

UNIVERSIDADE CANDIDO MENDES – UCAM
PROGRAMA DE PÓS-GRADUAÇÃO EM PESQUISA OPERACIONAL E
INTELIGÊNCIA COMPUTACIONAL
CURSO DE MESTRADO EM PESQUISA OPERACIONAL E INTELIGÊNCIA
COMPUTACIONAL

Willen Borges Coelho

APLICAÇÃO DE ALGORITMO GENÉTICO PARA O PROBLEMA DE
ALOCÇÃO DE PONTOS DE ACESSO EM UMA INSTITUIÇÃO
FEDERAL DE ENSINO

CAMPOS DOS GOYTACAZES, RJ
Julho de 2013

UNIVERSIDADE CANDIDO MENDES – UCAM
PROGRAMA DE PÓS-GRADUAÇÃO EM PESQUISA OPERACIONAL E
INTELIGÊNCIA COMPUTACIONAL
CURSO DE MESTRADO EM PESQUISA OPERACIONAL E INTELIGÊNCIA
COMPUTACIONAL

Willen Borges Coelho

APLICAÇÃO DE ALGORITMO GENÉTICO PARA O PROBLEMA DE
ALOCÇÃO DE PONTOS DE ACESSO EM UMA INSTITUIÇÃO
FEDERAL DE ENSINO

Dissertação apresentada ao Programa de Pós-Graduação em Pesquisa Operacional e Inteligência Computacional, da Universidade Candido Mendes – Campos/RJ, para obtenção do grau de MESTRE EM PESQUISA OPERACIONAL E INTELIGÊNCIA COMPUTACIONAL.

Orientador: Prof. Ítalo de Oliveira Matias, D.Sc.

Coorientador: Prof. Eduardo Shimoda, D.Sc.

CAMPOS DOS GOYTACAZES, RJ
Julho de 2013

C672a Coelho, Willen Borges.

Aplicação de algoritmo genético para o problema de alocação de pontos de acesso em uma instituição federal de ensino./ Willen Borges Coelho. – 2014.

70 f.; il.

Orientador: Ítalo de Oliveira Matias.

Coorientador: Eduardo Shimoda

Dissertação de Mestrado em Pesquisa Operacional e Inteligência Computacional – Universidade Candido Mendes – Campos dos Goytacazes - RJ, 2008.

Bibliografia: f. 63 - 70.

1. Algoritmo genético. 2. Alocação – pontos de acesso – wireless. 3. Heurística – inteligência computacional I. Universidade Candido Mendes. II. Título. III. Matias, Ítalo de Oliveira (orientador); IV. Shimoda, Eduardo (coorientador).

CDU – 004.036.26/056

WILLEN BORGES COELHO

APLICAÇÃO DE ALGORITMO GENÉTICO PARA O PROBLEMA DE
ALOCÇÃO DE PONTOS DE ACESSO EM UMA INSTITUIÇÃO
FEDERAL DE ENSINO

Dissertação apresentada ao Programa de Pós-Graduação em Pesquisa Operacional e Inteligência Computacional, da Universidade Candido Mendes – Campos/RJ, para obtenção do grau de MESTRE EM PESQUISA OPERACIONAL E INTELIGÊNCIA COMPUTACIONAL.

Avaliado em 05 de Julho de 2013.

BANCA EXAMINADORA

Prof. Ítalo de Oliveira Matias, DSc.– Orientador
Universidade Candido Mendes

Prof. Eduardo Shimoda, DSc
Universidade Candido Mendes Campos

Prof. Dalessandro Soares Vianna, DSc.
Universidade Federal Fluminense

CAMPOS DOS GOYTACAZES, RJ
2013

Ao meu Deus, minha família e aos grandes amigos do mestrado pelo apoio incondicional em todos os momentos na realização desse sonho.

AGRADECIMENTOS

A Deus pelo dom da vida e por conceder mais esse sonho.

À minha esposa, Alessandra Martini da Silva Coelho, pelo incentivo, compreensão e encorajamento, durante todo este período.

Ao meu filho, Arthur Martini Coelho, pelo incentivo diário em superar as barreiras e alcançar as vitórias.

Ao meu orientador, Prof. Doutor Ítalo de Oliveira Matias, pela disponibilidade, pela atenção dispensada e pela dedicação no processo de elaboração deste trabalho.

Aos meus grandes amigos do mestrado, pelos momentos de entusiasmo e dificuldade partilhados em conjunto.

Aos professores que fizeram parte dessa caminhada.

Ao Instituto Federal do Espírito Santo (IFES) e Universidade Candido Mendes Campos (UCAM - Campos), que tornaram possível a realização desse importante trabalho.

“E conhecereis a verdade, e a verdade
vos libertará”

João 8:32- Bíblia Sagrada - ACR

RESUMO

APLICAÇÃO DE ALGORITMO GENÉTICO PARA O PROBLEMA DE ALOCAÇÃO DE PONTOS DE ACESSO EM UMA INSTITUIÇÃO FEDERAL DE ENSINO

As redes locais sem fio fornecem as mesmas funcionalidades das redes convencionais com fio, porém, com maior flexibilidade, mobilidade, simplicidade e compatibilidade com diversos equipamentos, e o mais importante, prover conectividade com a internet, que tem se tornado uma ferramenta importante em pesquisas e trabalhos de diversas áreas. Pensando nisso, foi proposto o desafio encontrar o melhor posicionamento para as antenas de transmissão dentro do IFES - Instituto Federal do Espírito Santo *campus* Cachoeiro de Itapemirim, que por possui uma área superior a 25 mil metros quadrados torna a tarefa complexa. Por isso, a proposta desse trabalho foi solucionar o problema de localização de antenas no IFES, que consiste no atendimento do maior número de clientes (demandas) e na utilização do menor número de antenas (facilidades), considerando as restrições de alcance de transmissão e o menor número de sobreposição de sinal. Para isso aplicou-se matematicamente o processo de adaptação dos sistemas naturais, utilizando a heurística algoritmo genético. A ferramenta demonstrou resultados satisfatórios, fornecendo auxílio na tomada de decisão, quanto à avaliação da utilização do menor número de pontos de acesso, na minimização das áreas de colisão de sinal e na maior cobertura das demandas. Além disso, com a aplicação da ferramenta via *web*, possibilita o seu uso por outros campi, todavia sem necessitar que o profissional responsável possua conhecimento de algoritmo genético ou de programação.

PALAVRAS-CHAVE: Problema de localização; Heurísticas; Otimização; Algoritmos genéticos; Wireless.

ABSTRACT

APPLICATION OF GENETIC ALGORITHM TO THE PROBLEM OF ALLOCATION OF ACCESS POINTS IN A FEDERAL EDUCATION INSTITUTION

The wireless local area networks provide the same functionality of conventional wired networks, but with greater flexibility, mobility, simplicity and compatibility with various equipment, and most importantly, providing connectivity to the internet, which has become an important tool in research and papers in various areas. Thinking about it, it was proposed the challenge to find the best placement for the transmitting antennas within the IFES - Instituto Federal do Espírito Santo campus Cachoeiro de Itapemirim, which has an area greater than 25 square meters makes the complex task. Therefore, the purpose of this paper was to solve the problem of locating antennas at IFES, which consists in serving the largest number of customers (demand) and use the smallest number of antennas (facilities), considering the constraints of transmission range and smallest number of overlapping signal. For this applied mathematically the process of adaptation of natural systems, using the heuristic genetic algorithm. The tool demonstrated satisfactory results, providing aid in decision making, regarding the evaluation of the use of the smallest number of access points and greater coverage of demands. Moreover, with the use of the tool via a web browser, enables its use by other campuses, but without requiring the professional responsible genetic algorithm has knowledge or programming.

KEYWORDS: Location problem, Heuristics, Optimization, Genetic algorithms, Wireless.

LISTA DE FIGURAS

Figura 1	Localização geográfica dos campi do IFES no Espírito Santo	18
Figura 2	Exemplo de configuração do PMP	27
Figura 3	Exemplo de configuração de PMP com raio de alcance máximo	27
Figura 4	Exemplo de configuração do PLMC	28
Figura 5	Estrutura de um Evolution Program (HOLLAND, 1975)	29
Figura 6	Distribuição do AG dentro das técnicas de busca. (LINDEN, 2008)	31
Figura 7	Exemplo de representação cromossomial	32
Figura 8	Paisagem de aptidão (SOLÉ, MANRUBIA et al., 1999)	33
Figura 9	Planta estrutural do IFES	37
Figura 10	Fórmula do Teorema de Pitágoras	38
Figura 11	Fluxograma do algoritmo	39
Figura 12	Resultado contendo colisões de sinal	41
Figura 13	Método da roleta: com base na aptidão	42
Figura 14	Processo de cruzamento	42
Figura 15	Processo de Mutação	43
Figura 16	Gráficos para acompanhamento da avaliação da população	43
Figura 17	Mutação da função de viabilidade	44
Figura 18	Pseudocódigo da função de viabilidade	45
Figura 19	Resultado numérico da solução	46
Figura 20	Resultado gráfico da solução	46
Figura 21	Parâmetros da regressão da aptidão em função da mutação	49
Figura 22	Gráfico Cúbico-Raiz entre aptidão em função da taxa de mutação	50

Figura 23	Gráfico Cúbico entre aptidão em função da taxa de crossover	52
Figura 24	Gráfico Cúbico-Raiz entre aptidão em função do número de gerações	52
Figura 25	Gráfico comparativo da média da aptidão da população antes e depois do ajuste nos parâmetros	53
Figura 26	Gráficos da aptidão da população no decorrer das gerações, antes e depois da alteração dos parâmetros.	54
Figura 27	Resultado gráfico de solução satisfatória	56
Figura 28	Comparação dos resultados	58
Figura 29	Resultado gráfico obtido com o resultado de Lorena, Senne et al. (2001)	59
Figura 30	Resultado gráfico da solução atual	60

LISTA DE TABELAS

Tabela 1	Valores propostos na literatura	34
Tabela 2	Matriz de localização	37
Tabela 3	Matriz de distâncias	38
Tabela 4	Parâmetros utilizados no primeiro experimento	48
Tabela 5	Alguns dados obtidos no primeiro experimento	48
Tabela 6	Parâmetros utilizados no segundo experimento	50
Tabela 7	Alguns dados obtidos do segundo experimento	51
Tabela 8	Parâmetros propostos através dos experimentos	53
Tabela 9	Resultados numéricos	58

LISTA DE ABREVIATURAS E SIGLAS

PMP	- P-Median Problem
PLMC	Problema Delocalização de Máxima Cobertura
AG	Algoritmo Genético
EP	Evolution Program
IFES	Instituto Federal de Educação, Ciência e Tecnologia do Espírito Santo
CTI	Coordenadoria de Tecnologia da Informação

SUMÁRIO

1	INTRODUÇÃO	14
1.1	PRELIMINARES	14
1.2	IFES (ESTUDO DE CASO)	17
2	OBJETIVOS	19
2.1	OBJETIVO GERAL	19
2.2	OBJETIVOS ESPECÍFICOS	19
2.3	DEFINIÇÃO DO PROBLEMA	20
2.3.1	Modelagem matemática	20
2.3.1.1	Parâmetros	21
2.3.1.2	Índices	21
2.3.1.3	Variáveis de decisão	22
2.3.1.4	Modelo	22
3	REVISÃO DE LITERATURA	24
3.1	PROBLEMAS DAS P-MEDIANAS	24
3.2	PROBLEMA DE LOCALIZAÇÃO DE MÁXIMA COBERTURA	25
3.3	ALGORITMO GENÉTICO	29

3.4	PARÂMETROS DE ALGORÍTMO GENÉTICO	33
4	METODOLOGIA	36
4.1	REPRESENTAÇÃO CROMOSSÔMICA	38
4.2	DESCRIÇÃO DO ALGORITMO	39
4.3	EXPERIMENTOS	47
4.3.1	Primeiro Experimento	47
4.3.2	Segundo Experimento	50
4.3.3	Comparações	52
5	RESULTADOS E DISCUSSÃO	55
6	CONSIDERAÇÕES FINAIS	61
6.1	TRABALHOS FUTUROS	62
7	REFERÊNCIAS BIBLIOGRÁFICAS	63

1 INTRODUÇÃO

1.1 PRELIMINARES

Localizar um determinado ponto, dentro de uma região pré-estabelecida, para instalar um serviço específico, de forma mais apropriado é um problema que pode ser aplicado no mundo real. Existem problemas que necessitam de um único ponto ou de vários, conhecidos como facilidades. Esses pontos de facilidades podem ser associados à melhor localização de hospitais, escolas, indústrias, depósitos, dentre outros. Como também podem estar associadas à localização de antenas, para fornecer acesso de internet ou celular, contudo em locais no quais possam atender um número maior de habitantes ou clientes, de forma a maximizar ao máximo a cobertura de atendimento.

As redes de computadores passaram a ter fundamental importância com o avanço da tecnologia e com a difusão dos computadores, e atualmente eles estão presentes no mercado de trabalho e consequentemente nas escolas. Entretanto, a manutenção de uma rede convencional com fio é muitas das vezes complexa e impossibilitam, por exemplo, que se coloque uma mesa onde não haja uma tomada de rede ou que se tenha um número de computadores superior ao número de tomadas de rede em determinada sala, obrigando em alguns casos que se execute uma obra para ampliação, demandando um alto custo e uma paralisação temporária do local.

Uma alternativa para as redes com fio, é a tecnologia de redes locais sem fio, também denominada *Wireless Local Area Network* (WLAN), que permite fornecer as mesmas funcionalidades das redes convencionais com fio, porém, com maior flexibilidade, mobilidade, simplicidade e compatibilidade com diversos equipamentos,

como por exemplo: *notebooks*, *smartphones*, *tablets* e videogames. O padrão que especifica a comunicação entre dispositivos wireless é o IEEE 802.11, promovido pelo IEEE (*Institute of Electrical and Electronic Engineers*). A diminuição de custos tem acelerado o seu crescimento, com isso, o Instituto Federal de Educação, Ciência e Tecnologia do Espírito Santo (IFES) *campus* Cachoeiro de Itapemirim elaborou uma meta de conceder acesso à rede interna e internet para alunos, professores e visitantes através da tecnologia de rede sem fio.

Ao se comparar uma rede convencional com fio e uma sem fio, percebe-se que esta última também possui deficiências, uma delas em virtude da mesma utilizar ondas eletromagnéticas como meio de transmissão, tendo desta forma limite na área de abrangência do sinal, além da perda de sinal ao atravessar obstáculos. Portanto, para maximizar a área de cobertura é necessário que os pontos de facilidades (antenas) estejam em locais com maior número de demandas (clientes) sendo atendidos e com menor número de obstáculos. Contudo, é necessária uma análise para localizar os pontos de demanda, a fim de possibilitar uma análise posterior para encontrar o melhor posicionamento dos pontos de facilidade. Porém, as variáveis envolvidas para a tomada de decisão, como por exemplo, localização de instalação das antenas, alcance de transmissão do sinal, qualidade do sinal, locais de demanda, dentre outros, tornam o problema complexo.

É possível localizar esses pontos utilizando o Problema das p -Medianas (*p-Median Problem* - PMP), que inicialmente foi proposto por Hakimi (1964) para resolução de apenas uma mediana, e, em seguida, aperfeiçoada para a identificação de múltiplas medianas (Hakimi, 1965; Kariv e Hakimi, 1979). O objetivo do PMP é localizar p vértices (facilidades) em um grafo contendo n vértices (demandas), de tal forma a minimizar o somatório das distâncias de cada facilidade até a mediana mais próxima.

Segundo Garey e Johnson (1979), o PMP pertence à classe NP-difíceis (*non-deterministic polynomial time hard* - NP-hard) e possui ordem de complexidade exponencial, isto é, para sua resolução é necessário um esforço computacional que cresce exponencialmente com o tamanho do problema (número de vértices). É possível solucionar através de algoritmo exato, aplicando o método exaustivo, que combina todas as soluções possíveis. Entretanto, sendo somente apropriado para problemas de pequeno porte.

Para problemas de grande porte faz-se necessário a utilização de métodos heurísticos e metaheurísticos em sua resolução, pois conseguem boas soluções em tempos aceitáveis, tendo em vista complexidade do problema. Diversos métodos heurísticos têm sido desenvolvidos para o PMP, dentre eles: métodos que exploram busca em árvore (Teitz e Bart, 1968), *branch-and-bound* (Neebe, 1978), relaxação Lagrangeana (Beasley, 1993) e mais recentemente a relaxação Lagrangeana/*Surrogate* (Lorena, Senne *et al.*, 2001).

De acordo com Michalewicz (1996) o Algoritmo Genético (AG), considerado como um *evolution program* (EP), é um algoritmo probabilístico que mantém uma população de indivíduos para n interações, sendo que cada indivíduo (ou cromossomo) representa uma potencial solução para o problema. Essas soluções são submetidas à avaliação para distinguir sua aptidão (*fitness*). Então uma nova população é formada da seleção dos indivíduos mais aptos e os membros da nova população sofrem transformações por meio dos operadores genéticos, para formar novas soluções. Os novos indivíduos são submetidos ao processo de cruzamento (*crossover*), ou seja, os indivíduos (pais) selecionados são combinados formando novos indivíduos (filhos). Depois esses novos indivíduos são submetidos ao processo de mutação, a fim de buscar características novas, tornando-os diferentes de seus pais.

Solucionar o problema de localização de antenas no Instituto Federal de Educação, Ciência e Tecnologia do Espírito Santo (IFES) *campus* Cachoeiro de Itapemirim é o que motiva a implementação do processo de adaptação dos sistemas naturais, utilizando a heurística AG, introduzido inicialmente por Holland (1975), que consiste no atendimento do maior número de clientes (demandas) e na utilização do menor número de rádios e antenas (facilidades), considerando as restrições de alcance de transmissão das antenas. Além disso, desenvolver uma ferramenta que possibilite que profissionais sem conhecimento de heurísticas, algoritmo genético ou programação possam utilizá-la.

A relevância deste trabalho está em apresentar uma aplicação que solucione o problema da localização das facilidades, obtendo um resultado satisfatório em tempo viável. Com isso, reduzir o custo de aquisição das facilidades, cobrir ao máximo as áreas de demanda com um bom desempenho e oferecer acesso à rede interna e internet para servidores, alunos e visitantes para a realização de pesquisas e trabalhos, um dos objetivos de uma Instituição de Ensino.

1.2 IFES (ESTUDO DE CASO)

O IFES foi criado oficialmente em 1909, sob o nome de Escola de Aprendizizes Artífices do Espírito Santo (EEA). De acordo com Sueth (2009), nesse período existia somente uma escola em todo Espírito Santo, em Vitória na capital, seu propósito era formar profissionais artesãos, voltados para o trabalho manual. Com a reforma educacional do ministro Gustavo Capanema Filho, a EEA foi transformada em Escola Técnica de Vitória (ETV). Em 1965, passou a ser chamada Escola Técnica Federal do Estado do Espírito Santo (ETFES) e, em 1999 passou a ser chamada de Centro Federal de Educação Tecnológica (CEFET).

No ano de 2005, começou a funcionar a Unidade de Ensino Descentralizada (UNED) de Cachoeiro de Itapemirim, oferecendo o Curso Técnico em Eletromecânica e o Curso Técnico em Rochas Ornamentais. Depois foi oferecido o Curso Técnico em Informática, além dos cursos integrados e de nível superior, Engenharia de Minas e Licenciatura em Matemática. Atualmente também é oferecido o Curso de Licenciatura em Informática na modalidade à distância.

No final do ano de 2009, por decreto presidencial, o CEFET transformou-se Instituto Federal de Educação, Ciência e Tecnologia do Espírito Santo, composto por 15 *campi*, sendo 12 *campi* do antigo CEFET e 3 escolas agrotécnicas federais, mais a Reitoria, sediada em Vitória. Com a mudança a UNED de Cachoeiro de Itapemirim passou a chamar-se IFES *campus* Cachoeiro de Itapemirim. Atualmente o número de *campi* é maior, como pode ser observado na Figura 1.

A Coordenadoria de Tecnologia da Informação (CTI) é responsável pela área de tecnologia da informação do IFES *campus* Cachoeiro de Itapemirim. Dentre suas principais atividades, pode-se mencionar, a responsabilidade pela infraestrutura de rede sem fio, isto é, o posicionamento das antenas, a manutenção do serviço e o fornecimento de acesso à rede interna e internet para os servidores, alunos e visitantes.

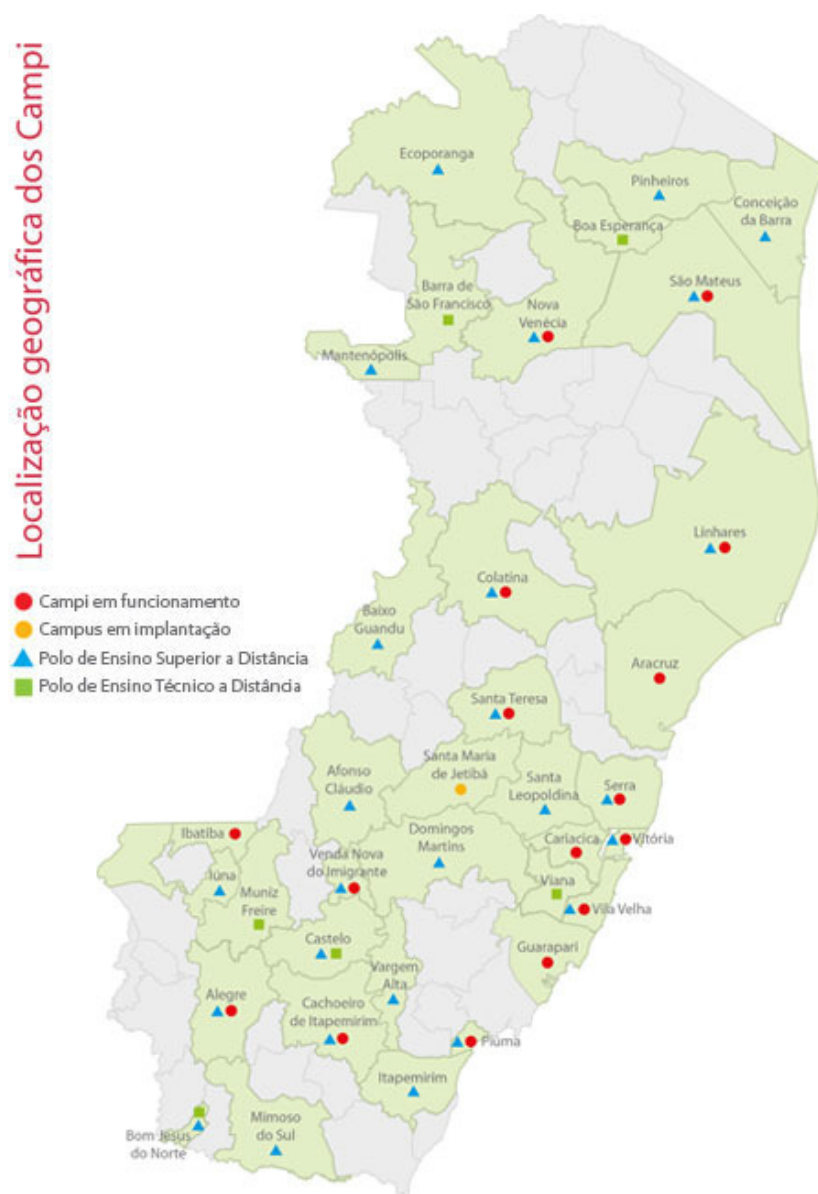


Figura 1 - Localização geográfica dos *campi* do IFES no Espírito Santo

2 OBJETIVOS

2.1 OBJETIVO GERAL

O presente trabalho tem como objetivo geral o desenvolvimento de uma ferramenta com inteligência computacional capaz de decidir pelo ótimo posicionamento das antenas disponíveis no IFES *campus* Cachoeiro de Itapemirim, de modo que seja uma distribuição inteligente, com o objetivo de maximizar a cobertura dos pontos de demanda e ao mesmo tempo reduzir as áreas com colisão de sinal, priorizar os locais com número de demandas alto e minimizar o número de facilidades.

2.2 OBJETIVOS ESPECÍFICOS

Este trabalho tem os seguintes objetivos específicos:

- Apresentar os problemas de localização;
- Aplicar o método do Problema de Localização de Máxima Cobertura (PLMC);
- Implementar a metaheurística Algoritmo Genético (AG);
- Desenvolver um aplicativo de fácil utilização para usuários sem conhecimento de programação e heurísticas.
- Desenvolver o aplicativo no formato web;
- Otimizar os parâmetros do AG;
- Desenvolver uma forma simples de informar os pontos de demanda que precisam de cobertura de rede sem fio, através de uma imagem contendo a

planta da área em escala, a fim de possibilitar o aplicativo calcular a distância euclidiana de todos os pontos.

- Implementar o resultado no formato gráfico, de forma que seja identificado os pontos eleitos como facilidade, quais demandas foram atendidas e por qual facilidade, o raio de abrangência do sinal e as demandas que não foram atendidas, com base na imagem original.
- Informar no formato numérico, as informações do resultado, como por exemplo: quantidade de pontos eleitos como facilidade, quantidade de demandas atendidas, percentual de demandas atendidas, quantidade de demandas não atendidas e quantidade de colisões de sinal.

2.3 DEFINIÇÃO DO PROBLEMA

De acordo com Lorena, Senne *et al.* (2001), os problemas de localização em alguns casos podem possuir restrições em relação à capacidade de atendimento da facilidade, isto é, cada facilidade possui uma capacidade de atendimento e a soma das demandas dos pontos cobertos não pode ultrapassá-la. Quando essa condição estiver presente, trata-se de um problema de localização com restrição de capacidade ou problema das p-medianas capacitado (PMPC).

Neste trabalho, utilizou-se o equipamento marca 3com/H3C modelo WA2110 (Apêndice A), que suporta até 64 usuários simultâneos, como objeto de estudo e como base para o desenvolvimento da solução proposta. Entretanto, em nenhum resultado as facilidades ultrapassaram a capacidade de atendimento da antena ou até mesmo excedeu os 60% (38 usuários) da capacidade da antena. Logo, o problema exposto neste trabalho corresponde ao modelo de localização não capacitado, pelo fato de que não são impostos limites ao tamanho das facilidades e considera apenas a distância entre o ponto de demanda e o ponto de facilidade e a colisão de atendimento, quando um ponto de demanda pode ser atendido por mais de uma facilidade, para efeito de avaliação.

2.3.1 Modelagem Matemática

Para este tipo de modelagem, no qual são necessários objetivos simultâneos, foi empregado o uso de pesos, definidos empiricamente, a fim de possibilitar que a solução almejada seja alcançada. Pois, além de maximizar o número de demandas cobertos, é necessário que seja minimizado o número de facilidades empregadas e o número de demandas que podem ser atendidos por mais de um ponto de facilidade (colisão de sinal). Para isso, realizaram-se testes empíricos com a finalidade de obter os pesos. Logo, cada ponto de demanda coberto recebe um benefício de 5 pontos, cada ponto de facilidade empregado recebe uma penalidade de 4 pontos e cada demanda que pode ser atendida por mais de uma facilidade recebe uma penalidade de 2 pontos.

O problema abordado pode ser modelado por um grafo $G(V,A)$, no qual V representa o conjunto de vértices e A o conjunto de arestas. Os vértices representam os pontos de demanda. Um aresta (u,v) pertencerá ao conjunto A se a distância entre os pontos de demandas (vértices) u e v não ultrapassar um valor pré-estabelecido. A seguir é apresentado o modelo de programação inteira para o problema abordado. Primeiramente os parâmetros do problema são descritos, seguidos pelos índices de intervalo, as variáveis de decisão e, finalmente, pela função objetivo e suas restrições, juntamente com a descrição de cada uma delas.

2.3.1.1 Parâmetros

N – Número total de demandas. (É obtido através da imagem)

L – Número máximo de antenas.

M – Valor grande.

p_1 – Benefício dado a cada ponto de demanda coberto.

p_2 – Penalidade dada a cada ponto de facilidade alocado.

p_3 – Penalidade dada a cada ponto de demanda que pode ser atendido por mais de um ponto de facilidade (colisão de sinal).

2.3.1.2. Índices

i – Índices dos pontos de demanda. $i \in [1, N]$.

j – Índices dos pontos de facilidade. $j \in [1, M]$.

V- Conjunto de vértices.

A - Conjunto de arestas.

2.3.1.3. Variáveis de Decisão

X_{ij} – Variável binária que representa as demandas no ponto i que estão sendo atendidas pela facilidade no ponto j .

Y_j – Variável binária que representa uma facilidade no ponto j .

Z_i – Variável binária que representa se houveram colisões no atendimento da demanda no ponto i .

$$X_{ij} = \begin{cases} 1 & \text{A facilidade } j \text{ foi alocada para atender a demanda } i. \\ 0 & \text{Caso contrário.} \end{cases}$$

$$Y_j = \begin{cases} 1 & \text{O ponto } j \text{ foi alocado como facilidade.} \\ 0 & \text{Caso contrário.} \end{cases}$$

$$Z_i = \begin{cases} 1 & \text{O ponto } i \text{ pode ser atendido por mais de uma facilidade (colisão).} \\ 0 & \text{Caso contrário.} \end{cases}$$

2.3.1.4. Modelo

$$\text{Max} \quad p1 \sum_{i \in V} \sum_{j \in V} X_{ij} - p2 \sum_{j \in V} Y_j - p3 \sum_{i \in V} Z_i \quad (1)$$

Sujeito a:

$$\sum_j X_{ij} \leq 1 \quad \forall i \in V \quad (2)$$

$$\sum_j Y_j \leq L \quad (3)$$

$$X_{ij} \leq Y_j \quad \forall i, j \in V \text{ e } (i, j) \in A \quad (4)$$

$$LZ_i \geq -\left(1 - \sum_j X_{ij}\right)M + \sum_{j \in V \text{ e } (i, j) \in A} Y_j - \sum_j X_{ij} \quad \forall i, j \in V \quad (5)$$

$$Y_j \in \{0,1\} \quad \forall j \quad (6)$$

$$Z_i \in \{0,1\} \quad \forall i \quad (7)$$

$$X_{ij} \in \{0,1\} \quad \forall i, j \quad (8)$$

No qual:

- 1) Função objetivo que visa maximizar o número de pontos de demandas cobertos, minimizando ao mesmo tempo o número de pontos de facilidades empregados e o número de colisões.
- 2) Afirma que cada demanda no ponto i só pode ser atendida por no máximo um ponto de facilidade.
- 3) Afirma que o número de facilidades empregadas deve ser inferior ou igual a L .
- 4) Afirma que uma demanda só pode ser atendida por um ponto de facilidade se este estiver aberto.
- 5) Verifica se há colisões no ponto i . A primeira parcela verifica quantos pontos de facilidades abertos podem atender o ponto i . A segunda parte permite que uma demanda seja atendida por um ponto de facilidade sem penalidades. A última parte garante que se a demanda não é coberta, nenhuma penalidade seja gerada.

3 REVISÃO DE LITERATURA

3.1 PROBLEMAS DAS P-MEDIANAS

Encontrar a localização ideal para um ponto de facilidade, seja nos dias atuais ou na antiguidade, é um problema que sempre esteve presente na vida da humanidade. Os povos primitivos buscavam locais com acesso à água, árvores frutíferas e animais, para poderem se alimentar e também poderem se acomodar. Se no passado, determinar a localização ideal dependia da intuição dos líderes ou gestores, atualmente, essa decisão deve estar amparada em métodos científicos, que vem sendo aperfeiçoados com o passar dos anos.

Segundo Azzoni (1982), o economista alemão Johann Heinrich Von Thünen foi o primeiro a tratar do problema da localização, em 1826, estudando a melhor localização de atividades agrícolas em torno de uma cidade. Em 1909, o economista alemão Alfred Weber aborda em seu trabalho que a localização ótima para a instalação de uma indústria, advém do equilíbrio da distância entre as três pontos fixos: matéria-prima, centro de consumo e mão de obra. A metodologia das p-medianas, surge a partir do trabalho de Weber.

A partir de 1960 houve um crescente interesse em problemas de localização, no qual se buscava determinar o número e a localização de centros que possam suprir, de forma mais econômica, um conjunto de clientes de localização conhecida. Vários autores, a fim de facilitar o estudo do modelo, classificaram os problemas de localização em três categorias: localização no plano com espaço de soluções infinito (os centros podem ser localizados em qualquer ponto do plano), localização no plano com espaço de soluções finito (os centros são limitados a um conjunto de

pontos previamente escolhidos) e localização em redes (o espaço de soluções consiste apenas de pontos da rede) (Galvão, 1981).

De acordo com Lacerda (1998), os estudos que tratam da localização de instalações possuem grande aproveitamento no mundo real em estudos exploratórios, análise de cenários ou problemas concretos, sendo estabelecidos em diferentes níveis de decisões: estratégico (determinação do número, tamanho e localização de fábricas e depósitos), tático (definição da alocação dos clientes aos centros de distribuição e dos centros de distribuição às fábricas) ou operacional (elaboração de planos de contingência, onde se pretende realocar de forma ótima os clientes em caso, por exemplo, da parada de uma linha de produção em uma das fábricas).

Garey e Johnson (1979) classifica, na teoria de NP-completude, os problemas de otimização combinatória em: P (*polynomial time*), NP (*non-deterministic polynomial time*), NP-difícil e NP-completo. A complexidade dos problemas P crescem polinomialmente em função do número de vértices e podem ser solucionados por algoritmos determinísticos. Logo os problemas NP crescem exponencialmente em função do número de vértices, são considerados intratáveis e, com isso só podem ser solucionados por algoritmos não-determinísticos, ou seja, na maioria dos trabalhos encontrados na literatura são utilizados abordagens heurísticas em sua resolução, já que os mesmos apresentam boas soluções em um tempo aceitável. Desta forma, opta-se por uma boa solução, ao invés de procurar pela solução ótima.

Garey e Johnson (1979) destaca ainda, em seu livro intitulado “*Computers and Intractability: A Guide to the Theory of NP-Completeness*”, que o PMP pertence à classe NP-difícil. Para problemas dessa classe são necessárias soluções alternativas, pois através do método exato é necessário um tempo computacional muito alto em sua resolução. Diversos métodos heurísticos têm sido desenvolvidos para o PMP, dentre eles: métodos que exploram busca em árvore (Teitz e Bart, 1968), *branch-and-bound* (Neebe, 1978), relaxação Lagrangeana (Beasley, 1993), mais recentemente a relaxação Lagrangeana/*Surrogate* (Lorena, Senne *et al.*, 2001) e o AG (Holland, 1975).

3.2 PROBLEMA DE LOCALIZAÇÃO DE MÁXIMA COBERTURA

O PLMC surgiu no trabalho de Church e Reville (1974), eles consideraram que a distância ou o tempo que o utilizador mais distante de uma instalação teria que percorrer para atingir essa facilidade como a segunda medida mais importante, considerando a eficácia de um problema de localização, sendo denominado como a distância máxima de serviço. Toregas e Reville (1972) também discutem sobre a utilização de uma distância máxima de serviço como uma medida de valor em um problema de localização. Analisando uma solução de localização, sem considerar a distância máxima de serviço, a maior distância entre a demanda e sua facilidade, refletiria no pior desempenho possível do sistema.

Segundo Church e Reville (1976), na versão original do PMP, não há restrição em relação à distância de um grupo de demandas para o ponto de facilidade mais próximo, mas sim a menor distância média de um grupo de demandas em relação ao seu ponto de facilidade, exigindo que todos os pontos de demanda sejam atendidos, como pode ser visualizada na Figura 2. Contudo nem sempre a facilidade possui capacidade de alcance suficiente para garantir a cobertura total à demanda, como pode ser observado na Figura 3, no qual foi inserido o raio de alcance máximo da facilidade. Com a inclusão de um limite de distância para um grupo de demandas alcançarem o seu ponto de facilidade, pode-se minimizar a distância média. Este problema tem sido denominado como o problema de p-medianas com restrição de distância máxima (KHUMAWALA, 1973).




Figura 2 - Exemplo de configuração do PMP




Figura 3 - Exemplo de configuração de PMP com raio de alcance máximo

O PLMC consiste em escolher a melhor localização para instalar os pontos de facilidade de forma que o maior número de pontos de demandas seja coberto, isto é,

maximizar a cobertura dentro de uma desejada distância T localizando um número fixo de facilidades, a Figura 5 ilustra o funcionamento do PLMC. Garantiu-se dessa forma que as demandas sejam atendidas com qualidade, visto que não existem antenas de transmissão com alcance ilimitado.




Figura 4 - Exemplo de configuração do PLMC

Pode-se encontrar na literatura uma diversificada aplicação do PLMC para a localização de facilidades, dentre eles localização de: bases de ambulância para atendimento médico (ADENSO-DÍAZ e RODRÍGUEZ, 1997; Azizan, Cheng Siong *et al.*, 2012), sirenes de alerta de emergência em uma cidade (CURRENT e O'KELLY, 1992), agências bancárias a fim de maximizar o recolhimento de fundos (Goberna, LOPEZ *et al.*, 1990), abrigos em caso de evento catastrófico em uma cidade (REN, CHEN *et al.*, 2009), postos de combustíveis alternativos no estado da Flórida (LIM e Kuby, 2010), transmissores para o planejamento de rede de celular (TUTSCHKU, 1998) e instalações para atender uma emergência no caso de ataque bio-terrorista de grande escala de antraz na cidade de Los Angeles (MURALI, ORDÓÑEZ *et al.*, 2012).

O PLMC também pertence à classe NP-difícil, assim como o PMP, sendo necessária a utilização de métodos heurísticos como solução alternativa, visto que o esforço computacional necessário em sua resolução é muito alto. Diversos métodos heurísticos têm sido desenvolvidos para o PLMC, dentre eles: relaxação Lagrangeana (GALVÃO e REVELLE, 1996), utilizando busca tabu (ADENSO-DÍAZ e RODRÍGUEZ, 1997), algoritmo guloso (CHURCH e REVELLE, 1974) e utilizando AG (JARAMILLO, BHADURY *et al.*, 2002).

3.3 ALGORITMO GENÉTICO

O AG foi sugerido inicialmente por Holland (1975), no qual se utiliza dos mecanismos naturais de evolução das espécies para solucionar diversos problemas práticos de busca e otimização. Esses problemas podem ser resolvidos através de algoritmos exatos, ou seja, aplicando o método exaustivo, que verifica todas as combinações possíveis. Entretanto, devido à sua complexidade e o tempo computacional necessário para a definição do melhor resultado, opta-se por utilizar métodos heurísticos para alcançar soluções satisfatórias, em um tempo computacional aceitável. Após o trabalho de Holland (1975), diversos conteúdos na literatura (GOLDBERG, 1989;); (DAVIS, 1991); (MICHALEWICZ, 1996) e em trabalhos (BEASLEY, BULL *et al.*, 1993); (BEASLEY, MARTIN *et al.*, 1993): (SRINIVAS e PATNAIK, 1994); (WHITLEY, 1994) tornaram-se disponíveis.

Procedimento EP

```

01   $t \leftarrow 0$ ;
02  Inicializar  $P(t)$ ;
03  Avaliar  $P(t)$ ;
04  enquanto (critério de parada não for alcançado) faça
05       $t \leftarrow t + 1$ ;
06      Selecciona  $P(t)$  de  $P(t - 1)$ ;
07      Altera  $P(t)$ ;
08      Avaliar  $P(t)$ ;
09  fim enquanto;
10  fim procedimento

```

Figura 5 - Estrutura de um evolution program (HOLLAND, 1975).

Na figura 5 é apresentado o pseudocódigo da estrutura do EP proposto por Holland (1975). O pseudocódigo exposto pode ser considerado genérico para um AG, devido às muitas implementações encontradas na literatura e a variedade de operadores incorporados atualmente, porém serviu de contribuição para todos os sistemas baseados em evolução.

Man, Tang *et al.* (1996) argumenta que o AG é inspirado nos mecanismos naturais, um processo biológico em que os indivíduos mais fortes são provavelmente os vencedores em um ambiente de competição, uma analogia direta à evolução natural. Presume-se que a solução de um potencial problema é um indivíduo e pode ser representado por um conjunto de parâmetros. Esses parâmetros são considerados como os genes de um cromossomo e pode ser estruturado por uma sequência de valores na forma binária. Um valor positivo, comumente conhecido como fitness, é empregado para avaliar o cromossomo escolhido para resolver o problema, e este valor está diretamente relacionado com a sua função objetivo.

Conforme Linden (2008), os algoritmos evolucionários utilizam o sistema natural de evolução para solucionar problemas. Existem uma variedade de modelos computacionais de evolução natural propostos, e todos tem em comum o conceito de evolução natural das espécies, através dos operadores genéticos. Os algoritmos evolucionários são considerados como técnicas de busca. Eles fazem parte de um grupo denominado de "Técnicas Aleatórias Guiadas", isto é, possuem componentes

aleatórios, mas se utilizam das informações da população corrente para guiar a pesquisa, diferenciando-se assim de métodos puramente aleatórios. A estrutura completa da classificação dos métodos de busca pode ser vista na Figura 6.

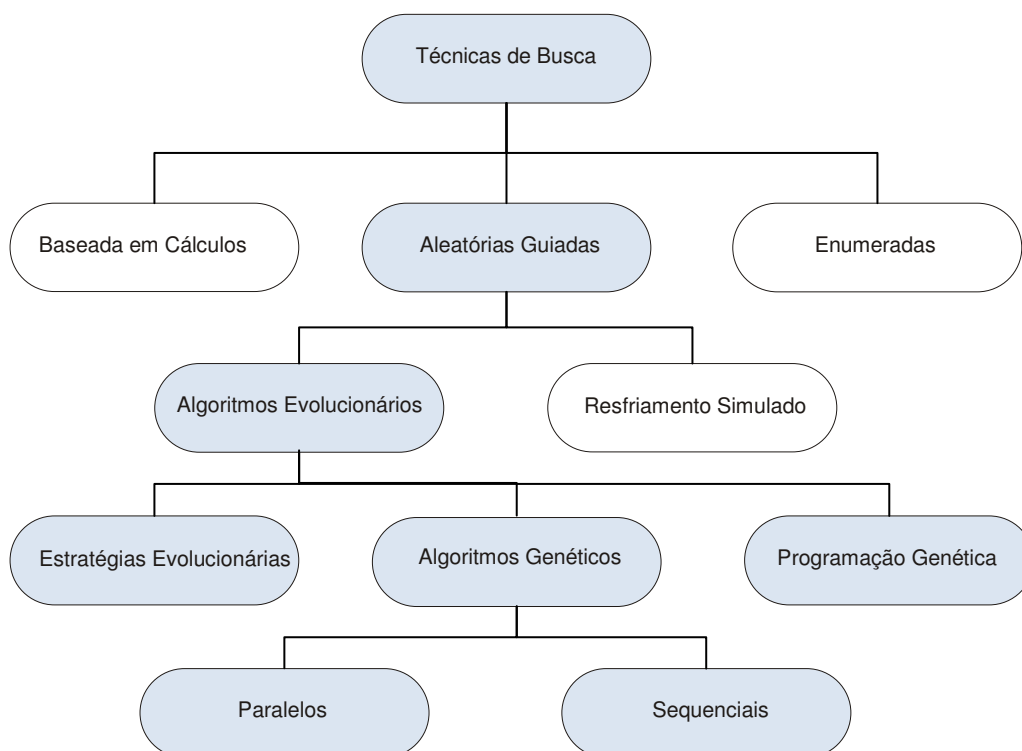


Figura 6 - Distribuição do AG dentro das técnicas de busca. (LINDEN, 2008)

Segundo Michalewicz (1996), os AG pertencem à classe dos algoritmos probabilísticos, mas eles são muito diferentes dos problemas aleatórios, pois combinam elementos da busca direta e estocástica. Devido a isso, os AG são também mais robustos que os métodos existentes de pesquisa direta, e visam problemas complexos. Outra propriedade importante dos métodos de pesquisa do AG, é que eles mantêm uma população de potenciais soluções, distinta de todos os outros métodos que processam um único ponto do espaço de busca.

Linden (2008) destaca ainda em seu livro, a importância da representação cromossomial para o AG, pois através dela é possível uma maneira de traduzir a informação do nosso problema, em uma maneira viável, que possa ser calculada pelo computador. Cada pedaço indivisível desta representação é chamado de um gene, formando um indivíduo ou cromossomo com a união de todos os genes. Sendo assim, um problema que possui 40 pontos de demandas e 5 pontos de

facilidades, será formado por um cromossomo de 45 genes, sendo diferenciado pelo valor binário do gene (0, 1), conforme exemplo mostrado na Figura 7. Caso o gene seja demanda terá o valor 0 (zero) e caso o gene seja facilidade terá valor 1 (um).




Figura 7 - Exemplo de representação cromossomial

A implementação do AG inicia com a criação de uma população aleatória de indivíduos. Esses indivíduos são, então, submetidos a um processo avaliativo, de modo que os melhores indivíduos tenham probabilidade maior de serem escolhidos para a próxima geração, proporcionando o que na natureza é denominado de "sobrevivência do mais forte".

Os indivíduos escolhidos, finalmente são selecionados para os dois operadores genéticos clássicos, descrito por Michalewicz (1996) como: *crossover* e *mutação*. Esses métodos são necessários para que seja possível o surgimento de novos indivíduos e se consiga gerar populações sucessivas que melhorem sua aptidão com o tempo. Dessa forma, os novos indivíduos herdam as características de seus pais, ou seja, a população é diversificada e mantém características de adaptação adquiridas pelas gerações anteriores. Possibilitou-se também que soluções melhores possam ser encontradas, evitando que a busca convirja para máximos locais, isto é, ampliando a varredura da busca para todo conjunto solução, procurando sempre por resultados melhores.

De acordo com (SOLÉ, MANRUBIA *et al.*, 1999) a seleção natural é interpretada em termos como um processo de subida de montanha, dirigindo a população em direção ao pico mais próximo atual. Contudo a finalidade da mutação é evitar que a busca fique "presa" em um máximo local, portanto ela diversifica o

indivíduo modificando o espaço de busca dentro do conjunto solução, possibilitando a busca de um novo máximo, podendo o mesmo ser até um máximo global. Na Figura 8 pode-se observar uma paisagem de aptidão tridimensional, no qual é possível identificar diversos máximos locais e somente um máximo global (melhor resultado).




Figura 8 - Paisagem de aptidão (SOLE; MANRUBIA *et al.*, 1999)

3.4 PARÂMETROS DO ALGORITMO GENÉTICO

O AG possui parâmetros que influenciam diretamente na qualidade do resultado e no tempo computacional gasto, por isso o ajuste dos parâmetros é de extrema importância. Os AG utilizam no mínimo três parâmetros numéricos: probabilidade de cruzamento, probabilidade de mutação e tamanho da população (ou número de indivíduos). Devido a sua importância, existem diversos trabalhos científicos que elaboram experimentos acerca do ajuste dos parâmetros do AG, dos

quais destacamos (JONG, 1975); (GREFENSTETTE, 1986); (GOLDBERG, 1989); (SCHAFFER, CARUANA *et al.*, 1989).

Jong (1975) testou combinações distintas nos parâmetros do AG com base em cinco funções com características diversas, incluindo contínua e descontínua, convexo e não convexo, uni modal e multi modal, determinística e não determinístico em sua tese de doutorado. Sua *suíte* de funções já foi aprovada por vários pesquisadores como base de teste padrão para avaliar projetos de AG (HORN e GOLDBERG, 1996); (HENDTLASS, 2001); (GIGER, KELLER *et al.*, 2007); (PAPERIN, 2008); (KOK e SANDROCK, 2009).

Jong (1975) utilizou AG simples com seleção por roleta, um único ponto de cruzamento e mutação simples para investigar os efeitos de quatro parâmetros: tamanho da população, taxa de cruzamento, taxa de mutação e o número de gerações. Suas principais conclusões foram:

- Aumentar o tamanho da população resultou em um desempenho melhor em longo prazo, mas a população menor respondeu mais rapidamente e, portanto, apresentaram resultados iniciais melhores.
- A mutação é necessária para restaurar alelos perdidos, mas isso deve ser mantido em probabilidades baixas, senão o AG degenera e proporciona em uma busca aleatória.
- A probabilidade de cruzamento em torno de 60% obteve o melhor resultado. Mas o aumento dessa probabilidade favoreceu a degradação do desempenho.
- O modelo de população não sobreposta funcionou melhor em geral.

Segundo Jong (1975), o conjunto de parâmetros que foram mais eficientes nas funções que ele estudou, estão representadas na Tabela 1. Seu trabalho foi muito importante na medida em que forneceu orientações práticas para a aplicação do AG. Suas recomendações têm sido vastamente adotado e muitas vezes referido como configuração padrão. Entretanto, a aplicação inconsequente dos valores, em alguns casos pode ser um erro grave.

Tabela 1 - Valores propostos na literatura

Autor	Cruzamento	Mutação	Indivíduos
Jong	60%	0,1%	50-100
Grefenstette	95%	1%	30
Schaffer	75% - 95%	0,5% - 10%	20-30

Mais tarde, Grefenstette (1986) nota que, o AG pode ser utilizado como um procedimento de otimização para otimizar os parâmetros de outro AG. Nos experimentos, a meta-heurística AG evoluía uma população de 50 indivíduos, tendo como objetivo aperfeiçoar o conjunto de parâmetros tratados por (Jong, 1975), em sua *suíte* de teste. Em sua representação cromossômica, cada indivíduo representava seis parâmetros do AG: tamanho da população, taxa de cruzamento, taxa de mutação, *generation gap*, *scaling window* e estratégia de seleção (elitista ou não elitista). A aptidão de um indivíduo era calculada em função do desempenho do AG usando os parâmetros codificados por esse indivíduo. A meta-heurística utilizava os parâmetros encontrados por (JONG, 1975). Na Tabela 1, são apresentados os parâmetros propostos por (GREFENSTETTE, 1986), outros estudos mostram que há muitas funções de aptidão para os quais esses parâmetros não são ótimos.

Reconhecendo que os valores dos parâmetros podem ter um impacto significativo sobre o desempenho de um AG e que uma análise mais profunda é necessária, Schaffer, Caruana *et al.* (1989) expandiram o experimento realizado por (Jong, 1975). Além das cinco funções que eles tinham estudado, introduziram mais cinco. Uma observação notável foi que bons resultados no desempenho do AG resultam de uma relação inversa entre o tamanho da população e a taxa de mutação, ou seja, as taxas de mutação elevadas associado com populações menores obtiveram bons resultados, como também taxas de mutação baixas associados com grandes populações conseguiram resultados bons. O conjunto de parâmetros que foram mais eficientes em sua *suíte* de teste, contendo 10 funções, está representado na Tabela 1.

4 METODOLOGIA

A solução proposta é o desenvolvimento de um aplicativo que utiliza técnicas baseadas em algoritmos evolucionários para a solução do problema de alocação de antenas para provimento de acesso a rede sem fio dentro do IFES *campus* Cachoeiro de Itapemirim. O IFES possui uma área construída de 6.773 m², composta por 14 blocos, e mais de 100 servidores, entre administrativo e professores, além disso, atende cerca de 1200 alunos, podendo chegar a 1800. Diante deste cenário é necessário que a instituição disponibilize acesso à rede sem fio para que alunos, servidores e visitantes possam conectar-se a rede interna e a internet.

Por se tratar de um problema com dimensões complexa, faz-se necessário o desenvolvimento de uma ferramenta para auxiliar a equipe de TI a alocar de maneira inteligente e eficiente as antenas que permitem acesso à rede interna e a internet. Além disso, o aplicativo precisa possuir interface intuitiva e simples, permitindo que profissionais sem conhecimento de programação, heurísticas ou algoritmo genético possam utilizá-lo.

Para realizar o cálculo do resultado é necessário obter informações das distâncias de todas as demandas. Para isso utilizou-se a imagem da planta estrutural em escala de 1:250 do IFES *campus* Cachoeiro de Itapemirim. A imagem foi convertida para o formato monocromático, de forma que o desenho original da planta fique diferenciado, permitindo a ferramenta realizar uma varredura de toda a imagem, pixel a pixel, a fim de obter os exatos pontos de demanda, que na imagem estão destacados na cor vermelha, conforme Figura 9.

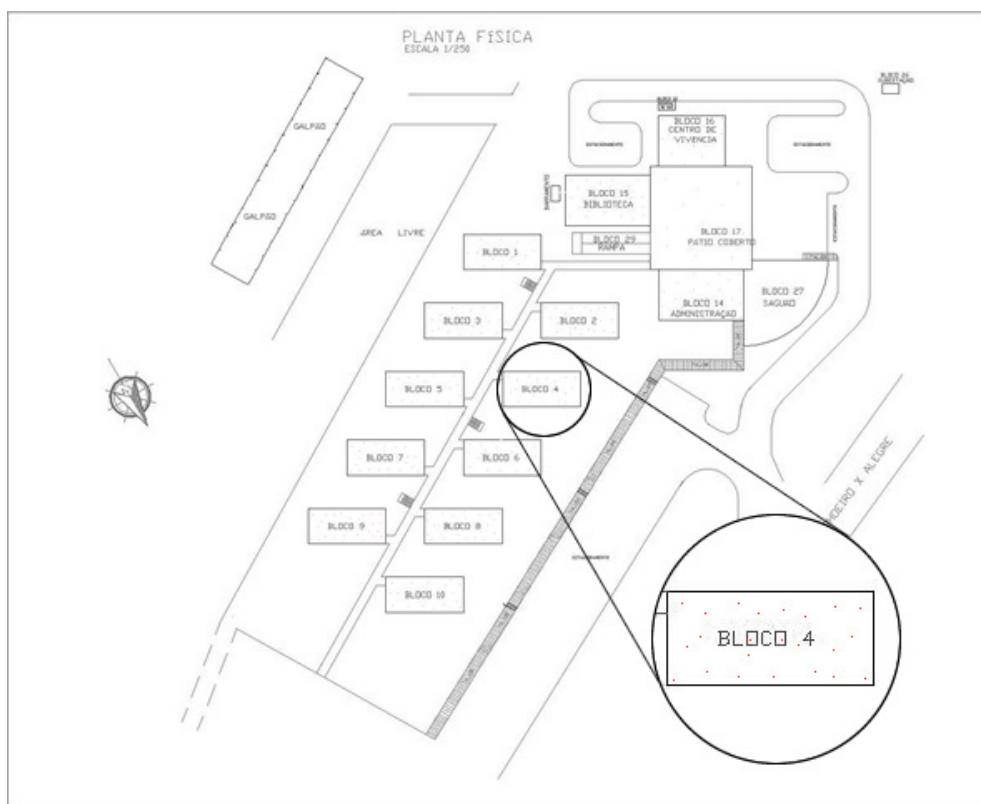


Figura 9 – Planta estrutural do IFES

Com a imagem da planta monocromática e também com os pontos de demanda definidos, é possível montar uma matriz com a localização de todos os pontos de demandas no plano cartesiano, contendo sua posição exata no eixo x e y, de acordo com a Tabela 2.

Tabela 2 - Matriz de localização

Demandas	Eixo X	Eixo Y
1	120	82
2	257	325
3	311	168
4	404	473
5	520	290

Através da matriz, que contém a localização dos pontos de demanda, é possível aplicar a métrica euclidiana, provada pelo Teorema de Pitágoras e determinar a distância entre os pontos, formando uma nova matriz com a distância

entre todos os pontos. Considerando os pontos $A = (x_A, y_A)$ e $B = (x_B, y_B)$, a distância d_{AB} entre A e B pode ser calculado através da fórmula contida na Figura 10.

$$d_{AB} = \sqrt{(x_B - x_A)^2 + (y_B - y_A)^2}$$

Figura 10 - Fórmula do Teorema de Pitágoras

Com a matriz de distância, que pode ser visualizada na Tabela 3, no qual contém a distância entre todos os pontos de demandas, obtidos a partir de uma imagem, a ferramenta inicia o processo de cálculo com base nos algoritmos evolucionários, definidos a seguir.

Tabela 3 - Matriz de distâncias

Demandas	1	2	3	4	5
1	0	411	250	131	344
2	411	0	210	402	178
3	250	210	0	200	94
4	131	402	200	0	282
5	344	178	94	282	0

4.1 REPRESENTAÇÃO CROMOSSÔMICA

O cromossomo é representado através de um vetor, constituído de diversos genes, sendo que cada gene identifica uma mediana. Os genes possuem valor binário e se diferenciam pelo seu valor: caso seja zero, significa que o vértice é um ponto de demanda e caso o valor seja um, significa que o vértice foi eleito como ponto de facilidade.

A imagem utilizada no trabalho possui 287 pontos de demanda, podendo ter no máximo 10 pontos eleitos como de facilidade.

4.2 DESCRIÇÃO DO ALGORITMO

O fluxograma do aplicativo pode ser visualizado na Figura 2, no qual após realizar a leitura da imagem que contém os pontos de demanda, gera uma matriz de distância entre todos os pontos de demanda, cria a população inicial e dá início ao processo evolutivo, gerando novas populações por n gerações.

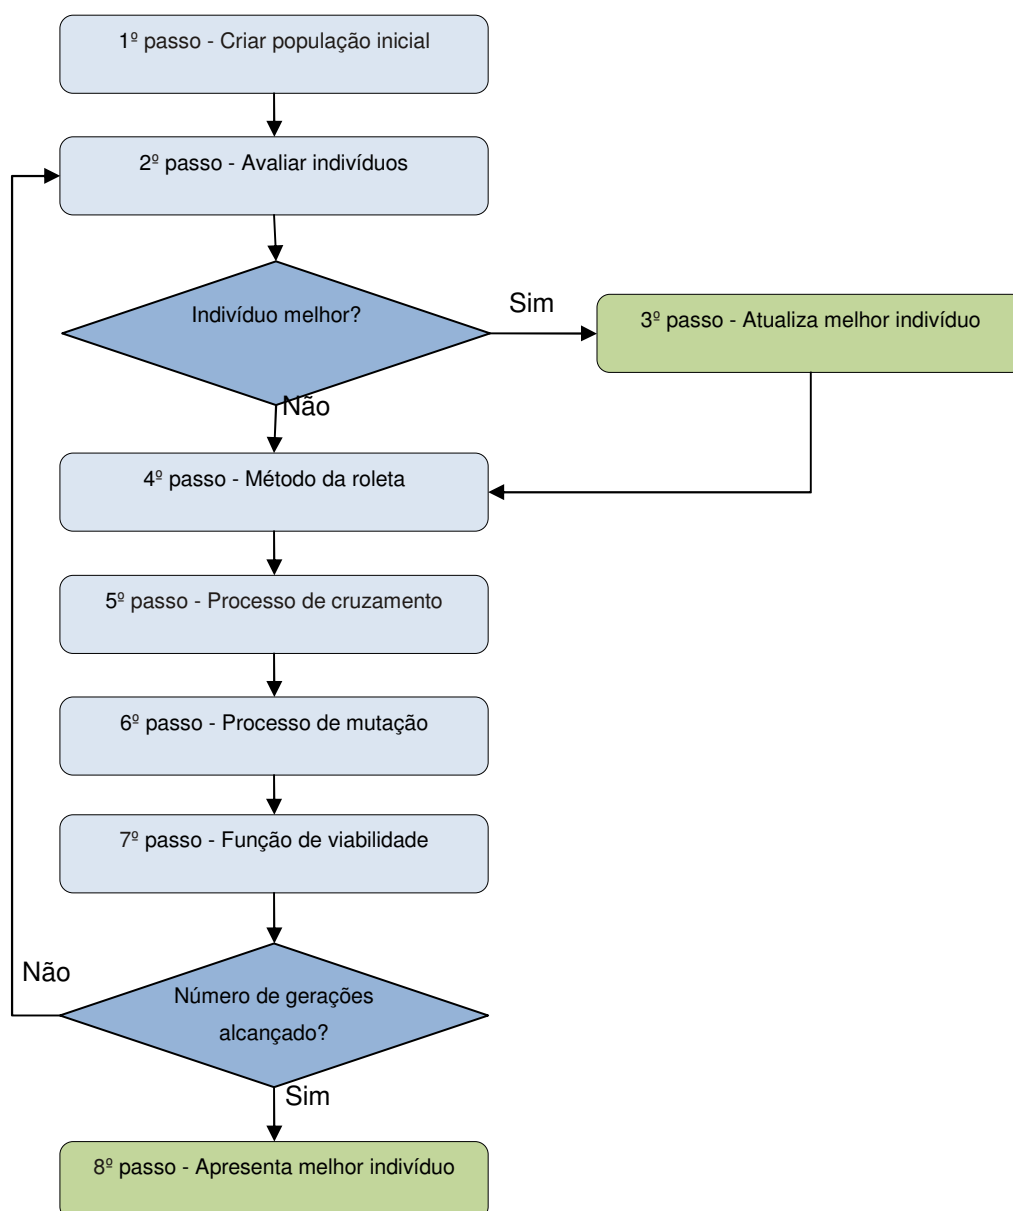


Figura 11 - Fluxograma do algoritmo

1º Passo - Criar população inicial: é criado um vetor de tamanho n para cada indivíduo, onde n é o número total de demandas que serão alocadas, inclusive os pontos de demanda que serão eleitos como pontos de facilidade. O vetor é responsável por conter os pontos de demandas que foram eleitos como pontos de facilidade, os pontos de demanda são representados pelo valor 0 (zero) e os pontos eleitos facilidade pelo valor 1 (um). A geração da primeira população é feita de forma aleatória, mas com uma função de controle que altera o percentual de alocação de pontos de facilidade nos indivíduos, devido à probabilidade do método randômico, que é de 50%, inviabilizando o indivíduo caso o percentual, de pontos de facilidade em relação aos pontos de demanda, seja menor.

2º Passo - Avaliar indivíduos: os indivíduos da população são avaliados segundo a função objetivo adotada, que visa maximizar o número de demandas cobertos (cada ponto coberto recebe um benefício de 5 pontos) e minimizando ao mesmo tempo o número de pontos de facilidade (cada ponto de facilidade utilizado recebe uma penalidade de 4 pontos) e o número de colisões (cada demanda que pode ser atendida por mais de 1 facilidade recebe uma penalidade de 2 pontos). As penalidades têm como finalidade assegurar que o resultado utilize um número necessário de facilidades e que elas fiquem espalhadas sobre as demandas, propiciando a propagação do sinal, além de evitar o uso excessivo de antenas e a perda de potência causada pela interferência da sobreposição de sinal. Além disso, todo indivíduo que ultrapassa o limite de pontos de facilidades é prematuramente desviado do processo de avaliação e o seu valor de aptidão fica nulo. Dessa forma, há penalidades para todos os indivíduos que saem do conjunto de soluções e evita que os mesmos possam ser selecionados no método da roleta e que os mesmos gerem novos indivíduos que não atendem o objetivo principal do problema. Na Figura 12 pode-se visualizar um resultado com problema de colisão de sinal, nos Blocos 1, 2 e 3 nota-se que existem três antenas atendendo a mesma área, causando interferência e prejudicando a qualidade do atendimento.

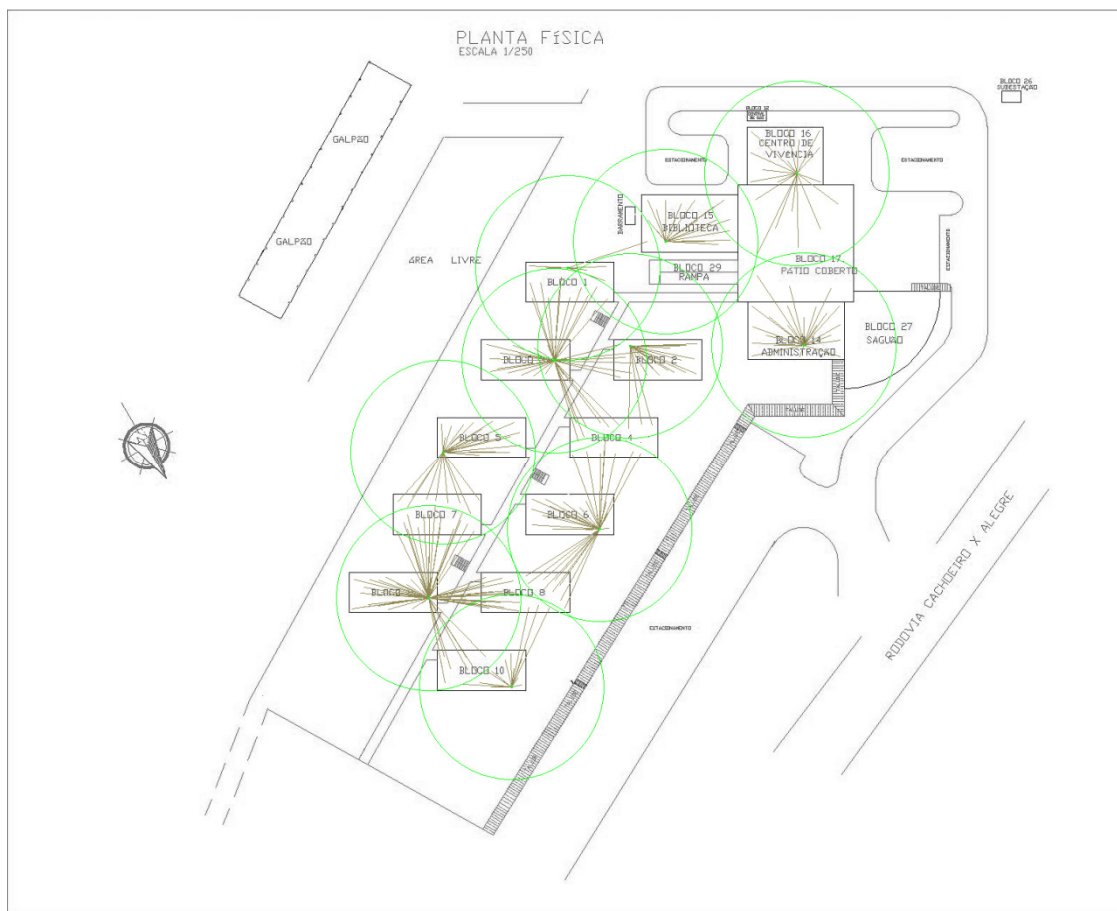


Figura 12 - Resultado contendo colisões de sinal

3º Passo - Atualiza melhor indivíduo: o melhor indivíduo da geração é comparado com o melhor indivíduo geral, caso tenha o valor de aptidão superior, o mesmo passa a ser o melhor indivíduo geral.

4º Passo - Método da roleta: cria-se uma nova população com i indivíduos com base na população anterior, utilizando como método de seleção a roleta. Todos os indivíduos da nova população são escolhidos pela roleta de forma aleatória. A probabilidade de um indivíduo ser escolhido é proporcional ao valor da sua aptidão dividido pela aptidão total da população, denominada de aptidão relativa, como pode ser visualizado na Figura 13.




Figura 13 - Método da roleta: com base na aptidão

5º Passo - Processo de cruzamento: os indivíduos selecionados pela roleta são então submetidos a um novo processo seleção, a uma taxa de 55% de probabilidade, com a finalidade de escolher os indivíduos que serão submetidos ao processo de cruzamento. Os indivíduos selecionados, os pais, são então agrupados em duplas e submetidos ao cruzamento, no qual 2 filhos são, então, formados por uma parte do pai1 e outra parte do pai2, utilizando ponto de corte único e variável, isto é, é realizado um único corte e o local é escolhido de forma aleatória, como pode ser observado na Figura 14.

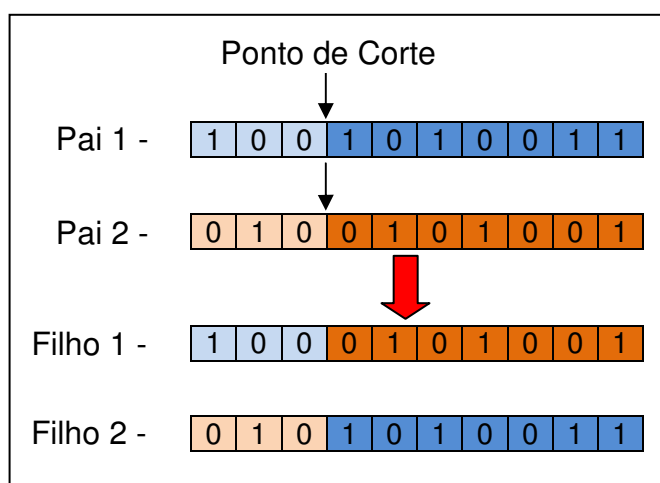


Figura 14 - Processo de cruzamento

6º Passo - Processo de mutação: os indivíduos provenientes do cruzamento são submetidos ao processo de mutação, no qual é realizada *bit-a-bit* conforme

Michalewicz (1996). Cada bit é submetido a um processo de seleção, a uma taxa de 0,01% de probabilidade, e os bits selecionados são então modificados, isto é, o valor do bit é alterado de 0 para 1 ou de 1 para 0, como pode ser visualizado na Figura 15.




Figura 15 - Processo de Mutação

7º Passo - Função de viabilidade: tem como objetivo evitar que os indivíduos que foram submetidos ao cruzamento e mutação saiam do conjunto de soluções, devido à restrição que limita a quantidade de pontos de facilidades, evitando dessa forma que a busca possa vir estagnar, como pode ser observado na Figura 16, no qual exhibe dois gráficos: o primeiro sem a utilização da função de viabilidade e o segundo utilizando a função de viabilidade.




Figura 16 - Gráficos para acompanhamento da avaliação da população

Com o acompanhamento da aptidão da população, a cada geração, foi identificado que os indivíduos possuíam uma quantidade grande de pontos de demandas em relação aos pontos de facilidade, e o processo de mutação propicia o indivíduo a sair do conjunto de soluções, já que o número de bits com valor zero é maior, consequentemente a probabilidade desses bits serem alterados para o valor 1 (um) também é maior, fazendo com que os indivíduos sujeitos a mutação terminem com um número de facilidades acima do aceitável. A função de viabilidade verifica se todos os indivíduos respeitam o número máximo de facilidades, caso o indivíduo ultrapasse o limite, ele seleciona os bits com valor igual a 1 (um), e força um novo processo de mutação, com uma probabilidade de 50%, como pode ser observado na Figura 17. O pseudocódigo da função de viabilidade é apresentado na Figura 18, a variável *população* representa um vetor com todos os indivíduos da geração, a variável *pop_size* representa a quantidade de indivíduos presentes na população, a função *qtd_bits_ativados* retorna a quantidade de bits ativados presentes no indivíduo, a variável *max_bits* representa a quantidade máxima de facilidades, a função *length* retorna o total de bits presentes no indivíduo, as variáveis *pop_size* e *max_bits* são definidas como parâmetros para o AG.

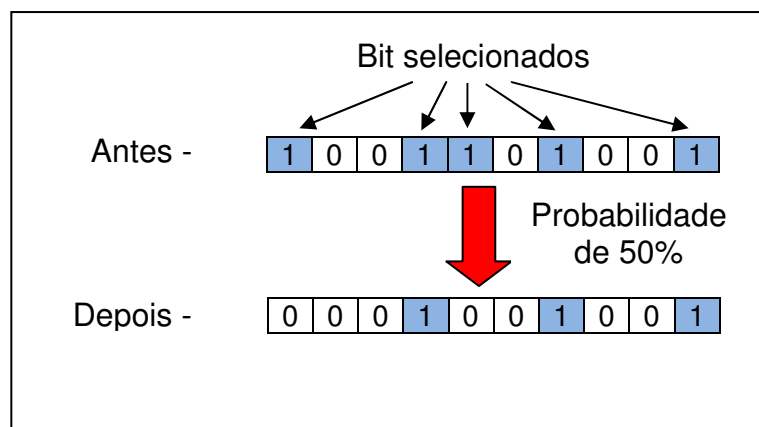


Figura 17 - Mutação da função de viabilidade

```

Função Viabilidade populacao
01  para ( i  $\leftarrow$  0 ) até pop_size faça
02      indivíduo  $\leftarrow$  população[ i ]
03      se ( qtd_bits_ativados( indivíduo ) > max_bits ) então
04          para ( j  $\leftarrow$  0 ) até length( indivíduo ) faça
05              rand  $\leftarrow$  randomico( 0, 100 )
06              se ( indivíduo[ j ] = 1 ) e ( rand > 50 ) então
07                  indivíduo[ j ]  $\leftarrow$  0
08          fim se
09      fim para
10  fim se
11  fim para
12  fim procedimento

```

Figura 18 - Pseudocódigo da função de viabilidade

8º Passo - Apresenta melhor indivíduo: o indivíduo selecionado é exibido de duas formas: a primeira em forma textual com a interpretação do resultado, como pode ser visualizado na Figura 19, informando o número de facilidades utilizados, total de demandas atendidos, percentual de demandas atendidos, total de colisões de sinal, qual geração o indivíduo foi selecionado e o valor da aptidão do indivíduo, e na segunda em forma de imagem, como pode ser observado na Figura 20, no qual utiliza-se a imagem inicial para representar os pontos eleitos como facilidade, na cor verde-claro, uma linha entre o ponto de demanda e o ponto de facilidade que o atendeu, na cor verde-escuro e um círculo com o raio de transmissão da facilidade, na cor verde-claro, possibilitando uma análise simples do resultado.

Calculo baseado na imagem: [planta-teste.png](#)

Dados do melhor individuo (maior fitness)

Total de facilidades: 8
 Total de demandas: 279
 Demandas atendidas: 259
 % das demandas atendidas: 92.831541218638 %
 Demandas nao atendidas: 20
 Colisoes de sinal: 14
 Indivduo da geracao: 789
 Valor do fitness: 1235

Resultado plotado na imagem: [368planta-teste.png](#)

Figura 19 - Resultado numérico da solução

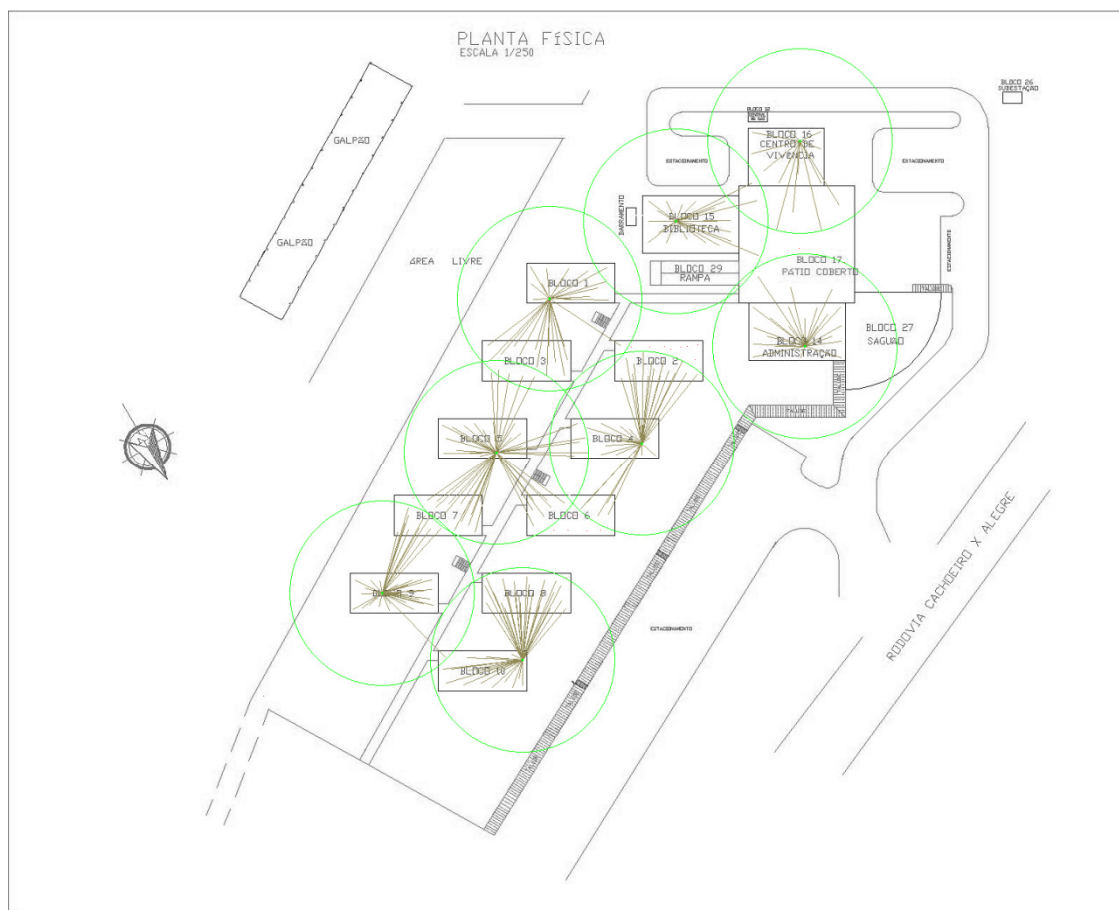


Figura 20 - Resultado gráfico da solução

Uma vantagem da ferramenta proposta é a facilidade em resolver novos problemas de localização de antenas, sendo necessária apenas a criação de uma

nova imagem, com o conteúdo da planta original em formato monocromático e a inclusão dos pontos de demandas na cor vermelha, e de uma simples alteração nos parâmetros do AG: o número máximo de facilidades e o raio de transmissão da facilidade em pixels. Possibilitando que usuários sem conhecimento específico de metaheurísticas, AG ou de programação possam utilizar a ferramenta.

4.3 EXPERIMENTOS

Nesta seção são apresentados os experimentos computacionais da heurística proposta, no qual foram desenvolvidas em PHP com banco de dados *Mysql* e foram executados em um servidor DELL R610 com dois processadores Intel Xeon de 2.13GHz e 6GB de memória.

4.3.1 Primeiro Experimento

Os parâmetros são responsáveis pelo controle do processo evolucionário, e são extremamente importantes, pois afetam diretamente no desempenho do AG. Diversos pesquisadores elaboraram experimentos a cerca do ajuste dos parâmetros do AG, dentre eles pode-se destacar (Jong, 1975; Grefenstette, 1986; Goldberg, 1989; Schaffer, Caruana *et al.*, 1989).

A fim de obter o melhor desempenho do AG, foram realizados testes com o aplicativo utilizando faixas de valores para os parâmetros empregados no AG, como pode ser observado na Tabela 4, no qual os valores foram escolhidos aleatoriamente em tempo de execução. A taxa de cruzamento teve o intervalo definido de 10% a 80%, a taxa de mutação teve o intervalo de 0,01% a 20%, o tamanho da população teve o intervalo definido entre 4 e 40 indivíduos e por final a quantidade de gerações de 10 a 5000. Os intervalos foram selecionados, com o intuito de abranger e ampliar os parâmetros propostos por (JONG, 1975); (GREFENSTETTE, 1986); (SCHAFFER, CARUANA *et al.*, 1989)

Tabela 4 - Parâmetros utilizados no primeiro experimento

Parâmetro	Valor Mínimo	Valor Máximo
Cruzamento	10%	80%
Mutação	0,01%	20%
Indivíduos	4	400
Gerações	10	5000

Com a definição da faixa de valores, foram realizadas simulações com o aplicativo e os dados obtidos em cada execução foram salvos em banco de dados *Mysql*, com a finalidade de realizar análises estatísticas posteriores, a fim de obter os melhores parâmetros.

Na 1ª simulação, foram obtidos 49.386 resultados com a execução da ferramenta com valores aleatórios, na Tabela 5 são apresentados alguns dados reais da simulação, no qual são informados: o id para controle dos dados, o valor de aptidão do melhor indivíduo alcançado dentre todas as gerações, a taxa de cruzamento usada (o valor está em decimal), a taxa de mutação empregada (o valor está em decimal), o número de indivíduos da população e o número de gerações.

Tabela 5 - Alguns dados obtidos no primeiro experimento

Id	Aptidão	Cruzamento	Mutação	População	Gerações
1	23340	0,580000	0,005600	24	1081
2	19840	0,750000	0,119500	263	1553
3	18980	0,440000	0,133500	394	4413
4	22700	0,210000	0,123600	342	1545
5	20760	0,110000	0,170400	327	3268
6	19980	0,590000	0,023800	54	4559
7	20040	0,770000	0,133700	75	2494
8	19540	0,620000	0,172700	123	604
9	19340	0,340000	0,153600	50	2636
10	22040	0,470000	0,156900	377	2844

Os dados do primeiro experimento foram inicialmente exportados do banco de dados *Mysql* e tabulados no software Microsoft Office Excel versão 2007. E, posteriormente, analisados estatisticamente utilizando o software SAEG (Sistema para Análises Estatísticas e Genéticas) versão 9.1, a fim de obter relação dos parâmetros empregados e o valor de aptidão. Foi obtida a regressão entre a aptidão (*fitness*) em função da taxa de mutação. Os valores de aptidão e mutação foram normalizados, a fim de possibilitar a análise pelo software SAEG. A escolha do modelo estatístico da regressão, dentre os apresentados pelo SAEG (Linear, Quadrático, Cúbico, Raiz Quadrada, Potencial, Exponencial, Cúbico-Raiz, dentre outros), foi feita mediante a análise dos parâmetros da regressão (significância e coeficiente de determinação), como pode ser visualizado na Figura 21, no qual foi escolhido o Cúbico-Raiz, por apresentar o maior valor de significância (R2) e coeficiente de determinação abaixo de 5% (F. sig.).

Modelos disponíveis - Pré-definidos				
Modelo	Equação	R2	R2ajust.	F.sig.
<input checked="" type="radio"/> Linear	$Y=a+b*X$	11.33	11.33	0.00
<input type="radio"/> Quadrático	$Y=a+b*X+c*X^2$	19.91	19.91	0.00
<input type="radio"/> Cúbico	$Y=a+b*X+c*X^2+d*X^3$	23.55	23.55	0.00
<input type="radio"/> Raiz Quadrada	$Y=a+b*X^{1/2}+c*X$	23.92	23.92	10.55
<input type="radio"/> Potencial	$Y=a*X^b$	14.95	14.94	4.06
<input type="radio"/> Exponencial	$Y=a*b^X$	8.61	8.60	0.00
<input type="radio"/> Hiperbólico-1	$Y=a+b/X$	3.09	3.09	0.00
<input type="radio"/> Hiperbólico-2	$Y=1/(a+b*X)$	5.50	5.50	0.00
<input type="radio"/> Logarítmico E	$Y=a+b*\ln(X)$	21.22	21.22	12.90
<input type="radio"/> Logarítmico 10	$Y=a+b*\log(X)$	21.22	21.22	12.90
<input type="radio"/> Log-Recíproco	$\log(Y)=a+b/X$	1.98	1.98	0.00
<input type="radio"/> Cúbico-Raiz	$Y=a+b*X^{1/2}+c*X+d*X^{1.5}$	24.28	24.28	0.00
<input type="radio"/> Log-Log	$\log(Y)=a+b*\log(X)$	14.95	14.94	4.06
<input type="radio"/> Ln-Ln	$\ln(Y)=a+b*\ln(X)$	14.95	14.94	4.06

Abandonar Processar

Figura 21 - Parâmetros da regressão da aptidão em função da mutação

Através da análise estatística do primeiro experimento, foi possível indicar uma taxa de mutação ótima, como pode ser visualizada pela Figura 22, no qual pode-se concluir que quanto menor a taxa de mutação maior é o *fitness* do

aplicativo. A taxa de mutação empregada inicialmente foi de 0,01% a 20%, assim a taxa selecionada foi de 0,01%.




Figura 22 - Gráfico Cúbico-Raiz entre aptidão em função da taxa de mutação

4.3.2 Segundo Experimento

Realizou-se um segundo experimento, com os mesmos intervalos de valores, mas com uma taxa de mutação fixa, obtida através do primeiro experimento. Na Tabela 6 são apresentados os parâmetros utilizados no segundo experimento, sendo que a taxa de mutação foi fixada em 0,01%.

Tabela 6 - Parâmetros utilizados no segundo experimento

Parâmetro	Valor Mínimo	Valor Máximo
Cruzamento	10%	80%
Indivíduos	4	400
Gerações	10	5000

No segundo experimento foram obtidos 36.818 resultados com a execução do aplicativo, na Tabela 7 são apresentados alguns dados reais do experimento, no qual pode-se observar que o valor da mutação não se altera.

Tabela 7 - Alguns dados obtidos do segundo experimento

Id	Aptidão	Cruzamento	Mutação	População	Gerações
1	22960	0,580000	0,000100	11	594
2	21100	0,130000	0,000100	67	14
3	24760	0,800000	0,000100	159	82
4	24120	0,690000	0,000100	150	185
5	24760	0,520000	0,000100	204	962
6	25540	0,770000	0,000100	400	543
7	24500	0,660000	0,000100	110	350
8	23900	0,390000	0,000100	29	2424
9	25600	0,320000	0,000100	380	695
10	23040	0,780000	0,000100	75	176

Os dados do segundo experimento foram submetidos ao mesmo processo do primeiro experimento e foram posteriormente analisados pelo SAEG, com intuito de obter relação dos parâmetros empregados e o valor de aptidão. Foi possível obter a regressão entre a aptidão em função da taxa de crossover e da aptidão em função do número de gerações.

Por meio da análise estatística do segundo experimento, foi possível indicar duas taxas como sendo ideais. Na Figura 23 é apresentado um gráfico do valor de aptidão em função da taxa de crossover, e a taxa de crossover que obteve o maior valor de fitness é de 55%. Já na Figura 24 é apresentado um gráfico do valor de aptidão em função do número de gerações, e como era esperado quanto maior o número de gerações, maior será o valor da aptidão, entretanto quanto maior o número de gerações maior será o custo computacional e consequentemente maior será o tempo para o resultado. Diante disto o número de gerações selecionado foi 1000, pois obtém boas soluções em tempo aceitável, em 2 minutos e 30 segundos.




Figura 23 - Gráfico Cúbico entre aptidão em função da taxa de crossover




Figura 24 - Gráfico Cúbico-Raiz entre aptidão em função do número de gerações

4.3.3 Comparações

Com o intuito de validar os parâmetros obtidos com os experimentos, executou-se o aplicativo desenvolvido vinte vezes: dez vezes com os parâmetros

propostos por Michalewicz (1996) e dez com os parâmetros propostos através dos experimentos, que podem ser visualizados na Tabela 8.

Tabela 8 - Parâmetros propostos através dos experimentos

Parâmetro	Valor Mínimo
Cruzamento	55%
Mutação	0,01%
Gerações	1000

Em cada execução do aplicativo, efetuou-se uma média da aptidão da população em todas as 1000 gerações. Os valores obtidos foram tabulados no software Microsoft Office Excel versão 2007, depois realizou-se uma média da aptidão da população antes e depois do ajuste dos parâmetros do AG e nota-se uma diferença significativa entre os valores, isto é, a aptidão da população após o ajuste dos parâmetros do AG apresentou um aumento de 28,09% em relação a aptidão da população utilizando os parâmetros propostos por (MICHALEWICZ, 1996). Na figura 25 pode-se visualizar um gráfico comparativo entre a média da aptidão da população antes e depois do ajuste dos parâmetros do Algoritmo Genético.




Figura 25 - Gráfico comparativo da média da aptidão da população antes e depois do ajuste nos parâmetros

Na figura 26 é possível acompanhar a aptidão da população no decorrer das gerações, antes e depois do ajuste dos parâmetros do AG. É perceptível a grande evolução da aptidão nas primeiras gerações, pelo fato da primeira geração ser criada aleatoriamente e possuir um valor de aptidão baixo. Contudo, no decorrer das gerações, com a melhora no valor da aptidão, fica nítida a diferença do valor de aptidão da população entre os dois gráficos. No primeiro gráfico, no qual é exibido o valor da aptidão da população utilizando os parâmetros propostos por (Michalewicz, 1996), os valores oscilam timidamente entre 600.000 e 700.000. Já o segundo gráfico apresenta valores e uma oscilação maior que a anterior, indício de que o aplicativo está conduzindo à busca para o máximo global e evitando que a busca fique paralisada em máximos locais.




Figura 26 – Gráficos da aptidão da população no decorrer das gerações, antes e depois da alteração dos parâmetros

5 RESULTADOS E DISCUSSÕES

Este capítulo é dedicado à análise dos resultados gerados pela implementação da solução e tem como objetivo validar o algoritmo proposto. Os testes foram executados em um servidor DELL R610 com dois processadores Intel Xeon de 2.13GHz e 6GB de memória.

Os experimentos computacionais consideram dados reais que representam a demanda de cobertura de sinal atual no IFES *campus* Cachoeiro de Itapemirim: 10 facilidades disponíveis para o fornecimento de transmissão de sinal da rede sem fio e 287 pontos de demandas posicionados nas áreas que necessitam de cobertura.

Nos experimentos, o critério de parada do algoritmo genético é o número de gerações, estabelecido em 1000 gerações. A taxa de cruzamento (tc) foi definida em 55% e a taxa de mutação (tm) em 0,01%. Estes valores, juntamente com o número de gerações, foram definidos através de experimentos e análises estatísticas.

O aplicativo foi desenvolvido para plataforma web, este gera uma imagem de resultado, utilizando a imagem original como base, representando os pontos eleitos como facilidade com a cor verde-claro, uma linha entre os pontos de demandas atendidos e os pontos de facilidade com a cor verde-escuro e um círculo com o raio de transmissão da facilidade com a cor verde-claro, informado como parâmetro pela ferramenta. Pode-se verificar na Figura 27 o resultado obtido pelo aplicativo, foram eleitos 8 pontos de facilidade. De cada ponto de facilidade eleito seguem linhas para as demandas atendidas, além do raio de amplitude do rádio.

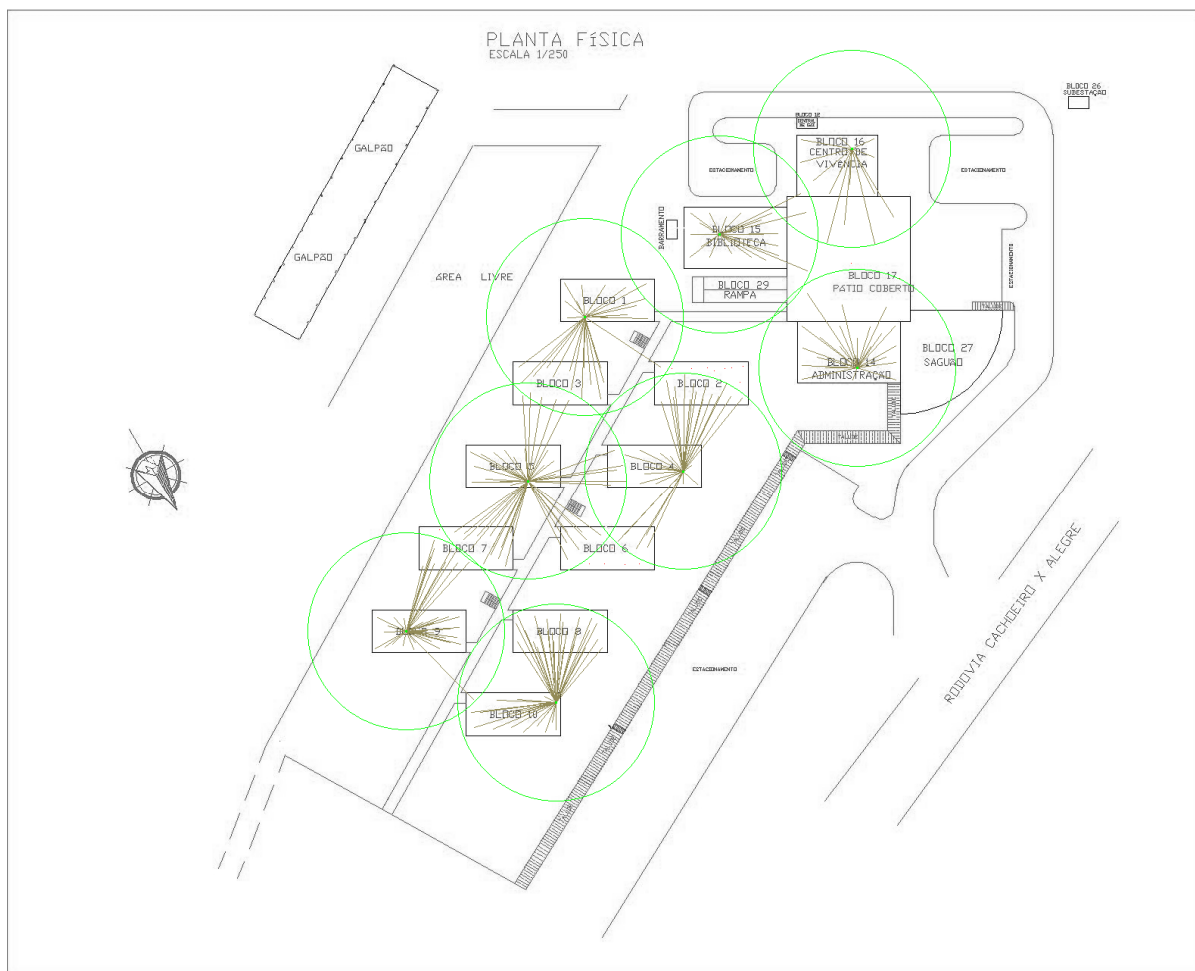


Figura 27 – Resultado gráfico de solução satisfatória

O resultado, destacado na Figura 27, apresentou-se satisfatório, uma vez, que o número de antenas informado pelo aplicativo, conforme Tabela 9, igual a 8, atende 92,83% das demandas que foram informadas como parâmetros de entrada e da mesma forma, minimizou o número de demandas que podem ser atendidas por mais de um ponto de facilidade, isto é, reduziu a colisão de sinal entre as antenas, sendo esse resultado benéfico para o bom funcionamento da rede sem fio.

Tabela 9 – Resultados numéricos

Resultados	Proposto	Lorena	Atual
Total de facilidades	8	10	7
Total de demandas	279	277	280
Demandas atendidas	259	277	235
Demandas atendidas (%)	92.83 %	100 %	83.92 %
Demandas não atendida	20	0	45
Colisões de sinal	14	158	110
Valor do fitness	24700	20580	18540

No primeiro experimento, comparou-se os resultados da heurística proposta com a heurística Lagrangeana/*Surrogate*, proposto por Lorena, Senne *et al.* (2001), utilizando os mesmos pontos de demanda, a mesma quantidade de pontos de demanda e facilidade, a mesma distância euclidiana entre os pontos e a mesma distância máxima de atendimento da facilidade. Os dados de posicionamento dos pontos de demanda da imagem, utilizada neste trabalho, foram exportados para formato de texto, a fim de possibilitar uma comparação equivalente com a heurística Lagrangeana/*Surrogate* implementada no aplicativo desenvolvido por Lorena, Senne *et al.* (2001).

Os resultados obtidos com a heurística Lagrangeana/*Surrogate*, atenderam 100% das demandas, com 10 facilidades e obtendo 158 colisões de sinal, como ser visualizado na Tabela 9 e na Figura 28, no qual apresenta uma comparação entre o resultado da heurística proposta e o resultado da heurística Lagrangeana/*Surrogate*. Entretanto, o aplicativo com a heurística Lagrangeana/*Surrogate*, proposto por Lorena, Senne *et al.* (2001), objetiva unicamente o atendimento das demandas, não considerando a redução do número de facilidades empregadas na solução e nem mesmo reduzir a colisão de sinal.

Comparação de resultados




Figura 28 - Comparação dos resultados

Os pontos eleitos como facilidade, obtidos através da heurística Lagrangeana/*Surrogate*, foram utilizados como parâmetros no aplicativo proposto e gerou-se o resultado gráfico do o resultado, como pode ser visualizado na Figura 29, a fim de auxiliar na análise do resultado.



Figura 29 - Resultado gráfico obtido através da heurística Lagrangeana/Surrogate

Analisando a Figura 29, é possível constatar que algumas facilidades estão sobrepostas, causando interferência de sinal entre as facilidades e prejudicando o atendimento as demandas. Além disso, foram alocadas duas facilidades em um mesmo bloco, Bloco 5, e também não foram minimizadas o número de facilidades, com a finalidade de diminuir custos e reduzir a colisão de sinal.

No segundo experimento, comparou-se os resultados do método proposto com o posicionamento das antenas de transmissão da rede sem fio presentes atualmente no IFES *campus* Cachoeiro de Itapemirim, como pode ser observado na Figura 30, o resultado gráfico da solução atual, obtido com o aplicativo proposto.

6 CONSIDERAÇÕES FINAIS

Neste trabalho foi proposta uma solução para o problema de alocação de antenas para rede sem fio do IFES *campus* Cachoeiro de Itapemirim, demonstrando a importância de utilizar um aplicativo com base em inteligência computacional na solução do melhor posicionamento para antenas de rede sem fio, de forma que o atendimento seja maximizado, o número de antenas seja minimizado e seja respeitado o limite na área de abrangência do sinal. Atualmente não existem softwares que forneçam uma solução completa, desde a alocação dos pontos de demandas, realizar os cálculos de distâncias e encontrar a melhor solução para o problema.

A utilização de uma imagem, com todos os pontos de demandas incluídos, facilita e auxilia o profissional na tomada de decisão, pois montar uma matriz de distância entre todos os 287 pontos de demandas é oneroso e impraticável, já que terão que ser realizadas mais de 82 mil medições de pontos. Ainda assim, algumas medições podem ser consideradas improváveis, pois podem, por exemplo, existir objetos entre os pontos, locais de difícil acesso ou por estarem em prédios diferentes sem acesso direto. Por se tratar de uma imagem em escala, idêntica a estrutura atual, não há a necessidade de realizar as medições, porque através do teorema de Pitágoras é possível calcular a distância entre dois pontos no plano cartesiano, utilizando com base em suas coordenadas (x,y) , possibilitando que problemas com grande quantidade de pontos de demanda possam ser calculadas. Outra facilidade que a utilização de imagem produz é o controle das áreas mais importantes, que não podem ser deixadas sem atendimento, bastando adicionar mais pontos de demandas na determinada área e induzindo o aplicativo a atender á essas áreas mais populosas.

Disponibilizar o aplicativo via web, possibilita que seu uso seja feito por outros *campi* do IFES, porém sem a necessidade de ter um vasto conhecimento de programação, heurísticas ou algoritmo genético. Tendo somente que exportar a planta do *campus* para uma imagem em boa resolução, adicionar os pontos de demandas na imagem e informar dois dados: número máximo de antenas e o seu alcance de transmissão, em pixels.

A ferramenta demonstrou ser uma excelente opção para auxílio na tomada de decisão, quanto à avaliação da utilização do menor número de antenas e na maior cobertura das demandas.

6.1 TRABALHOS FUTUROS

Para uma aplicação eficiente da ferramenta em ambientes internos, é necessário que sejam levados em consideração objetos que atenuam a transmissão do sinal entre o ponto de facilidade e a demanda. Sugere-se, portanto, um estudo mais aprofundado, procurando identificar a real consequência dos impactos na transmissão do sinal e um aperfeiçoamento na ferramenta, visando uma abordagem mais funcional nestes ambientes.

Analisar a cobertura de sinal de rede sem fio em todos os *campi* do IFES, de forma, apoiar na tomada decisão sobre o melhor posicionamento dos rádios e antenas em virtude das demandas locais.

7. REFERÊNCIAS BIBLIOGRÁFICAS

ADENSO-DÍAZ, B.; RODRÍGUEZ, F. A simple search heuristic for the MCLP: Application to the location of ambulance bases in a rural region. **Omega Journal**, v. 25, n. 2, p. 181-187, 1997. Disponível em: <<http://www.journals.elsevier.com/omega/>>. Acesso em 29 jan 2013

AZIZAN, M. H. et al. Application of openstreetmap data in ambulance location problem . In: INTERNATIONAL CONFERENCE ON COMPUTATIONAL INTELLIGENCE, COMMUNICATION SYSTEMS AND NETWORKS, 4, 2012, Malaysia. **Proceedings** Malaysia : CICSyN, 2012. p.321-325. Disponível em: <<http://ieeexplore.ieee.org> >. Acesso 20 abril 2013.

AZZONI, C. R. **Teoria da localização**: uma análise crítica : a experiência de empresas instaladas no Estado de São Paulo. São Paulo: Instituto de Pesquisas Econômicas, 1982.

BEASLEY, D.; BULL, D. R.; MARTIN, R. R. An overview of genetic algorithms: part 2: research topics. **The Computer Journal**, v. 15, n. 4, p. 170-181, 1993. Disponível em: < <http://comjnl.oxfordjournals.org/>>. Acesso 08 maio 2013

_____; _____. An overview of genetic algorithms: Part 1, Fundamentals. **The Computer Journal**, v. 15, n. 2, p. 58-69, 1993. Disponível em: <<http://comjnl.oxfordjournals.org/>>. Acesso 08 maio 2013

BEASLEY, J. E. Lagrangean heuristics for location problems. **European Journal of Operational Research**, v. 65, n. 3, p. 383-399, 1993. <<http://www.journals.elsevier.com/european-journal-of-operational-research/>>. Acesso 18 maio 2013

CHURCH, R. L.; REVELLE, C. S. The maximal covering location problem. **Papers in Regional Science**, v. 32, n. 1, p. 101-118, 1974. Disponível em: <[http://onlinelibrary.wiley.com/journal/10.1111/\(ISSN\)1435-5957](http://onlinelibrary.wiley.com/journal/10.1111/(ISSN)1435-5957)>. Acesso em 20 fev 2013.

_____. Theoretical and computational links between the p-median, location set-covering, and the maximal covering location problem. **Geographical Analysis Journal**, v. 8, n. 4, p. 406-415, 1976. Disponível em: <<http://www.questia.com/library/>>. Acesso 14 março 2013.

CURRENT, J.; O'KELLY, M. Locating emergency warning sirens. **Decision Sciences Journal**, v. 23, n. 1, p. 221-234, 1992. Disponível em: <<https://subscriptions.economist.com/LA/SRCH/ETE/ggle/reg/>>. Acesso em 30 março de 2013.

DAVIS, L. **Handbook of genetic algorithms**. New York: Van Nostrand Reinhold, 1991.

GALVÃO, R. D. Modelos e algoritmos para problemas de localização em redes. **Revista Pesquisa Operacional**, v. 1, p. 3-22, 1981. Disponível em: <http://www.scielo.br/scielo.php/script_sci_serial/Ing_pt/pid_0101-7438/nrm_>. Acesso em 12 março 2013.

GALVÃO, R. D.; REVELLE, C. A Lagrangean heuristic for the maximal covering location problem. **European Journal of Operational Research**, v. 88, n. 1, p. 114-123, 1996. Disponível em: <http://www.sciencedirect.com/science/journal/03772217>>. Acesso em 20 março 2013.

GAREY, M. R.; JOHNSON, D. S. **Computers and intractability: a guide to the theory of np-completeness**. New York: W. H. Freeman, 1979.

GIGER, M.; KELLER, D.; ERMANNI, P. AORCEA - An adaptive operator rate controlled evolutionary algorithm. **Comput. Struct Journal**, v. 85, n. 19-20, p. 1547-1561, 2007. Disponível em: <<http://www.journals.elsevier.com/computers-and-structures/>>. Acesso em 30 set 2012.

GOBERNA, M. A.; LOPEZ, M. A.; PASTOR, J. T. **Performance and location of bank branches**. North Wales, UK: University College of North Wales, 1990.

GOLDBERG, D. E. **Genetic algorithms in search, optimization and machine learning**. New Jersey: Addison-Wesley., 1989.

GREFENSTETTE, J. J. Optimization of control parameters for genetic algorithms. **Systems, Man and Cybernetics, IEEE Transactions on**, v. 16, n. 1, p. 122-128, 1986. Disponível em: < <http://www.ieeesmc.org/publications/>>. Acesso em 20 março 2013.

HAKIMI, S. L. Optimum Locations of Switching Centers and the Absolute Centers and Medians of a Graph. **Operations Research Applications and Algorithms**, v. 12, n. 3, p. 450-459, 1964. Disponível em: <<http://www.amazon.com/Operations-Research-Applications-Algorithms-InfoTrac/dp/0534380581>>. Acesso em 30 maio 2013.

_____. Optimum Distribution of Switching Centers in a Communication Network and Some Related Graph Theoretic Problems. **Operations Research Applications and Algorithms**, v. 13, n. 3, p. 462-475, 1965. <<http://www.amazon.com/Operations-Research-Applications-Algorithms-InfoTrac/dp/0534380581>>. Acesso em 15 maio 2013.

HENDTLASS, T. A combined swarm differential evolution algorithm for optimization problems. In: INTERNATIONAL CONFERENCE ON INDUSTRIAL AND ENGINEERING APPLICATIONS OF ARTIFICIAL INTELLIGENCE AND EXPERT SYSTEMS: ENGINEERING OF INTELLIGENT SYSTEMS, 14, 2001, New York. **Proceedings** New York: Springer-Verlag:. 2001. p. 11-18

HOLLAND, J. H. **Adaptation in natural and artificial systems**: an introductory analysis with applications to biology, control, and artificial intelligence. Oxford, UK: University Michigan Press, 1975.

HORN, J.; GOLDBERG, D. E. Natural niching for evolving cooperative classifiers. IN: ANNUAL CONFERENCE ON GENETIC PROGRAMMING, 1, 1996, Stanford, California. **Proceedings** Stanford, California : MIT Press, 1996. p. 553-564.

JARAMILLO, J. H.; BHADURY, J.; BATTÀ, R. On the use of genetic algorithms to solve location problems. **Computers and . Operations. Research**, v. 29, n. 6, p. 761-779, 2002. Disponível em: < <http://www.journals.elsevier.com/computers-and-operations-research/>>. Acesso 12 março 2013.

JONG, K. A. D. **An analysis of the behavior of a class of genetic adaptive systems**. Oxford, UK: University Michigan Press, 1975.

KARIV, O.; HAKIMI, S. L. An Algorithmic approach to network location problems. II: the p-medians. **SIAM Journal on Applied Mathematics**, v. 37, n. 3, p. 539-560, 1979. Disponível em: < <http://www.siam.org/journals/siap.php>>. Acesso em 13 maio 2013.

KHUMAWALA, B. M. An efficient algorithm for the p-median problem with maximum distance constraints. **Geographical Analysis**, v. 5, n. 4, p. 309-321, 1973. Disponível em: < http://www.questia.com/library/p4971/geographical-analysis?gclid=COyss_auncACFWwQ7AodtxIAaw>. Acesso em 16 março 2013.

KOK, S.; SANDROCK, C. Locating and characterizing the stationary points of the extended rosenbrock function. **Evolutionary. Comput.ation**, v. 17, n. 3, p. 437-453, 2009. Disponível em: <<http://www.mitpressjournals.org/toc/evco/16/4>>. Acesso 13 maio 2013.

LACERDA, L. S. Considerações sobre o estudo de localização de instalações. **Revista Tecnológica**, n. 27, 1998. Disponível em: <<http://www.tecnologica.com.br/>>. Acesso em 18 março 2013.

LIM, S.; KUBY, M. Heuristic algorithms for siting alternative-fuel stations using the flow-refueling location model. **European Journal of Operational Research**, v. 204, n. 1, p. 51-61, 2010. Disponível em: < <http://www.euro-online.org/web/pages/518/european-journal-of-operational-research-ejor>>. Acesso em 20 jan 2013.

LINDEN, R. **Algoritmos genéticos**. 2. Rio de Janeiro: Brasport, 2008.

LORENA, L. A. N. et al. Integração de modelos de localização a sistemas de informações geográficas. **Gestão & Produção**, v. 8, p. 180-195, 2001. Disponível em: < http://www.scielo.br/scielo.php?script=sci_serial&pid=0104-530X&lng=en&nrm=iso>. Acesso em 30 jan 2013.

MAN, K. F.; TANG, K. S.; KWONG, S. Genetic algorithms: concepts and applications in engineering design. **Industrial Electronics, IEEE Transactions on**, v. 43, n. 5, p. 519-534, 1996. Disponível em: <<http://ieeexplore.ieee.org/xpl/RecentIssue.jsp?reload=true&punumber=41>>. Acesso em 20 maio 2013.

MICHALEWICZ, Z. **Genetic algorithms + data structures**. New York: Springer-Verlag, 1996.

MURALI, P.; ORDÓÑEZ, F.; DESSOUKY, M. M. Facility location under demand uncertainty: Response to a large-scale bio-terror attack. **Socio-Economic Planning Sciences**, v. 46, n. 1, p. 78-87, 2012. Disponível em: <<http://www.journals.elsevier.com/socio-economic-planning-sciences/>>. Acesso em 22 maio 2013.

NEEBE, A. W. A branch and bound algorithm for the p-median transportation problem. **The Journal of the Operational Research Society**, v. 29, n. 10, p. 989-995, 1978. Disponível em: < <http://www.palgrave-journals.com/jors/index.html>>. Acesso em 30 abril 2013.

PAPERIN, G. **Using holey fitness landscapes to counteract premature convergence in evolutionary algorithms**. In: _CONFERENCE COMPANION ON GENETIC AND EVOLUTIONARY COMPUTATION, 2, 2008, Atlanta, GA, USA: **Proceedings ...** Atlanta, GA, USA: GECCO ACM:. 2008. p. 1815-1818

REN, X. Q. et al. The application of the maximal coverage and partial coverage model in the shelter location problem. In: SIMPÓSIO BRASILEIRO DE PESQUISA OPERACIONAL, 45, 2009, Natal/RN. **Anais....** Natal/RN: SBPO, 2009. p.1472-1478.

SCHAFFER, J. D. et al. **A study of control parameters affecting online performance of genetic algorithms for function optimization**. In: INTERNATIONAL CONFERENCE ON GENETIC ALGORITHMS, 3, 1989, George Mason, US. **Proceedings...** George Mason, US: : Morgan Kaufmann, 1989. p. 51-60.

SOLÉ, R. V. et al. Criticality and scaling in evolutionary ecology. **Trends in Ecology & Evolution**, v. 14, n. 4, p. 156-160, 1999. Disponível em: <<http://www.cell.com/trends/ecology-evolution/home>>. Acesso em 20 abril 2013.

SRINIVAS, M.; PATNAIK, L. M. Genetic algorithms: a survey. **The Computer Journal**, v. 27, n. 6, p. 17-26, 1994. Disponível em: <<http://comjnl.oxfordjournals.org/>>. Acesso em 18 abril 2013.

SUETH, J. C. R. **A trajetória de 100 anos dos eternos titãs; da Escola de Aprendizizes Artífices ao instituto federal**. Vitória, ES: Instituto Federal de Educação, Ciência e Tecnologia do Espírito Santo, 2009.

TEITZ, M. B.; BART, P. Heuristic methods for estimating the generalized vertex median of a weighted graph. **Operations Research**, v. 16, n. 5, p. 955-961, Disponível em: < <http://pubsonline.informs.org/journal/opre>>. Acesso em 30 abril 2013.

TORGAS, C.; REVELLE, C. Optimal location under time or distance constraints: **Papers in Regional Science**, v. 28, n. 1, p. 133-144, 1972. Disponível em: <[http://onlinelibrary.wiley.com/journal/10.1111/\(ISSN\)1435-5957](http://onlinelibrary.wiley.com/journal/10.1111/(ISSN)1435-5957)>. Acesso em 20 maio 2013.

TUTSCHKU, K. **Demand-based radio network planning of cellular mobile communication systems**. Würzburg , Germany: University of Würzburg 1998. p.1054-1061. Disponível em: <http://pdf.aminer.org/000/402/655/demand_based_radio_network_planning_of_cellular_mobile_communication_systems.pdf>. Acesso em 30 março 2013.

WHITLEY, D. A genetic algorithm tutorial. **Statistics and Computing**, v. 4, n. 2, p. 65-85, 1994. Disponível em: < <http://link.springer.com/journal/11222>>. Acesso em 18 maio 2013.