

USO DA REGRESSÃO ESTATÍSTICA PARA O AJUSTE DOS PARÂMETROS DO ALGORITMO GENÉTICO

Willen Borges Coelho

IFES – Instituto Federal do Espírito Santo
e-mail: willen@ifes.edu.br

Italo de Oliveira Matias

UCAM – Universidade Cândido Mendes
e-mail: italo@ucam-campos.br

Eduardo Shimoda

UCAM – Universidade Cândido Mendes
e-mail: shimoda@ucam-campos.br

Bruno Missi Xavier

UCAM – Universidade Cândido Mendes
e-mail: bmissix@gmail.com

Alcione Dias da Silva

UCAM – Universidade Cândido Mendes
e-mail: diasalcione@gmail.com

RESUMO

Encontrar o local ideal de instalação para antenas de transmissão é o que motiva a implementação de um aplicativo com base em inteligência computacional, utilizando o Problema de Localização de Máxima Cobertura (PLMC) e a metaheurística Algoritmo Genético (AG). Entretanto, o AG possui parâmetros que influenciam diretamente na qualidade e no tempo computacional gasto do resultado, tornando o ajuste dos parâmetros de extrema importância. Por isso, são propostas duas análises estatísticas, através de experimentos com o aplicativo desenvolvido, utilizando valores com base no cenário real, com o intuito de encontrar os parâmetros ideais para o algoritmo genético. Para isso utilizam-se, modelos de regressão com a finalidade de estabelecer associação entre variáveis explicativas (como por exemplo, taxa de cruzamento, taxa de mutação, número de indivíduos, número de gerações, entre outros) e a variável resposta (aptidão do indivíduo). No primeiro experimento foram obtidos 49.386 resultados e foi possível propor uma taxa de mutação que potencializa o valor de aptidão. No segundo experimento foram obtidos 36.818 resultados e foi possível propor mais dois parâmetros: taxa de crossover e o número de gerações.

PALAVRAS CHAVE: Problema de localização; Heurísticas; Algoritmos genéticos; Regressão.

Área principal (MH - Metaheurísticas)

ABSTRACT

Find the ideal place installation for transmitting antennas is what motivates the implementation of an application based on computational intelligence, using the Maximal Covering Location Problem (MCLP) and metaheuristic Genetic Algorithm (GA). However, the

AG has parameters that directly influence the quality and computational time spent in the result, making the adjustment of the parameters of the utmost importance. Are therefore proposed two statistical analyzes, through experiments with application developed using values based on real scenario, in order to find the ideal parameters for the genetic algorithm. For this are used, regression models in order to establish the association between explanatory variables (eg, rate of crossover, mutation rate, number of individuals, number of generations, among others) and the response variable (individual fitness). In the first experiment 49 386 results were obtained and it was possible to propose a mutation rate that optimizes the fitness value. In the second experiment were 36,818 results obtained and it was possible to propose two more parameters: crossover rate and the number of generations.

KEYWORDS: Location problem; Heuristics; Genetic Algorithms; Regression analysis.

Main area (MH - Metaheuristics)

1. Introdução

O Ifes - Instituto Federal de Educação, Ciência e Tecnologia do Espírito Santo campus Cachoeiro de Itapemirim possui aproximadamente 1100 alunos do curso técnico, integrado ao ensino médio e superior, e a fim de fomentar a pesquisa, ensino, extensão e inovação dentro do campus, estabeleceu uma meta de conceder acesso à rede interna e internet para alunos, professores, técnicos administrativos e visitantes através da tecnologia de rede sem fio.

A rede local sem fio, também denominada *Wireless Local Area Network* (WLAN), é uma rede 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. Este tipo de conectividade utiliza ondas de rádio para estabelecer conexão entre o ponto de acesso ou *access point* e o dispositivo móvel. O padrão que especifica a comunicação entre dispositivos sem fios ou *wireless* é o IEEE 802.11, promovido pelo IEEE (*Institute of Electrical and Electronic Engineers*).

Ao se comparar uma rede convencional com fio e uma sem fio, percebe-se que esta última também possui deficiências, como por exemplo, limite na área de cobertura do sinal e perda de sinal ao atravessar obstáculos, devido a mesma utilizar ondas eletromagnéticas como meio de transmissão. Portanto, para uma maior área de cobertura é necessário que os pontos de acessos estejam em locais com maior número de clientes sendo atendidos e com menor número de obstáculos.

Encontrar o local ideal de instalação das antenas é o que motiva a implementação de um aplicativo com base em inteligência computacional, para isso aplicou-se matematicamente o processo de adaptação dos sistemas naturais, com o Algoritmo Genético (AG), utilizando os problemas de localização, em especial o Problema de Localização de Máxima Cobertura (PLMC), como fundamento para encontrar soluções satisfatórias. Entretanto, o AG possui parâmetros que influenciam diretamente na qualidade do resultado e no tempo computacional gasto, tornando o ajuste dos parâmetros de extrema importância.

Neste trabalho, são propostas duas análises estatísticas, através de experimentos com o aplicativo desenvolvido, utilizando valores com base no cenário real, com o intuito de encontrar os parâmetros ideais para o algoritmo genético, de forma que seu resultado e tempo de execução sejam otimizados. Para isso utilizam-se, modelos de regressão com a finalidade de estabelecer relação entre variáveis explicativas (como por exemplo, taxa de cruzamento, taxa de mutação, número de indivíduos, número de gerações, entre outros) e a variável resposta (aptidão do indivíduo).

2. Problema de Localização

Através do Problema das p -Medianas (*p-Median Problem* - PMP) é possível localizar os pontos de demandas, que inicialmente foi proposto por HAKIMI (1964). 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. Entretanto, de acordo com CHURCH; REVELLE (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, dessa forma, que todos os pontos de demanda sejam atendidos, contudo nem sempre a facilidade possui capacidade de alcance suficiente para garantir a cobertura total à demanda, por isso é necessário a utilização de um limite no raio de alcance da antena, na Figura 1 é apresentada uma solução com o PMP e outra com o PMP com o raio de alcance máximo. Este problema tem sido denominado como o problema de p -Medianas com restrição de distância máxima ou PLMC (KHUMAWALA, 1973).

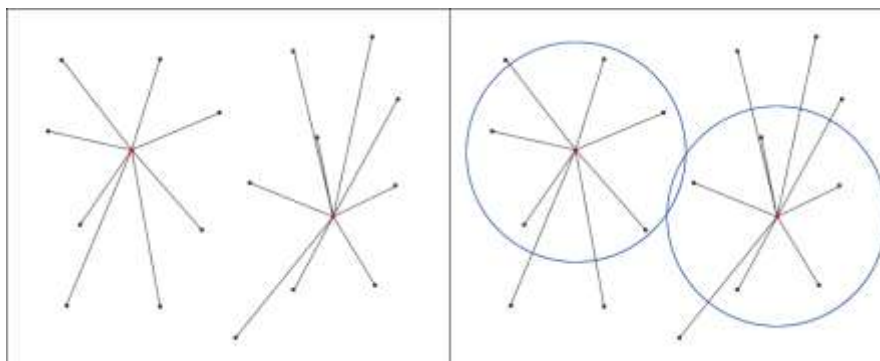


Figura 1 - Exemplo de solução do PMP sem e com o raio de alcance máximo

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. Assegurando dessa forma, que as demandas sejam atendidas com qualidade, pois não existem antenas de transmissão com alcance ilimitado.

Pode-se encontrar na literatura uma diversificada aplicação do PLMC para a localização de facilidades, dentre eles: localização das bases de ambulância para atendimento médico (AZIZAN et al., 2012), localização de abrigos em caso de evento catastrófico em uma cidade (REN et al., 2009), localização de postos de combustíveis alternativos no estado da Flórida (LIM; KUBY, 2010) e também na localização de instalações para atender uma emergência no caso de ataque bio-terrorista de grande escala de antraz na cidade de Los Angeles (MURALI; ORDÓÑEZ; DESSOUKY, 2012).

O PLMC pertence à classe NP-difícil (*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 (GAREY; JOHNSON, 1979; SHEN; ZHAN; ZHANG, 2011). Como uma alternativa para a resolução do PLMC, algoritmos evolucionários podem ser levados em consideração. Entre eles, o conceito de Algoritmo Genético, inspirado na teoria de Darwin na sobrevivência do mais forte. 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 AGs 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.

3. 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 AGs 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 (GOLDBERG, 1989; GREFENSTETTE, 1986; JONG, 1975; SCHAFFER et al., 1989).

JONG (1975), em sua tese de doutorado, 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. Sua *suíte* de funções já foi aprovada por vários pesquisadores como base de teste padrão para avaliar

projetos de AG (GIGER; KELLER; ERMANNI, 2007; HENDTLASS, 2001; HORN; GOLDBERG, 1996; KOK; SANDROCK, 2009; PAPERIN, 2008).

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 por ele utilizadas, 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 amplamente adotadas e muitas vezes referidas 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

Um pouco 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 aconselhados 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 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. 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.

4.1. Algoritmo Genético Proposto

O fluxograma do algoritmo genético proposto pode ser visualizado na Figura 2. Ele inicia seu processo carregando uma imagem que possui os pontos de demanda, a imagem utilizada nos experimentos possuem 287 pontos de demanda, representando os locais nos quais são necessária cobertura de acesso à rede sem fio, além disso, limitou-se em dez o número de pontos de facilidade, devido ao IFES *campus* Cachoeiro possuir esse mesmo número de rádios e antenas para fornecer o acesso a rede sem fio. Logo após carregar a imagem, ele gera uma matriz de distância entre todos os pontos de demanda, cria a população inicial e dá início ao processo evolutivo.

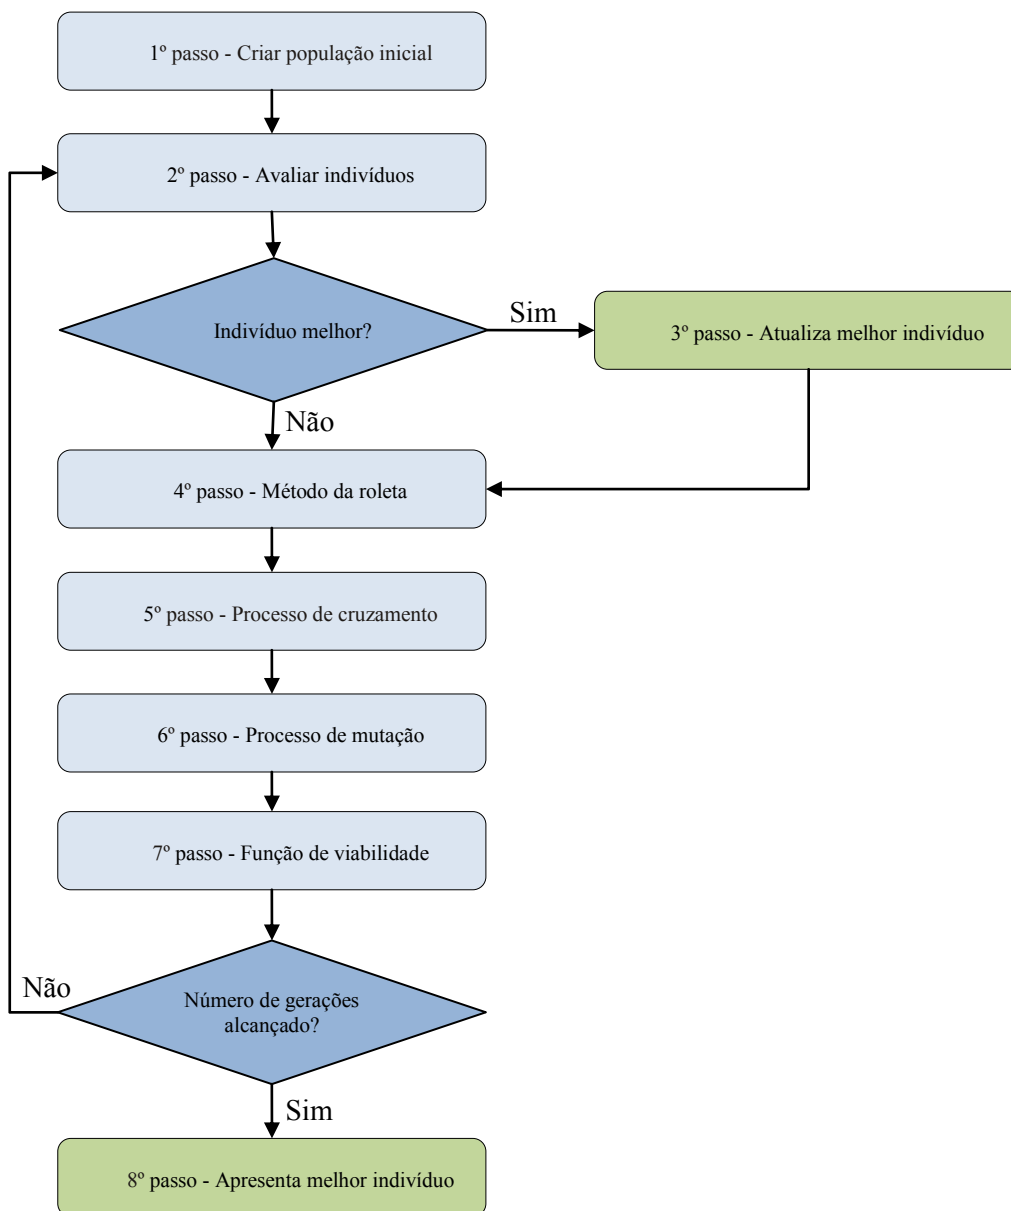


Figura 2 - Fluxograma do algoritmo genético proposto

A criação da população inicial é aleatória, entretanto, alterou-se o percentual do método randômico, a fim de que o número de pontos de facilidades nunca seja maior o valor limite, que é dez.

Para efetuar o cálculo de aptidão do indivíduo utilizou-se de pesos para compensar os objetivos simultâneos, isto é, além de maximizar o número de demandas cobertos, é necessário que seja minimizado o número de facilidades empregadas (evitando o desperdício de equipamento) e o número de pontos de demandas que podem ser atendidos por mais de um ponto de facilidade (evitando a colisão de sinal). Por isso, 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.

Os indivíduos da nova geração são selecionados de forma aleatória, utilizando o método da roleta, entretanto, a probabilidade de um indivíduo ser escolhido é proporcional ao valor da sua aptidão dividido pela aptidão total da população, denominada de aptidão relativa.

Os indivíduos selecionados pela roleta são então submetidos a um novo processo seleção, com a finalidade de escolher os indivíduos que serão submetidos ao processo de cruzamento. Os indivíduos selecionados, os pais, são submetidos ao cruzamento utilizando ponto de corte único e variável, isto é, o local é escolhido de forma aleatória.

O processo de mutação é realizado *bit-a-bit*, no qual, cada bit é submetido a um processo de seleção e os bits selecionados são então modificados, isto é, o valor do bit é alterado de 0 para 1 ou de 1 para 0.

A 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.

Caso o número de gerações seja satisfeito, o aplicativo exibe o melhor resultado encontrado de forma textual com a interpretação do resultado, 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 também no formato gráfico, no qual utiliza-se da imagem inicial para representar os pontos eleitos como facilidade, uma linha entre o ponto de demanda e o ponto de facilidade e um círculo com o raio de transmissão da facilidade, possibilitando uma análise simples do resultado.

4.2. Primeiro Experimento

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 2, no qual os valores eram 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.

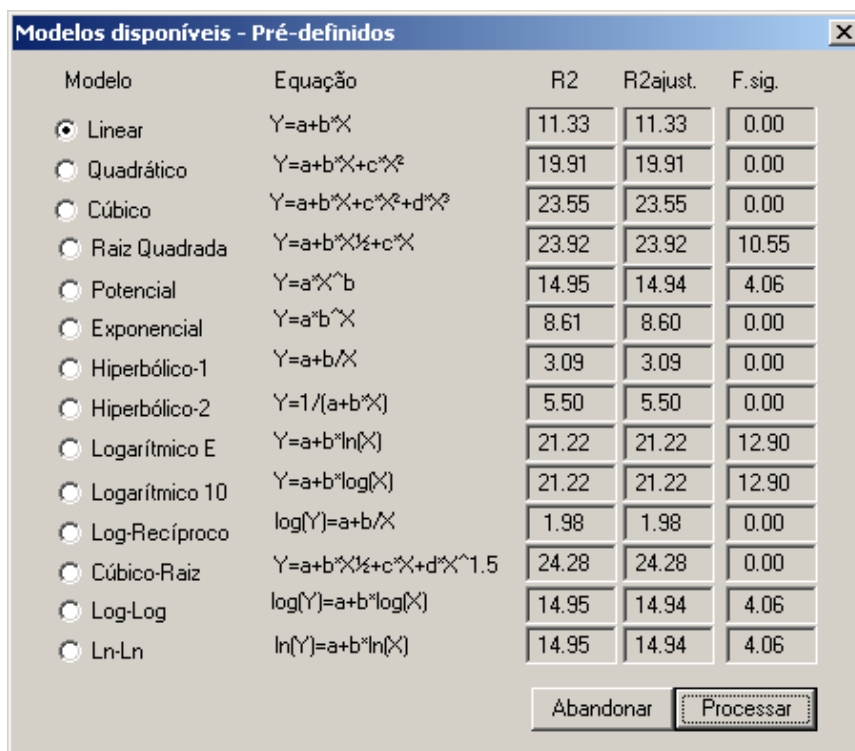
Tabela 2 - Parâmetros utilizados no primeiro experimento

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. No primeiro experimento foram obtidos 49.386 resultados com a execução do aplicativo com valores aleatórios, que corresponde a mais de 4 meses de execução do aplicativo ininterruptamente.

Os dados do primeiro experimento foram inicialmente exportados do banco de dados *Mysql*, 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, desenvolvido por EUCLYDES (1988), 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 3, no qual foi escolhido o Cúbico-Raiz, por apresentar o maior valor de significância (R2) e coeficiente de determinação abaixo de 5% (F. sig.).



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	$Y=a+b*X^{\frac{1}{2}}+c*X$	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	$Y=a+b*X^{\frac{1}{2}}+c*X+d*X^{1.5}$	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

Figura 3 - Parâmetros da regressão da aptidão em função da mutação

Através da análise estatística do primeiro experimento, foi possível indicar uma taxa de mutação fixa, como pode ser visualizada pela Figura 4, 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 4 - Gráfico Cúbico-Raiz entre aptidão em função da taxa de mutação

4.3. 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 3 são apresentados os parâmetros utilizados no segundo experimento, sendo que a taxa de mutação foi fixada em 0,01%.

Tabela 3 - 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, correspondentes a três meses de execução do aplicativo sem interrupção. Os dados 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 5 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 6 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 conseqüentemente maior será o tempo para o resultado. Diante disto o número de gerações selecionado foi 1000, pois obtém boas soluções em tempo aceitável.




Figura 5 - Gráfico Cúbico entre aptidão em função da taxa de crossover




Figura 6 - Gráfico Cúbico-Raiz entre aptidão em função do número de gerações

O resultado da execução do aplicativo é composto do detalhamento do melhor resultado, como por exemplo: antenas eleitas como facilidades, quantidade de demandas atendidas, porcentagem de demandas atendidas, quantidade de colisões de sinal, em qual geração o indivíduo foi criado e valor da aptidão do resultado, do resultado em forma de imagem, no qual é possível observar quais as demandas foram atendidas e o raio de transmissão da facilidade, como pode ser observado na Figura 7.



Figura 7 - Resultado obtido pelo aplicativo com base em Inteligência computacional

5. Conclusões

Neste trabalho, foram propostas e analisadas dois experimentos, com base no algoritmo genético, a fim de aperfeiçoar os parâmetros de funcionamento do aplicativo responsável por encontrar uma solução para o problema de localização de antenas no IFES campus Cachoeiro de Itapemirim, visando o atendimento do maior número de demandas (clientes) e na utilização do menor número de facilidades (antenas), considerando as restrições de alcance de transmissão das facilidades.

No primeiro experimento foram obtidos 49.386 resultados, que corresponde a mais de quatro meses de execução do aplicativo, isto devido a variação do número de indivíduos e do número de gerações, pois as duas variáveis afetam diretamente no custo computacional e conseqüentemente no tempo de execução, apesar da alta capacidade de processamento do servidor e das diversas *threads* que executavam concorrentemente para aproveitar ao máximo os *multi-cores* presentes nos dois processadores. No segundo experimento foram obtidos 36.818 resultados, que corresponde a três meses de execução do aplicativo, aproveitando ao máximo o *hardware* disponível.

Na análise dos resultados computacionais do primeiro experimento foi possível propor uma taxa de mutação que potencializa o valor de aptidão. Na análise dos resultados computacionais do segundo experimento foi possível escolher mais dois parâmetros que aprimoram ainda mais o valor de aptidão, são eles a taxa de crossover e o número de gerações, sendo que este último, o resultado já era esperado, pois quanto maior o número de gerações, maior será a possibilidade de o algoritmo genético encontrar um valor da aptidão superior, entretanto o número de gerações influencia diretamente no custo computacional e conseqüentemente no tempo de execução do

aplicativo. Diante disto o número de gerações selecionado foi 1000, pois obtém boas soluções em tempo aceitável.

Referências

- AZIZAN, M. H. et al. **Application of OpenStreetMap data in ambulance location problem. Computational Intelligence**, Communication Systems and Networks (CICSyN), 2012. Phuket. 24-26 July 2012. p.321-325.
- CHURCH, R. L.; REVELLE, C. S. Theoretical and Computational Links between the p-Median, Location Set-covering, and the Maximal Covering Location Problem. **Geographical Analysis**, v. 8, n. 4, p. 406-415, 1976.
- EUCLYDES, R. F. **Manual de Utilização do programa SAEG. (Sistema para análises estatísticas e genéticas)**. VIÇOSA: UFV - CPD: 82 p. 1988.
- GAREY, M. R.; JOHNSON, D. S. **Computers and Intractability: A Guide to the Theory of NP-Completeness**. New York: W. H. Freeman & Co., 1979. 338
- GIGER, M.; KELLER, D.; ERMANNI, P. AORCEA - An adaptive operator rate controlled evolutionary algorithm. **Computers Structures**, v. 85, n. 19-20, p. 1547-1561, 2007.
- GOLDBERG, D. E. **Genetic Algorithms in Search, Optimization and Machine Learning**. Boston: Addison-Wesley Longman Publishing Co., Inc., 1989. 372
- GREFENSTETTE, J. J. Optimization of Control Parameters for Genetic Algorithms. **IEEE Transactions on Systems, Man and Cybernetics**, v. 16, n. 1, p. 122-128, 1986.
- HAKIMI, S. L. Optimum Locations of Switching Centers and the Absolute Centers and Medians of a Graph. **Operations Research**, v. 12, n. 3, p. 450-459, 1964.
- HENDTLASS, T. A Combined Swarm Differential Evolution Algorithm for Optimization Problems. In: (Ed.). **Engineering of Intelligent Systems**. Budapest: Springer Berlin Heidelberg, v.2070, 2001. cap. 2, p.11-18.
- HORN, J.; GOLDBERG, D. E. Natural niching for evolving cooperative classifiers. In: (Ed.). **Proceedings of the First Annual Conference on Genetic Programming**. Stanford, California: MIT Press, 1996. p.553-564.
- JONG, K. A. D. **An analysis of the behavior of a class of genetic adaptive systems**. 1975. University of Michigan, Ann Arbor, MI, USA.
- 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.
- KOK, S.; SANDROCK, C. Locating and characterizing the stationary points of the extended rosenbrock function. **Evolutionary Computation**, v. 17, n. 3, p. 437-453, 2009.
- 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.
- 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.
- PAPERIN, G. Using holey fitness landscapes to counteract premature convergence in evolutionary algorithms. **Proceedings of the 2008 GECCO conference companion on Genetic and evolutionary computation**, Atlanta, GA, USA, p. 1815-1818, 2008.

REN, X. Q. et al. **The application of the maximal coverage and partial coverage model in the shelter location problem.** Ninth International Conference of Chinese Transportation Professionals (ICCTP), 2009. Harbin, China. p.1472-1478.

SCHAFFER, J. D. et al. **A study of control parameters affecting online performance of genetic algorithms for function optimization.** Proceedings of the third international conference on Genetic algorithms, 1989. San Francisco, CA, USA. Morgan Kaufmann Publishers Inc. p.51-60.

SHEN, Z.-J. M.; ZHAN, R. L.; ZHANG, J. The Reliable Facility Location Problem: Formulations, Heuristics, and Approximation Algorithms. **INFORMS J. on Computing**, v. 23, n. 3, p. 470-482, 2011. ISSN 1526-5528.