

Genetic Algorithm and Simulated Annealing in EE Transmission Expansion Planning

Algoritmo Genético e Têmpera Simulada no Planejamento da Expansão de Transmissão de EE

S. M. Campo¹, L. Valdez², A. J. Burgos¹ and HA Rodríguez-Arias²

Universida Cooperativa de Colômbia UCC¹, sergio.martinezc@campusucc.edu.co, arthur.burgos@campusucc.edu.co
Fundación Universitaria Antonio de Arévalo², decano.fadi@unitecnar.edu.co,

Abstract— *In the present article, it shows the evaluation of two heuristic optimization methods, called genetic algorithms AG and simulated tempering AS (Simulated Annealing), applied to find the best solution with the lowest cost in planning the expansion of a network transmission system, which, in addition to meeting the expected demand, considers a list of candidate alternatives with known cost and transport capacity. With the development of the AG and AS algorithms, it is possible to guarantee the best optimization solution, measuring the computational cost of the algorithms. It was verified that the Genetic Algorithm optimization method can find the best optimal solution at a lower computational cost, compared to the Simulated Annealing algorithm. All results obtained in this work for the expansion of the system in an optimal way are satisfactory as they also meet all restrictions.*

Keywords— *AG genetic algorithms, simulated annealing AS, heuristic optimization, planning, network expansion, electric power transmission.*

Resumo— *No artigo a apresentar, mostra a avaliação de dois métodos de otimização heurística, denominados como algoritmos genéticos AG e tempera simulada AS (Simulated Annealing), aplicados a fim de encontrar a melhor solução com o menor custo no planejamento da expansão de uma rede de transmissão de energia elétrica, que além de visar atender a demanda esperada considera uma lista de alternativas candidatas com custo conhecido e capacidade de transporte. Com o desenvolvimento dos algoritmo AG e AS, é possível garantir a melhor solução de otimização, medindo o custo computacionais dos algoritmos. Verificou-se que o método de otimização Algoritmo Genético é capaz de encontrar a melhor solução ótima num custo computacionais menor, ao algoritmo Têmpera Simulada. Todos resultados obtidos neste trabalho para a expansão do sistema de forma ótima são satisfatórios pois além atendem a todas as restrições.*

Palavras-chave— *Algoritmos genéticos AG, Tempera simulada AS, otimização heurística, planejamento, expansão de uma rede, transmissão de energia elétrica.*

I. INTRODUÇÃO

O sistema de energia elétrica é considerado um sistema em constante expansão devido à crescente demanda que existe ao longo do tempo, com o objetivo de suprir de forma confiável e segura essa demanda de energia elétrica, são necessárias novas obras de geração, transmissão e em geral um toda a obra de ampliação da rede elétrica, para a qual deve ser realizada de forma adequada uma complexa tarefa denominada planejamento, a qual através de métodos de otimização busca

obter a melhor alternativa para realizar a expansão do sistema de energia elétrica da forma mais eficiente técnica e economicamente.

Assim, neste trabalho são desenvolvidas técnicas de otimização heurística: algoritmos genéticos e simulação de temperatura, para determinar a melhor solução na expansão de um sistema de transmissão, considerando a carga, demanda, fluxos e injeções de potência do sistema, ou seja, conseguir atender a demanda ao mínimo custo, levando em consideração as restrições operacionais do sistema

O método de otimização de algoritmos genéticos (AG) foi inicialmente formado por Holland [1], este tipo de otimização se baseia em algoritmos que operam sobre um conjunto de possíveis soluções do problema, em cada iteração, operadores são aplicados aos indivíduos para simular os fenômenos de seleção natural, de geração de novos indivíduos pela reprodução sexuada e de mutação aleatória dos indivíduos.[2]

Para atingir a solução ótima, o algoritmo é basicamente composto por 5 partes: codificação, população inicial, função de adaptação, operadores genéticos e vários parâmetros; de forma que “a cada iteração do algoritmo as soluções mais promissoras do problema, ou seja os indivíduos mais aptos têm maior probabilidade de serem selecionadas para gerar descendentes, que podem se entender como possíveis soluções; depois alguns indivíduos são selecionados aleatoriamente, independentemente de sua aptidão, para sofrerem uma mutação. Assim o valor da função objetivo é então calculado para cada elemento deste novo conjunto de soluções tentativa. Os métodos de seleção são projetados para escolher preferencialmente indivíduos com maiores notas de aptidão, embora não exclusivamente, a fim de manter a diversidade da população” [3]

Por outra parte, sé tem o método da temperatura simulada como o segundo método de otimização heurístico a avaliar, está baseado na técnica de Monte Carlo, que busca escolher uma partícula aleatoriamente determinado um movimento também aleatório para mudar ele de energia e aceitar ou rejeitar, tendo probabilidade de aceitar ele de forma diretamente proporcional á temperatura, iterando o mesmo até a temperatura atingir um valor nulo, que significa a solução ótima. [4]

Digital Object Identifier (DOI):

<http://dx.doi.org/10.18687/LACCEI2022.1.1.826>

ISBN: 978-628-95207-0-5 ISSN: 2414-6390

Como os métodos heurísticos são procedimentos eficientes que servem para encontrar boas soluções, mesmo que não se possa provar que são ótimas, nestes métodos de otimização a velocidade do processo é tão importante quanto a qualidade da solução obtida, pelo qual o melhor método serão aquele que consiga atender as duas características.

II. ALGORITMO GENÉTICO

A continuação é apresentado a estruturação do algoritmo e a explicação de cada passo.

1. Codificação

1.1 Dados iniciais

1.2 Definições iniciais

1.2.1 Probabilidade cumulativa (números de pais)

1.2.2 Inicializa vetor e matrizes (melhor fitness, elite e número de criança)

1.3 População inicial

2. Ciclo de evolução

2.1 Avaliação da função de adaptação (função fitness)

2.2 Escolhei o melhor fitness (elitismo)

2.3 Recombinação (crossover)

2.3.1 Escolhe o um melhor pai e mãe (probabilidade cumulativa)

2.3.2 Determina o ponto de cruzamento

2.3.3 Obtém duas crianças e atualiza a população

2.4 Mutação

2.4.1 Determina o número de mutação (número de elementos pelo número de mutação).

2.4.2 Determina pontos de mutação (posições aleatórias)

2.4.3 Gera uma nova população com a atualização de e mutação.

1. Codificação

Os indivíduos, que são as possíveis soluções para o problema de planejamento da expansão de uma rede de transmissão de energia elétrica, podem ser codificados um conjunto de parâmetros (que chamaremos de genes), que, quando agrupados, formam uma cadeia de valores (muitas vezes referida como um cromossomo). Neste caso, o alfabeto usado para representar os indivíduos estão constituído por 0 e 1, próprio da naturaliza de posicionamento de circuitos candidatos a serem instalados.

Em termos biológicos, o conjunto de parâmetros que representam um cromossomo específico é denominado fenótipo. O fenótipo contém as informações necessárias para construir um organismo, que é conhecido como genótipo [4]. Os mesmos termos são usados no campo dos algoritmos genéticos. A adaptação ao problema de um indivíduo depende da avaliação do genótipo. Este último pode ser inferido a partir do fenótipo, ou seja, pode ser calculado a partir do cromossomo, por meio da função de avaliação [4].

1.1 Dados iniciais

numero_de_elementos. Para o problema de planejamento de expansão de uma rede de transmissão de energia elétrica, o número de genes (genótipo) é a quantidade NL de linha (ramos) disponibilizada para uma conexão de um novo circuito. Essa variável é assignada pela topologia da rede de energia elétrica, seja o caso estudo.

tamanho_da_população. No contexto dos algoritmos genéticos, o termo indivíduo refere-se a cada uma das soluções possíveis para o problema a ser resolvido. No caso de minimização de uma função, cada indivíduo representa uma possível combinação de valores das variáveis. Para representar essas combinações, podem ser usados vetores (arrays), aonde as linhas são os indivíduos e as colunas são as variáveis (NL), e cada posição assume um valor numérico. Este dado é definido pelo usuário do algoritmo.

numero_do_pai. Determina o elitismo ou número que permanece nas primeiras posições da função fitness, na matriz população (melhores indivíduos) e define o comprimento do vetor da probabilidades cumulativas. Então, os demais indivíduos são as possível crianças.

taxa_de_mutação. Define a probabilidade de mutação, ou seja, determina quantos genes são truncados no processo de mutação.

max_geracao. Define o ciclo da evolução do algoritmo. É a quantidade de ciclos que a população muda.

1.2 Definições iniciais

1.2.1 Probabilidade acumulativa (números de pais)

O Amostragem Estocásticos Universal é feito por uma função de probabilidade acumulativa, consiste em assignar uma probabilidade igual a cada indivíduo, pelo tanto, não depende da atitude [5].

$$p(i) = \frac{1}{N} \quad (1)$$

Aonde $p(i)$ é a probabilidade do individuo i e N e o tamanho da população.

$$F(x) = P(X \leq x) = P(X = 0) + P(X = 1) + \dots + P(X = x)$$

Para,

$$X \sim B(n; p) \quad (2)$$

Onde,

$F(x)$ é a função de distribuição acumulativa de uma variável aleatória binomial

$f(x)$ é a função de probabilidade

X é a variável aleatória

x são os valores inteiros

n é o número de ensaios

B é a distribuição binomial

p é a probabilidade de êxito

No Matlab, é possível fazer a probabilidade acumulativa com o comando CUMSUM, da seguinte função:

Digital Object Identifier: (only for full papers, inserted by LACCEI).
ISSN, ISBN: (to be inserted by LACCEI).

$$f(x) = \left(\frac{x_{NP} + x_{NP-1} + \dots + x_i}{\sum_{x_i}^{NP} x_i} \right) \quad (3)$$

$$PU = \text{cumsum}(f(x)) \quad (4)$$

PU é a probabilidade acumulativa

NP é o número de pai

Como a coerência da seleção do melhor elite é de forma ascendente (o melhor fitness fica no primeiro lugar), então a probabilidade cumulativa também é de forma ascendente. Desta maneira, vai-se selecionar os candidatos de pai e mãe, nos indivíduos elite, no espaço de tamanho de NP .

O vetor de probabilidade acumulativas, ajudará selecionar de forma distribuída e aleatoriamente o pai e a mãe, em cada ciclo de recombinação no espaço das crianças.

1.2.2 Inicializa vetor e matrizes (melhor fitness, elite e número de criança)

Se inicializa em zeros, o vetor de melhor fitness y a matriz elite. O número de criança é feito pela diferença entre tamanho da população e o número de pai.

1.3 População inicial

Para o problema do planejamento da expansão da transmissão, é gerada uma população inicial aleatória, ou qual, determina aleatoriamente o número de linhas que comporão o ramo candidato. Esta inicialização é utilizada para sistemas de pequeno e médio porte. Para sistemas de grande porte, é utilizada a inicialização através dos métodos aproximados como, Garver, Villasana-Garver, mínimo esforço e mínimo corte de carga [6].

2. Ciclo de evolução

2.1 Avaliação da função de adaptação (função fitness)

Dentro do ciclo de evolução, determinado pelo número de gerações máximas, se faz a avaliação da função fitness (resolve o problema de fluxo) para uma nova população em cada iteração. Na primeira iteração, a avaliação é feita pela população inicial.

2.2 Escolhei o melhor fitness (elitismo)

Organiza de maneira ascendente a função fitness. Se fixa na primeira posição da matriz da população, o melhor indivíduo e se guarda na matriz elite.

2.3 Recombinação (crossover)

2.3.1 Escolhe o um melhor pai e mãe (probabilidade cumulativa)

No espaço dos números de pais (comprimento), se escolhe uma mãe e um pai aleatoriamente, baseado na função de probabilidade acumulativa.

2.3.2 Determina o ponto de cruzamento

O ponto de cruzamento do cromossoma, é determinado aleatoriamente, e depende do comprimento de número de elementos.

2.3.3 Obtém duas crianças e atualiza a população

No espaço das crianças, se gera dois filhos em cada iteração, fazendo a recombinação com o pai e a mãe escolhida. E é atualizada a matriz da população, inserindo os filhos.

2.4 Mutaç o

2.4.1 Determina o n mero de muta o (n mero de elementos pelo n mero de muta o).

Excluindo os elites, determina-se uma matriz para muta o e o n mero de genes, tamanho da popula o (menos os elites), por o n mero de elementos.

O n mero de muta o ou a quantidade de muta o a ser feita,   determinada pelo n mero de genes por a taxa de muta o.

2.4.2 Determina pontos de muta o (posi es alect rias)

As posi es dos genes pra mutar, s o selecionados aleatoriamente no espa o de n meros de genes, desde um at  o n mero de muta o.

2.4.3 Gera uma nova popula o com a atualiza o de muta o.

  atualizada a matriz popula o, com a muta o. Finalmente se gera uma nova popula o com a recombina o e muta o, ou qual, vai ser o novo espa o de poss vel solu es.

III. T MPERA SIMULADA

O m todo de otimiza o heur stica simulado templo ou Simulated Annaeling (AS),   um algoritmo utilizado para problemas de otimiza o global, que visa encontrar uma boa aproxima o do ponto  timo geral, ou seja, o ponto m nimo global para todo o espa o de solu o, conseguindo v rias modifica es que pioram ou temporariamente fugir das solu es  timas locais [6].

O m todo SA baseia-se na modelagem de um sistema termodin mico movendo-se de um estado atual para outro, sempre em uma dire o que apresente uma taxa mais elevada de varia o em uma fun o objetivo, ou seja, de uma solu o atual para outra poss vel que est  sob probabilidade. de aceita o diretamente proporcional   temperatura.

O algoritmo pode ser descrito da seguinte forma descrita tamb m em [7]

1. Sele o da solu o inicia donde o m nimo global pertence ao espa o de solu o.
2. Sele o do contador de cambio de temperatura $k=0$.
3. Sele o do esquema de temperatura de esfriamento, tk
4. Sele o de uma temperatura inicial $T = T_0 \geq 0$
5. Definir o esquema de itera es.
6. Repetir

Assim o processo a obter pode-se definir:

- Gera ruma solu o $\omega' \in N(\omega)$
- Calcular $\Delta\omega = f(\omega') - f(\omega)$
- Si $\Delta\omega \leq 0$, ent o $\omega \leftarrow \omega'$
- Si $\Delta\omega > 0$, ent o $\omega \leftarrow \omega'$ com a probabilidade de: $\exp(-\Delta\omega/Tk)$

- $m \leftarrow m + 1$
- Até que $m = Mk$
- Iterar até o critério de convergência

Onde:

$$\omega' \in N(\omega)$$

ω é o mínimo global

$N(\omega)$ é a solução da vizinhança

$f(\omega)$ são os valores de função objetiva

As probabilidades de transição definidas como:

$$\Delta\omega \leq 0, \text{então } \omega \leftarrow \omega', \text{ ou } \Delta\omega > 0, \text{então } \omega \leftarrow \omega'$$

são definidas por uma série de soluções geradas em eventos imediatamente anteriores.

IV. RESULTADOS E ANÁLISE DE ALGORITMO GENÉTICO

A continuação são apresentado os resultados para cada caso: garver1dados (rede Garver COM redespacho), garver2dados (rede Garver SEM redespacho), sul46barras1dados (rede 46 barras COM redespacho) e sul46barras2dados (rede 46 barras SEM redespacho).

Primeiramente se testou o caso garver1dados, mudando o número de pai com entre 10 e 90, fixando o tamanho da população em 100, a taxa de mutação em 0,03 e um número de geração em 30.

A. Garver1dados

TABELA I
RESULTADOS DA REDE GARVER COM REDESPACHO PARA DIFERENTE NÚMEROS DE PAIS

Gerações	F. Custo pu (\$)	No Indivíduos Diferentes	F. Custo pu (\$)	No Indivíduos Diferentes	F. Custo pu (\$)	No Indivíduos Diferentes
	No Pais = 10		No Pais = 50		No Pais = 90	
	T. decorrido = 20.25sg		T. decorrido = 21.55sg		T. decorrido = 21.28sg	
1	505	100	482	100	444	100
2	346	67	377	95	444	98
3	306	43	377	84	388	96
4	306	19	357	69	388	96
5	268	12	339	54	388	95
6	268	12	337	52	388	91
7	268	12	308	41	368	93
8	268	15	299	29	368	92
9	268	10	288	31	348	91
10	268	13	268	30	348	93
11	268	12	268	28	328	92
12	268	12	268	19	328	92
13	268	15	268	17	328	93
14	268	11	268	19	328	93

15	268	14	268	13	308	92
16	268	13	268	16	308	92
17	268	12	268	13	308	91
18	268	13	268	15	308	89
19	268	12	268	11	308	87
20	268	11	268	13	308	82
21	268	15	268	14	308	82
22	268	11	268	13	308	76
23	268	11	268	12	268	77
24	268	14	268	10	268	72
25	268	13	268	15	268	74
26	268	14	268	15	268	75
27	268	14	268	15	268	77
28	268	14	268	12	268	73
29	268	14	268	11	268	69
30	268	11	268	12	268	70

^aAutores

É possível determinar que o algoritmo consegue o ótimo nas primeiras gerações, quando o número de pais é menor. As seguinte gráficas apresentam o comportamento.




Fig. 1 Rede Garver Com Redespacho Número de pais = 10 e 50

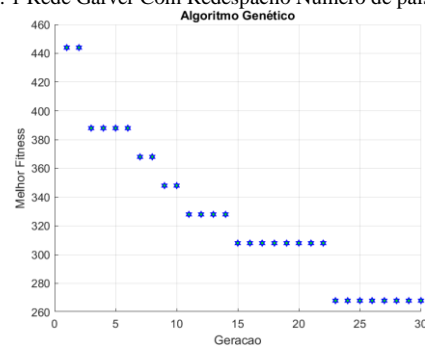


Fig. 2 Rede Garver Com Redespacho Número de pais = 90

B. Fixando o número de pais em 10, obtém-se os seguintes resultados para os casos: garver2dados, sul46barras1dados e sul46barras2dados.

TABELA II
RESULTADOS COM O NÚMEROS DE PAIS ESTABELECIDOS EM 10

	Garver2dados	Sul46barras1dados	Sul46barras2dados
--	--------------	-------------------	-------------------

Gerações	F. Custo pu (\$)	Individuos Diferentes	F. Custo pu (\$)	Individuos Diferentes	F. Custo pu (\$)	Individuos Diferentes
	T. decorrido = 21.66sg		T. decorrido = 25.45sg		T. decorrido = 24.70sg	
1	2,1606E+10	100	397768	100	8,57E+10	100
2	1,7794E+10	55	395757	93	6,8169E+10	95
3	1,697E+10	44	363125	83	5,4131E+10	99
4	1685811.79	25	301360	93	357214893 9	91
5	1685811.79	19	284467	94	2,4327E+10	93
6	1,6825E+10	13	266427	80	185002115 1	90
7	1,6825E+10	17	232670	90	1,6708E+10	89
8	1,6825E+10	15	201379	86	1,4243E+10	90
9	1,6825E+10	14	185798	81	1,2601E+10	93
10	1,6825E+10	13	181752	84	1,1408E+10	92
11	1,6825E+10	12	172317	69	1,0478E+10	94
12	1,6825E+10	16	160993	74	1,0214E+10	85
13	1,6825E+10	14	159630	78	1,0027E+10	71
14	1,6825E+10	18	158620	72	962401389 6	68
15	1,6825E+10	14	155736	68	932714654 9	81
16	1,6825E+10	12	148817	60	924536654 9	86
17	1,6825E+10	14	142852	67	908940141 7	81
18	1,6825E+10	12	139968	77	899374086 7	79
19	1,6825E+10	14	139968	77	890755021 2	74
20	1,6825E+10	9	139968	68	890194969 9	82
21	1,6825E+10	14	139968	62	882577021 2	70
22	1,6825E+10	12	139968	58	877756994 6	74
23	1,6825E+10	14	139968	65	871720658 3	80
24	1,6825E+10	18	134306	64	865730519 6	78
25	1,6825E+10	11	134306	65	862058548 8	79
26	1,6825E+10	14	134306	65	850715081 7	71
27	1,6825E+10	12	130260	58	850715081 7	76
28	1,6825E+10	15	130260	68	850715081 7	62
29	1,6825E+10	11	130260	59	842621190 4	63
30	1,6825E+10	16	130260	60	842621190 4	71

^aAutores

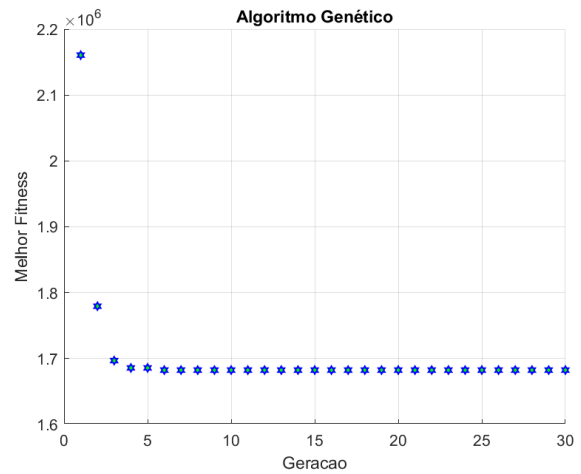


Fig. 3 Rede Garver Sem Redespacho Número de pais = 10




Fig. 4 Rede 46 barras COM e SEM redespacho Número de pais = 10

IV. RESULTADOS E ANALISE DE TÊMPERA SIMULADA

A continuação são apresentado os resultados para cada caso: garver1dados (rede Garver COM redespacho), garver2dados (rede Garver SEM redespacho), sul46barras1dados (rede 46 barras COM redespacho) e sul46barras2dados (rede 46 barras SEM redespacho).

Primeiramente se testou o caso garver1dados, mudando a hipotermia entre 0,1 e 0,9, fixando a temperatura inicial em 100 e o tamanho da vizinhança em 80.

A. Garver1dados

TABELA III
RESULTADOS DA REDE GARVER COM REDESPACHO PARA DIFERENTE DADOS DE HIPOTERMIA

F. Custo pu (\$)	Temperatura °C	F. Custo pu (\$)	Temperatura °C	F. Custo pu (\$)	Temperatura °C
Hipotermia = 0.1		Hipotermia = 0.5		Hipotermia = 0.9	
T. decorrido = 1.379 sg		T. decorrido = 4.634 sg		T. decorrido = 30.797 sg	
639503071	10	1566557446	50	2233817387 1	90
585800284 2	1	1334717851 7	25	5964291769	81
497		1830388740 1	13	318785579	73
		7519215276	6	9144233741	66
		9621385093	3	2032471479	59

		500319	2	7658961013	53
		500319	1	8884930955	48
		366		1266072879 8	43
F. Custo pu (\$)	Tempera tura °C	F. Custo pu (\$)	Temper atura °C	F. Custo pu (\$)	Temperat ura °C
Hipotermia = 0,9		Hipotermia = 0,9		Hipotermia = 0,9	
T. decorrido = 30.797 sg		T. decorrido = 30.797 sg		T. decorrido = 30.797 sg	
589280060 5	39	1149419817	10	1725242007 3	3
1,2085E+10	35	319	9	8025514382	2
1472966.78	31	1057222555 9	8	5364882696	2
287383325 7	28	1266072879 8	7	9406138265	2
384544609 2	25	7204387616	6	1500323	2
1500302	23	5964291769	6	9022728198	1
203247147 9	21	318785579	5	1033592379 6	1
720438761 6	19	9575294897	5	3596847011	1
1,2705E+10	17	1500321	4	1871690679 9	1
1,0181E+10	15	9134575067	4	1126803576 2	1
2,8318E+10	14	1208733159	3	319	
120873315 9	12	9144233741	3		
120873315 9	11	8229376084	3		

^aAutores

É possível determinar que o algoritmo consegue o ótimo global em poucas iterações, quando o valor de hipotermia é de 0,1. As seguinte gráficos apresentam o comportamento.




Fig. 5 Rede Garver Com Redespacho Hipotermia = 0,1 e 0,5

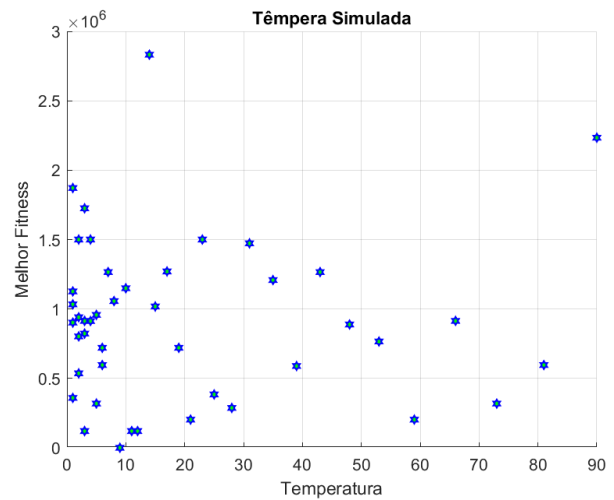


Fig. 6 Rede Garver Com Redespacho Hipotermia = 0,9

B. Fixando o valor da hipotermia em 0,9, obtém-se os seguintes resultados para os casos: garver2dados, sul46barras1dados e sul46barras2dados.

TABELA IV
RESULTADOS COM O HIPOTERMIA ESTABELECIDOS EM 0,9

Garver2dados		Sul46barras1dados		Sul46barras2dados	
F. Custo pu (\$)	Temper atura °C	F. Custo pu (\$)	Temper atura °C	F. Custo pu (\$)	Temper atura °C
T. decorrido = 29.905 sg		T. decorrido = 35.687 sg		T. decorrido = 36.575 sg	
2913523508 7	90	5506277720 9	90	3,15505E+11	90
3853914450 2	81	2945594721 5	81	2,04259E+11	81
3905962226 4	73	1040167362 5	73	4700050782 2	73
3864937422 9	66	5308966107	66	2,61009E+11	66
3380237017 5	59	6646582983 2	59	22741713	59
3970209	53	7865105292 5	53	2,68732E+11	53
3261324147 1	48	1601483419 8	48	2,21129E+11	48
3279697084 7	43	1134649456 5	43	22741713	43
1973783133 1	35	1442570535 8	35	1,73731E+11	35
3750266	31	6692524087	31	1,84777E+11	31
4450281	25	1,27203E+11	25	1,60689E+11	25
3344120529 4	23	1,92505E+11	23	1,53069E+11	23
2339531743 2	21	18696068.83	21	2,49497E+11	21
2294843705 4	19	8075404727 2	19	1,74925E+11	19
3767840613 8	15	8618688659	15	2,03708E+11	15
3970209	14	9638102442 8	14	1,49249E+11	14
2954982454 1	12	9189229309 6	12	1,23346E+11	12

1745607119 7	11	6646582983 2	11	26385997	11
3153446495 3	10	1,12671E+11	10	2,82178E+11	10
2913523508 7	9	4195482748 5	9	28656443	9
3853914450 2	8	1,49411E+11	8	3,38032E+11	8
1973783133 1	7	1442570535 8	7	2,34868E+11	7
2750186	6	1,05559E+11	6	28656443	6
3670220	5	6670892027 9	5	3084577367 2	5
2970327	5	5308966107	5	2,27781E+11	5
3110471154 8	4	5079253602 5	4	4700050782 2	4
3688295098 8	4	9189229309 6	4	2,60379E+11	4
3864937422 9	3	1,71206E+11	3	1,14605E+11	3
3261324147 1	3	1,39239E+11	3	4700050782 2	3
4450201	2	8462602655 7	2	1,01644E+11	2
3970323	2	1,29346E+11	2	7778124863 9	2
3853914450 2	2	1,22914E+11	2	1,58541E+11	2
2745186177 5	1	2945594721 5	1	1,74925E+11	1
4670243	1	6646582983 2	1	1,99115E+11	1
3210163542 6	1	1793151985 6	1	1,53069E+11	1
1745607		489757		4700050	

^aAutores

É possível determinar que o algoritmo consegue o melhor ótimo global quando diminui a temperatura lentamente, ou seja, com um valor de hipotermia de 0,9. As seguinte gráficas apresentam o comportamento.




Fig. 7 Rede Garver Sem Redespacho Hipotermia 0,9




Fig. 8 Rede 46 barras COM redespacho Hipotermia 0,9

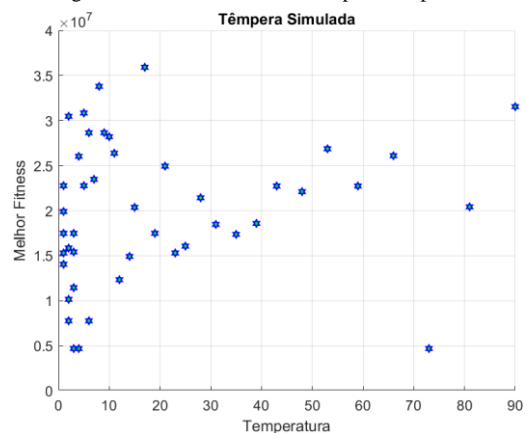


Fig. 9 Rede 46 barras Sem redespacho Hipotermia 0,9

CONCLUSÕES

No algoritmo genético AG, se evidenciou que ao aumentar o número de pais, torna-se mais lento para chegar na solução. O custo computacionais é o mesmo, já que esta definido pelo número de gerações. Pode-se recomendar um número de pais baixo.

No algoritmo têmpera simulada SA, se evidenciou que ao diminuir o valor da hipotermia, torna-se mais rápido para chegar numa solução. Mais não é a solução ótima. O custo computacionais muda dependendo da hipotermia. Pode-se recomendar o valor da hipotermia perto de 1.

O AG apresentou melhores resultados que o AS, em quanto a melhor solução e menor custo computacional.

REFERENCES

- [1] J. H. Holland, "Adaptation in natural and artificial systems: an introductory analysis with applications to biology, control, and artificial intelligence". The University of Michigan Press, 1975
- [2] H.A.Romero, "Optimización de flujo de carga en los sistemas eléctricos de potencia utilizando algoritmos genéticos" Universidad de los Andes Venezuela, 2008
- [3] Algoritmos genéticos UFRJ
- [4] S.Haffner, "Otimização Heurística-Recozimento simulado, UFRGS, 2020
- [5] Maneiro, N. (2001). Algoritmos genéticos aplicados a problemas de localização de facilidades. Ph.d. thesis, Universidad de Carabobo.

- [6] DE OLIVEIRA, S.A.; DE ALMEIDA, C.R.T.; MONTICELLI, A. Times assíncronos aplicados a métodos heurísticos construtivos de planejamento da expansão da transmissão. In: CONGRESSO BRASILEIRO DE AUTOMÁTICA - CBA, 12., 1998, Uberlândia. Proceedins... Uberlândia: SBA/UFU, v.III, 1998. p.1029- 1034.
- [7] Henderson, S. G., & Nelson, B. L. (2006). Stochastic computer simulation. Handbooks in operations research and management science: simulation, 1-18
- [8] DE OLIVEIRA, S.A.; DE ALMEIDA, C.R.T.; MONTICELLI, A. Time assíncrono inicializador de métodos combinatoriais para planejamento da expansão da transmissão. In: SEMINARIO NACIONAL DE PRODUÇÃO E TRANSMISSÃO DE ENERGIA ELÉTRICA - SNPTEE, 15., 1999, Foz do Iguaçu. Anais... Foz do Iguaçu: CIGRE - Itaipu Binacional, 1999. Grupo VII-GPL/04.