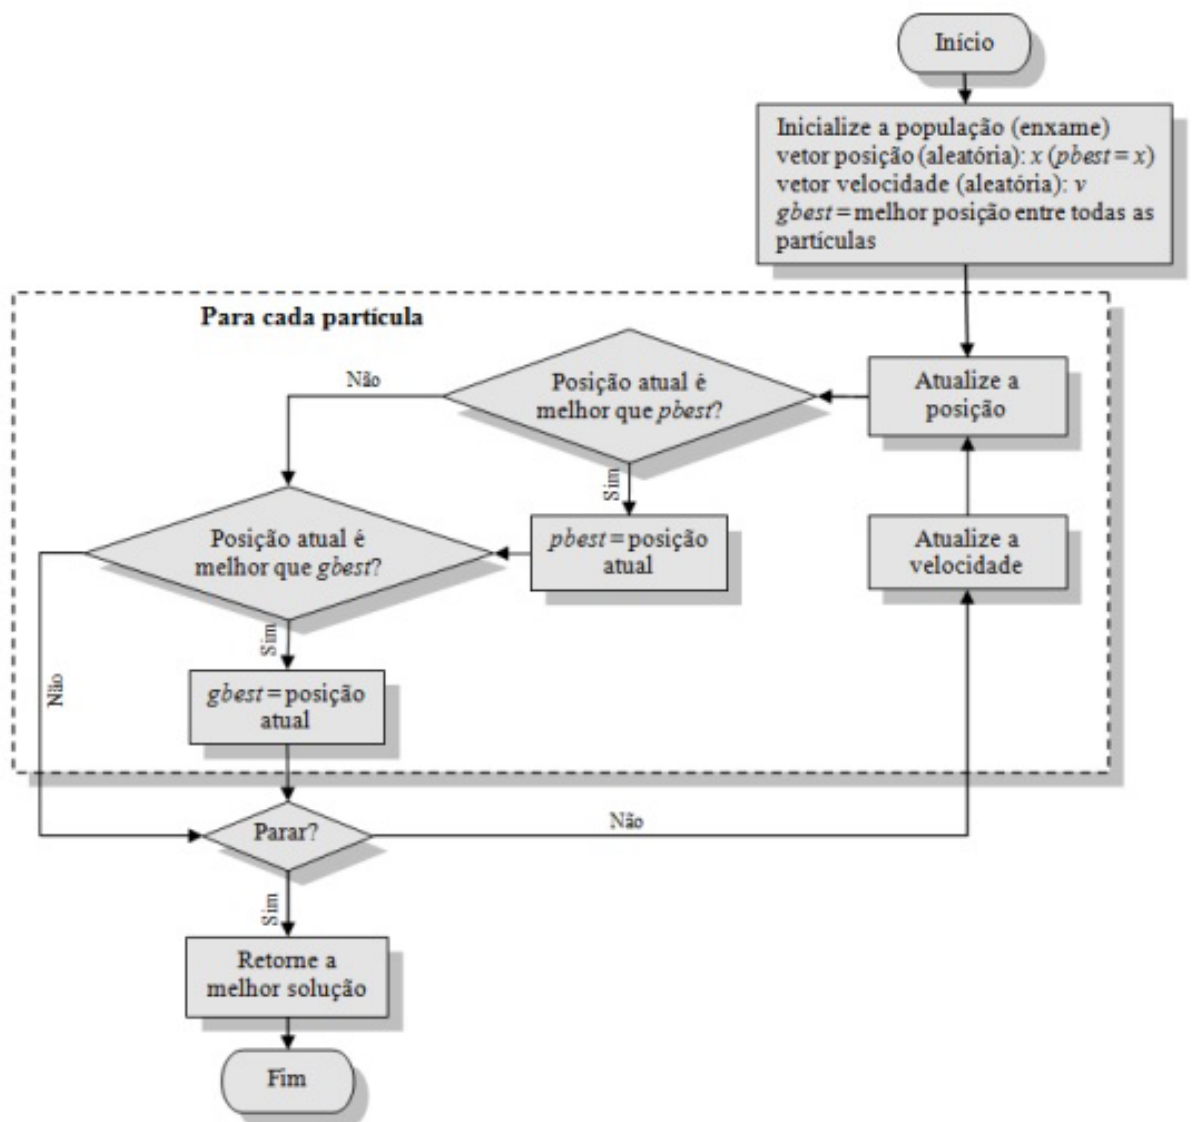
**Figura 2.5** O vetor de posição sendo atualizado em uma iteração  
Fonte: (CORTES, 2017)

Desta forma, o algoritmo do PSO pode ser definido através dos seguintes passos:

1. O algoritmo inicia cada partícula com valores aleatórios de posição e velocidade. A posição é limitada pelo tamanho do espaço de busca do problema e a velocidade, limitada pelo valor do coeficiente de velocidade máxima.
2. Depois de inicializado, o algoritmo entra em um *loop* até o limite de parada estabelecido. Dentro do *loop* cada partícula avaliará a sua posição atual (ou solução atual) em relação a melhor posição encontrada por ela mesmo, isto permite que o *pbest* seja atualizado. Cada partícula também avaliará a qualidade da melhor posição encontrada em sua vizinhança, permitindo a atualização do valor do *gbest*. A avaliação da melhor posição é avaliada através da função objetivo  $F(X)$ , também chamada de *fitness*.

3. Após atualizar o valor da velocidade com os novos valores de *pbest* e *gbest*, cada partícula irá se deslocar para uma nova posição.
4. O algoritmo PSO é repetido até que um critério de parada é atingido ou as mudanças nas velocidades das partículas estejam perto de zero

O fluxograma da Figura 2.6 apresenta, resumidamente, os passos do PSO.



**Figura 2.6** Fluxograma do PSO  
 Fonte: (NASCIMENTO et al., 2013)





## **PROPOSTA: DESCRIÇÃO E MÉTODO**

Posicionar ERB's em sistemas de radiocomunicação depende, de maneira geral, da densidade do tráfego, das condições do canal de comunicação, possíveis interferências, quantitativo de estações, além de outros parâmetros de planejamento da rede. Isso torna o problema de posicionamento das estações bastante complexo, pois envolve uma grande quantidade de variáveis.

Para resolver esse problema, a proposta deste trabalho é definir uma quantidade  $K$  de ERB's para serem posicionadas em uma região de estudo (espaço de busca) visando a maximização da cobertura com o menor quantitativo de estações (redução de custos) a partir do uso do PSO. Para isso, é necessário definir um modelo de propagação de sinal capaz de prever a potência recebida em cada ponto da região de estudo. Nesse caso, diferente das pesquisas apresentadas em Talau (2010), Monshi e Islam (2012), Pereira (2014) e Filho (2019), esse modelo de propagação foi obtido a partir de medições realizadas em campo, ou seja, em um ambiente real.

Tendo em vista essa ideia, as principais etapas desta pesquisa são listadas abaixo:

1. Definição do modelo de propagação do sinal;
2. Elaboração de um algoritmo que a partir das coordenadas definidas pelo usuário delimita uma região de estudo;
3. Implementação do algoritmo de otimização PSO.

Com relação a implementação computacional da proposta, por possuir grande parte das bibliotecas necessárias para o desenvolvimento da solução, a linguagem de programação utilizada para construção do modelo foi a *Python*. O *Google Colab* foi a ferramenta utilizada como

plataforma de programação por ser gratuita e útil para desenvolvimento de *softwares* de código aberto. Na Figura 3.1 é apresentado um resumo dos passos implementados no algoritmo, cujo detalhamento é apresentado nas próximas seções.

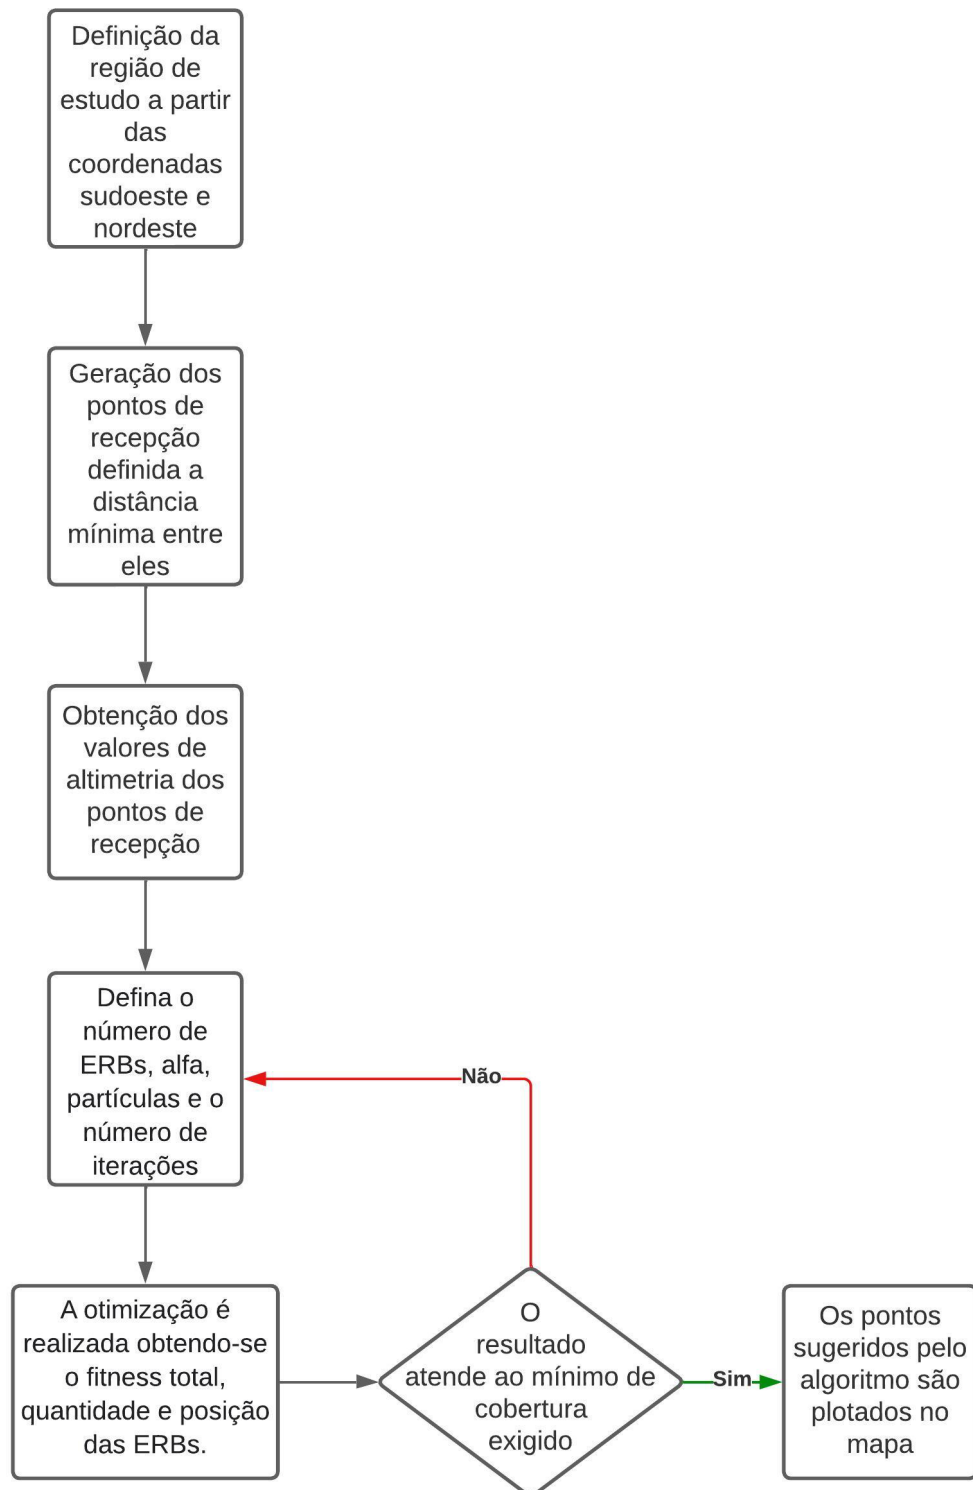
### 3.1 DEFINIÇÃO DO MODELO DE PROPAGAÇÃO

Inicialmente, foi realizado um estudo sobre o modelo de predição de cobertura radioelétrica mais adequado para a região, utilizando-se de dados reais medidos em campo. Como esses dados foram obtidos através da rede de radiocomunicação digital da Secretária da Segurança do Estado da Bahia (SSP/BA), os parâmetros para aplicação dos modelos de predição serão os de operação desta rede, cujas características são listadas abaixo:

1. Altura da antena na torre de 60 metros e altura do receptor será a do terminal portátil, isto é, 1,7 metros considerando uma aproximação média para altura de um usuário. Foi adicionado à altura da estação móvel, dados de altimetria obtidos através da Interface de Programação de Aplicativos (API) do *JawgMaps*;
2. Frequência de 380 MHz escolhida por estar em operação sendo a faixa licenciada pela Agência Nacional de Telecomunicações (ANATEL) para utilização nos sistemas de radiocomunicação da Segurança Pública;
3. A potência do transmissor considerada foi de 10 W (40 dBm), ganho da antena do transmissor de 7,15 dBi e antena do receptor sem ganho. Foi usado cabo *Cellflex 7/8* que geralmente possui perdas de 2,32 dB para cada 100 metros.

Foi realizada uma comparação entre os resultados medidos em campo com aqueles obtidos pelos modelos de propagação (resultado teórico). Para realização desta comparação, foi escolhida uma ERB da rede da SSP/BA onde foram realizados os estudos de campo sendo utilizados como referência 20 pontos de medição escolhidos aleatoriamente. Para estes pontos, através do algoritmo, foram obtidos os dados de distância para a ERB, os valores de altimetria em metros, as atenuações (L) em dB e os valores de potência recebidos  $P_R$  em dBm, sendo dado pelo somatório da potência do transmissor e ganho das antenas e subtração das perdas dos cabos e atenuação calculada através dos modelos de propagação.


A avaliação do melhor modelo, baseou-se nos valores de erro médio e do desvio padrão de cada um deles com os resultados da medição em campo. Os modelos avaliados foram os de Okumura-Hata, Lee e Longley-Rice, que são normalmente utilizados para estudos na faixa de frequência em questão.



**Figura 3.1** Fluxograma do algoritmo implementado.

### 3.2 REGIÃO DE ESTUDO

A região de estudo é definida pelo algoritmo a partir do lançamento das coordenadas Sudoeste e Nordeste das extremidades usando a ferramenta *Google Earth*. Para aplicação do PSO foi definida uma região no município de Itaparica através das coordenadas sudoeste (-13,15; -39,30) e nordeste (-12,85; -38,80) obtendo-se uma área aproximada de  $1809 \text{ km}^2$ , com dimensões de 33,5 x 54,0 Km. A região de estudo delimitada pode ser observada na Figura 3.2.



**Figura 3.2** Região de estudo

Em seguida, a região é dividida em pontos de recepção, dentro de um intervalo estabelecido (distância entre os pontos). Para obtenção dos pontos de recepção, é utilizada a função *Geodesic* da biblioteca *geographiclib.geodesic* no *Python*.

A função *Geodesic* utiliza as formas direta e inversa da equação de *Vincenty*. A forma direta permite obter os dados de uma coordenada a partir de uma coordenada central e um azimuth. Já a forma inversa permite calcular a distância entre duas coordenadas. A função inversa de *Vincenty* é aplicada de forma iterativa e apresentam precisão de alguns centímetros para linhas de até 20.000 km de extensão, considerando a terra como uma elipsoide (VINCENTY, 1975).

Através da função inversa de *Vincenty*, foram obtidos a partir do algoritmo 9548 pontos de recepção distanciados 450 metros entre si. A limitação da distância decorre, como dito, da restrição do quantitativo de requisições de altimetria em 10.000 de forma gratuita. Na Figura 3.3 é apresentada a disposição dos pontos de recepção dentro da região de estudo.



**Figura 3.3** Região de estudo com pontos de recepção

Para realização dos cálculos de atenuação, após definição dos pontos de recepção, é necessário obter os dados de altimetria da coordenada de cada ponto usando a função *elevation*. Esta função utiliza a API do *JawgMaps* para obter os dados de altimetria de um ponto de coordenada.

Em seguida os dados obtidos são armazenados em um *Data Frame* contendo as informações de latitude, longitude e de altimetria dos pontos de recepção. Este arquivo possibilita que não seja necessário realizar novas requisições de altimetria a cada otimização.

### 3.3 ALGORITMO PSO

Uma vez que foram definidos o modelo de propagação e a região de estudo, é aplicado o algoritmo do PSO para otimizar o posicionamento e a quantidade de ERB's a serem usadas. Assim, é possível apresentar ao projetista em qual par ou pares de coordenadas (latitude e longitude) de instalação das ERB's serão obtidos os melhores resultados de potência recebida, com a menor quantidade de ERB's possíveis.

Para isso, inicialmente, foi definida a partícula (possível solução) como uma tupla formada pelo valor de latitude e longitude da coordenada e um índice binário (0 ou 1) que sinaliza se a ERB é ou não utilizada na solução.



$$\{Lat_1, Long_1, binario_1, Lat_2, Long_2, binario_2, \dots, Lat_K, Long_K, binario_K\},$$

Em seguida, o algoritmo posiciona aleatoriamente as partículas e a partir do cálculo da função *fitness* reposiciona vetorialmente as partículas na busca de uma solução ótima. Dessa forma, o algoritmo irá identificar o par ou pares de coordenadas, dentro dos limites estabelecidos, que promoverá os melhores resultados baseados na função *fitness*.

Esta função é composta por um termo que quantifica a cobertura ( $f_1$ ) e um segundo termo para os custos,  $f_2$ . Considerando o primeiro termo, a avaliação de cobertura consiste em verificar a partícula que possui maior quantidade de pontos bons, ou seja, aqueles que possuem valores de potência recebida  $P_R$  superiores a -70 dBm.

A base para estabelecimento deste parâmetro (-70 dBm) é o fato do Instituto Europeu de Padrões de Telecomunicações (ETSI) estabelecer no módulo ETSI EN 300 392-2 V2.3.2 para padronização do protocolo de Rádio Troncalizado Terrestre (TETRA), por exemplo, uma sensibilidade dinâmica mínima de -103 dBm. Entretanto, as medições realizadas na prática demonstram que limites inferiores a -90 dBm já apresentam dificuldades de se efetivar a comunicação, desta forma uma margem aproximada de 30% foi aplicada para garantir a máxima probabilidade de comunicação no ponto em questão, arredondando o valor para -70 dBm.

Assim, dentro dos pontos analisados será atribuído o valor 1 aos pontos de recepção com valores maiores que -70 dBm e 0 para os demais pontos, conforme

$$\delta_i = \begin{cases} 1 & \text{para } P_R \geq -70 \text{ dBm} \\ 0 & \text{para } P_R < -70 \text{ dBm}, \end{cases}$$

Assim, a função objetivo  $f_1$  é obtida a partir da Equação 3.1

$$f_1 = \frac{\sum_i^N \delta_i}{N}, \quad (3.1)$$

no qual  $N$  é o número total de pontos analisados.

Estando o resultado desta função limitado a valores entre 0 e 1, o resultado da otimização consiste em tentar obter a partícula (lat, lon) que possua como resultado de  $f_1$ , valores mais próximos de 1.

A condição econômica é avaliada a partir da função objetivo  $f_2$  que considera o quantitativo de ERB's a ser instalada para atender a cobertura da região. O termo avaliará, dentro de um quantitativo máximo de ERB's, a quantidade mínima para atender a cobertura total dos pontos definidos para a região de estudo.

O termo de economia é dado por

$$f_2 = \frac{K - M}{K}, \quad (3.2)$$

no qual  $K$  é o quantitativo máximo de ERB's definido e  $M$ , o número de ERB's utilizado no projeto. A ideia é maximizar a função de forma que seja utilizada a menor quantidade de ERB's possível.

Desta forma, a função *fitness* total passa a ser dada pela Equação 3.3

$$fitness = \underbrace{\alpha_1 \left( \frac{\sum_i^N \delta_i}{N} \right)}_{cobertura f_1} + \underbrace{\alpha_2 \left( \frac{K - M}{K} \right)}_{custos f_2}, \quad (3.3)$$

em que  $\alpha_1$  e  $\alpha_2$  são os pesos atribuídos a avaliação de cobertura e econômica, respectivamente.

Ao final é definido um peso entre 0 e 1 a ser aplicado em cada função, conforme o entendimento do projetista para o caso específico.

Para implementar o algoritmo PSO, é necessário definir os parâmetros  $w$ ,  $c_1$  e  $c_2$ , apresentados na Equação 2.26. Considerando os resultados obtidos por Shigang, Zhou e Wang (2013) e Wang, Tan e Liu (2018), foi adotado um coeficiente de inércia  $w$  variando linearmente entre 0,9 e 1,2, conforme definido na Equação 2.28, e  $c_1 = c_2 = 1,05$ . Os parâmetros  $r_1$  e  $r_2$  foram obtidos aleatoriamente no intervalo  $[0,1]$ .

Além dos valores de  $w$ ,  $c_1$ ,  $c_2$ ,  $r_1$  e  $r_2$ , para realização da otimização é necessário definir a quantidade de partículas, quantidade  $K$  de ERB's (tomando como base as dimensões da região de estudo), número máximo de iterações e, por fim, o valor dos coeficientes  $\alpha_1$  e  $\alpha_2$ . O valor destes parâmetros é tratado com mais detalhe no próximo capítulo.

No Capítulo 04, para fins de validação do algoritmo e escolha do modelo de propagação mais adequado, os dados de potência recebida são comparados aos resultados obtidos pelas medições em campo. E por fim, são apresentados os resultados obtidos com o uso do PSO no posicionamento das ERB's, a partir do uso da ferramenta *Google Earth*, ilustrando no mapa as coordenadas para o melhor resultado da função *fitness*.





## RESULTADOS

Neste Capítulo são apresentados os resultados obtidos que nortearam a escolha do modelo matemático de propagação a ser utilizado no cálculo da função *fitness* e os resultados de otimização obtidos com o PSO.

### 4.1 COMPARATIVO COM MEDIDAS DE CAMPO

Com intuito de definir qual modelo de propagação é o mais adequado para utilização no algoritmo, foram realizados estudos comparativos entre os resultados dos modelos obtidos no algoritmo com as medições realizadas em campo. Para esta análise, foram implementados, em linguagem *Python*, algoritmos para os modelos de Okumura-Hata, Lee e Longley-Rice.


As medições em campo foram realizadas com suporte técnico da fabricante *Teltronic* através da utilização de uma solução proprietária específica para realização de estudos de cobertura. O procedimento consiste num terminal veicular conectado a um computador que possui um *software* embarcado. O programa realiza *frames* de medições a cada segundo apresentando os resultados através dos pontos no mapa. Na Figura 4.1 observa-se a interface do *software* para o usuário no momento das medições.

Os estudos foram realizados no município de Itaparica, estado da Bahia, num trecho da rodovia identificada como BA-532. Como dito, os resultados são apresentados como pontos no mapa através de níveis de recepção identificados através de cores. Um recorte da apresentação dos resultados é apresentado na Figura 4.2.

Em cada *frame*, Figura 4.1, é possível ver os dados de data, horário, localização (coordenadas), identificação da ERB em que o terminal se encontra registrado na rede, canal de



**Figura 4.1** Interface para medições em campo

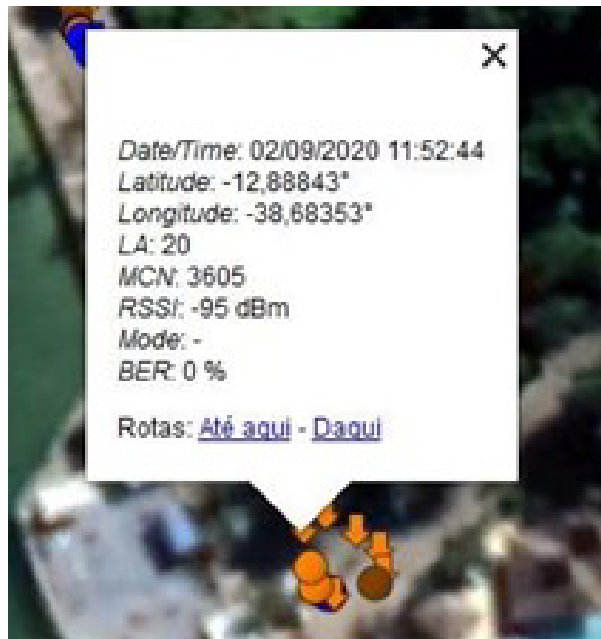


**Figura 4.2** Resultado das medições no município de Itaparica.

comunicação, potência do sinal recebido, modo de operação e a Taxa de Erro de Bit (BER). Um exemplo das informações apresentadas em um *frame* é ilustrado na Figura 4.3.

Na ilustração da Figura 4.3 é possível extrair as seguintes informações:

- 02/09/2020 – 11:52:44 – data e horário de realização da medição;
- Coordenadas do ponto de medição: -12,88843, -38,68353;



**Figura 4.3** Exemplo de *frame*

- O terminal está registrado na ERB identificada na rede como LA: 20 (ERB Ponta de Areia);
- MCN: 3605 - representa o canal de operação na rede, neste caso a frequência de 390,125 MHz
- RSSI: -95 dBm – representa o nível de potência do sinal recebido no ponto;
- O modo de operação não apresentado
- BER:0% - representa o resultado para taxa de erro de bits;

Com o intuito de realizar um comparativo dos dados medidos com os resultados do algoritmo, foram escolhidos 20 (vinte) pontos aleatórios dentre aqueles apresentados na Figura 4.2. Desta forma, através da função *elevation*, foram obtidos os dados de elevação de cada ponto escolhido. Na Figura 4.4 é possível observar a obtenção dos valores de altitude para coordenada do exemplo.

```
In [5]: elevation (-12.901078, -38.661988)
Out[5]: 41.92593765258789
```

**Figura 4.4** Obtenção do ponto de elevação - Altimetria.

A ERB-LA20 (Ponta de Areia) está a 41,926 metros de altitude em relação ao nível do mar, possui instalada uma ERB do tipo MBS (Estação Base Móvel – sigla em Inglês) com 10W de potência e opera na frequência de 390,125 MHz. As antenas, com ganho de 7,15 dBi, estão posicionadas a 55 metros numa torre que possui altura de 60 metros. Na Figura 4.5 é apresentada a localização e visualização da torre.



**Figura 4.5** Local e visualização da torre.

A seguir foram realizados os cálculos da distância entre os vinte pontos aleatórios escolhidos do estudo com relação a ERB-LA20. Para tal, fora utilizada a função *geod.inverse*. É possível visualizar na Figura 4.6 o cálculo da distância entre a ERB-LA20 e a coordenada de exemplo, onde é obtido o resultado de 1756,39 metros.

```
In [38]: g = geod.Inverse(-12.901078, -38.661988, -12.89237, -38.67552)
print("The distance is {:.3f} m.".format(g['s12']))
The distance is 1756.392 m.
```

**Figura 4.6** Cálculo da distância.

Por fim, foram preenchidos no algoritmo os parâmetros de configuração da ERB e os dados de altitude e distância dela com relação aos pontos escolhidos com intuito de realizar o estudo comparativo.

Os resultados das medições foram comparados com os modelos de predição de Okumura-Hata, Lee e Longley-Rice. Na Tabela 4.1 são apresentados os valores dos parâmetros aplicados a estes modelos.

**Tabela 4.1** Parâmetros/Valores dos modelos.

Parameters	Okumura-Hata	Lee	Longley-Rice
$f$ (MHz)	390,125	390,125	390,125
$H_b$ (m)	55,0	55,0	55,0
$D$ (km)	–	–	100,0
$\gamma_s$	–	–	5,0
$\gamma_L$	–	–	0,0
$\gamma_r$	–	–	1,0
$P_0$ (dBm)	–	61,7	–
$\gamma$ (dB/dec)	–	38,4	–
$n$ (dB/dec)	–	20	–

#### 4.1.1 Modelo de Hata

A primeira análise foi realizada com aplicação do modelo de Hata. Os dados obtidos foram relacionados e apresentados na Tabela 4.2. Assim, é possível realizar uma comparação entre os níveis de potência medidos em campo com os níveis gerados pelo algoritmo.

Da análise da Tabela 4.2 destaca-se o ponto 14 que apresenta a maior diferença absoluta entre os valores gerados pelo algoritmo e aquelas medidos em campo, sendo este de 19,27 dB, e o ponto 16 que representa a menor diferença entre os valores com valor absoluto de 2,17 dB. Também foi verificado um erro médio de 9,88 dB e desvio de 4,96 dB. Na Figura 4.7 é apresentando um gráfico onde observa-se um comparativo entre os valores de potência medidos em campo com os obtidos pelo algoritmo, em função da distância.

#### 4.1.2 Modelo de Lee

Na avaliação do Modelo Lee, foram utilizados os mesmos parâmetros de configuração daqueles utilizados para análise no modelo de Hata. Para os fatores  $P_0$ ,  $\gamma$  e  $A_f$  foram escolhidas valores para ambientes urbanos. Para o fator de ajuste  $n$ , utilizado o valor 20 dB/década, conforme sugerido por Lee (1989) para frequências inferiores a 450 MHz.


Os dados obtidos com o modelo foram relacionados na Tabela 4.3. De forma análoga ao modelo anterior, foi realizada uma comparação entre os níveis de potência medidos em campo com os níveis gerados pelo algoritmo.

Na análise da Tabela 4.3, é possível identificar o ponto 18 que apresenta a maior diferença, 27,14 dB, entre os valores medidos e os calculados. A menor diferença apresentada foi a de ponto 10 com 0,47 dB. Ainda da mesma, obtém-se um erro médio de 8,95 dB e desvio de 8,00 dB.

No Figura 4.8 é apresentado o comparativo entre os valores de potência medidos em campo

**Tabela 4.2** Comparação entre as medições em campo e o modelo Hata

Ponto	Altura (m)	Coordenada		Distância (m)	Potência (dBm)		Diferença (dB)	
		Latitude	Longitude		Algoritmo	Medida	Absoluta	%
1	12,98	-12.8923	-38,6755	1756,40	-70,58	-64,00	-6,58	9,32
2	12,17	-12.8927	-38,6754	1726,20	-70,69	-57,00	-13,69	19,37
3	12,20	-12.8933	-38,6752	1672,62	-70,24	-59,00	-11,24	16,00
4	12,55	-12.8937	-38,6751	1637,30	-69,80	-72,00	2,20	3,15
5	12,57	-12.8951	-38,6746	1527,48	-67,61	-56,00	-11,61	17,17
6	18,43	-12.8957	-38,6745	1483,32	-66,20	-51,00	-15,20	22,96
7	16,37	-12.8965	-38,6742	1423,00	-66,33	-53,00	-13,33	20,10
8	16,15	-12.8972	-38,6740	1373,80	-65,92	-60,00	-5,92	8,98
9	15,68	-12.8979	-38,6738	1332,41	-65,68	-63,00	-2,68	4,08
10	14,58	-12.8986	-38,6736	1291,70	-65,67	-51,00	-14,67	22,34
11	7,61	-12.9005	-38,6729	1181,46	-67,83	-59,00	-8,83	13,02
12	5,80	-12.9020	-38,6722	1111,88	-68,21	-53,00	-15,21	22,30
13	3,73	-12.9031	-38,6714	1042,48	-69,04	-60,00	-9,04	13,09
14	3,01	-12.9038	-38,6708	1006,11	-69,27	-50,00	-19,27	27,82
15	32,66	-12.9120	-38,6632	1218,23	-59,75	-53,00	-6,75	11,30
16	34,42	-12.9136	-38,6622	1386,58	-61,17	-59,00	-2,17	3,55
17	34,33	-12.9162	-38,6601	1689,00	-63,92	-71,00	7,08	11,08
18	39,51	-12.9170	-38,6590	1785,00	-63,69	-79,00	15,31	24,04
19	40,58	-12.9179	-38,6579	1911,35	-64,45	-76,00	11,55	17,92
20	39,04	-12.9203	-38,6569	2196,80	-66,65	-72,00	5,35	8,03

**Figura 4.7** Gráfico - Medidas em campo x Modelo Hata

**Tabela 4.3** Comparação entre as medições em campo e o modelo Lee

Ponto	Altura (m)	Coordenada		Distância (m)	Potência (dBm)		Diferença (dB)	
		Latitude	Longitude		Algoritmo	Medida	Absoluta	%
1	12,98	-12.8923	-38,6755	1756,40	-56,00	-64,00	8,00	14,29
2	12,17	-12.8927	-38,6754	1726,20	-56,08	-57,00	0,92	1,64
3	12,20	-12.8933	-38,6752	1672,62	-55,54	-59,00	3,46	6,23
4	12,55	-12.8937	-38,6751	1637,30	-55,07	-72,00	16,93	30,74
5	12,57	-12.8951	-38,6746	1527,48	-53,07	-56,00	2,93	5,52
6	18,43	-12.8957	-38,6745	1483,32	-51,91	-51,00	-0,91	1,75
7	16,37	-12.8965	-38,6742	1423,00	-51,70	-53,00	1,30	2,51
8	16,15	-12.8972	-38,6740	1373,80	-51,16	-60,00	8,84	17,28
9	15,68	-12.8979	-38,6738	1332,41	-50,76	-63,00	12,24	24,11
10	14,58	-12.8986	-38,6736	1291,70	-50,53	-51,00	0,47	0,93
11	7,61	-12.9005	-38,6729	1181,46	-51,51	-59,00	7,49	14,54
12	5,80	-12.9020	-38,6722	1111,88	-51,45	-53,00	1,55	3,01
13	3,73	-12.9031	-38,6714	1042,48	-51,84	-60,00	8,16	15,74
14	3,01	-12.9038	-38,6708	1006,11	-51,89	-50,00	-1,89	3,64
15	32,66	-12.9120	-38,6632	1218,23	-46,28	-53,00	6,72	14,52
16	34,42	-12.9136	-38,6622	1386,58	-48,23	-59,00	10,77	22,33
17	34,33	-12.9162	-38,6601	1689,00	-51,53	-71,00	19,47	37,78
18	39,51	-12.9170	-38,6590	1785,00	-51,86	-79,00	27,14	52,33
19	40,58	-12.9179	-38,6579	1911,35	-52,89	-76,00	23,11	43,69
20	39,04	-12.9203	-38,6569	2196,80	-55,37	-72,00	16,63	30,03

com os obtidos pelo algoritmo.


#### 4.1.3 Modelo de Longley - Rice

Para um comparativo final, os dados medidos em campo foram comparados aos resultados obtidos no modelo de Longley-Rice. Este modelo foi implementado a partir da rotina *ITMAre-adBLoss* da função *pyitm.itm* no *Python*.

Realizando-se os ajustes nos parâmetros relacionados as características do ambiente foram obtidos os dados apresentados na Tabela 4.4. De acordo com a Tabela, o ponto 18 apresenta a maior diferença entre as medidas com 18,86 dB e o ponto 1 com a menor diferença de valor absoluto de 0,37 dB. Para este caso, o erro médio apresentado foi de 7,29 dB e desvio padrão, 4,94 dB.

Na Figura 4.9 visualiza-se o gráfico que demonstra o comparativo entre os dados gerados no modelo de Longley-Rice e os dados medidos em campo






**Figura 4.8** Gráfico - Medidas em Campo x Modelo Lee.

## 4.2 COMPARAÇÃO ENTRE OS MODELOS DE PROPAGAÇÃO

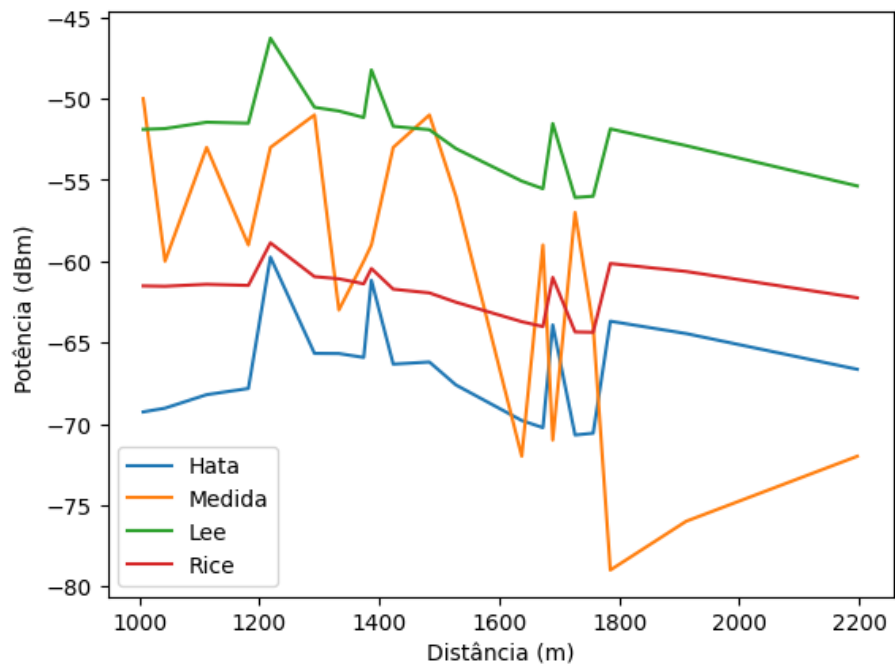
Para uma melhor análise dos resultados obtidos, é apresentado na Figura 4.15, um gráfico comparativo entre os dados oriundos dos modelos e aqueles derivados das medições em campo. Por fim, na Tabela 4.5 é apresentado um comparativo entre os erros médios e desvios obtidos entre as medições. Levando em consideração os estudos realizados por Taraldsen et al. (2015), em que observa a necessidade de verificar possíveis diferenças nos valores de erro médio e desvio padrão quando utilizadas medidas logarítmicas, optou-se em fazer esse estudo considerando medições em Watts.

Nas suas pesquisas, Cavalcante (2010), Valente, Rodrigues e Pinheiro (2016) e Moreira (2017) realizaram a otimização dos modelos de propagação utilizando algoritmos genéticos. Moreira (2017), após otimização, obteve um erro médio de 9,69 dB e desvio padrão de 4,31 dB para o modelo de Okumura Hata. Já Valente, Rodrigues e Pinheiro (2016), atingiu um erro médio de 2,52 dB e desvio padrão de 5,81 dB para o modelo de COST 231 em uma das rotas otimizadas. Por fim, Cavalcante (2010) realizou uma otimização para os modelos de SUI e ECC-33. Como resultado, obteve um erro médio de 6,95 dB e desvio padrão de 8,82 dB para o modelo SUI e 5,09 dB e 6,41 dB para o modelo ECC-33, respectivamente.

Comparando-se os resultados de desvio e erro médio obtidos da Tabela 4.5 com os obtidos por Cavalcante (2010), Valente, Rodrigues e Pinheiro (2016) e Moreira (2017), já otimizados,



**Figura 4.9** Gráfico - Medidas em Campo x Modelo Rice.



**Figura 4.10** Gráfico - Comparativo Geral

**Tabela 4.4** Comparação entre as medições em campo e o modelo Rice

Ponto	Altura (m)	Coordenada		Distância (m)	Potência (dBm)		Diferença (dB)	
		Latitude	Longitude		Algoritmo	Medida	Absoluta	%
1	12,98	-12.8923	-38,6755	1756,40	-64,37	-64,00	-0,37	0,57
2	12,17	-12.8927	-38,6754	1726,20	-64,35	-57,00	-7,35	11,42
3	12,20	-12.8933	-38,6752	1672,62	-64,02	-59,00	-5,02	7,84
4	12,55	-12.8937	-38,6751	1637,30	-63,72	-72,00	8,28	12,99
5	12,57	-12.8951	-38,6746	1527,48	-62,52	-56,00	-6,52	10,43
6	18,43	-12.8957	-38,6745	1483,32	-61,95	-51,00	-10,95	17,68
7	16,37	-12.8965	-38,6742	1423,00	-61,72	-53,00	-8,72	14,13
8	16,15	-12.8972	-38,6740	1373,80	-61,39	-60,00	-1,39	2,26
9	15,68	-12.8979	-38,6738	1332,41	-61,08	-63,00	1,92	3,14
10	14,58	-12.8986	-38,6736	1291,70	-60,95	-51,00	-9,95	16,32
11	7,61	-12.9005	-38,6729	1181,46	-61,49	-59,00	-2,49	4,05
12	5,80	-12.9020	-38,6722	1111,88	-61,42	-53,00	-8,42	13,71
13	3,73	-12.9031	-38,6714	1042,48	-61,54	-60,00	-1,54	2,50
14	3,01	-12.9038	-38,6708	1006,11	-61,52	-50,00	-11,52	18,73
15	32,66	-12.9120	-38,6632	1218,23	-58,87	-53,00	-5,87	9,97
16	34,42	-12.9136	-38,6622	1386,58	-60,45	-59,00	-1,45	2,40
17	34,33	-12.9162	-38,6601	1689,00	-61,00	-71,00	10,00	16,39
18	39,51	-12.9170	-38,6590	1785,00	-60,14	-79,00	18,86	31,36
19	40,58	-12.9179	-38,6579	1911,35	-60,63	-76,00	15,37	25,35
20	39,04	-12.9203	-38,6569	2196,80	-62,25	-72,00	9,75	15,66

**Tabela 4.5** Detalhamento do Erro médio e Desvio Padrão

Método	Erro médio (dB)	Desvio padrão (dB)	Erro médio (nW)	Desvio padrão (nW)
Medidas (Hata)	4,96	9,88	2,46	3,00
Medidas (Lee)	8,00	8,94	4,95	4,50
Medidas (Rice)	4,95	7,29	2,29	2,79

mostra que os resultados obtidos pelo algoritmo possui valores bem aproximados das medições realizadas em campo, podendo ser utilizados sem necessidade de adequações nos parâmetros do modelo.

Visualizando-se os resultados na Figura 4.15 e os valores de erro médio e desvio padrão na Tabela 4.5 é possível notar que o modelo de Longley-Rice apresentou resultados mais aproximados com relação aos valores medidos, inclusive, com menor erro médio. Entretanto, os modelos possuem curvas com comportamento muito semelhante entre si. As curvas de Hata e Lee possuem ainda maior destaque pela semelhança, aparentando somente diferenciar-se pelos valores absolutos de potência recebida. Tal fato, pode ser oriundo da escolha referente ao fator de ajuste  $n$  do modelo de Lee.

Como dito, o modelo de Longley-Rice obteve os melhores resultados de erro médio e desvio padrão nos estudos comparativos com as medições em campo. Diante disto, este será o modelo escolhido para a predição de potência recebida no uso do algoritmo de otimização.

### 4.3 RESULTADOS DO ALGORITMO POR ENXAME DE PARTÍCULAS

Neste trabalho, o PSO foi utilizado para otimizar o posicionamento de múltiplas ERBs, dentro de uma região definida, através da função *fitness*  $f$  dada pela Equação 3.3. Os valores dos parâmetros  $w$ ,  $c_1$ ,  $c_2$ ,  $r_1$  e  $r_2$  utilizados são apresentados no Capítulo 3. Para verificação do desempenho do algoritmo, inicialmente foi utilizado  $\alpha = 0,7$  (cobertura mínima de 70%) considerando um total de 6 ERB's. Foram realizadas otimizações para 10, 20 e 50 partículas considerando 20, 50 e 100 iterações.

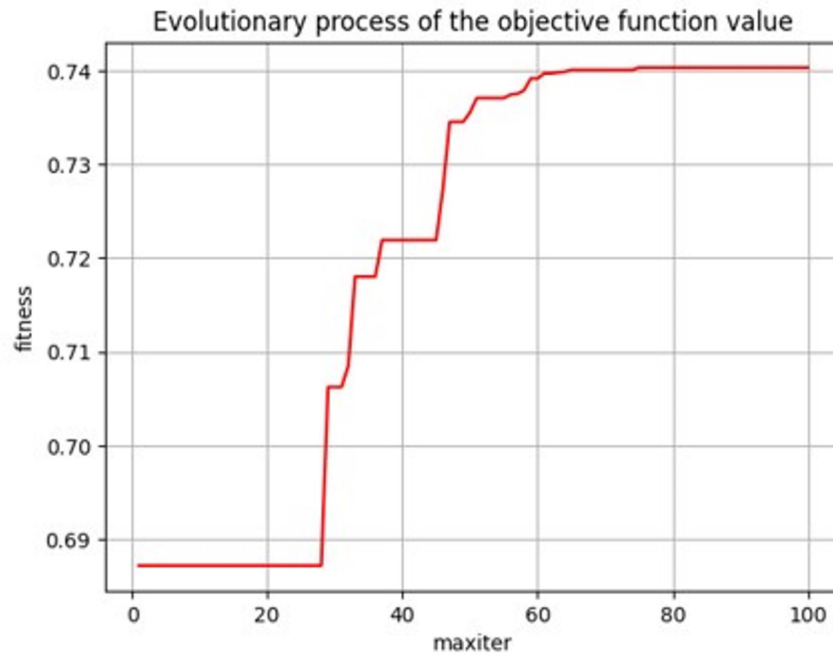
Os resultados para a otimização são os apresentados na Tabela 4.6. Além dos valores para *fitness*,  $f_1$  e  $f_2$  são apresentados o desempenho e o quantitativo de ERBs alocadas, com destaque aos dois resultados de melhor *fitness*.

**Tabela 4.6** Parâmetros de operação do PSO

Otimização	Partículas	iterações	<i>Fitness</i>	$f_1$	$f_2$	desempenho	ERBs alocadas
1	10	20	0,6280	0,6829	0,50	37min32seg	3
2	10	50	0,7397	0,8424	0,50	1h29min12seg	3
3	10	100	0,7020	0,8600	0,33	3h8min11seg	4
4	20	20	0,7296	0,8994	0,33	1h32min48seg	4
5	20	50	0,7404	0,8434	0,50	2h50min7seg	3
6	20	100	<b>0,7483</b>	0,8547	0,50	5h39min57seg	3
7	50	20	<b>0,7521</b>	0,8601	0,50	3h3min43seg	3
8	50	50	0,7124	0,7320	0,67	5h13min14seg	2
9	50	100	0,7442	0,8489	0,50	18h32min13seg	3

Da análise da Tabela 4.6 verifica-se que o resultado de *fitness* 0,7521 representa ao projetista o melhor custo benefício, pois é possível obter percentuais de cobertura superiores a 86% com emprego de três das seis ERBs previstas. A otimização 4, por exemplo, apresenta uma cobertura estimada de 89%, entretanto, com emprego de quatro ERBs. Isto representa um custo maior para implantação de mais uma ERBs obtendo-se somente 3% a mais de cobertura.

Na Figuras 4.11 e 4.12 são apresentados os gráficos dos resultados das duas otimizações de melhor *fitness*. E nas Figuras 4.13 e 4.14 o posicionamento das ERBs no mapa.

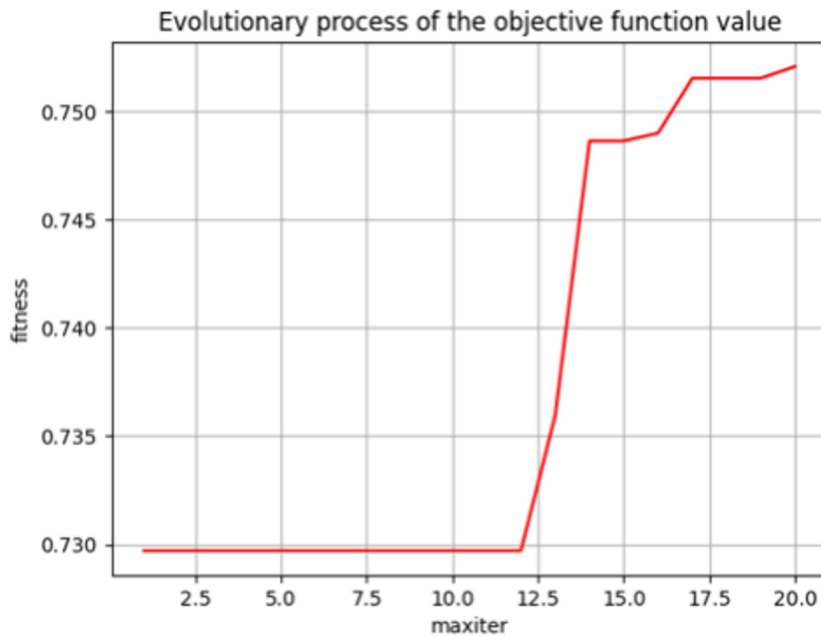


FINAL RESULT

0,7403

(-12.9841, -38.9221, 1, -12.983, -38.9942, 0, -12.895, -39.1528, 0, -13.0563, -39.174, 1, -12.8524, -39.1663, 1, -13,109, -38.833, 0)

**Figura 4.11** Resultado da *fitness* para a otimização 6 e  $\alpha = 0,7$ .




FINAL RESULT

0,7521

(-13.1132, -38.9689, 1, -12.9411, -38.923, 1, -13.1131, -39.2924, 0, -12.9873, -39.2638, 0, -12.9844, -39.191, 1, -13,0355, -38.8821, 0)

**Figura 4.12** Resultado da *fitness* para a otimização 7 e  $\alpha = 0,7$ .



**Figura 4.13** Posicionamento das ERBs no mapa para a otimização 6 e  $\alpha = 0.7$   
Fonte: O Autor, 2023

Considerando que para os projetos de radiocomunicação da SSP/BA é necessário um requisito mínimo de cobertura de 90%, o algoritmo foi agora executado para  $\alpha = 0,9$ . Os demais parâmetros foram mantidos.

Este percentual mínimo é exigido em virtude dos projetos terem como objetivo a disponibilização de uma rede de radiocomunicação para missão crítica, isto é, para comunicação policial e do corpo de bombeiros, assim os resultados de cobertura da rede são essenciais para o desempenho destas atividades. Isto difere, por exemplo, das operadoras de telefonia celular que, em linhas gerais, mantém o foco principal nos lucros e condicionam a cobertura do projeto a concentração de possíveis clientes na região.

Os resultados de otimização são apresentados na Tabela 4.7, no qual é destacado o resultado de melhor *fitness*.

Na Figura 4.15 é apresentado o gráfico do resultado de melhor *fitness*. Incluindo as coordenadas sugeridas para as estações. Na Figura 4.16 é apresentada a alocação das ERBs na região de estudo.

De forma semelhante a análise realizada na Tabela 4.6, é possível verificar a partir da Tabela 4.7 que o resultado de melhor *fitness* (0,89) apresenta o melhor custo benefício, pois são obtidos percentuais de cobertura superiores a 95% com emprego de quatro das seis ERBs previstas.





**Figura 4.14** Posicionamento das ERBs no mapa para a otimização 7 e  $\alpha = 0.7$   
 Fonte: O Autor, 2023

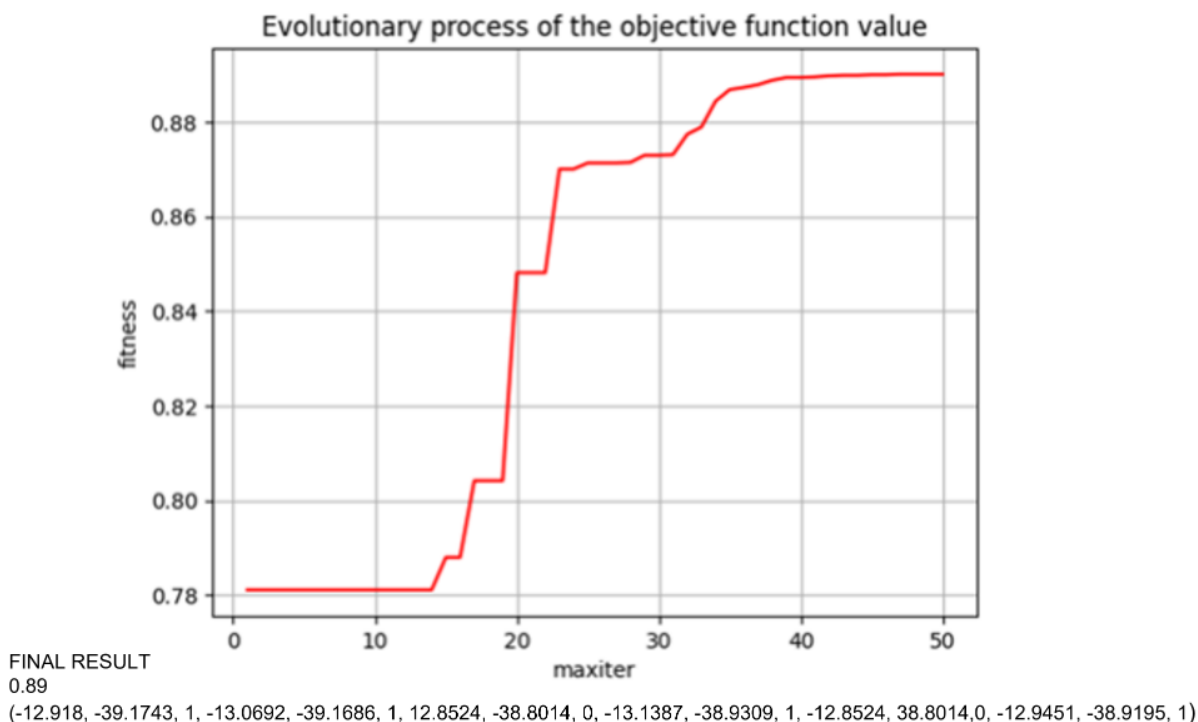
**Tabela 4.7** Parâmetros de operação do PSO.

Otimização	Partículas	iterações	Fitness	$f_1$	$f_2$	desempenho	ERBs alocadas
1	10	20	<b>0,8449</b>	0,9017	0,33	26min54seg	4
2	10	50	0,8062	0,8402	0,50	1h24min59seg	3
3	10	100	0,8093	0,8437	0,50	2h55min41seg	3
4	20	20	0,8518	0,9094	0,33	1h29min54seg	4
5	20	50	0,8583	0,9351	0,17	2h35min12seg	5
6	20	100	0,8136	0,8484	0,50	5h55min1seg	3
7	50	20	0,8458	0,9027	0,33	3h47min37seg	4
8	50	50	<b>0,8900</b>	0,9519	0,33	9h31min30seg	4
9	50	100	0,8140	0,8489	0,50	18h51min3seg	3

Fonte: O Autor, 2023

Sendo, também, a melhor solução entre aquelas que obtiveram a cobertura mínima de 90%. Contudo, vale destacar que o tempo necessário de otimização, utilizando-se de um compilador gratuito foi de 9h31min30seg.

Neste sentido, levando-se em consideração o tempo de processamento, a otimização de



**Figura 4.15** Resultado da *fitness* para otimização 8 e  $\alpha = 0,9$

Fonte: O Autor, 2023

*fitness* = 0,8449 (otimização 1), destaca-se por ter obtido o percentual mínimo necessário de cobertura (90%) com tempo de 26min54s, menor tempo entre as otimizações. Na Figura 4.17 é apresentado o gráfico de otimização para esse caso.

Verificado o resultado dentre as otimizações de melhor custo benefício é possível alocar as ERBs na região de estudo. Para tal, novamente a ferramenta do *Google Earth* foi utilizada.

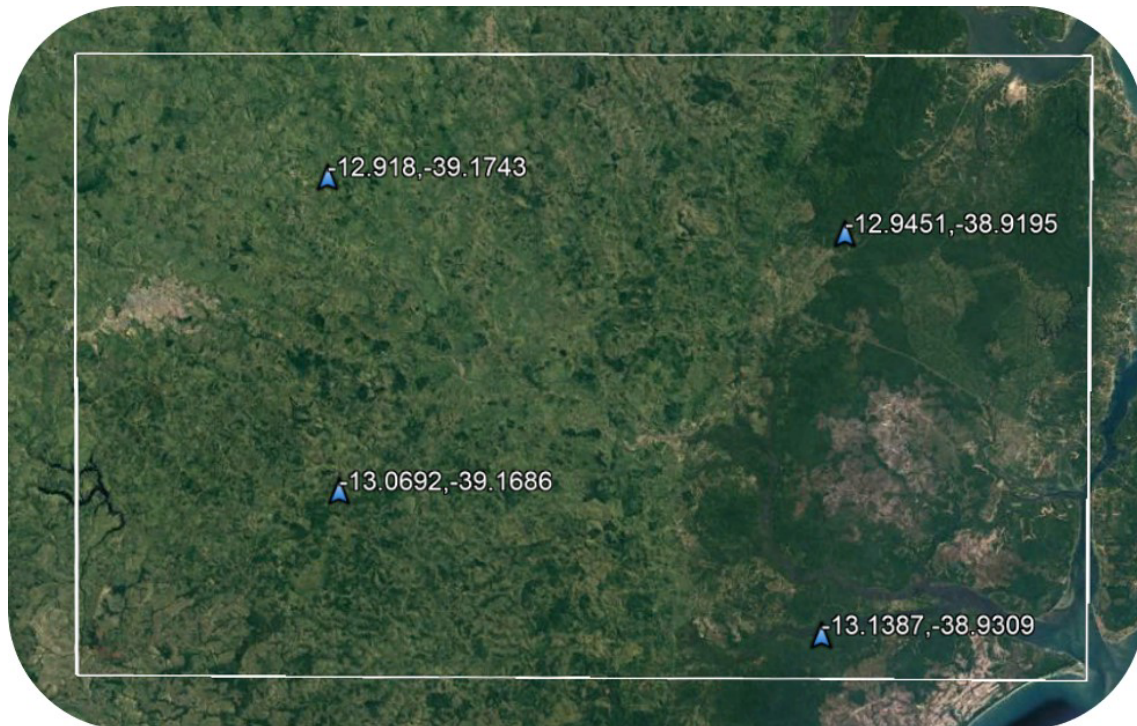
Na Figura 4.18 é apresentada a alocação das ERBs na região de estudo.

Estes resultados podem tornar mais eficientes os estudos de campo da equipe de projetos que pode, a partir das coordenadas obtidas através das otimizações, verificar a viabilidade técnica para implantação das estações.

Por fim, na Tabela 4.8 é apresentado um resumo dos trabalhos relacionados e uma análise comparativa de alguns dos modelos e métodos heurísticos utilizados.

Dos trabalhos relacionados, os desenvolvidos por Costa (2016), Filho (2019) e Monshi e Islam (2012) são os que mais se assemelham a esta pesquisa, principalmente pelo fato de Han et al. (2001), Suriya e Porter (2014), Yangyang et al. (2004), Talau (2010) e Pereira (2014) terem utilizado como modelo de propagação o espaço livre e em alguns casos regiões de busca simuladas, sendo em sua maioria o plano cartesiano. Tais premissas, influenciam de maneira significativa a construção e desempenho do algoritmo. Na utilização do espaço livre, por exem-





**Figura 4.16** Posicionamento das ERBs no mapa para otimização 8 e  $\alpha = 0,9$   
 Fonte: O Autor, 2023


**Tabela 4.8** Comparativo com trabalhos relacionados.

Autor	Heurística	Frequência	Modelo de propagação	Espaço de busca	Resultados
Han et al. (2001)	AG	Não definido	Espaço livre/Hata	Simulado	100%
Suriya e Porter (2014)	AG	Não definido	Espaço livre	Simulado	100%
Costa (2016)	AG	700 e 2500 MHz	Hata	Real	99,38%
Ouamri (2017)	AG	900 MHz	Hata	Simulada	97,52%
Antunes et al. (2021)	AG	LTE/4G	Variados	Real	95%
Yangyang et al. (2004)	PSO	Não definido	Espaço livre	Simulado	100%
Talau (2010)	PSO	1800 MHz	Espaço livre	Indoor	100%
Monshi e Islam (2012)	PSO	150 - 1000 MHz	Hata	Simulado	53,69%
Pereira (2014)	PSO	2000 MHz	Espaço livre	Real	aumento de 17%
Filho (2019)	PSO/FPA	3.5 - 73 GHz	ABG/CI	Real	100%
Pesquisa	PSO	380 MHz	Longley Rice	Real	95,19%

Fonte: O Autor, 2020

plo, não há necessidade de consulta aos dados de altimetria, bem como em ambiente simulados não são considerados aspectos característicos como a urbanização e não há possibilidade de ajuste do modelo as características específicas da região.

Em Costa (2016) foi utilizado AG, modelo de atenuação de Hata e espaço de busca real. O modelo de propagação foi escolhido por ser o mais utilizado para faixa de frequência utilizada, contudo não foi escolhido a partir de comparativo com medidas de campo. O autor obteve como desempenho um tempo de 21min30seg para a cobertura mínima exigida. Entretanto,



FINAL RESULT  
0,8449

(-13.0886, -38.9008, 1, -12.8524, -38.932, 1, -12.8524 -39.2598, 0, -12.9029, -38.9538, 0, -12.9556, -39.1785, 1, -13,150, -39.1297, 1)


**Figura 4.17** Resultado da *fitness* para otimização 1 e  $\alpha = 0.9$

Fonte: O Autor, 2023

a sua otimização baseou-se somente em um único objeto, isto é, uma única ERB. Em sua conclusão, pontuou que o tempo de processamento vai se elevando a medida que se aumenta o quantitativo de pontos de recepção e ERBs. Considerando que na sua modelagem o autor utilizou uma área de  $116 \text{ km}^2$  e 1947 pontos de recepção, os resultados de desempenho obtidos na otimização 1 para  $\alpha = 0,9$  (26min54seg) mostram-se superiores aos da sua pesquisa.

Já Filho (2019) utilizou um espaço de busca real, inclusive com escolha e ajuste dos modelos ABG e CI a partir de medições em campo. A otimização foi realizada baseando-se somente nos níveis de cobertura considerando um número fixo de ERBs. Assim, a variação dos resultados de cobertura foram impactados pela variação das frequências utilizadas (3, 5, 10, 24, 28, 60 e 73 GHz) em cada otimização. Tal fato, impossibilita a realização de um comparativo no que se refere ao desempenho do algoritmo.

Por fim, a pesquisa de Monshi e Islam (2012) também apresentou alguma similitude com este trabalho. Nela, o autor utilizou PSO e atenuação baseada no modelo Hata. A modelagem utilizada baseou-se na aplicação de variadas combinações de  $\alpha$  (entre 0,2 e 0,7) possibilitando ao projetista verificar, para o caso específico, qual opção utilizar. Entretanto, além de trabalhar num espaço de busca simulado, o autor utilizou na otimização diferentes alturas de antena e potência das ERBs.



**Figura 4.18** Posicionamento das ERBs no mapa para otimização 8 e  $\alpha=0,9$   
Fonte: O Autor, 2023

Diante do exposto, verifica-se que um comparativo mais fidedigno fica prejudicado em virtude das variadas formas utilizadas para modelar os sistemas e realizar os estudos.

Contudo, esta pesquisa se destaca pela utilização de um espaço de estudo real, baseado em coordenadas geográficas, possibilitando que ao final as ERBs do resultado otimizado fossem posicionadas no mapa, bem como o fato do modelo de propagação utilizado ter sido validado através de medições em campo sendo o mais aproximado para as características do ambiente de estudo.

## CONCLUSÃO

Um dos maiores desafios para projetistas de redes de telecomunicações é identificar o melhor posicionamento para as ERBs. Um estudo bem elaborado pode evitar pontos sem cobertura ou um gasto desnecessário com uma quantidade maior de estações. Para dimensionar a rede, geralmente, os projetistas utilizam ferramentas de predição para prever os possíveis níveis de cobertura para uma determinada posição escolhida. Bons resultados estão vinculados, principalmente, a experiência do projetista em identificar as melhores posições.

Com objetivo de otimizar os resultados dos estudos de projetos de radiocomunicação crítica (sistemas para Segurança Pública e Defesa), o presente projeto de pesquisa propôs o uso de um algoritmo baseado na meta-heurística PSO para identificar a posição ótima e a quantidade de estações dentro de um espaço de busca definido.

Para tal, primeiramente, foi escolhido o modelo de atenuação a partir do comparativo com medições realizadas em campo. Em virtude de ter apresentado menor erro médio e desvio padrão, o modelo de Longley -Rice foi utilizado.

Em seguida uma rotina em *python* foi desenvolvida para aplicação do PSO. O modelo aplicado considerou a partícula como um par de coordenadas (Lat, Long) e um indicador para utilização ou não da ERB na otimização. Para composição da função *fitness*, foi realizada uma ponderação entre cobertura e economia. A cobertura foi definida através do conjunto de pontos de potência recebida, sendo os pontos bons aqueles com valores superiores a -70 dBm. O peso econômico, definido pelo quantitativo de ERBs utilizadas. O objetivo do algoritmo foi maximizar a função *fitness* buscando a solução ótima para máxima cobertura e menor quantitativo de ERBs.

O estudo foi realizado para uma área de 1809 km<sup>2</sup> e 9548 pontos de recepção para uma cobertura mínima de 70% e 90% levando em consideração um quantitativo máximo de 6 ERBs.

Os resultados obtidos comprovaram o potencial no uso do algoritmo PSO na solução de problemas relacionados ao posicionamento de ERBs para sistemas de radiocomunicação, com obtenção, por exemplo, de 90% de cobertura com aplicação de 4 ERBs e tempo de processamento próximo aos 26 minutos. Ao final, através da utilização de um ambiente real, foi possível posicionar no mapa as coordenadas das soluções otimizadas.

Sugere-se para trabalhos posteriores a utilização nos estudos de modelos de otimização para o padrão LTE militarizado, levando em consideração outros parâmetros além da cobertura e economia, como a taxa de transmissão de dados.

## REFERÊNCIAS BIBLIOGRÁFICAS

- ALENOGHENA, C.; EMAGBETERE, J.; AIBINU, A. M. Artificial intelligence based technique for bts placement. *IOP Conference Series: Materials Science and Engineering*, v. 53, n. 13, 2013.
- ALMEIDA, B. S. G. de; LEITE, V. C. Particle swarm optimization: A powerful technique for solving engineering problems. In: SER, J. D.; VILLAR, E.; OSABA, E. (Ed.). *Swarm Intelligence*. Rijeka: IntechOpen, 2019. cap. 3. Disponível em: <https://doi.org/10.5772/intechopen.89633>.
- AMARAL, C. T. do. *Uma Análise do Modelo de Propagação Longley-Rice sob a perspectiva de Ambientes Urbanos Localizados em Área de Clima Tropical*. 8 p. Dissertação (Mestrado) — Universidade Federal de Minas Gerais, Belo Horizonte, 2012.
- AMORIM1, L. O. et al. Base station placement across a simulated city using a biased random-key genetic algorithm. *Universidade Federal de Alagoas (UFAL) Macei ´o – AL – Brazil*, 2019.
- ANTUNES, E. et al. Soluções otimizadas para o problema de localização de máxima cobertura em redes militarizadas 4g/lte. In: . [S.l.: s.n.], 2021.
- BASTOS, E. A. *Otimização de Seções Retangulares de Concreto Armado Submetidas à Flexo-Compressão Oblíqua Utilizando Algoritmos Genéticos*. Dissertação (Mestrado) — UFRJ, Rio de Janeiro, 2004.
- BELL, N.; OOMMEN, B. J. Particle field optimization: A new paradigm for swarm intelligence. In: . Richland, SC: International Foundation for Autonomous Agents and Multiagent Systems, 2015. ISBN 9781450334136.
- BERNARDES, W. M. S. *Algoritmo Enxame de Partículas Discreto para Coordenação de Relés Direcionais de Sobrecorrente em Sistemas Elétricos de Potência*. Dissertação (Mestrado) — USP, São Carlos, 2013.
- BRANDÃO, M. A. L. *Estudo de Alguns Métodos Determinísticos de Otimização Irrestrita*. Dissertação (Mestrado) — Universidade Federal de Uberlândia, Uberlândia, MG, 2010.
- CARVALHO, E. da C. R. *Solução de Problemas de Otimização com restrições usando estratégias de penalização adaptativa e um algoritmo do tipo PSO*. Dissertação (Mestrado), UFJF, Juiz de Fora, 2014.
- CASTRO, L. D. Fundamentals of natural computing: An overview. *Physics of Life Reviews*, v. 4, p. 1–36, 03 2007.

CASTRO, L. D.; JOSÉ, F.; ZUBEN, A. A. von. Artificial immune systems: Part i-basic theory and applications. 01 2000.

CAVALCANTE, G. A. *Otimização de modelos de predição da perda de propagação aplicáveis em 3,5 GHz utilizando algoritmo genéticos*. Dissertação (Mestrado) — UFRN, Natal/RN, 2010.

CEKUS, D.; SKROBEK, D. The influence of inertia weight on the particle swarm optimization algorithm. *Journal of Applied Mathematics and Computational Mechanics*, v. 17, p. 5–11, 12 2018.

CORTES, O. A. C. *Implementado Algoritmos Genéticos em R*. 2017. Disponível em: <https://medium.com/semper-evolutionis/implementado-algoritmos-geneticos-em-r-845219a56984>.

COSTA, V. O. *Alocação de Antenas para Rede Celular de 4G utilizando Algoritmos Meméticos*. Dissertação (Mestrado), Universidade Federal do Tocantins Palmas, 2016.

DIAS, M. H. C. *Ferramenta de predição de cobertura para planejamento de comunicações táticas V/UHF*. Dissertação (Mestrado), ITA, São Paulo, 2018.

ELIAS, M. E. P. *Comparação entre Modelos Empíricos e Semi empíricos de predição de Cobertura Móvel Celular: Estudo de Caso em ambiente Outdoor*. Dissertação (Mestrado), USP, São Carlos, SP, 2005.

ERTEL, P. C. R. *Uma abordagem contínua para o problema do caixeiro viajante*. Dissertação (Mestrado) — Universidade de São Paulo, São Paulo, SP, 2023.

FILHO, F. G. S. da S. *Otimização do Posicionamento de Múltiplas Small Cells em Ambientes Outdoor da Região Amazônica Utilizando Enxame de Partículas e Polinização de Flores*. Dissertação (Mestrado), UFPA / ITEC / PPGEE Campus Universitário do Guamá Belém-Pará-Brasil, 2019.

GOEDERT, M. L.; FILHO, P. L. P.; BLANCO, D. R. Computação natural: conceitos e aplicações da computação inspirada na natureza. *Revista Espacios*, v. 38, p. 31, 03 2017.

GOES, A. A. *Redes 4G: Aplicação de Modelos de Propagação*. 2017. Disponível em: <https://www.teleco.com.br/tutoriais/tutorialredes4g/default.asp>.

GOMES, C. R. *Modelo de rádio propagação em UHF para ambientes não homogêneos e climas distintos utilizando técnica de aprendizagem de máquina*. Tese (Doutorado), Universidade Federal do Pará, 2015.

HAN, J. et al. Genetic approach with a new representation for base station placement in mobile communications. In: . [S.l.: s.n.], 2001. p. 2703 – 2707 vol.4.

HAO, J.-K. A heuristic approach for antenna positioning in cellular networks. *Journal of Heuristics*, v. 7, p. 443–472, 2001.



- HASSAN, R.; COHANIM, B.; WECK, O. de. A comparison of particle swarm optimization and the genetic algorithm. In: . [S.l.: s.n.], 2005. v. 2.
- HUFFORD, G.; LONGLEY, A.; KISSICK, W. *A Guide to the Use of the ITS Irregular Terrain Model in the Area Prediction Mode*. U.S Department of Commerce Malcolm Baldrige - NTIA REPORT 82-100: [s.n.], 1982.
- ISABELA. *O que são algoritmos bioinspirados?* <https://www.ecycle.com.br/algoritmos-bioinspirados/>: [s.n.], 2012.
- JUNIOR, E. N. *Implantação de algoritmo para análise de radiopropagação em aplicações de segurança pública*. Dissertação (Mestrado), Universidade Federal do Paraná, 2015.
- JUNIOR, J. V. F. M. *Comparação de Métodos de dimensionamento em redes de distribuição de água*. Dissertação (Mestrado) — Universidade Federal do Ceará, Fortaleza, 2012.
- LEE, W. *Mobile Cellular Telecommunications Systems*. [S.l.]: McGraw-Hill Inc.,US, 1989.
- LEMOS, N. A. *Caracterização de cobertura de sinais na faixa de 700 MHz em ambientes indoor*. Dissertação (Mestrado) — Instituto Federal de Educação, Ciência e Tecnologia, Paraíba, 2016.
- LIESKA, K.; LAITINEN, E.; LAHTEENMAKI, J. Radio coverage optimization with genetic algorithms. In: *Ninth IEEE International Symposium on Personal, Indoor and Mobile Radio Communications (Cat. No.98TH8361)*. [S.l.: s.n.], 1998. v. 1, p. 318–322 vol.1.
- LONES, M. Sean luke: essentials of metaheuristics. *Genetic Programming and Evolvable Machines*, v. 12, p. 333–334, 09 2011.
- LUZIA, L. F. *Introdução ao Escalonamento e Aplicações: Estudo sobre as Metaheurísticas*. Editora Unisonos: [s.n.], 2010.
- MACLENNAN, B. Natural computation and non-turing models of computation. *Theor. Comput. Sci.*, v. 317, p. 115–145, 06 2004.
- MILLONAS, M. M. *Swarms, Phase Transitions, and Collective Intelligence*. 1993.
- MONSHI, m.; ISLAM, S. M. Base station placement of mobile communication system-a particle swarm optimization. In: . [S.l.: s.n.], 2012.
- MOREIRA, T. da C. *Utilização de algoritmos genéticos para otimização de modelos de predição na cidade de Apodi - RN*. Dissertação (Mestrado), UFERSA, Pau dos Ferros, 2017.
- NASCIMENTO, F. et al. Meta-heurística otimização por enxame de partículas aplicada ao planejamento florestal. In: \_\_\_\_\_. [S.l.: s.n.], 2013. p. 355–366. ISBN 9788564619104.
- OLIVEIRA, A.; MACULAN, N. Combinatorial optimization, combined algorithms and problem positioning radio stations based wireless and mobile. In: . [S.l.: s.n.], 2015.



- OLIVIERI, B. P. *Otimização do Projeto de Pontes Protendidas Pré-Moldadas pelo Método dos Algoritmos Genéticos*. Dissertação (Mestrado) — UFRJ, Rio de Janeiro, 2004.
- OUAMRI, M. A. Base station placement optimization using genetic algorithm. *International Journal of Computer Aided Engineering and Technology*, v. 12, 05 2017.
- PATRIOTA, G. D. *Modelo de Propagação Outdoor para região urbana densa na Cidade de Curitiba*. Dissertação (Mestrado), UFPR, Curitiba, 2011.
- PEREIRA, M. A. B. *Análise de modelos de propagação na área urbana da região de Curitiba – PR na faixa de frequência de 1800 MHz*. Dissertação (Mestrado), Universidade Federal do Paraná, 2007.
- PEREIRA, M. B. Particle swarm optimization for base station placement. In: *2014 International Telecommunications Symposium (ITS)*. [S.l.: s.n.], 2014. p. 1–5.
- SARAMAGO, S. P. *Técnicas heurísticas de Otimização Aplicadas em Engenharia*. <https://seer.ufu.br/index.php/horizontecientifico/article/view/4425/3225>: :text=S[s.n.], 2009.
- SECCHI, A. R. *Otimização de Processos. Aulas Piloto*. COPPE, UFRJ, Rio de Janeiro: [s.n.], 2018.
- SERAPIAO, A. Fundamentos de otimização por inteligência de enxames: Uma visão geral. *Controle y Automacao*, v. 20, p. 271–304, 07 2009.
- SHIGANG; ZHOU, F.; WANG, F. Effect of inertia weight w on pso-sa algorithm. *International Journal of Online Engineering*, v. 9, p. 87–91, 06 2013.
- SURIYA, A.; PORTER, J. D. Genetic algorithm based approach for rfid network planning. In: *TENCON 2014 - 2014 IEEE Region 10 Conference*. [S.l.: s.n.], 2014. p. 1–5.
- TAKAHASHI, R. H. C. *Otimização Escalar e Vetorial Volume 2: Otimização Escalar*. Notas de Aula. UFMG. Belo Horizonte: [s.n.], 2007.
- TALAU, M. An approach for solving the base station placement problem using particle swarm intelligence. In: . [S.l.: s.n.], 2010.
- TARALDSEN, G. et al. Uncertainty of decibel levels. *The Journal of the Acoustical Society of America*, v. 138, 09 2015.
- THEVENOT, A. *Particle Swarm Optimization Visually Explained*. <https://towardsdatascience.com/particle-swarm-optimization-visually-explained-46289eeb2e14>: [s.n.], 2020.
- VALAVANIS, I. et al. Base-station location optimization for lte systems with genetic algorithms. In: . [S.l.: s.n.], 2014.
- VALENTE, A.; RODRIGUES, J.; PINHEIRO, M. Otimização de modelos de perda de propagação da rede lte 1800 mhz utilizando algoritmo genético. In: . [S.l.: s.n.], 2016.

VENKATASESHIAH, C.; ARUMUGAM, M. S. Particle swarm optimization with various inertia weight variants for optimal power flow solution. *Hindawi Publishing Corporation*, v. 10, 08 2010.

VINCENY, T. Direct and inverse solutions of geodesics on the ellipsoid with application of nested equations. *Survey Review*, XXII, 176, 1975.

WANG, D.; TAN, D.; LIU, L. Particle swarm optimization algorithm: an overview. *Soft Computing*, v. 22, 01 2018.

YACOUB, M. D. *Foundations of mobile radio engineering*. [S.l.]: CRC Press, 1993.

YANGYANG, Z. et al. Particle swarm optimization for base station placement in mobile communication. In: . [S.l.: s.n.], 2004. v. 1, p. 428 – 432 Vol.1. ISBN 0-7803-8193-9.