

unesp

UNIVERSIDADE ESTADUAL PAULISTA
FACULDADE DE ENGENHARIA DE ILHA SOLTEIRA
PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

DISSERTAÇÃO DE MESTRADO
EM
ENGENHARIA ELÉTRICA

121000112



Nº 19

PLANEJAMENTO DE REATIVOS EM SISTEMAS DE ENERGIA
ELÉTRICA UTILIZANDO UMA METODOLOGIA MISTA:
PROGRAMAÇÃO LINEAR E ALGORÍTMO GENÉTICO
ALUNA: SONIA ANGELINA GARCIA MODESTO
ORIENTADOR: JOSÉ ROBERTO SANCHES MANTOVANI

Te.1112



UNIVERSIDADE ESTADUAL PAULISTA "JULIO DE MESQUITA FILHO"
FACULDADE DE ENGENHARIA DE ILHA SOLTEIRA
DEPARTAMENTO DE ENGENHARIA ELÉTRICA

CURSO DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA
STRICTU SENSU

AUTOMAÇÃO

PLANEJAMENTO DE REATIVOS EM SISTEMAS DE ENERGIA ELÉTRICA
UTILIZANDO UMA METODOLOGIA MISTA:
PROGRAMAÇÃO LINEAR E ALGORITMO GENÉTICO

1210001112



Proc. 054/99-NPD 122

UNESP - "CAMPUS DE ILHA SOLTEIRA"	
SERVIÇO DE BIBLIOTECAS E DOCUMENTAÇÃO	
DATA DE ENTRADA <i>13/9/99</i>	DATA DE RECEBIMENTO <i>29/10/99</i>
EMPRESA <i>leília</i>	TOMBO <i>1.112</i>
AQUISIÇÃO <i>Doação - autor</i> <i>20.10.00</i>	CLASSIFICAÇÃO <i>m691p</i>

"Dissertação apresentada à Faculdade de Engenharia de Ilha Solteira (UNESP), como parte dos requisitos para obtenção do título de Mestre em Engenharia Elétrica"

Sonia Angelina Garcia Modesto
Orientador: José Roberto Sanches Mantovani

Ilha Solteira, Dezembro de 1.997



**PLANEJAMENTO DE REATIVOS EM SISTEMAS DE ENERGIA
ELÉTRICA UTILIZANDO UMA METODOLOGIA MISTA:
PROGRAMAÇÃO LINEAR E ALGORITMO GENÉTICO**


SONIA ANGELINA GARCIA MODESTO

**DISSERTAÇÃO APRESENTADA À FACULDADE DE ENGENHARIA DE ILHA
SOLTEIRA - UNESP - COMO PARTE DOS REQUISITOS PARA OBTENÇÃO DO
TÍTULO DE MESTRE EM ENGENHARIA ELÉTRICA**



Nobuo Oki - coordenador

COMISSÃO EXAMINADORA:



José Roberto Sanches Mantovani - Orientador



Takaaki Ohishi



Rubén Augusto Romero Lázaro

Ilha Solteira - SP, Dezembro de 1997



DEDICATÓRIA

Ao Vinícius, razão de todo o meu ser...

Ao Aguimair, pela compreensão e pela liberdade concedida...

Ao meu mano Altamiro, pelo apoio nas horas difíceis...

Aos meus pais, Altamiro e Maria, pelo exemplo de vida e espírito de luta...

A Deus, pelo seu imenso amor para comigo....

Agradecimentos Especiais

Aos professores da Pós Graduação da UNESP de Ilha Solteira, em especial aos professores Rubén e Ana Diva, pela especial contribuição.

Ao Prof. José Roberto Sanches Mantovani, pela competente orientação.

Aos servidores do Departamento de Engenharia Elétrica, pela atenção e pelos serviços prestados.

Aos amigos especiais: Fernando Casari, Alessandro Basso, José Viana, Eliedete, Maria Cândida, Marcos Duarte, Jair Longo, Valdeci, Cezar e à todos que contribuíram para a realização deste trabalho.

À UFMS, pelo apoio.



Resumo

O planejamento de reativos em Sistemas de Energia Elétrica pode ser formulado como um complexo problema de programação matemática não linear, de grande porte, envolvendo variáveis reais, discretas (magnitudes de bancos reativos) e inteiras (binárias-decisão de alocar ou não potência reativa em uma barra do sistema). Nesta dissertação, propõe-se, para resolver o planejamento de reativos, uma metodologia mista, que consiste de programação linear sucessiva e algoritmo genético. A programação linear sucessiva resolve o problema de otimização em que estão envolvidas as variáveis reais, ao passo que o algoritmo genético é usado para contornar as dificuldades em considerar as variáveis discretas (“taps” de transformadores, magnitudes de bancos reativos) no algoritmo de programação linear sucessiva, desenvolvido por outros autores. Os algoritmos genéticos são baseados nos mecanismos de evolução das espécies na natureza: cruzamento, mutação e seleção natural. Utilizando-se a metodologia proposta, Programação Linear Sucessiva – Algoritmo Genético, apresentam-se resultados para dois sistemas testes amplamente divulgados na bibliografia – IEEE30 e o IEEE118.

Abstract

Reactive planning in electrical power systems can be formulated as a complex problem of nonlinear mathematical programming, of great importance involving real variables, discrete variables (reactive banks magnitudes) and binary variables (a decisions to put or not the reactive power in a bus of the system). In this work, a mixed methodology is proposed to solve the planning of reactives, which consists of a successive linear programming and genetic algorithm, The successive linear programming solves the problem of optimization in which the real variables are involved, and the genetic algorithm is used to try to solve the difficulties in considering discrete variables (as transformers taps, reactive bank magnitudes) in the successive linear programming algorithm, as developed by other authors. Genetic algorithms are based on natural evolution mechanisms: crossing, mutation and natural selection. Using the proposed methodology, successive linear programming – genetic algorithms, results are presented for two test systems, that are widely spread in the current literature: IEEE30 and IEEE118.

ÍNDICE

	Página
INTRODUÇÃO.....	1
1. ALGORITMOS GENÉTICOS.....	5
1.1 Técnicas de buscas para soluções de problemas de otimização.....	7
1.1.1 Técnicas tradicionais de otimização	9
1.1.2 Técnicas enumerativas	9
1.1.3 Técnicas de busca aleatoriamente direcionadas.....	10
1.2 Algoritmos genéticos	11
1.3 Um Algoritmo Genético Simples (AGS)	14
1.3.1 Componentes e estrutura de um AGS	14
1.3.1.1 Função aptidão.....	15
1.3.1.2 Seleção.....	16
1.3.1.3 Manipulação	18
1.4 Ciclo Geracional.....	21
1.5 Critério de Parada.....	21
1.6 Problemas críticos relacionados com a implementação dos AG	21
1.6.1 Minimizar a função objetivo	22
1.6.2 Configurações infactíveis.....	22
2. PROBLEMA DE PLANEJAMENTO E DESPACHO DE REATIVOS.....	24
2.1 Despacho ótimo de reativos	24
2.1.1 Programação quadrática sequencial	25
2.1.2 Programação linear sucessiva	26
2.1.3 Programação não linear.....	26
2.1.4 Métodos de busca estatística	28
2.1.5 Sistemas especialistas	28
2.2 Planejamento de Reativos em Sistemas de Energia Elétrica	29
2.3 Fontes de Potência Reativa no Sistema de Energia Elétrica	30
2.3.1 Geradores síncronos.....	31
2.3.2 Linhas de transmissão de alta tensão	31
2.3.3 Alteração da topologia do sistema	32
2.3.4 Transformadores com mudança de “tap” sob carga.....	32

2.4 Principais Equipamentos de Compensação Considerado na Etapa de Planejamento de Reativos	33
2.4.1 Capacitores “shunt”	34
2.4.2 Indutores “shunt”	34
2.4.3 Compensadores estáticos	35
2.4.4 Compensadores síncronos	36
2.5 Custos dos investimentos em fontes reativas	36
2.6 Condições que requerem o planejamento de reativos	37
3. FORMULAÇÃO GERAL DO PROBLEMA DE PLANEJAMENTO DE REATIVOS E MODELOS DE SOLUÇÃO PROPOSTO	39
3.1 Formulação Geral do Problema	39
3.2 Solução do Problema de Planejamento de Reativos Através de uma Metodologia Mista: Programação Linear Sucessiva e Algoritmo Genético	42
3.2.1 Fluxo de potência	43
3.2.2 Programação linear	43
3.2.3 Algoritmo genético	46
3.2.3.1 Codificação das variáveis discretas – composição dos indivíduos	47
3.2.3.2 Avaliação da função aptidão	48
3.2.3.3 Esquema de seleção proporcional	51
3.2.3.4 Seleção	52
3.2.3.5 Cruzamento	52
3.2.3.6 Mutação	52
3.2.4 Algoritmo geral do problema	53
4. TESTES COMPUTACIONAIS	55
4.1 Sistema IEEE30	55
4.1.1 Comentários sob os testes – Caso A	77
4.1.2 Comentários sob os testes – Caso B	97
4.2 Sistema IEEE118	99
4.2.1 Comentários sob os teste IEEE118	108
CONCLUSÕES	109

REFERÊNCIAS BIBLIOGRÁFICAS..... 112

APÊNDICE A..... 117



Introdução

A presente dissertação trata de alternativas para a solução do Problema de Planejamento de Reativos através da utilização de Algoritmos Genéticos, que pode ser formulado como um problema de otimização de grande porte, não linear, a variáveis reais, discretas (magnitudes de bancos reativos) e inteiras (binárias - decisão de alocar ou não potência reativa em uma barra do sistema). A investigação centra-se fundamentalmente, na determinação do local e da natureza das fontes reativas (indutores, capacitores, compensadores síncronos, etc) que devem ser alocados no sistema, se necessárias, visando à obtenção de um ponto de operação que minimize critérios de natureza econômica, qualidade do fornecimento de energia e segurança da operação do sistema. A otimização reativa é reconhecida como o grande desafio em controle e planejamento de sistemas de potência, visando garantir um perfil de tensão adequado e atender restrições operacionais do sistema de potência. Na impossibilidade do atendimento às restrições impostas utilizando-se apenas as reservas reativas existentes no sistema, deve-se obter a expansão ótima (custos mínimos) de fontes reativas considerando-se características físicas, econômicas e de operação.

O planejamento de reativos é um tema abordado por diversos pesquisadores, razão pela qual têm sido publicados diversos trabalhos envolvendo a formulação e a solução dos problemas [1-8]. Destacam-se, dentre esses trabalhos, o de W. M. Lebow et al [1], que

apresentam uma formulação completa para o problema e propõem resolvê-lo por meio do uso da decomposição generalizada de Benders, executada em dois níveis para cada cenário de operação considerado (nível de carga, contingências) e o de S. Granville et al [2], que também apresentam uma formulação completa do planejamento de reativos considerando várias condições de carga e contingências nos modos corretivo e preventivo, além de proporem a solução do problema por intermédio da decomposição hierárquica de Benders em três estágios. K. H. Abdul - Hahman e S. M. Shahidehapor [25] resolvem o planejamento de reativos pela decomposição hierárquica de Benders em dois níveis, utilizando uma modelagem mais realística no subproblema de operação, através da representação "fuzzy" trapezoidal das restrições de tensões de barras e um tratamento não probabilístico das demandas de cargas reativas, consideradas, também, através de um modelo de distribuição trapezoidal mapeando a variável fuzzy no intervalo $[0,1]$. J.R. Mantovani e A. V. Garcia propõem, para a solução do problema, uma metodologia baseada em técnicas de buscas binárias e o uso de uma heurística especial para obter soluções discretas relacionadas com os bancos reativos existentes no sistema [27]. Y. T. Hsiao e outros [7] formulam o planejamento de reativos como um problema de otimização restrita, multi-objetivo e não diferenciável. A metodologia proposta para a solução do problema consiste na técnica "Simulated Annealing". K. Iba [5] propõe a solução do planejamento e despacho ótimo de reativos usando um algoritmo genético modificado: a idéia básica está apoiada em algoritmos genéticos, mas o método proposto é bem diferente das técnicas de algoritmos genéticos convencionais, pois, para as variáveis discretas, utilizam-se valores discretizados ao invés dos "bits" 0/1 que são usados nos algoritmos genéticos. O sistema é decomposto em diferentes áreas/regiões, utilizando-se uma técnica aproximada, de modo que cada subsistema é avaliado, utilizando-se as melhores informações de cada um deles para um certo objetivo. Este tipo de abordagem permite considerar a natureza discreta de algumas variáveis envolvidas no problema de planejamento de reativos. C. R. R. Dornellas e outros [21] apresentam um método de otimização do despacho de reativos combinando um Algoritmo Genético Simples e um programa de fluxo de carga convencional.

Os métodos de busca estatística - simulated annealing e algoritmos genéticos têm sido propostos para a solução do despacho e/ou alocação ótima de reativos [5, 7, 21, 24]. O interesse em algoritmos de buscas estatísticas que pudessem imitar os processos físicos e biológicos, a exemplo do que ocorre na natureza, começaram a surgir em 1975, quando J. H. Rolland [5], propôs o primeiro algoritmo genético. Os Algoritmos Genéticos são métodos de

busca estatística adequados à solução de problemas de otimização normalmente mal comportados envolvendo diversos tipos de variáveis, como é o caso do fluxo de potência ótimo reativo. São baseados nos mecanismos de seleção e de troca de informações genéticas, a exemplo do que ocorre na natureza [22, 23, 28], sendo capazes de buscar a solução ótima ou quase ótima do problema, mas com elevado esforço computacional. Esses algoritmos foram aplicados juntamente com um programa de fluxo de potência na solução de problemas de reativos, destacando-se, dentro desse enfoque para solução do problema os trabalhos de K. Iba [5], C.R.R. Dornellas et al [21], J.R. Gomes et al [24] e L.L. Lai et al [33].

O objetivo deste trabalho é obter o despacho e a alocação ótima de fontes de reativos e ajustes dos "taps" dos transformadores para manter as tensões nas barras, próximas de um valor desejado ou, no mínimo, dentro de limites aceitáveis. A técnica de solução proposta para o problema consiste da combinação de programação linear sucessiva (Fluxo de Carga – Algoritmo Genético) [29] e um algoritmo de otimização combinatorial, denominado Algoritmo Genético Simples. Enquanto a programação linear trata da otimização das variáveis reais, envolvidas no problema reativo (magnitude e ângulos das tensões, capacidade de geração de reativos de máquinas e compensadores síncronos), o algoritmo genético trata da otimização das variáveis discretas envolvidas no problema ("taps" de transformadores, magnitudes das capacidades reativas fornecidas por bancos de capacitores).

A solução através de programação linear sucessiva e algoritmo genético apresentou-se adequada para a solução do problema de planejamento de reativos conforme pode ser constatado com os resultados dos testes utilizando-se os sistemas IEEE30 e IEEE118.

A presente dissertação está dividida em quatro capítulos, além destas considerações introdutórias e das conclusões, retrospectivas e prospectivas.

O Capítulo I , consiste na apresentação teórica do Método Algoritmo Genético com vistas a determinação de sua estrutura e aplicação. É descrita a concepção do método, o algoritmo (denominado Algoritmo Genético Simples), seus Operadores Genéticos e o seu Ciclo Geracional. Também são analisados, neste Capítulo, os problemas críticos na aplicação deste Método.

No capítulo II, apresenta-se a definição do Problema de Planejamento dos Despachos de Reativos, descrevendo-se as principais fontes de geração e controle de reativos existentes no sistema, além das características físicas e econômicas dos principais dispositivos de compensação de reativos utilizados na fase de planejamento. Apresentam-se também, neste Capítulo, comentários referentes a clássicos métodos de solução para problemas de Fluxo de Potência Ótimo, encontrados na bibliografia pertinente ao assunto.

No capítulo III, o problema de Planejamento de Reativos é formulado como um problema não linear de grande porte, com a descrição das variáveis e equações envolvidas, apresentando-se a estrutura lógica do algoritmo para resolvê-lo, combinando-se o uso de técnicas de Algoritmo Genético e Programação Linear Sucessiva. Pode-se adiantar que a estratégia de Algoritmo Genético é perfeitamente adequada ao Problema de Planejamento

No capítulo IV, apresentam-se os testes realizados e os resultados obtidos com o programa computacional desenvolvido a partir da metodologia proposta neste trabalho, utilizando-se dois sistemas teste, a saber, as redes IEEE30 e IEEE118.



Capítulo I

Algoritmos genéticos

Neste Capítulo apresentam-se os principais conceitos em que se fundamentam os Algoritmos Genéticos utilizados na solução de problemas de otimização.

Nos Algoritmos de busca simples, baseados em critérios e/ou condições de otimalidade, tais como Programação Linear, métodos de Newton, entre outros, há um único caminho desde a solução inicial até a solução final do problema. Eles partem da solução inicial e melhoram seus resultados a cada iteração, chegando-se a um ótimo local, porém não se pode assegurar que será um ótimo global, dependendo das condições de convexidade do problema. Por exemplo, no problema de maximização não convexo da Figura 1, o resultado pode ser um ponto máximo local, mas não há modo de se julgar se é ou não um ótimo global. Existem casos em que, dependendo da estrutura da busca, os métodos conduzem para ótimos locais e não há forma de se deslocar de tais pontos com vistas a buscar o ótimo global, exceto aplicando ruídos aleatórios. No treinamento de redes neurais artificiais, tais como o modelo de Hopfield, este problema acontece frequentemente. Outra dificuldade encontrada na aplicação de técnicas convencionais de otimização está na natureza discreta e/ou inteira das variáveis existentes na modelagem do Problema. Em alguns problemas desse tipo, o Algoritmo Genético é utilizado com sucesso, contornando a dificuldade.




Figura 1: Representação da superfície tridimensional relativa a um problema que apresenta duas soluções ótimas locais e uma solução ótima global.

Os Algoritmos Genéticos apresentam condições de contornar algumas dificuldades encontradas nos algoritmos tradicionais para resolver problemas de otimização. Essas condições se fundamentam principalmente no fato de representarem uma modelagem mais realística de problemas práticos, usando várias funções objetivos simultaneamente, múltiplos caminhos de busca (o que assegura uma maior probabilidade de encontrar o ótimo global). Além disso, os problemas de otimização são abordados naturalmente, tanto discretos como contínuos; e, para encontrar a solução ótima, essa técnica utiliza-se dos operadores genéticos: cruzamento e mutação.

Para ilustrar o problema e a dificuldade de se obter um ponto de ótimo local, quando da aplicação de técnicas de otimização, considere a figura (2a). Partindo da condição inicial, chega-se a um único ponto de ótimo que, neste caso e por um acaso, é um ótimo global. Porém, na Figura (2b), partindo de três pontos, obtém-se três pontos ótimos, dos quais um deles é ótimo global. Uma das filosofias em que se fundamentam os métodos de busca estatística como é mostrado na figura (2b), consiste na realização de busca em várias direções, aumentando a probabilidade de encontrar o ótimo global. Outro fator de importância fundamental para a convergência e possibilidade de se encontrar o ponto ótimo global é o número de pontos de partida, comumente referenciado como tamanho da população. Quanto maior a população, maiores são as possibilidades de convergência para o ponto de ótimo

global, ou quase ótimo do problema, ou seja, apesar de não haver garantias de que irá para o ótimo global, há maior probabilidade de que isso aconteça.

Um dos fatos que constitui a motivação fundamental para a utilização do Algoritmo Genético, é a troca de informações entre os indivíduos, que poderá levar a um ótimo global mais rapidamente, uma vez que altera as configurações, direcionando o processo de busca em favor das melhores soluções. Iniciando uma busca simples, embora por vários caminhos, e utilizando-se das técnicas tradicionais, tem-se a impressão de que seria semelhante à busca estatística orientada. Vale ressaltar, no entanto, que, na técnica que utiliza busca multidimensional aliada a técnicas de otimização tradicionais, não existe a troca de informações entre os indivíduos, estando aí a principal diferença entre a repetição da busca por caminhos simples e a busca estatisticamente orientada.

(a) busca numa única direção



□ Condição Inicial
 ■ Ponto Intermediário
 ■ Ponto Ótimo

(b) busca em várias direções



□ Primeira Geração
 ■ Segunda Geração
 ■ Terceira Geração
 ■ Geração Final

Figura 2 : Busca numa única direção e busca em várias direções

1.1- Técnicas de buscas para soluções de problemas de otimização

Propostas por diversos pesquisadores, as diferentes técnicas de buscas para solução de problemas de Otimização podem ser agrupadas em três grandes classes: Técnicas Tradicionais de Otimização (Gradiente, Newton, Fibonacci), Busca Aleatória Direcionada e

Técnicas Enumerativas [22]. Na figura-3, apresenta-se o diagrama de blocos, mostrando as ramificações destas três importantes técnicas.




Figura 3 : Classificação das técnicas de buscas

1.1.1 Técnicas tradicionais de otimização

As técnicas tradicionais de otimização (determinísticas) usam um conjunto de condições necessárias e suficientes para serem satisfeitas pelas soluções de um problema de otimização. Estas técnicas se subdividem em métodos diretos e indiretos. Os métodos indiretos procuram por ótimos locais, resolvendo geralmente o conjunto de equações não lineares resultantes da aplicação da condição de otimalidade de Karush - Kuhn - Tucker [13]

Como no exemplo de métodos diretos, têm-se os métodos de Newton e Fibonacci. O método de Fibonacci procura o ponto de ótimo, reduzindo o tamanho do intervalo de incerteza, de tal forma que a razão dos intervalos de incerteza entre uma iteração e outra do método segue os números gerados pela série Fibonacci. O método de Newton faz uma aproximação quadrática da função em torno de um ponto inicial e busca o ótimo da aproximação, verificando se as condições de otimalidade aplicadas ao problema estão sendo atendidas dentro de uma certa precisão pré estabelecida. Se as condições de otimalidade não forem atendidas, atualiza-se o ponto, efetivando-se sua correção através da solução do sistema de equações de otimalidade aplicando-se o método de Newton, e realiza-se uma nova aproximação. Ambos satisfazem as condições de factibilidade e de melhoria da função objetivo e asseguram o novo ponto que direciona a busca. Estas técnicas podem ser usadas apenas em um conjunto restrito de problemas bem comportados.

1.1.2 Técnicas enumerativas

As técnicas enumerativas buscam um ponto por vez, considerando-se um conjunto domínio, normalmente definido em um período de tempo, de uma função objetivo e um conjunto de restrições amplamente utilizadas em diversas aplicações, são simples para implementar, mas podem exigir um elevado tempo computacional. A programação dinâmica é um bom exemplo de técnica enumerativa.



1.1.3 Técnicas de busca aleatoriamente direcionadas

As técnicas de busca aleatórias direcionadas são baseadas nas técnicas enumerativas, mas usam informação adicional para direcionar a busca. Elas são geralmente muito eficientes e podem resolver muitos problemas complexos. As duas maiores subclasses são *Simulated Annealing* e *Algoritmo Evolucionário*. Ambos são baseados em processos de evolução, mas *Simulated Annealing* usa um processo de evolução termodinâmico para buscas em estados de energia mínimos. Os *Algoritmos Evolucionários*, por outro lado, são baseados em princípios de seleção natural. Esta forma de busca, através das gerações, melhora o comportamento de soluções potenciais, através de operações inspiradas biologicamente.

Os Algoritmos Evolucionários se subdividem em dois tipos, os quais são denominados de Estratégia de Evolução e Algoritmo Genético. As estratégias de evolução foram propostas por Rechenberg e Schwefel no começo da década de 70 e podem adaptar o processo de “evolução artificial” com base em informações referentes ao comportamento ótimo da função objetivo e/ou outros parâmetros, associados ao problema, que possibilitem a busca de soluções ótimas. Isto significa que as Estratégias de Evolução, ao contrário do Algoritmo Genético Tradicional, podem adaptar seus principais parâmetros de estratégia durante o processo de busca do ótimo para o problema, de acordo com o comportamento da função objetivo.

Originalmente, o *Algoritmo Genético* foi proposto por Holland, e a partir deste algoritmo básico muitas variações têm sido apresentadas. As pesquisas realizadas têm demonstrado melhoria no desenvolvimento e execução do *Algoritmo Genético*. Essas inovações são aplicadas em sistemas computacionais de processamentos distribuídos e sequenciais. Nos *Algoritmos Genéticos Simples* originais, a cada iteração cria-se uma população totalmente nova, distinta daquela já existente, técnica essa denominada de *Algoritmo Genético* geracional. Portanto, no *Algoritmo Genético* original, adotou-se uma política de reposição geracional, segundo a qual uma população é substituída em cada geração. Entretanto, muitos seguidores do AGS utilizam a técnica denominada estado-fixa, em que fazem a substituição seletiva da população. Isso torna possível, por exemplo, manter um ou mais membros da população nas diversas gerações. Tipicamente, as novas séries

criadas através da recombinação repõem as piores séries (séries com os mais baixos valores de aptidão, em problemas de maximização). Finalmente, a técnica do estado-fixado difere da técnica geracional no *Algoritmo Genético*, quanto ao elitismo populacional (preservação das espécies), o que traz como consequência uma maior probabilidade de cruzamento, em virtude das diferentes populações. Uma importante característica distintiva do *Algoritmo Genético Simples*, comparado a outros algoritmos, é a manipulação da população, em que é possível a substituição da população inteira ou apenas parte dela. Os Algoritmos Genéticos são bastante adequados para implementação em máquinas de memória distribuída, em decorrência da própria estrutura deles.

1.2 Algoritmos genéticos

Os *Algoritmos Genéticos* têm se apresentado como técnicas de otimização robusta. Os mecanismos que os algoritmos genéticos utilizam para buscar as melhores soluções para os problemas são baseados na teoria da genética e evolução natural. Na natureza os indivíduos mais bem dotados, ou seja, indivíduos que possuem um conteúdo genético de excelente qualidade, têm maior capacidade de sobrevivência quando os recursos se tornam escassos ou quando muda o meio ambiente.

Primeiramente propostos por John Holland, no começo da década de 70, os Algoritmos Genéticos são uma classe atrativa para os modelos computacionais, pois imitam a evolução natural para resolver problemas em uma extensa variedade de domínios. O Algoritmo Genético usa um conjunto de configurações (populações de indivíduos) para resolver um problema complexo, simulando o que acontece no meio ambiente. Ao lado de Holland, Goldberg, DeJong, Grefenstette, Davis, Muhlenbern e outros estimularam o crescimento dos *Algoritmos Genéticos* [22,23]. O interesse em Algoritmos de pesquisa heurística com embasamento em processos naturais e físicos, reacendeu graças a Kirkpatrick e Gelatt, com a técnica Simulated Annealing em 1983. Essa técnica Simulated Annealing é baseada em considerações termodinâmicas e surgiu em analogia algorítmica com o Processo de Annealing em sólidos, enquanto Estratégias de Evolução e Algoritmos Genéticos vêm da inspiração na evolução natural das espécies e no processo de seleção.

Simulated Anneling, *Algoritmo Genético* e Estratégias de Evolução são similares em suas concepções graças ao uso de mecanismo de busca probabilística atuando diretamente no aumento ou diminuição do custo. Esses três métodos têm grandes probabilidades de alcançar o ótimo global.

Simulated Anneling - gera probabilisticamente uma sequência de transições controladas por um programa de resfriamento para, finalmente, buscar convergir para o ótimo global.

Estratégia de Evolução - usa mutação como mecanismo de pesquisa e seleção para direcionar a busca a regiões prospectivas no espaço de busca.

Algoritmos Genéticos - são técnicas de busca estatística baseadas nos mecanismo de evolução das espécies na natureza, consistindo em seleção natural, cruzamento e mutação e consta de um programa de controle formado pelas taxas de cruzamento (**tc**) e mutação (**tm**) e o tamanho da população (**tp**) [22]. Portanto, esse tipo de técnica serve-se das teorias biológicas de evolução para resolver problemas de otimização, normalmente mal comportados envolvendo diversos tipos de variáveis, como é o caso do fluxo de potência ótimo reativo. Portanto, os *Algoritmos Genéticos* manipulam a população de soluções para um problema de otimização ou uma pesquisa, e a exemplo dos mecanismos de seleção e troca de informações genéticas que ocorrem na natureza, apenas os elementos mais apropriados de uma população são os prováveis sobreviventes e geram descendentes na geração subsequente. Assim, de acordo com a evolução natural, transmitem sua hereditariedade biológica a novas gerações. Nos problemas onde se aplicam os *Algoritmos Genéticos*, as melhores soluções permanecem na próxima população, o que na bibliografia que aborda o *Algoritmo Genético Simples* é denominada como técnica do estado-fixa.

Os *Algoritmos Genéticos* trabalham com representações codificadas das soluções, equivalentes ao material genético dos indivíduos na natureza. Para que o Algoritmo Genético represente adequadamente uma configuração do problema, deve-se optar por uma codificação adequada às características do problema. Originalmente, foi muito utilizada a codificação binária, pois nesta codificação é fácil de implementar os operadores cruzamento e mutação e também porque nessa codificação existem provas de convergência que justificam matematicamente o *Algoritmo Genético*. Neste trabalho, para a codificação das variáveis

discretas, optou-se pelo sistema de base decimal devidamente discretizada de acordo com a definição de cada variável envolvida no problema de planejamento de reativos.

Em problemas de otimização, deve-se encontrar uma forma adequada para avaliar a função objetivo ou o seu equivalente. Assim, identificam-se as configurações de excelente qualidade como sendo aquelas que apresentam uma função objetivo de excelente qualidade. Cada solução está associada a um valor de aptidão, que reflete quão boa ela é, comparada com outras soluções na população. Quanto melhor o valor da aptidão de um indivíduo, maiores são as chances de sua sobrevivência e reprodução, e maior sua representação na geração subsequente (no caso de um problema de maximização). A existência de uma estratégia de seleção das configurações que têm direito a participar na formação das configurações da nova geração, é de suma importância. Após a seleção, então, é realizada a recombinação do material genético, que, no *Algoritmo Genético*, é simulado através do mecanismo de cruzamento (que troca porções entre os "*strings*"). Deve-se definir antes uma estratégia de cruzamento que forneça informações sobre como as configurações deverão ser cruzadas, para dar origem às novas gerações. Outra operação, chamada mutação, provoca a alteração esporádica e aleatória no "bit" de um "*string*". A mutação também tem uma analogia direta com a natureza, no que tange ao fato de exercer a função de regenerar material genético perdido. Em todos esses mecanismos, há a necessidade de serem definidos alguns parâmetros, tais como o tamanho da população, uma estratégia para gerar a população inicial e um critério de parada.

Os *Algoritmos Genéticos* são aplicados em diversas áreas: Composição musical, tecnologia VLSI ("Very Large Scale Integrated"), estratégia para definir programas de planejamento. Eles são particularmente apropriados para resolver problemas de otimização complexos e, portanto, para aplicações que necessitam de uma técnica adaptativa para solução de problemas estratégicos.

A principal diferença entre *Algoritmo Genético* e Estratégias de Evolução, consiste em que o *Algoritmo Genético* tem o cruzamento como principal operador genético, que consiste em um mecanismo probabilístico que troca informações entre as soluções, enquanto que Estratégias de Evolução utilizam, como principal operação genética, a mutação, um mecanismo de busca aleatória onde as soluções são alteradas, sem haver troca de

informações entre elas. Embora *Simulated Annealing*, Estratégias de Evolução e *Algoritmos Genéticos* tenham basicamente diferentes aplicações, vários intercâmbios destas técnicas têm sido proposto em bibliografia recente, diminuindo essas diferenças.

1.3 Um algoritmo genético simples (AGS)

Na bibliografia, o *Algoritmo Genético* de Holland é comumente chamado de *Algoritmo Genético Simples* ou AGS. Trabalha-se com uma população, “*strings*”, onde cada um dos “bits” 0 ou 1 é a versão codificada de uma solução para problemas de otimização. Usando os operadores genéticos - **cruzamento e mutação** - o Algoritmo cria a geração seguinte através de “*strings*” a partir da população atual. Esse ciclo geracional é repetido até que um critério de parada seja atingido.

1.3.1 Componentes e estrutura de um AGS

A estrutura geral de um *Algoritmo Genético Simples* [22, 23] deverá ter definida a população inicial bem como o seu mecanismo de codificação, os parâmetros de controle a serem utilizados, a avaliação da função, o mecanismo de seleção, os operadores genéticos (cruzamento e mutação) e o critério de parada. Os Algoritmos Genéticos são muito sensíveis a estes parâmetros. Um Algoritmo Genético Simples opera através de um conjunto dos estágios:

- a. Gerar uma população inicial após escolher a forma de codificação;
- b. Calcular a função objetivo de cada configuração e armazenar a incumbente;
- c. Implementar a Seleção;
- d. Implementar o Cruzamento (“*Crossover*”);
- e. Implementar a Mutação e terminar de gerar a nova geração;
- f. Se o critério de parada for satisfeito pára, caso contrário volta para b.

Os passos **b - e** são chamados de Ciclo Geracional do *Algoritmo Genético*, o qual está representado na Figura-4.






Figura 4: O Ciclo do Algoritmo Genético

1.3.1.1 Função aptidão

O fundamental para a estrutura do Algoritmo Genético é o mecanismo de codificação para representar as variáveis nos problemas de otimização. Os primeiros Algoritmos Genéticos usaram a codificação binária. O mecanismo de codificação depende das variáveis do problema e existem problemas com variáveis que são mais simples de implementar, outros têm variáveis reais, discretas(inteiras) ou contínuas e são mais complexos. Um método comum para codificá-las é usar sua representatividade inteira.

Após definida a codificação que será utilizada, deve-se ter disponível uma estratégia para calcular a função objetivo para cada configuração. A função objetivo, função a ser otimizada, fornece o mecanismo para a avaliação de cada "string", contudo seu intervalo varia de problema para problema. Para manter uniformidade sobre o domínio de vários

problemas, geralmente torna-se necessário normalizar a função objetivo dentro de determinados parâmetros. O parâmetro que identifica a qualidade de uma configuração, que pode ser a própria função objetivo ou uma equivalente (que poderá ser mais adequada para o *Algoritmo Genético*), é chamado de função aptidão, "*fitness function*", que o mecanismo de seleção usa para avaliar cada indivíduo da população. Neste estágio, o desempenho (ou a aptidão) de cada função é avaliado com respeito às restrições impostas pelo problema. Baseado na aptidão de cada um, o mecanismo de seleção escolhe os indivíduos que farão pares no processo de manipulação genética.

1.3.1.2 Seleção

Na natureza, o mecanismo de seleção indica a sobrevivência do ser mais adaptado. Em problemas que utilizam *Algoritmos Genéticos*, por serem semelhantes aos mecanismos biológicos, as soluções mais adaptadas sobrevivem, enquanto as mais fracas perecem.

No AGS desenvolvido para problemas de maximização, um "*string*" com um valor de aptidão maior é considerado bem adaptado e, portanto, tem maiores chances de sobreviver; e na geração subsequente, terá habilidade de gerar um maior número de descendentes. Tipicamente, para selecionar os indivíduos é utilizado o chamado *esquema de seleção proporcional*. No *esquema de seleção proporcional*, define-se o número de descendentes a que cada configuração tem direito. Para selecionar as configurações que têm direito a descendente, e o número de descendentes, a forma mais simples é usando o chamado esquema de seleção da roleta. Apesar de existirem vários esquemas de seleção proporcional, o mais tradicional é o baseado no jogo da roleta. Com essa estratégia, a seleção é implementada de forma aleatória, designando, a cada configuração, um setor circular proporcional a sua função aptidão.

Assim, utiliza-se a seguinte relação :

$$2 \pi (1/n) Nd \Leftrightarrow 360 (1/n) Nd$$

n : tamanho da população

N_d : número de descendentes de cada configuração

onde cada “string” é alocado em um setor (“slot”) de uma roleta metálica com o ângulo descrito pelo setor do centro do disco igual a $2\pi (1/n)N_d$. A um “string” é alocado um descendente, se um número aleatoriamente gerado no intervalo 0 a 2π cai no setor correspondente ao “string”. O algoritmo seleciona os “strings” desta maneira até que seja gerada toda a população para a próxima geração. A seleção através da roleta pode gerar grandes erros de amostragem, já que o número final de descendentes alocados para um “string” pode variar significativamente do número esperado. O número alocado de descendentes aproxima-se do esperado somente para grandes tamanhos de população. Esta política de seleção é a principal responsável pelo sucesso do algoritmo, visto que assegura a sobrevivência dos indivíduos mais bem adaptados. A combinação entre a avaliação e processo de seleção é chamado reprodução.

Neste trabalho, em decorrência da dificuldade prática em implementar o esquema da roleta, utilizou-se um esquema de seleção proporcional que procurasse imitar o esquema da roleta. Desta forma:

$$N_d = \frac{fap_i}{fap_m}$$

Sendo

N_d : número de descendentes

fap_i : valores da função aptidão

fap_m : média aritmética da função aptidão de todos indivíduos da população

Neste esquema, são gerados os descendentes, utilizando-se o número decimal correspondente a função aptidão de cada indivíduo, dividido pela média da função aptidão de toda a população. Inicialmente atribuem-se descendentes de acordo com a parte inteira de N_d e, depois, para completar o número de indivíduos da população, designam-se descendentes usando o maior valor fracional de N_d até completar as N configurações escolhidas.

1.3.1.3- Manipulação

O processo de manipulação utiliza os operadores genéticos para produzir uma nova população de indivíduos (descendentes) através da manipulação da “informação genética” denominada como genes, atribuídos aos pais (originais) da população atual, compreendendo as operações de cruzamento e mutação, que serão discutidas a seguir.

(a) **Cruzamento.** Uma vez selecionadas as configurações, deve-se tomar os pares de acasalamento e realizar o cruzamento, uma operação crucial no AGS. Pares de “strings” são “trocados” aleatoriamente dentre os elementos da população que estão sujeitos ao cruzamento. No cruzamento, um par de configurações mistura seus conteúdos genéticos e forma dois descendentes. Existem três técnicas básicas de cruzamentos: cruzamentos de um simples ponto, cruzamentos de dois pontos e cruzamento uniforme. No cruzamento de dois pontos, são selecionados dois pontos aleatoriamente, P_1 e P_2 . Assim, dois “strings” selecionados trocarão o conteúdo das posições que vão desde P_1 até P_2 . No outro tipo de cruzamento, o uniforme, cada bit dos “strings” selecionados para cruzamento é confrontado, isto é, tem probabilidades iguais de cruzamento. O AGS utiliza a técnica de cruzamento de um único ponto (*single point crossover*). Primeiro decide-se pelo cruzamento sorteando um número no intervalo $[0 \ 1]$, denominado taxa de cruzamento (**pc**) e que controla a probabilidade de cruzamento. Se o número sorteado for menor ou igual a taxa de cruzamento (**pc**), então ocorrerá cruzamento. Caso contrário, o par de “string” permanece inalterado. Portanto, nem sempre o cruzamento é efetuado. Decidido para um par de configurações em que será realizado o cruzamento, deve ser definido o tipo de cruzamento e os pontos na estrutura das configurações que estarão sujeitos ao cruzamento, pontos esses denominados *pontos de cruzamento*. Exemplificando: considere duas configurações como candidatas, que possuam k elementos. Sorteia-se um número aleatório no intervalo 1 e $(k - 1)$. Todos os números neste intervalo têm a mesma probabilidade de serem sorteados. Uma vez escolhido o ponto de cruzamento, assinala-se nas duas configurações candidatas, fazendo-se então o cruzamento, que é a permutação da parcela à direita deste ponto de uma configuração, pela parcela à direita da outra, gerando as duas novas configurações. Assim, o operador cruzamento é semelhante ao realizado na natureza, onde os indivíduos possuem cromossomos e trocam parte das informações genéticas de dois deles, para produzirem dois novos indivíduos. Finalizando, o *Algoritmo Genético* permuta parte de suas configurações produzindo seus descendentes. Dessa forma, para implementar o cruzamento de um único ponto, o algoritmo a ser seguido é o seguinte:



- (i) Escolher as duas configurações candidatas a cruzamento;
- (ii) Gerar um número aleatório p no intervalo $[0-1]$;
- (iii) Se $p <$ taxa de cruzamento, efetua-se o cruzamento. Caso contrário, passar as duas configurações para a fase da mutação.

A Figura 5 mostra que, após o ponto de cruzamento ter sido aleatoriamente escolhido, partes dos “strings” P1 e P2 são permutadas para produzir novos “strings” (descendentes) 01 e 02. Nesta figura, o operador cruzamento é aplicado para o 5º e 6º elementos do “string”.




Figura 5 : Cruzamento

(b) Mutação. Depois do cruzamento, os “strings” estão sujeitos à mutação. A mutação exerce uma influência especial para o Algoritmo Genético, pois procura o mínimo local (convergência prematura). A necessidade da mutação decresce na fase final do procedimento quando as populações tornam-se mais homogêneas e dominadas pelos genes mais eficientes. A mutação introduz mudança em torno das variáveis, explorando novas zonas no campo da Otimização. Na maioria das pesquisas sobre Algoritmo Genético, a mutação é considerada um operador secundário. A taxa de mutação fornece a probabilidade de que um bit será mutado. Os Algoritmos Genéticos Simples tratam a mutação somente como um operador secundário, uma regra para a recuperação de material genético perdido. Na codificação binária, a mutação de um “bit” consiste em transformar o valor de uma posição de 0 para 1, ou vice-versa. A Figura 6 mostra o operador mutação aplicando para o 4º elemento da “string”.




Figura 6 : Mutação

Os descendentes produzidos pelo processo de manipulação genética serão a próxima população a ser avaliada. Os AGS podem substituir uma população inteira (abordagem geracional) ou apenas seus membros menos adaptados (abordagem estado-fixa).

O ciclo **criação – avaliação – seleção – manipulação** se repete até que uma solução satisfatória para o problema seja encontrada ou algum outro critério de parada para o algoritmo seja atendido.

As implementações levam em conta um número de parâmetros dependentes do problema, tais como tamanho da população, taxas de cruzamento e de mutação e critérios de convergência. Os AG são muito sensíveis a estes parâmetros. Um grupo diferente de operadores genéticos tem sido introduzido, desde que Holland propôs este modelo básico. Estes operadores genéticos são, em geral, versões de recombinação e processos de alteração genética adaptados aos requisitos de problemas particulares ou a tentativas de simular processos genéticos menos frequentes presentes na seleção natural. Exemplos de outros operadores genéticos são inversão, dominância e recombinação da margem genética.

1.4- Ciclo geracional

O ciclo geracional compreende os processos de seleção, cruzamento e mutação (correção de infactibilidade), que permitem encontrar as configurações da nova

geração a partir da população corrente. O ciclo geracional é realizado com base no Programa de Controle do Algoritmo Genético, um conjunto de parâmetros que define o tamanho da população, a taxa de cruzamento e a taxa de mutação. Variando de problema para problema e em grande medida, define a qualidade do algoritmo. Valores típicos considerados são:

Número de elementos das populações:	Ne [30 300]
Taxa de cruzamento:	Pc [0,5 1,0]
Taxa de mutação:	Pm [0,001 0,05]

1.5 Critério de parada

Existem vários critérios de parada do algoritmo genético. Pode-se adotar um critério de parada quando for executado um número determinado de gerações, ou quando a solução incumbente encontrou um valor especificado, ou ainda quando as configurações da população ficam muito homogêneas. Pode-se utilizar, também, a combinação de dois destes critérios, ou mesmo dos três. Além disso, podem ser considerados outros critérios não estabelecidos aqui, porém de acordo com a característica do problema a ser resolvido.

1.6 Problemas críticos relacionados com a implementação dos AG

Existem alguns problemas críticos que ocorrem na implementação prática de algoritmos genéticos, relativos a problemas da vida real. Os principais são referentes a problemas cuja função objetivo é de minimização, uma vez que foram inicialmente desenvolvidos para problemas de maximização. Outra dificuldade ocorre quando uma das configurações envolvidas é inactivável.

1.6.1 Minimizar a função objetivo

Um dos problemas existentes na implementação do Algoritmo Genético, ocorre quando a função objetivo é de minimização. A função objetivo utilizada neste trabalho na

solução do problema tem duas componentes: custo de investimentos reativos e fantasmas de injeções reativas em barras do sistema. O custo de investimentos consiste em funções de variáveis de decisão (variáveis inteiras representando a adição de novo equipamento de compensação de reativos e ajustes dos dispositivos de controle de tensão existentes no sistema); as injeções reativas penalizadas são funções de variáveis de operação contínua. Os Algoritmos Genéticos convencionais que aparecem na bibliografia são formulados para problemas de maximização. Problemas de minimização são transformados em problemas equivalentes a maximização. Como a seleção é uma função extremamente importante para o bom desempenho dos *Algoritmos Genéticos* e essa função está intimamente relacionada com a natureza da função objetivo (minimização ou maximização), ela pode ser afetada pela escolha inadequada e/ou imprópria no tipo de transformação da função objetivo. Para converter uma função de minimização para maximização, conforme proposto em [31], minimizar $f(x)$, é semelhante para fins de implementação do Algoritmo Genético a maximizar $[k - f(x)]$, onde k é um parâmetro que pode ser ajustado durante o processo de solução. Quando o algoritmo é inicializado com uma população de configurações obtidas em outros algoritmos, e. g. Garver's, k pode ser uma constante baseada em alguma solução incumbente inicial, isto é, k é fixado em um valor correspondente a 20% do custo da configuração típica da população inicial. Em [32] propõe-se que minimizar uma função $f(x)$ pode ser considerado para fins de função aptidão para o *Algoritmo Genético*, semelhante a maximizar uma inversa da função $f(x)$, $(1/f(x))$. Uma outra forma pode ser modificar a estratégia de seleção usando critérios de seleção diferentes do esquema de seleção proporcional.

1.6.2 Configurações infactíveis

O outro problema surge quando algumas configurações (elementos) da nova geração são infactíveis. Existem duas formas de contornar esse problema :

- Usar uma heurística (preferencialmente) construtiva para transformar essas configurações candidatas de infactíveis em factíveis. Assim, nessa estratégia são aceitas somente configurações factíveis e se aparece uma configuração candidata infactível, deve-se transformá-la em factível. Essa estratégia tem o trabalho adicional de gerar a codificação inicial com todas as configurações factíveis.

- Penalizar as infactibilidades na função objetivo. Nessa estratégia, todas as configurações são consideradas “factíveis”, mas aquelas realmente infactíveis são penalizadas na função objetivo para transformar essas configurações pouco atrativas. A própria dinâmica do processo elimina sistematicamente aquelas configurações com uma infactibilidade significativa.



Capítulo II

Problema de planejamento e despacho de reativos

O Planejamento de Reativos em Sistemas de Energia Elétrica é um problema de Programação Não Linear de grande porte, envolvendo variáveis reais, inteiras e binárias. Consiste na determinação da magnitude, da natureza e da localização de fontes reativas (reatores/capacitores) visando atender às restrições de operação (limite de operação atendido) e de carga (atendimento das demandas ativa e reativa) tanto no funcionamento normal do sistema, como no caso de contingências.

No planejamento de reativos estão envolvidos, normalmente, dois tipos de problemas: Despacho Ótimo de Reativos e o Planejamento de Reativos propriamente dito [10], que serão apresentados e descritos neste capítulo.

2.1 Despacho ótimo de reativos

O Despacho Ótimo Reativos em sistema de energia elétrica é um subproblema do Fluxo de Potência Ótimo(FPO), constituindo-se uma importante etapa dentro da solução de problema relativo ao planejamento de reativos. Sua solução consiste em determinar os

ajustes dos dispositivos de controle das magnitudes das tensões existentes no sistema (banco de capacitores e reatores, taps de transformadores, capacidades próprias de geração de reativos dos geradores, compensadores síncronos e estáticos), com vistas a obter um perfil pré determinado das magnitudes das tensões em todas as barras do sistema e a satisfação das restrições operacionais do sistema de potência, ou seja, o Despacho Ótimo de Reativos é um caso particular do Fluxo de Potência Ótimo que consiste em determinar o estado de um sistema de potência elétrica que otimiza uma função objetivo dada e satisfaz um conjunto de restrições físicas e operacionais.

Na Otimização de Despacho de Reativos (ORD), os modelos matemáticos utilizados envolvem dificuldades como não-linearidades e não-convexidades, milhares de restrições, variáveis discretas e/ou inteiras, etc.; o que ocasiona problemas de difícil solução, tornando-se um tema que tem sido abordado por vários pesquisadores. São encontrados, na bibliografia diferentes métodos para solução do problema, que utilizam técnicas de programação não-linear – Método do Gradiente Reduzido de Dommel & Tinney [15], Método das Penalidades e das Barreiras Logarítmicas [6, 7, 15], Programação Quadrática Sequencial [7], Programação Linear – Programação Linear Sucessiva [11], Sistemas Especialistas e Métodos de Busca Estatística [8,10]. No entanto, todos esses métodos apresentam vantagens e desvantagens no que tange à termos de eficiência computacional e à flexibilidade no tratamento dos aspectos operacionais do problema. A seguir será feita uma breve descrição de alguns desses métodos.

2.1.1 Programação quadrática sequencial [7]

Neste método de solução de FPO , define-se uma zona de interesse, executando a otimização apenas dentro desta zona, mas resolvendo o fluxo de potência para o sistema completo.

O procedimento Programação Quadrática Sequencial – Fluxo de Potência é considerado convergido quando os valores de controle (tensões em barras de geração) nos problemas de otimização e fluxo de potência coincidem (obedecendo a uma tolerância pré especificada) .



2.1.2 Programação linear sucessiva [11]

Técnica proposta inicialmente por Stott, consiste em obter um estado de operação ótimo para o sistema, através da solução alternada de um Fluxo de Carga (FC, não-linear) e um problema de Programação Linear (PL). Para empregar este tipo de abordagem [8], alguns aspectos referentes a escolha adequada das matrizes de sensibilidade para a PL e à natureza não convexa do problema devem ser considerados.

2.1.3 Programação não linear [6, 7, 15]

Vários métodos de Programação Não Linear (PNL) foram propostos para solução do fluxo de potência ótimo. Na aplicação desta categoria de métodos para solução do despacho de reativos, devem ser adotadas soluções para contornar problemas relativos à natureza não linear, em redes que estão sob severas condições de operação, tornando o subproblema reativo excessivamente mal comportado, o que, por sua vez, dificulta a determinação do conjunto de restrições que estão ativas em cada iteração, podendo causar sérios problemas de instabilidade numérica. Dentro desta categoria de métodos, estão os chamados métodos de **pontos interiores**, cujas metodologias vêm se mostrando promissoras na solução de problemas para Otimização de Despacho de Reativos (ORD) em sistemas de grande porte.

Vários trabalhos que utilizam estes métodos têm sido divulgados desde a publicação de Karmarkar, acerca de seu novo algoritmo para solução de problemas de programação linear [1964]. O interesse pelo método de pontos interiores não se deve apenas às suas propriedades de complexidade teórica, mas também à sua eficiência computacional. Um dos fatores para a motivação da aplicação do Método de Ponto Interiores (PI) é atribuído ao crescente avanço deste método na solução de problemas de otimização não linear, particularmente aqueles chamados “infeasible interior point methods”, que permitem partir de uma solução interior, porém falha, isto é, que não satisfaz as restrições de igualdade. O crescente avanço no método de Pontos Interiores tem propiciado o aparecimento de algoritmos cada vez mais poderosos tanto para problemas de programação linear como não-linear. Para resolver problemas convexos, o tradicional Método de Penalidade Interior classicamente apresentado por Fiacco e McCormick tem apresentado bons resultados. No



Algoritmo para o método de Pontos Interiores, baseado no Método de barreiras logarítmicas do tipo Primal-Dual, a resolução se processa da seguinte forma: o problema é transformado em um problema com restrições de igualdade através da adição de variáveis de folga (variáveis primais) às desigualdades. A condição de não-negatividade das variáveis de folga é tratada através de uma função barreira logarítmica adicionada à função objetivo. As restrições de igualdade são incorporadas à função objetivo através de multiplicadores de Lagrange (variáveis duais) resultando na função Lagrangeana. Aplicam-se as condições de otimalidade de primeira ordem de KKT. Testa-se a convergência. As equações não lineares são resolvidas pelo método de Newton. O método de Newton apresenta rápida convergência, em termos de atendimento das restrições de potência ativa nas barras de carga, e utiliza um modelo mais realista (expansão até segunda ordem de Taylor–não linear) do problema. A sua solução determina o incremento das variáveis na direção de busca, resultando, a cada iteração, em um sistema linear. Com o objetivo de manter a busca da solução ótima no interior da região das soluções viáveis, calcula-se a magnitude do passo correspondente às variáveis primais e duais. A nova solução é determinada pela atualização das variáveis (primais e duais). Ajusta-se o parâmetro da função barreira, parâmetro este que está relacionado ao “gap” de dualidade entre os problemas primal e dual e recomeça-se o processo.

Este método, tipo primal-dual, apresenta um desempenho computacional superior quando aplicado a problemas de programação linear e quadrática.

Considerando a aplicação do Método de Pontos Interiores a problemas de planejamento de reativos tratados em [4]; as restrições de igualdade correspondem ao modelo de Fluxo de Potência AC e os exemplos numéricos contendo as restrições de desigualdade são apenas limites das variáveis, de modo que não existem desigualdades funcionais. Além disso todos os controles são considerados contínuos. Isto pode ser uma séria limitação no caso de bancos ajustáveis, mas o presente estágio dos algoritmos de otimização não permite que um grande número de variáveis discretas seja otimizada completamente em problemas de programação linear e não linear de grande porte. Para algumas aplicações específicas, algum tipo de estratégia de pós otimização pode ser necessária.

Tanto a formulação matemática quanto os aspectos gerais dos métodos de Programação Não Linear (PNL) são encontrados na bibliografia [5, 7, 21, 24].



2.1.4 Métodos de busca estatística [5, 10, 21, 23]

Técnicas heurísticas, também chamada de Métodos de Otimização Combinatorial, *Algoritmos Genéticos (AG)* e *Simulated Annealing (AS)*, nos últimos anos estão sendo propostas por alguns autores na solução do problema de despacho ótimo de reativos. Tais métodos, baseados em analogia com fenômenos naturais, são muito interessantes quanto à sua concepção e são similares quanto ao uso de seus mecanismos probabilísticos de busca dirigida para o decréscimo do custo ou crescimento do lucro. São algoritmos assintoticamente convergentes (estáveis).

O *Algoritmo Genético* é o método analisado e avaliado na presente dissertação, juntamente com um algoritmo de Programação Linear Sucessiva, para solução do problema de planejamento de reativos. *Algoritmos Genéticos* surgiram nos anos 70 e foram introduzidos por Holland em 1975 [22], como um mecanismo análogo ao de evolução e genética natural. Já *Simulated Annealing* surgiu em 1983, sob a autoria de Kirkpatrick, Gelat e Vecchi[2], em analogia algorítmica com o Processo “Annealing” em sólidos. A característica geral destes métodos é de que convergem para soluções ótimas ou quase ótimas, permitindo que se adote uma modelagem mais realística do problema, embora com elevado esforço computacional. Porém, tornaram-se métodos viáveis e interessantes com o surgimento de ambientes computacionais mais poderosos.

2.1.5 Sistemas especialistas

Segundo o trabalho citado na referência [6], são apresentados dois módulos do Sistema Especialista. O primeiro módulo trabalha com a análise das condições de operação do sistema. Baseado nos resultados desta análise, o Sistema Especialista irá sugerir se as curvas potência ativa-tensão(P-V), potência reativa-tensão(Q-V) ou potência aparente-tensão(S-V) devem ser estudadas. Este sistema especialista será chamado de Sistema de Análise e Seleção de Curva (SAS) para o caso em questão. O outro Sistema Especialista é usado para determinar as magnitudes e as posições dos dispositivos de controle de tensão e dos bancos reativos, como faz a maioria dos programas de controle de potência reativa. Este método heurístico incorpora ambos, custo variável e fixo, e é capaz de obter soluções sub-ótimas. Este

módulo de Sistema Especialista, projetado para determinar as posições e as capacidades dos compensadores, é chamado de Sistema Especialista de Controle de Tensão (VPES).

Estes sistemas, então, foram propostos para resolver o problema de planejamento de reativos, considerando duplas contingências e colapso de tensão. O SACS analisa a condição de operação e então seleciona as curvas $P-V/Q - V/S-V$ para o estudo do colapso de tensão. O VPES determina a magnitude e a locação de novos compensadores a serem instalados, considerando custos fixos e variáveis, além de solução discreta de novos compensadores.

2.2 Planejamento de reativos em sistemas de energia elétrica

Nos últimos anos, o planejamento de reativos em Sistemas de Energia Elétrica tem sido tema de várias publicações [1-10, 21, 23]. O problema de planejamento de reativos em Sistemas de Energia Elétrica consiste na alocação de fontes reativas em barras estratégicas do sistema, com vistas a melhorar a qualidade do serviço oferecido aos clientes. Dessa forma, as fontes reativas são alocadas no Sistema de Energia Elétrica com vistas a:

- Reduzir a perda de energia;
- Regular ou melhorar o perfil de tensão para diferentes níveis de carga;
- Melhorar a segurança do sistema;
- Liberar a capacidade da Transmissão do sistema.

Os benefícios econômicos da instalação de tais fontes vão depender:

- Da localização, dos tipos e dos tamanhos a serem instaladas;
- Do esquema de controle em diferentes níveis de carga.

O problema de alocação de fontes reativas consiste da determinação dos seguintes fatores, que compõem a formulação do problema reativo:

- Localizações e tipos de fontes reativas (reator, capacitor, bancos, compensadores síncronos, compensadores estáticos, etc) a serem instaladas;
- Os tipos de fontes a serem instaladas;
- Os números de capacitores a serem instalados;

- As magnitudes das fontes;

Assim, na solução do problema de planejamento de reativos estão envolvidos dois subproblemas: operação e investimento. O subproblema de operação é o fluxo de potência ótimo reativo, conforme foi exposto no item anterior. O outro tipo de subproblema é de investimento e consiste em determinar a natureza, magnitude e localização das fontes reativas que devem ser instaladas no sistema, com vistas a atender às condições de operação pré estabelecidas.

Apresentam-se a seguir, de forma resumida, algumas das principais fontes reativas que são utilizadas no despacho reativo. Destacam-se, também, as características principais das fontes reativas usadas na etapa de planejamento e os custos envolvidos em sua instalação e operação. Apresenta-se, ainda, a formulação geral do planejamento de reativos como um problema de programação matemática não linear de grande porte com variáveis reais, binárias e discretas.

2.3- Fontes de potência reativa no sistema de energia elétrica [10]

O conjunto dos equipamentos que constituem um sistema de energia elétrica geralmente é capaz de suprir toda a demanda ativa e reativa necessária para manter o sistema operando em condições normais de projeto - carga e topologia da rede.

O suprimento da demanda reativa necessária é feito pelas capacidades de geração de reativos das máquinas geradoras e linhas de transmissão de alta tensão (longas) entre as principais fontes. Os transformadores com “taps” variáveis sob carga, apesar de não serem fontes geradoras de reativos, têm um importante papel no despacho reativo, eliminando problemas de violações de tensões que seriam resolvidos com a alocação, na maioria das vezes desnecessária, de novas fontes reativas. Uma estratégia de alterar a topologia do sistema retirando componentes (por exemplo linhas de transmissão longas), em determinadas condições de operação, pode ser analisada.

2.3.1 Geradores síncronos

Os geradores síncronos, principal fonte de potência ativa nos sistemas de energia elétrica, são também grandes fornecedores e consumidores de potência reativa. Suas capacidades de consumo/fornecimento estão vinculadas a limites físicos de projeto tais como limites de capacidade térmica da máquina e a problemas dinâmicos de operação do sistema de energia elétrica, associados a limites de estabilidade transitória. Uma importante característica dos geradores síncronos é sua capacidade de responder rapidamente a perturbações no sistema. Os geradores síncronos representam, na maioria das vezes, a única reserva reativa disponível na operação do sistema que pode ser usada na ocorrência de um distúrbio que necessite de resposta rápida. Dado esse aspecto, no planejamento da operação o fornecimento de reativos dos geradores deve estar ajustado em níveis que proporcionem uma capacidade reativa de reserva capaz de suprir o suporte reativo necessário na ocorrência de uma perturbação.

2.3.2 Linhas de transmissão de alta tensão

As linhas de transmissão de alta tensão são altamente capacitivas, o que as torna elementos reativos normais dos sistemas, fornecendo capacidades reativas proporcionais ao quadrado das magnitudes das tensões de barras a que estão ligadas. O efeito capacitivo dessas linhas é bastante benéfico para o sistema, operando em condições de carga nominal ou pesada, uma vez que a linha se comporta como uma fonte distribuída para compensação de perdas reativas. Em condições de carga leve, este efeito capacitivo pode causar problemas de sobretensões nos terminais das linhas.

Há casos de carregamento no sistema em que mesmo o efeito capacitivo das linhas não é suficiente para evitar problemas de baixas tensões. Esse problema poderia ser resolvido através da adição de uma nova linha que acrescentaria capacitância ao sistema e reduziria as perdas reativas. Porém, do ponto de vista reativo, economicamente é difícil de justificar a construção de uma nova linha, pois existem outras alternativas de compensação de reativos que podem resolver os problemas de baixas tensões a custos menores.

A capacidade da topologia das linhas de transmissão é automaticamente considerada no planejamento ótimo de reativos através de solução do problemas de fluxo de potência.

2.3.3 Alteração da topologia do sistema

A mudança da topologia da rede não está relacionada com fontes de compensação de reativos, mas o replanejamento de fluxos ativos e reativos em linhas de transmissão através da ação do chaveamento adequado dos equipamentos de manobra, pode aliviar problemas com tensões. Não é confiável, no entanto, adotar esse tipo de procedimento apenas para melhorar o perfil de tensão da rede no planejamento ótimo de reativos, que raramente considera restrições de segurança estática e dinâmica.. O estudo de viabilidade das condições topológicas do sistema é tratado como estratégia operacional.

2.3.4 Transformadores com mudança de “tap” sob carga

Grande parte dos transformadores dos sistema de energia elétrica têm incorporados dispositivos de controle de tensão. Posições de “tap” são pontos discretos sobre os enrolamentos de um transformador, que alteram sua relação de transformação, permitindo que as tensões variem dentro de um certo intervalo correspondente ao número desses pontos. A alteração do valor eficaz da tensão permite o controle e a redistribuição do fluxo de potência reativa no sistema, melhorando o seu perfil de tensão.

A mudança de “tap” sob carga não representa fonte de reativos, mas seu uso apropriado, associado a outro dispositivo de regulação e controle de reativos, permite considerável flexibilidade em manter níveis de tensão adequados no sistema. A calibração dos “taps” existentes pode adiar a necessidade da instalação de novas fontes reativas, tornando essencial a modelagem e o ajuste deste tipo de controle durante o procedimento de planejamento de reativos.

Operacionalmente a mudança de “tap” pode ser manual ou automática, respondendo a sinais de controle de tensão de uma conexão ou barra vizinha. A diferença

entre o envio do sinal e a mudança efetiva do “tap” é de alguns minutos. Esse tempo de atuação enquadra o “tap” como um dispositivo de controle adequado para as regulações normais de tensão ou a alteração de tensão decorrente de distúrbios pequenos ou moderados, não permitindo seu uso para assegurar e manter a estabilidade do sistema durante um distúrbio.

2.4 Principais equipamentos de compensação considerado na etapa de planejamento de reativos

Na especificação dos equipamentos para compensação de reativos estão envolvidos diversos aspectos:

- Tipo de compensação necessária - indutiva, capacitiva ou um intervalo de compensação que, em algum cenário, é indutiva; em outros, capacitiva.
- Magnitude da fonte em MVar ou em “por unidade”- pu.
- Velocidade de resposta do equipamento de compensação e seus dispositivos de controle. E esta característica está relacionada com a natureza do problema dinâmico envolvido (instabilidade de tensão, estabilidade dinâmica e transitória, etc), que determina o tempo de resposta adequado para o equipamento de compensação. Quanto mais rápida for essa resposta, maior será o custo do equipamento.
- Localização do equipamento no sistema: Infra estrutura existente, nível de tensão, condições do equipamento.

Os equipamentos de compensação mais utilizados durante a etapa de planejamento ótimo de reativos são os capacitores e reatores “shunt”, compensadores síncronos e de estado sólido (estáticos). Existem outras formas de compensação que são mais utilizadas durante a fase de projeto do sistema em um dado cenário: capacitores e reatores série.

2.4.1 Capacitores “shunt”

Os capacitores “shunt” são amplamente utilizados durante a etapa de planejamento. Podem ser do tipo fixos ou bancos que possibilitam combinações série/paralela para determinar a magnitude necessária da fonte em diferentes cenários, proporcionando maior flexibilidade na operação dos capacitores “shunt” existentes no sistema. Outras características desses equipamentos são a modularidade e a confiabilidade, já que não têm partes móveis. O tempo necessário para instalar novas unidades é relativamente curto.

O custo destes equipamentos varia de médio a baixo quando comparado ao de outros equipamentos de compensação. Esse custo depende, entre outros fatores, dos dispositivos de controle, que podem ser:

- Chaves com fechamento automático sob cargas ou disjuntores que podem ser operados automática, remota ou manualmente, se necessário.
- Chaves projetadas para resolver problemas de sobretensões e surtos decorrentes de ações de chaveamento de capacitor.

As principais limitações desse tipo de equipamento são relativas a:

- Tempo de resposta alto, impossibilitando-os de participarem da solução de problemas de estabilidade transitória.
- A compensação reativa proporcionada (MVar) é função das tensões de linhas nas barras onde os equipamentos estão instalados.

2.4.2 Indutores “shunt”

Os reatores “shunt” são utilizados em sistemas de energia elétrica com dois objetivos:

- Assegurar quedas de tensões de barras em estado estacionário;
- Compensar os efeitos dos reativos capacitivos das linhas longas de alta tensão durante período de cargas leves eliminando problemas de sobretensão. Trata-se de equipamentos importantes no planejamento e controle ótimo de reativos, que podem ser do tipo fixo (uma única capacidade MVar ou bancos), que permitem um melhor ajuste da

capacidade dependendo das condições de cargas do sistema. São, normalmente, conectados no sistema de dois modos:

- Conectados às linhas de transmissão. Não são chaveados, são parte do sistema de transmissão e seus valores considerados nos cálculos dos parâmetros das linhas onde estão inseridos. O chaveamento desses equipamentos causa problema de surto de tensão de chaveamento;

- Conectados ao terciário de transformadores. Nesse modo de ligação, os equipamentos são controlados por ação de chaveamento automático.

- Os custos destes equipamentos são superiores aos dos capacitores “shunt”, variando de acordo com a magnitude e dispositivos de comando e proteção. Para grandes capacidades (MVar) os custos são elevados.

2.4.3 Compensadores estáticos

Os compensadores estáticos são uma família de sistema de compensação de reativos “shunt”, compostos de dispositivos de chaveamento convencionais e de estado sólido (eletrônico de potência), associados a sistemas de controle que propiciam o ajuste rápido e refinado das compensações reativas necessárias para atender o sistema.

Algumas características dos compensadores devem ser consideradas no planejamento de reativos:

- Custos relativamente altos, da ordem de duas a três vezes o custo da operação “shunt” convencional;

- Geração de harmônicos, havendo necessidade de filtros e manutenção rigorosa;

- Necessidades de transformadores de acoplamento ou enrolamento terciário de outros transformadores por problemas de limitação de tensão;

- Tempo de resposta instantâneo;

- Fornecem potência reativa contínua e propiciam, quando necessário, o controle independente de fase.

Desta forma, a aplicação de compensadores estáticos está limitada a situações onde se necessita de respostas dos equipamentos de compensação ou intervalo de compensação contínuo ou, ainda, controle independente de fase.

2.4.4 Compensadores síncronos

São máquinas síncronas ajustadas para gerar ou absorver grandes magnitudes de potência reativa (MVar), propiciando um intervalo contínuo de compensação. Fornecem resposta rápida (um ou dois segundos) a desvios de tensão no sistema e são considerados elementos altamente estabilizantes. Durante um pequeno intervalo de tempo, possuem capacidade de sobrecargas, que podem ser utilizadas em situações críticas de operação.

Os compensadores síncronos têm custos de instalação, manutenção, dispositivos e controle, além de equipamentos de compensação substancialmente maiores que dos reatores e capacitores “shunt” com capacidade de compensação semelhante. As taxas de falhas destes equipamentos também são maiores.

O uso de compensadores síncronos em sistemas de transmissão está em grande parte limitado aos equipamentos em operação. A especificação de novos equipamentos deve ser feita de forma muito criteriosa e justificada com base nos seguintes atributos:

- Necessidade de um intervalo de compensação de reativos (indutivo, capacitivo);
- Necessidades de um tempo de resposta rápido e sobrecargas reativas durante distúrbios no sistema.

2.5- Custos dos investimentos em fontes reativas

Para o planejamento ótimo de reativos, é importante a representação dos custos de expansão de novas fontes, uma vez que o objetivo principal do problema é a minimização destes custos. Esses dados podem ser encontrados com precisão em concessionárias de energia elétrica e/ou com os fabricantes de equipamentos de compensação de reativos.

Segundo a referência [1], no custo total de uma fonte reativa estão embutidos custos de capital, custos de operação e instalação. Uma representação mais genérica e adequada para o planejamento de reativos divide o custo total da instalação de uma nova fonte reativa em duas parcelas:

Custos Fixos: são independentes da magnitude das fontes (MVar). Dependem, entre outros, dos seguintes fatores:

- Local onde será instalada a nova fonte no sistema que decorre de problemas relativos a espaço físico e adequação da infra-estrutura disponível, acarretando ou não a necessidade de novas construções;
- Equipamentos de comando: disjuntores e chaves no caso de instalação de reatores.

Custo Variáveis: dependem do tipo de compensação - indutiva/capacitiva, capacidade da fonte (MVar) e nível de tensão.

2.6 Condições que requerem o planejamento de reativos

O sistema de energia elétrica planejado, considerando certas condições de carga e topologia, tem reservas reativas necessárias para operar atendendo a restrições de segurança e operação. Com a evolução do sistema, o sistema originalmente planejado sofre alterações topológicas e de crescimento de cargas, podendo não mais atender a tais restrições.

Com base nesses aspectos, as principais situações e/ou condições que requerem planejamento de reativos são:

- Crescimento de cargas em barras de baixa tensão distantes das unidades geradoras, causando dificuldades quanto à qualidade de serviço para os consumidores, problemas de instabilidade de tensão e perdas excessivas no sistema de transmissão;
- Linhas de transmissão longas (ou subterrâneas) de alta tensão operando em condições de cargas leves ocasionam problemas de sobretensões em seus terminais, de que decorrem problemas em máquinas síncronas, cargas e equipamentos;
- Necessidade de uma estratégia adequada de planejamento reativos/operação do sistema de geração/transmissão, visando manter o suporte reativo necessário para operação

e manutenção seguras e manutenção de reservas reativas das fontes de respostas rápidas (compensadores síncronos e estáticos, máquinas síncronas), para serem usadas em condições transitórias do sistema.

- Crescimento dos sistemas de transmissão e subtransmissão com a adição de novas linhas e alteração das necessidades reativas;

- Necessidade de substituir os capacitores de uma área do sistema de energia elétrica por motivos técnicos e/ou econômicos: problemas com os equipamentos de compensação velhos, alteração do nível de tensão de um setor do sistema de energia elétrica.



Capítulo III

Formulação geral do problema de planejamento de reativos e modelo de solução proposto

Neste capítulo, apresenta-se a formulação do problema de planejamento de reativos considerando uma função cujo objetivo é minimizar custos (fixos e variáveis) da instalação de novas unidades de capacitores em relação a restrições de investimento e operação. As equações do fluxo de potência são linearizadas em torno de um ponto de operação e o problema geral de planejamento de reativos é formulado como um problema linear inteiro misto (PLIM). A técnica usada para resolver o problema geral de planejamento é a programação linear sucessiva (FC-PLIM) e um Algoritmo Genético Simples.

3.1 Formulação geral do problema

O planejamento ótimo de reativos consiste em determinar, sob vários cenários de operação (contingências, níveis de carga), as localizações e as magnitudes das fontes reativas que asseguram operação factível do sistema de energia elétrica. Para cada cenário de operação, o problema reativo pode ser formulado como [10]:



$$\text{Min} \sum_{i \in I} f_i [qc_i, qr_i] \quad (4.1)$$

Sujeito a

$$G_P(X) = 0 \quad (4.2)$$

$$G_Q(X) + B([qc_i, qr_i] + [qc_i^r, qr_i^r]) = 0 \quad (4.3)$$

$$C_{QG}(X) - [qc_v^0, qr_v^0] \leq 0 \quad (4.4)$$

$$X^{\min} \leq X \leq X^{\max} \quad (4.5)$$

$$[(0,0)] \leq [(qc_k, qr_k)] \leq [(qc_k^{\max}, qr_k^{\max})] \quad k \in K \quad (4.6)$$

$$(qc_l, qr_l) \in \{n \times S\} \quad n = 0, 1, \dots, N_s \quad l \in L \quad (4.7)$$

$$I = K \cup L \quad (4.8)$$

Sendo,

I : conjunto de barras (nós elétricos) candidatas à alocação de novas fontes reativas;

K : conjunto de barras onde podem ser alocadas fontes reativas com intervalo de compensação contínuo;

L : conjunto de barras onde podem ser alocadas fontes reativas fixas ou bancos;

qc_i^r, qr_i^r : fontes reativas fixas ou bancos existentes no sistema e/ou alocados devido à simulação de outros cenários;

qc_v^0, qr_v^0 : fontes reativas contínuas existentes no sistema e/ou alocados devido à simulação de outros cenários;

$G_P(X), G_Q(X)$: conjunto de restrições não lineares referentes as equações estáticas do fluxo de carga, com NB (número de barras) restrições cada uma;

- C_{QG} : conjunto de restrições lineares de acoplamento que relacionam as capacidades reativas contínuas existentes no sistema;
- $B [.]$: é uma matriz diagonal de dimensão NB;
- n : número de estágios considerados para fontes reativas discretas;
- N_s : número máximo de estágios
- S : magnitude de cada estágio
- X : é o vetor composto pela magnitude das tensões de barras (V), pelos ângulos das tensões de barras (θ), taps de transformadores (T) e a capacidade reativa instalada (Q_G);

Os conjuntos de equação (4.2) e (4.3) são as equações estáticas do fluxo de potência [9], que representam o balanço de potência ativa e reativa do sistema. São dadas por:

$$P_{qk} - P_{lk} - P_k(\theta, V, T) = 0 \quad (4.9)$$

$$Q_{gk} - Q_{lk} - Q_k(\theta, V, T) = 0 \quad (4.10)$$

$$K = 1, \dots, NB$$

- NB : número de barras do sistema;
- P_{lk}, Q_{lk} : cargas ativa e reativa na barra k ;
- $P_k(\theta, V, T)$: injeção líquida de potência ativa na barra k dada pela equação geral:

$$P_k = V_k \sum_{m \in \Omega_k} V_m (G_{km} \cos \theta_{km} + B_{km} \sin \theta_{km}) \quad (4.11)$$

- Ω_k : conjunto formado pela barra k e todas as suas vizinhas;
- $Q_k(\theta, V, T)$: injeção líquida de potência reativa na barra K , dada pela equação geral:

$$Q_K = V_K \sum V_M (G_{KM} \sin \theta_{K+} + B_{km} \cos \theta_{km}) \quad (4.12)$$

O conjunto de equação (4.4) representa as restrições lineares envolvendo variáveis de operação e variável de investimento contínuas:

$$Q_{GK}^{\min} - qr_k^0 \leq Qg_k \leq Qg_k^{\max} - qc_k^0 \quad (4.13)$$

$$k=1,\dots,NB$$

qc_k^0, qr_k^0 : fontes reativas contínuas $y_v^0 = (q_c^0, q_r^0)$ devido a simulação de outros cenários;

$Q_{gk}^{\min}, Q_{gk}^{\max}$: limites de geração de fontes reativas contínuas (geradores, compensadores síncronos ou estáticos).

A função objetivo $f_i(y_i)$ representa os custos de investimento da instalação de novas fontes reativas no sistema. Nesses custos, estão incluídos: investimento de capital, instalação e operação. Para cada barra do sistema, os custos são representados por uma componente de custo fixo e outra de custos variáveis:

$$f_i(y_i) = \begin{cases} d_i + c_i y_i & \text{se } y_i > 0 \\ 0 & \text{se } y_i = 0 \end{cases} \quad (4.14)$$

onde d_i é a componente de custo fixo e c_i a componente de custo variável associada à fonte y_i . Trata-se de uma função objetivo côncava, sobre um poliedro (conjunto de restrições (4.2-4.8)) onde não se pode afirmar nada sobre convexidade [21].

3.2 Solução do problema de planejamento de reativos através de uma metodologia mista: programação linear sucessiva e algoritmo genético

O algoritmo desenvolvido permite a simulação do planejamento de reativos, obtendo-se os valores das compensações reativas capacitivas. Se a solução do despacho inicial indicar necessidade de suporte reativo, então deve-se resolver um problema de planejamento de reativos, o que é feito decompondo-o nos dois subproblemas, um de investimento e um de operação.

O algoritmo desenvolvido nesse trabalho para tratar do Planejamento de Reativos consiste basicamente em três etapas:

Fluxo de Potência (não linear)

Despacho de Reativo via Programação Linear (PL) Sucessiva

Aplicação de Algoritmos Genéticos

3.2.1 Fluxo de potência

Os dados para a primeira PL do processo iterativo de planejamento de reativos são gerados por um programa que calcula fluxo de potência (FP) com tratamento especial das barras de carga. As magnitudes das tensões são mantidas em uma faixa especificada permitindo, em geral, que se obtenha convergência e um melhor desempenho do processo de otimização. Os limites de geração de reativos são considerados abertos para as barras de tensão controlada (PV's e referência). Para as barras em que não há controle de tensão - barras PQ's - as magnitudes das tensões são recalculadas a cada iteração. Se a magnitude de uma tensão cai fora de seus limites, o tipo de barra é redefinido passando de PQ para PV, com a magnitude de tensão especificada no limite violado ($V_k^{esp} = V_k^{lim}$). Ao mesmo tempo, a injeção de reativos Q_k nessa barra é liberada, passando a ser recalculada a cada iteração. No final do fluxo de potência, têm-se todas as tensões dentro dos limites especificados, além de que as possíveis necessidades de reativos estão nas injeções nodais (tanto em barras PV's quanto em barras originalmente PQ's). A partir da solução do problema linear inicial, calcula-se fluxo de potência através do método convencional [9].

3.2.2 Programação linear

Considere o problema não linear (4.1) - (4.8). O conjunto de restrições não lineares de operação (4.2) e (4.3) (equações de fluxo de potência), sensibilidades entre potências ativa e reativa e variáveis do problema, são linearizadas em torno de um ponto de operação (V^0, θ^0, T^0) , utilizando-se a matriz "Jacobiana reativa" $[L_c]$ desenvolvida por J. L. Carpentier [26]. Essa matriz é formada por sensibilidades entre potência reativa e tensão

(magnitude), considerando que os fluxos de potência ativa através dos bipolos do sistema são constantes durante a iteração reativa. Essa situação é um caso particular do que se deseja no planejamento de reativos, que é manter inalteradas as injeções de potência ativa do sistema

($\Delta P=0$), quando a parte reativa (tensões ou injeções de potência reativa) sofre alterações. O resultado que se obtém da aplicação desses conceitos é a construção de um jacobiano genérico das injeções reativas, em termos dos módulos das tensões e dos “taps” dos transformadores com grau de esparsidade igual ao dos métodos desacoplados tradicionais.

Adotando-se a matriz L_C como sensibilidade e não considerando os limites na variação dos ângulos das tensões ($\Delta\theta$) e da potência ativa da barra de balanço (ΔP_s) o problema de planejamento de reativos linearizado pode ser escrito como [10]:

$$\text{Min} \sum_{i \in I} [(d_{ci} + c_{ci}\Delta q_{ci})r_i + (d_{ri} + c_{ri}\Delta q_{ri})r_i] \quad (4.15)$$

s.a.

$$[L_c] \begin{bmatrix} \Delta V \\ \Delta T \end{bmatrix} = \begin{bmatrix} \Delta q_{cl} - \Delta q_{rl} + \Delta q_{pl} \\ \Delta q_{ck} - \Delta q_{rk} + \Delta q_{pk} \\ 0 \end{bmatrix} \quad l \in L, k \in K \quad (4.16)$$

$$-\infty \leq \Delta\theta \leq \infty \quad (4.17)$$

$$-\infty \leq \Delta P_s \leq \infty \quad (4.18)$$

$$V^{\min} - V \leq \Delta V \leq V^{\max} - V \quad (4.19)$$

$$T^{\min} - T \leq \Delta T \leq T^{\max} - T \quad (4.20)$$

$$(qg^{\min} - qr_v^0) - q_p \leq \Delta q_p \leq (qg^{\max} + qc_v^0) - q_p \quad (4.21)$$

$$-qr_k \cdot r \leq \Delta qr_k \leq (qr_k^{\max} - qr_k) r \quad k \in K \quad (4.22)$$

$$-qc_k \cdot r \leq \Delta qc_k \leq (qc_k^{\max} - qc_k) r \quad l \in L \quad (4.23)$$

$$\Delta qr_l, \Delta qc_l \in \{n \cdot x \cdot S\} \quad n = 0, 1, \dots, N_s \quad l \in L \quad (4.24)$$

$$I = K \cup L$$

- ΔP_s : Variação da injeção de potência ativa nas barras de referência;
- Δq_p : variação incremental da capacidade reativa própria existente na barra;
- $\Delta qr_i, \Delta qc_i$: variação das fontes reativas (indutivas e capacitivas respectivamente), variáveis ($i \in K$) ou bancos ($i \in L$), a serem alocados no sistema;
- $\Delta qr_i^f, \Delta qc_i^f$: variação das fontes reativas (indutivas e capacitivas respectivamente) fixas ou bancos existentes no sistema e/ou alocadas devido à simulação de cenários previamente considerados;
- K : conjunto de barras onde existem fontes reativas contínuas, ou se permite a alocação de fontes de compensação com características contínuas;
- L : conjunto de barras onde existem fontes reativas discretas, ou se permite a alocação de fontes de compensação com características discretas;
- r : variável binária de decisão;
- d_e, d_r : Custos fixos associados à alocação de fontes reativas capacitivas e indutivas;
- c_r, c_c : custos variáveis de reatores e capacitores;
- $\Delta qr_v^0, \Delta qc_v^0$: Variação das fontes reativas indutivas e capacitivas contínuas existentes na barra, devido à simulação de outros cenários.

O problema representado pelo conjunto de equações (4.15) - (4.24), é um problema linear inteiro misto (PLIM) onde estão envolvidas variáveis reais, inteiras e discretas.

O principal objetivo e a proposta deste trabalho consistem na solução desse problema usando um algoritmo misto Programação Linear Sucessiva e Algoritmo Genético. A hipótese básica consiste em usar a Programação Linear para resolver o problema em que estão envolvidas as variáveis contínuas e o Algoritmo Genético para solução do problema envolvendo as variáveis discretas (taps de transformadores, bancos capacitivos), através de um processo em que estes dois tipos de abordagem interagem.

3.2.3 Algoritmo genético

O Algoritmo Genético é usado para resolver o problema (4.1) – (4.8), juntamente com a programação linear sucessiva. Considere o problema (4.15) – (4.24), alterado com a troca das variáveis de investimento reativo $\Delta q_{ri}^f, \Delta q_{ci}^f$ $i \in I$, por variáveis de folga contínuas $(\Delta y1_i, \Delta y2_i)$ e, ainda, considerando como função objetivo a minimização da soma dessas variáveis. O problema de PL que se origina dessas alterações é um problema relaxado (em relação ao original) e se torna [10]:

$$\text{Min } w = \sum_{i \in I} (\Delta y1_i + \Delta y2_i) \quad (4.25)$$

s.a.

$$[L_c] \quad \begin{bmatrix} \Delta V \\ \Delta T \end{bmatrix} = \begin{bmatrix} \Delta Q_p + \Delta y1_i - \Delta y2_i \\ 0 \end{bmatrix} \quad (4.26)$$

$$-\infty \leq \Delta \theta \leq \infty \quad (4.27)$$

$$-\infty \leq \Delta P_s \leq \infty \quad (4.28)$$

$$V^{\min} - V \leq \Delta V \leq V^{\max} - V \quad (4.29)$$

$$T^{\min} - T \leq \Delta T \leq T^{\max} - T \quad (4.30)$$

$$(qg^{\min} - qr_v^0) - q_p \leq \Delta q_p \leq (qg^{\max} + qc_v^0) - q_p \quad (4.31)$$

$$\Delta y1_i \geq 0, \quad \Delta y2_i \quad I = k \cup L \quad (4.32)$$

No problema (4.25) – (4.32), as variáveis $(\Delta y1_i, \Delta y2_i)$ representam injeções reativas fictícias e fornecem informações, caso existam, das regiões com falta de suporte de reativos.

Inicialmente resolve-se o problema (4.25)-(4.32) através de um algoritmo de Programação Linear Sucessiva (PL-FC), obtendo-se uma solução para o problema reativo em que todas as variáveis são consideradas contínuas: o que representa uma solução otimista para um ponto de operação factível $((\underline{V}, \underline{\theta}, \underline{T}))$. A partir dessa etapa dentro do processo de solução,

utiliza-se o algoritmo genético para tratar as variáveis discretas “Taps” de transformadores e bancos capacitivos, envolvidas no problema de planejamento de reativos.

3.2.3.1 Codificação das variáveis discretas – composição dos indivíduos

O conjunto de “taps” variáveis (T) para o sistema e as barras do sistema pertencentes ao conjunto de candidatas que possuem fontes reativas capacitivas discretas (qc) foram considerados como uma indivíduo da população do algoritmo genético. Dessa forma, cada indivíduo possui a seguinte estrutura básica.

$$[T_1 \dots T_{nt} \mid qc_1 \dots qc_{mc}] \quad (4.33)$$

- nt** : número de taps variáveis existentes no sistema
- mc** : número de barras com fontes reativas capacitivas discretas e/ou se permite alocar fontes reativas capacitivas discretas ($m \in L$).

A geração e a codificação de cada elemento da população (4.33) obedeceram às seguintes regras:

- (a) Os valores de “Taps” foram discretizados, entre os limites ($T^{\min} - T^{\max}$), e, para obter inicialmente a posição do “tap” para cada barra e para cada indivíduo, utilizou-se um gerador de número aleatório que forneceu um valor discretizado de “tap” entre os limites ($T^{\min} - T^{\max}$) pré estabelecidos.
- (b) As fontes reativas capacitivas foram discretizadas entre os limites ($0 - qc^{\max}$). Para determinar o valor de qc_i , $i=1, \dots, mc$, primeiro deve-se decidir alocar (1) ou não (0) fonte reativa na barra em análise. Essa decisão é tomada com base num gerador de números aleatórios. Uma vez decidida a alocação, novamente utilizando um gerador de números aleatórios, opta-se pela magnitude do banco discreto.

A codificação das variáveis (4.33), para formação dos indivíduos da população, não foi efetuada utilizando-se a codificação binária como proposto em alguns trabalhos envolvendo algoritmos genéticos, mas foi utilizada a representação decimal, devidamente discretizada de acordo com a definição de cada variável envolvida. A escolha da base decimal

para representar as variáveis que compõem cada indivíduo deve-se à natureza do problema, ou seja:


- Valores de algumas variáveis que não se encaixam exatamente no intervalo considerando-se um número fixo de bits;
- Limitação de memória do computador para representar em binário um grande número de variáveis.
- Ao se realizarem as operações genéticas de cruzamento e mutação, podem ser obtidos valores fora dos intervalos pré especificados para as variáveis, e perdidas informações sobre o intervalo de discretização.

O conjunto de **np** elementos com a estrutura igual a (4.33), gerado conforme (a) e (b), constitui uma população inicial para o algoritmo genético especializado para solução do problema de planejamento de reativos juntamente com a programação linear. A próxima etapa constitui em avaliar a função aptidão para cada indivíduo da população.


3.2.3.2 Avaliação da função aptidão

Para cada indivíduo da população, deve-se avaliar o valor da função aptidão. No caso específico do problema reativo procedeu-se da seguinte forma:

- (a) Fixam-se os valores de “taps” de acordo com o especificado para cada indivíduo da população;
- (a) Para cada indivíduo da população, as (**mc** – **nt**) posições correspondentes à alocação e/ou ajuste dos equipamentos de compensação de reativos capacitivos discretos são consideradas como compensação reativa “shunt” e incluídas diretamente nos respectivos elementos da diagonal da matriz admitância do sistema. Por exemplo, considere uma barra **m** do sistema de energia elétrica que permite alocar banco de capacitores. A Figura-7(a) ilustra essa barra normalmente ligada ao sistema com as compensações reativas “shunt” do modelo π das respectivas linhas de transmissão. A matriz admitância nodal do sistema é formada da seguinte forma:



(a)



(b)

Figura 7 : Representação Simbólica de uma barra “m” do Sistema de Energia Elétrica (a) sem Compensação Reativa “shunt” e (b) com Compensação Reativa “shunt”

$$Y_{mm} : \sum_{k \in U_m} (y_{mk} + j b_{mk}^{sh}) \text{ [Somatório de todas as admitâncias ligadas à barra m]}$$

- Y_{mk} : - y_{mk} [negativo da admitância que liga diretamente a barra **m** à barra **k**]
- Y_{mm} : elemento da diagonal, referente à barra **m**, da matriz admitância nodal;
- Y_{mk} : elemento da matriz admitância nodal linha **m** e coluna **k**;

Na Figura-7.(b) adicionou-se um banco de capacitores à barra **m**. Para considerar sua influência no estado do sistema fornecido pelo fluxo de carga, uma maneira é através de uma admitância “shunt” que pode ser calculada em pu, com boa precisão pela seguinte relação:

$$qc_m = V_m^2 \cdot B_m^{sh}$$

- B_m^{sh} : admitância “shunt” na barra **m** em pu, devido à alocação do banco de capacitores com capacidade reativa qc (em pu);
- V_m : Magnitude em pu da tensão na barra **m**.

Em seguida, deve-se considerá-la no elemento da diagonal **m** da matriz admitância nodal:

$$Y'_{mm} = \sum_{k \in \Omega_m} (y_{mk} + jb_{mk}^{sh}) + jB_m^{sh}$$

$$Y'_{mm} = \sum (y_{mm} + jb_m^{sh})$$

- Y'_{mm} : Elemento da diagonal da matriz admitância nodal referente à barra **m**, modificado devido à alocação de um banco reativo capacitivo na barra **m**.

A partir do estado fornecido pela P. L. Sucessiva convergida, $(\underline{V}, \underline{\theta}, \underline{T})$, e procedendo-se conforme (a) e (b), resolve-se um PL (4.25) - (4.32) seguido de um Fluxo de Carga tradicional [9]; gerando, dessa forma, os diferentes componentes da função aptidão que são:

- (1) Somatório das fontes reativas discretas qc_m , $m \in L$;

- (2) Somatório das fontes reativas contínuas, caso necessárias ($qc_i, qr_i, i \in K$) multiplicadas pelos respectivos custos variáveis (cc_i, cr_i) $i \in K$;
- (3) Somatório das injeções reativas fictícias ($y1_i, y2_i$) $i \in L$, multiplicadas por um termo de penalidade

Assim, para cada indivíduo da população a função aptidão é calculada como::

$$Fap = \sum_{m \in L} qc_m + \sum_{i \in K} (cc_i qc_i + cr_i qr_i) + fp \sum_{i \in L} (y1_i + y2_i)$$

em que fp é um fator de penalidade, que tem de ser cuidadosamente calibrado, para não descaracterizar os objetivos envolvidos na solução do problema.

3.2.3.3 Esquema de seleção proporcional

O esquema de seleção utilizado foi o Esquema de Seleção Proporcional(1.3.1.2), de modo que os indivíduos com maior valor proporcional terão maiores chances de ser selecionados a sofrerem os Operadores Genéticos: Cruzamento e Mutação.

Neste trabalho, utilizou-se uma forma alternativa e mais prática para implementar a seleção, realizada do seguinte modo:

- Calcula-se, para cada indivíduo, a relação (Nd) entre os valores de sua função aptidão (Fap_i) e a média aritmética da função aptidão de todos os indivíduos da população (Fap_m); para cada configuração, designa-se um número de descendentes igual à parte inteira desta relação (Nd) e depois designam-se descendentes usando o maior valor fracionário de Nd até completar as N configurações escolhidas, que, no caso, são iguais ao tamanho da população.

3.2.3.4 Seleção

De acordo com o número gerado no esquema de seleção proporcional, os indivíduos correspondentes às barras candidatas são selecionados a sofrerem as operações genéticas.


3.2.3.5 Cruzamento

Considerando um número aleatoriamente gerado, entre 0 e 1, definem-se quais os pares que sofrerão o cruzamento. Utilizamos a taxa de cruzamento no intervalo $[0,4 \ 0,9]$ e, como o tipo de cruzamento, optamos pelo cruzamento simples em um único ponto (1.3.1.3 -a).

3.2.3.6 Mutação

Também através de um número aleatório gerado, selecionam-se os indivíduos que sofrerão a mutação. Aqui, o intervalo considerado como taxa de mutação foi $[0,06 \ 0,001]$.

Indivíduo: (n.)



A mutação abordada neste trabalho consiste em alterar aleatoriamente, de acordo com a taxa de mutação pré estabelecida [10], os valores discretizados de taps de transformadores, adicionando ou subtraindo a eles 0,01 pu, ou fontes reativas capacitivas, adicionando ou subtraindo a estas um módulo referente à sua discretização. Verifica-se então

se o problema convergiu. Se houver convergido, verifica-se o resultado da PL sucessiva, observando o melhor valor da função aptidão encontrado, qual a iteração encontrada, bem como as quantidades de potência reativa a serem alocadas nas propostas de investimentos e os valores dos taps.

3.2.4 Algoritmo geral do problema

Apresenta-se a seguir na Figura-8 um diagrama de blocos ilustrando a estrutura geral do Algoritmo implementado para a solução do Problema de Planejamento de Reativos em Sistemas de Energia Elétrica utilizando-se a metodologia mista: Programação Linear Sucessiva e Algoritmo Genético Simples, proposta neste trabalho.




Figura 8: Diagrama de blocos do algoritmo desenvolvido

Capítulo IV

Testes Computacionais

Neste capítulo apresentam-se os resultados obtidos com a simulação dos sistemas testes amplamente divulgados na bibliografia - IEEE30 [30] e o IEEE118 [1], de 30 e 118 barras, respectivamente.

O programa computacional utilizado, que envolve a implementação do algoritmo genético como parte da solução do planejamento de reativos, foi desenvolvido no Laboratório Computacional do Departamento de Engenharia Elétrica da Faculdade de Engenharia de Ilha Solteira, UNESP. As subrotinas referentes à Programação Linear Sucessiva foram desenvolvidas no Laboratório de Sistemas de Energia Elétrica da Faculdade de Engenharia Elétrica e de Computação, UNICAMP.

4.1- Sistema IEEE30

Para analisar o desempenho da metodologia proposta, foram realizados testes utilizando-se o sistema IEEE30 [30]. Este sistema consiste de 30 barras, 37 linhas de transmissão e 4 transformadores com “taps” controlados automaticamente. Na Tabela – 4.1.1,



estão indicados os limites na capacidade de geração de reativos e as admitâncias “shunts” nas barras onde existem. Na Tabela – 4.1.2, são apresentadas as barras, dentre as quais existem transformadores com mudança automática de “taps”. As colunas ($T^{\min}$, $T^{\max}$) referem-se, respectivamente, aos valores mínimos e máximos que cada “taps” pode assumir. Esse intervalo foi discretizado em passos, variando de 0,01, para ser considerado pelo algoritmo genético. As demais condições de teste para esse sistema são:

- Limites das magnitudes das tensões entre [0,97 1,03] pu ;
- Limites das fontes reativas a serem alocadas e/ou ajustadas entre [0 1,125] pu, discretizadas em 0,125 pu ;
- Conjunto de barras candidatas $I = \{1, 2, 5, 8, 11, 13, 19, 27\}$;

Tabela 4.1.1 : Limites de Geração de reativos em barras de tensão controlada e admitância shunt (IEEE30)

BARRA	$qg^{\min}$ [MVar]	$qg^{\max}$ [MVar]	SHUNT [MVar]
1	0,0	0,0	-
2	-40,0	50,0	-
5	-40,0	40,0	-
8	-10,0	40,0	-
10	-	-	19,0
11	-6,0	24,0	-
13	-6,0	24,0	-
24	-	-	4,3

Tabela 4.1.2 : “Taps” de transformadores (IEEE 30)

N°	LIGAÇÕES		$T_{\min}$	$T_{\max}$
	K	L		
1	6	9	0,90	1,10
2	6	10	0,90	1,10
3	4	12	0,90	1,10
4	28	27	0,90	1,00

Para fins de testar o algoritmo genético, considerou-se que a natureza das fontes a serem alocadas em todas as barras do conjunto I é capacitiva discreta. O Sistema foi simulado considerando-se duas condições de necessidade de reativos:

CASO A:

Os limites nas capacidades próprias de reativos nas barras de tensão controlada (qg^{min} , qg^{max}), fornecidos na Tabela 4.1.1, iguais a zero;

CASO B:

Limites nas capacidades próprias de geração de reativos iguais aos dados na Tabela 4.1.1.

Para cada taxa de cruzamento (**tc**) e taxa de mutação (**tm**) apresentada na tabela 4.1.3, realizaram-se testes, considerando diferentes tamanhos de população.

Tabela 4.1.3 : Taxa de cruzamento (pc) e taxa de mutação (pm) adotadas nos testes com o sistema IEEE30.

CASO 1		CASO 2		CASO 3		CASO 4		CASO 5		CASO 6	
tc	Tm	Tc	tm	Tc	tm	Tc	Tm	tc	tm	tc	Tm
0,4	0,06	0,5	0,03	0,6	0,009	0,7	0,006	0,8	0,003	0,9	0,001

CASO 7		CASO 8		CASO 9		CASO 10		CASO 11		CASO 12	
Tc	Tm	Tc	tm	Tc	tm	Tc	Tm	tc	tm	tc	Tm
0,4	,001	0,5	0,003	0,6	0,006	0,7	0,009	0,8	0,03	0,9	0,06

O tamanho das populações consideradas neste trabalho, para o sistema IEEE30, foram os seguintes: 30, 50, 80, 100, 140, 200.

Em todos os testes realizados, verifica-se a eficiência da metodologia proposta para encontrar boas soluções discretas para o planejamento de reativos. A validade das soluções pode ser constatada comparando-se o total de reativos necessários obtidos através da PL sucessiva (contínuo), para manter o sistema operando dentro das condições pré estabelecidas ao total de reativos, considerando a magnitude das fontes reativas e taps discretizados, utilizando-se o algoritmo genético no caso **A** (tabelas 1 –12) e no caso **B** (tabelas 13-24). A solução do problema obtida através do algoritmo genético depende, além dos parâmetros de controle do algoritmo, da população inicial – semente, que é gerada aleatoriamente. Dessa forma, é importante, para um mesmo conjunto de parâmetros de controle do algoritmo, proceder-se a várias simulações e analisar a qualidade dos resultados obtidos.

Os resultados obtidos nestes testes são apresentados a seguir, em tabelas devidamente especificadas, de acordo com os casos **A** e **B**, respectivamente. Para fins de análise consideram-se boas soluções aquelas que apresentam um montante de reservas reativas discretas, próximo ao montante da solução contínua obtida através da PL Sucessiva e onde não aparecem injeções reativas fictícias ($\sum_{i \in I} (y1_i + y2_i) = 0$).



Tabela 1- Desconsiderando a capacidade própria de geração (tc=0,4 e tm = 0,06)

Barra $i \in \alpha$	Solução Real	tp = 30	tp = 50	tp = 80	tp = 100	tp = 140	tp = 200
2	---	---	---	---	---	---	0,125
5	0,520	1,000	0,750	0,625	0,500	0,750	0,625
8	---	---	0,625	0,750	0,750	0,875	0,875
11	0,200	---	---	---	---	0,125	0,125
13	0,240	---	---	---	---	0,250	---
19	0,270	---	0,375	0,375	0,250	---	---
24	0,300	---	0,375	0,375	---	---	0,375
27	0,370	---	---	0,125	0,375	0,125	---
Total	1,900	1,000	2,125	2,250	2,000	2,125	2,125
Σ^*		1,110	0,060	0,000	0,290	0,050	0,070

* Soma das infactibilidades $\sum (\Delta y1_i + \Delta y2_i)$

Tabela 2- Desconsiderando a capacidade própria de geração (tc=0,5 e tm = 0,03)

Barra $i \in L$	Solução Real	tp = 30	tp = 50	tp = 80	tp = 100	tp = 140	tp = 200
2	---	0,125	---	---	---	---	---
5	0,520	0,875	0,750	0,500	0,875	0,875	0,875
8	---	---	0,875	1,1250	0,875	1,000	1,000
11	0,200	---	---	---	---	---	---
13	0,240	---	---	---	0,250	---	---
19	0,270	0,125	---	0,375	---	---	0,125
24	0,300	0,375	0,500	0,125	---	0,125	---
27	0,370	---	---	---	0,125	0,125	0,125
Total	1,900	1,500	2,125	2,125	2,125	2,125	2,125
Σ^*		0,630	0,050	0,120	0,030	0,000	0,000

* Soma das infactibilidades $\sum (\Delta y1_i + \Delta y2_i)$




Gráfico 1: Desconsiderando a capacidade própria de geração da máquina
 $tc=0,4$ $tm=0,06$




Gráfico 2: Desconsiderando a capacidade própria de geração da máquina
 $tc=0,5$ $tm=0,03$

Tabela 3- Desconsiderando a capacidade própria de geração ($t_c=0,6$ e $t_m = 0,009$)

Barra $i \in L$	Solução Real	tp = 30	tp = 50	tp = 80	tp = 100	tp = 140	tp = 200
2	---	---	---	---	---	---	---
5	0,520	---	0,750	0,500	0,625	0,750	0,625
8	---	1,125	1,000	1,125	0,875	1,125	1,125
11	0,200	---	---	---	---	---	---
13	0,240	0,125	0,125	0,125	0,125	---	---
19	0,270	---	---	---	0,125	0,125	---
24	0,300	---	0,250	0,250	0,375	---	---
27	0,370	0,375	---	---	---	0,250	0,375
Total	1,900	1,625	2,125	2,00	2,125	2,250	2,125
Σ^*		0,450	0,000	0,090	0,030	0,000	0,000

* Soma das infactibilidades $\sum (\Delta y_{1_i} + \Delta y_{2_i})$

Tabela 4- Desconsiderando a capacidade própria de geração ($t_c=0,7$ e $t_m = 0,006$)

Barra $i \in L$	Solução Real	tp = 30	tp = 50	tp = 80	tp = 100	tp = 140	tp = 200
1	---	---	---	0,125	---	---	---
2	---	---	---	---	---	---	---
5	0,520	0,250	0,125	0,750	0,500	1,000	0,625
8	---	0,625	1,125	1,000	1,000	0,500	1,000
11	0,200	---	---	---	---	---	---
13	0,240	0,250	---	---	0,250	---	0,250
19	0,270	---	---	---	0,125	0,250	---
24	0,300	0,250	0,250	0,375	---	---	0,250
27	0,370	---	0,250	---	0,250	0,500	---
Total	1,900	1,375	1,750	2,250	2,125	2,250	2,125
Σ^*		0,790	0,330	0,000	0,000	0,000	0,000

* Soma das infactibilidades $\sum (\Delta y_{1_i} + \Delta y_{2_i})$




Gráfico 3: Desconsiderando a capacidade própria de geração da máquina
 $tc=0,6$ $tm=0,009$




Gráfico 4: Desconsiderando a capacidade própria de geração da máquina
 $t_c=0,7$ $t_m=0,006$

Tabela 5- Desconsiderando a capacidade própria de geração (tc=0,8 e tm = 0,003)

Barra $i \in L$	Solução Real	tp = 30	tp = 50	tp = 80	tp = 100	tp = 140	tp = 200
2	---	---	---	---	0,125	---	---
5	0,520	0,625	0,750	0,750	0,750	0,750	1,000
8	---	1,125	0,875	0,875	0,625	1,000	0,625
11	0,200	---	---	---	---	---	---
13	0,240	0,250	0,250	0,125	0,125	---	---
19	0,270	---	0,250	---	---	---	0,125
24	0,300	0,125	---	---	0,375	0,375	0,375
27	0,370	---	---	0,375	0,125	---	---
Total	1,900	2,125	2,125	2,125	2,125	2,125	2,125
Σ^*		0,000	0,110	0,000	0,030	0,000	0,000

* Soma das infactibilidades $\sum (\Delta y_{1_i} + \Delta y_{2_i})$

Tabela 6- Desconsiderando a capacidade própria de geração (tc=0,9 e tm = 0,001)

Barra $i \in L$	Solução Real	tp = 30	tp = 50	tp = 80	tp = 100	tp = 140	tp = 200
2	---	---	---	---	---	---	---
5	0,520	0,500	0,750	0,875	1,000	0,500	0,500
8	---	1,125	1,000	0,875	0,625	0,875	1,000
11	0,200	---	---	---	---	---	---
13	0,240	---	---	---	---	0,250	---
19	0,270	---	---	---	0,250	---	0,250
24	0,300	---	0,250	0,375	0,375	0,125	---
27	0,37	0,375	---	0,125	---	0,375	0,375
Total	1,900	2,000	2,000	2,250	2,250	2,125	2,125
Σ^*		0,14	0,12	0,03	0,00	0,06	0,00

* Soma das infactibilidades $\sum (\Delta y_{1_i} + \Delta y_{2_i})$




Gráfico 5: Desconsiderando a capacidade própria de geração da máquina
 $tc=0,8$ $tm=0,003$




Gráfico 6: Desconsiderando a capacidade própria de geração da máquina
 $tc=0,9$ $tm=0,001$

Tabela 7 - Desconsiderando a capacidade própria de geração (tc=0,4 e tm = 0,001)

Barra $i \in L$	Solução Real	tp = 30	tp = 50	tp = 80	tp = 100	tp = 140	tp = 200
2	---	---	---	---	---	---	---
5	0,520	1,125	0,875	0,750	1,000	---	0,875
8	---	1,125	0,500	1,125	0,625	1,000	0,875
11	0,200	0,125	---	---	---	1,125	---
13	0,240	---	---	---	---	---	---
19	0,270	0,500	---	---	0,125	---	---
24	0,300	0,375	0,375	0,250	0,250	---	0,375
27	0,370	---	---	---	0,250	---	---
Total	1,900	2,250	1,750	2,125	2,250	2,125	2,125
Σ^*		0,290	0,380	0,030	0,050	0,190	0,000

* Soma das infactibilidades $\sum (\Delta y_{1_i} + \Delta y_{2_i})$

Tabela 8- Desconsiderando a capacidade própria de geração (tc=0,5 e tm = 0,003)

Barra $i \in L$	Solução Real	tp = 30	tp = 50	tp = 80	tp = 100	tp = 140	tp = 200
2	---	---	---	---	0,250	---	---
5	0,520	0,375	1,000	1,125	0,750	1,000	1,125
8	---	1,000	0,250	---	0,375	0,750	0,750
11	0,200	---	0,250	---	---	---	---
13	0,240	---	0,125	---	---	---	---
19	0,270	0,250	---	0,125	0,375	0,375	0,250
24	0,300	---	---	0,375	---	---	---
27	0370	---	---	0,125	0,500	---	---
Total	1,900	1,625	1,625	1,750	2,250	2,125	2,125
Σ^*		0,490	0,540	0,270	0,000	0,040	0,050

* Soma das infactibilidades $\sum (\Delta y_{1_i} + \Delta y_{2_i})$




Gráfico 7: Desconsiderando a capacidade própria de geração da máquina
 $tc=0,4$ $tm=0,001$




Gráfico 8: Desconsiderando a capacidade própria de geração da máquina
 $t_c=0,5$ $t_m=0,03$

Tabela 9 - Desconsiderando a capacidade própria de geração (tc=0,6 e tm = 0,006)

Barra $i \in L$	Solução Real	tp = 30	tp = 50	tp = 80	tp = 100	tp = 140	tp = 200
2	---	---	---	---	---	0,125	---
5	0,520	1,125	1,000	1,125	1,125	0,625	0,625
8	---	---	0,750	0,500	0,500	0,750	1,000
11	0,200	---	---	---	---	---	---
13	0,240	---	---	---	---	---	0,250
19	0,270	0,125	0,375	0,375	---	---	---
24	0,300	0,250	0,125	---	0,500	0,500	---
27	0,370	0,375	---	---	---	---	0,250
Total	1,900	1,175	2,250	2,000	2,125	2,000	2,125
Σ^*		0,350	0,000	0,130	0,050	0,170	0,030

* Soma das infactibilidades $\sum (\Delta y1_i + \Delta y2_i)$

Tabela 10 - Desconsiderando a capacidade própria de geração (tc=0,7 e tm = 0,009)

Barra $i \in L$	Solução Real	tp = 30	tp = 50	tp = 80	tp = 100	tp = 140	tp = 200
2	---	0,250	0,125	---	---	---	---
5	0,520	0,750	1,000	1,125	1,000	0,750	0,625
8	---	1,000	0,250	0,250	0,250	1,000	0,750
11	0,200	---	---	---	0,125	---	0,250
13	0,240	---	---	---	0,250	---	0,125
19	0,270	---	---	0,250	---	---	---
24	0,300	---	---	0,250	0,500	0,375	0,375
27	0,370	---	0,250	0,250	---	0,125	0,125
Total	1,900	2,000	1,625	2,125	2,125	2,250	2,250
Σ^*		0,170	0,510	0,050	0,090	0,000	0,000

* Soma das infactibilidades $\sum (\Delta y1_i + \Delta y2_i)$




Gráfico 9: Desconsiderando a capacidade própria de geração das máquinas
 $t_c = 0,6$ $t_m = 0,006$




Gráfico 10: Desconsiderando a capacidade própria de geração da máquina
 $tc=0,7$ $tm=0,009$

Tabela 11 - Desconsiderando a capacidade própria de geração (tc=0,8 e tm = 0,003)

Barra $i \in L$	Solução Real	tp = 30	tp = 50	tp = 80	tp = 100	tp = 140	Tp = 200
2	---	---	---	---	---	---	---
5	0,520	0,875	0,625	0,375	0,750	0,875	0,875
8	---	---	0,750	0,875	0,750	0,875	0,875
11	0,200	---	---	---	---	---	---
13	0,240	---	---	---	0,250	---	---
19	0,270	0,250	---	0,375	---	0,125	0,250
24	0,300	---	0,375	---	0,375	---	---
27	0,370	0,500	0,125	0,125	---	0,250	0,125
Total	1,900	1,625	1,875	1,750	2,125	2,125	2,125
Σ^*		0,520	0,270	0,360	0,050	0,000	0,040

*Soma das infactibilidades $\sum (\Delta y1_i + \Delta y2_i)$

Tabela 12 - Desconsiderando a capacidade própria de geração (tc=0,9 e tm = 0,06)

Barra $i \in L$	Solução Real	tp = 30	tp = 50	tp = 80	tp = 100	tp = 10	tp = 200
2	---	---	---	---	---	---	---
5	0,520	0,750	0,875	0,750	0,750	0,750	0,500
8	---	0,875	0,750	1,000	1,125	0,875	1,125
11	0,200	---	---	---	---	---	---
13	0,240	---	---	---	---	---	---
19	0,270	0,375	0,125	0,250	---	0,250	0,250
24	0,300	---	0,375	0,250	0,250	---	0,250
27	0,370	0,375	---	---	---	0,375	---
Total	1,900	2,375	2,125	2,250	2,125	2,250	2,125
Σ^*		0,080	0,000	0,000	0,000	0,000	0,050

* Soma das infactibilidades $\sum (\Delta y1_i + \Delta y2_i)$




Gráfico 11: Desconsiderando a capacidade própria de geração da máquina
 $t_c=0,9$ $t_m=0,03$




Gráfico 12: Desconsiderando a capacidade própria de geração da máquina
 $t_c=0,9$ $t_m=0,06$

4.1.1 Comentários sobre os testes – Caso A

No caso A, onde não se considera a capacidade própria de reativos da máquina síncrona, comparando-se os testes realizados e apresentados nas tabelas (1-12), verifica-se que os melhores resultados obtidos, 53,85%, correspondem às populações maiores ($tp=140$ e $tp=200$), enquanto para as demais populações, nos melhores resultados, 30,77% correspondem às populações $tp=80$ e $tp=100$; 11,54% correspondem à $tp=50$ e 3,84% referenciam-se à $tp=30$. Este aspecto está relacionado com a própria concepção dos Algoritmos Genéticos, pois, quanto maior a população, mais diversificada ela será e maiores serão as probabilidades na realização dos operadores genéticos, cruzamento e mutação, e, conseqüentemente, melhores serão os descendentes dessa população. Por outro lado, uma população muito grande vai consumir elevado tempo computacional e o ideal é conciliar estes dois aspectos, ou seja a eficiência computacional e a qualidade da solução.

As melhores soluções discretas obtidas são as dos casos referentes à tabela 4, à tabela 5 e à tabela 12.

Outros fatores de fundamental importância são a taxa de cruzamento (**tc**) e a taxa de mutação (**tm**), influenciando diretamente na eficiência do algoritmo, sendo que, para tamanhos diversificados de população (4 tamanhos diferentes), os casos referentes à tabela 4, à tabela 5 e à tabela 12, com $tc=0,7$ e $tm=0,006$, $tc=0,8$ e $tm=0,003$ e $tc=0,9$ e $tm=0,06$, respectivamente, foram os melhores, representando, juntos, 25% dos resultados satisfatórios. Também os resultados referentes à tabela 3 (3 tamanhos diferentes de população), com $tc=0,6$ e $tm=0,009$, apresentam-se como satisfatórios, porém representando apenas 8,33%. Os resultados com 2 tamanhos diferentes de população foram representados, também, com 25%, enquanto aqueles com apenas 1 tamanho de população representaram-se por 41,68%.

Observe que, além das observações feitas anteriormente, apenas para populações maiores, ou seja, $tp=100$, $tp=140$ e $2tp=200$, os testes referentes às tabelas (2, 3,

6, 7, 8, 10, 11 apresentaram bons resultados, correspondendo à 58,33% de todos os testes realizados.

No caso A, a quantidade de reativos varia entre 2,125 ou 2,250 nos diferentes testes.

Quanto aos gráficos referentes aos testes realizados, em que é apresentado a média da função aptidão pelo número de iterações, observam-se os seguintes aspectos:

1. Nas populações de 30 e 50 elementos, ocorre uma disparidade na maioria dos gráficos, tais como 1, 2, 3, 4, 5, 7, 8, 10, 11 e 12, verificando-se inclusive um enorme pico no gráfico 1 com relação à população de 30 e um pico menor no gráfico 2, com relação à população de 50.

2. Nos gráficos números 1, 2, 3, 7, 8, 9, 10, 11 à medida que aumenta o número de iterações, não há uniformidade nas curvas, enquanto nos gráficos 4, 5, 12, pode-se ver claramente que, à medida que as iterações vão aumentando, as funções vão se estabilizando. Para a população de 200 elementos, apenas os gráficos 6 e 7 apresentam picos elevados no início das iterações, uniformizando-se depois e apresentando resultado satisfatório.

Tabela 13 – Sistema IEEE30 considerando a capacidade própria de geração
($t_c=0,4$ e $t_m = 0,06$)

Barra $i \in L$	Solução Real q_c (pu)	$tp = 30$	$tp = 50$	$tp = 80$	$tp = 100$	$tp = 140$	$tp = 200$
2	---	---	---	---	0,500	---	---
5	0,540	0,500	0,625	1,000	0,875	1,000	0,875
8	---	0,625	1,125	0,250	---	0,500	0,375
13	0,190	0,125	---	---	---	---	---
19	0,290	---	0,250	0,375	0,375	---	0,375
24	0,330	0,500	---	---	---	---	---
27	0,370	---	---	0,375	0,250	0,375	---
Total	1,720	1,750	2,000	2,000	2,000	1,875	2,000
Σ^*		0,280	0,000	0,050	0,000	0,070	0,08

* Soma das infactibilidades $\sum (\Delta y_{1_i} + \Delta y_{2_i})$

Tabela 14 – Sistema IEEE30 considerando a capacidade própria de geração
($t_c=0,5$ e $t_m = 0,03$)

Barra $i \in L$	Solução Real q_c (pu)	$tp = 30$	$tp = 50$	$tp = 80$	$tp = 100$	$tp = 140$	$tp = 200$
2	---	0,125	---	0,125	---	---	---
5	0,540	0,250	0,875	0,875	1,000	0,500	0,875
8	---	0,875	0,250	0,750	0,625	1,125	0,750
11	0,010	0,125	0,125	---	---	---	---
13	0,190	---	---	---	---	---	0,125
19	0,290	---	---	---	---	---	---
24	0,330	0,125	0,500	0,250	---	---	0,250
27	0,3670	---	---	---	0,375	0,375	---
Total	1,730	1,500	1,750	2,000	2,000	2,000	2,000
Σ^*		0,490	0,280	0,000	0,080	0,000	0,000

* Soma das infactibilidades $\sum (\Delta y_{1_i} + \Delta y_{2_i})$




Gráfico 13: Considerando a capacidade própria de geração da máquina
 $tc=0,4$ $tm=0,06$




Gráfico 14: Considerando a capacidade própria de geração da máquina
 $tc=0,5$ $tm=0,03$



Tabela 15 – Sistema IEEE30 considerando a capacidade própria de geração
($t_c=0,6$ e $t_m = 0,009$)

Barra $i \in L$	Solução Real q_c (pu)	$tp = 30$	$tp = 50$	$tp = 80$	$tp = 100$	$tp = 140$	$tp = 200$
2	---	0,250	---	---	---	---	---
5	0,540	0,500	0,625	0,500	0,875	0,875	0,875
8	---	0,500	1,125	1,125	0,375	1,000	0,875
11	0,010	---	---	---	---	---	---
13	0,190	---	---	0,250	0,125	0,125	---
19	0,290	---	---	---	0,250	0,125	---
24	0,330	0,500	0,250	1,250	0,375	---	0,375
27	0,370	0,125	---	---	---	---	0,125
Total	1,730	1,875	2,000	3,075	2,000	2,125	2,250
Σ^*		0,280	0,050	0,030	0,070	0,000	0,000

* Soma das infactibilidades $\sum (\Delta y_{1_i} + \Delta y_{2_i})$

Tabela 16 – Sistema IEEE30 considerando a capacidade própria de geração
($t_c=0,7$ e $t_m = 0,006$)

Barra $i \in L$	Solução Real q_c (pu)	$tp = 30$	$tp = 50$	$tp = 80$	$tp = 100$	$tp = 140$	$tp = 200$
2	---	---	---	0,125	---	---	---
5	0,540	1,000	0,750	0,625	0,500	1,000	0,750
8	---	0,500	0,750	0,375	1,000	0,750	0,875
11	0,010	---	---	0,125	0,125	---	---
13	0,190	0,125	0,125	---	---	---	---
19	0,290	---	---	0,375	---	---	---
24	0,330	0,500	0,250	---	---	0,125	0,375
27	0,370	---	0,125	0,375	0,375	0,250	---
Total	1,730	2,125	1,950	2,000	2,000	2,125	2,000
Σ^*		0,000	0,000	0,000	0,000	0,000	0,000

* Soma das infactibilidades $\sum (\Delta y_{1_i} + \Delta y_{2_i})$




Gráfico 15: Considerando a capacidade própria de geração da máquina
 $t_c = 0,6$ $t_m = 0,009$




Gráfico 16: Considerando a capacidade própria de geração da máquina
 $t_c = 0,7$ $t_m = 0,006$

Tabela 17 – Sistema IEEE30 considerando a capacidade própria de geração
(tc=0,8 e tm = 0,003)

Barra $i \in L$	Solução Real qc (pu)	tp = 30	tp = 50	tp = 80	tp = 100	tp = 140	tp = 200
2	---	---	---	---	---	---	---
5	0,540	0,250	0,500	0,750	1,000	0,500	0,750
8	---	1,125	0,875	1,000	0,875	0,875	1,000
11	0,010	---	---	---	---	---	---
13	0,190	0,125	0,125	---	---	---	---
19	0,290	---	---	---	---	0,375	---
24	0,330	---	0,375	0,500	0,250	---	0,250
27	0,370	---	0,250	---	---	0,375	---
Total	1,730	1,500	2,125	2,250	2,125	2,125	2,000
Σ^*		0,420	0,000	0,040	0,000	0,020	0,000

* Soma das infactibilidades $\sum (\Delta y1_i + \Delta y2_i)$

Tabela 18 – Sistema IEEE30 considerando a capacidade própria de geração
(tc=0,9 e tm = 0,001)

Barra $i \in L$	Solução Real qc (pu)	tp = 30	tp = 50	tp = 80	tp = 100	tp = 140	tp = 200
2	---	---	0,125	---	---	---	---
5	0,540	0,750	0,375	0,875	1,125	---	1,000
8	---	0,625	0,875	0,500	0,625	0,250	1,000
11	0,010	---	---	---	--	0,125	---
13	0,190	0,250	---	0,125	---	---	---
19	0,290	---	---	0,250	---	---	---
24	0,330	0,500	---	0,375	0,375	0,375	---
27	0,370	0,000	0,375	---	---	0,375	---
Total	1,730	2,125	1,750	2,125	2,125	1,125	2,000
Σ^*		0,000	0,240	0,030	0,030	0,000	0,000

* Soma das infactibilidades $\sum (\Delta y1_i + \Delta y2_i)$




Gráfico 17: Considerando a capacidade própria de geração da máquina
 $tc=0,8$ $tm=0,003$




Gráfico 18: Considerando a capacidade própria de geração da máquina
 $tc=0,9$ $tm=0,001$

Tabela 19 – Sistema IEEE30 considerando a capacidade própria de geração
($t_c=0,4$ e $t_m = 0,001$)

Barra $i \in L$	Solução Real qc (pu)	tp = 30	tp = 50	tp = 80	tp = 100	tp = 140	tp = 200
2	---	---	---	---	---	0,125	---
5	0,540	0,625	1,125	1,125	1,000	0,750	1,000
8	---	0,500	0,500	---	0,750	0,750	0,625
11	0,010	---	---	--	--	---	---
13	0,190	---	---	---	---	---	---
19	0,290	---	---	0,375	---	0,250	---
24	0,330	---	0,250	---	---	---	0,375
27	0,370	---	0,250	0,500	0,250	0,125	---
Total	1,730	1,125	2,125	2,000	2,000	2,000	2,000
Σ^*		0,930	0,700	0,100	0,080	0,000	0,000

* Soma das infactibilidades $\sum (\Delta y_{1_i} + \Delta y_{2_i})$

Tabela 20 – Sistema IEEE30 considerando a capacidade própria de geração
($t_c=0,5$ e $t_m = 0,003$)

Barra $i \in L$	Solução Real qc (pu)	tp = 30	tp = 50	tp = 80	tp = 100	tp = 140	tp = 200
2	---	0,125	---	---	---	---	---
5	0,540	0,625	---	1,125	0,500	0,750	0,750
8	---	0,500	1,125	0,375	1,125	0,875	0,750
11	0,010	---	---	---	--	---	---
13	0,190	---	---	---	---	---	---
19	0,290	---	0,250	---	---	0,250	---
24	0,330	---	0,125	0,500	0,375	0,375	0,500
27	0,370	0,500	---	---	---	---	---
Total	1,730	1,745	1,500	2,000	2,000	2,250	2,000
Σ^*		0,300	0,430	0,050	0,000	0,060	0,030

* Soma das infactibilidades $\sum (\Delta y_{1_i} + \Delta y_{2_i})$




Gráfico 19: Considerando a capacidade própria de geração da máquina
 $tc=0,4$ $tm=0,001$




Gráfico 20: Considerando a capacidade própria de geração da máquina
 $t_c=0,5$ $t_m=0,003$

Tabela 21 – Sistema IEEE30 considerando a capacidade própria de geração
($t_c=0,6$ e $t_m = 0,006$)

Barra $i \in L$	Solução Real q_c (pu)	$tp = 30$	$tp = 50$	$tp = 80$	$tp = 100$	$tp = 140$	$tp = 200$
2	---	---	0,025	---	---	---	---
5	0,540	0,625	0,875	0,750	1,000	0,375	0,875
8	---	0,500	0,625	1,000	0,375	0,875	0,625
11	0,010	---	---	--	--	---	---
13	0,190	---	---	---	0,250	---	0,125
19	0,290	0,250	---	---	---	0,250	0,375
24	0,330	0,375	---	0,375	0,125	0,375	---
27	0,370	---	---	---	0,250	0,250	---
Total	1,730	1,750	1,750	2,125	2,000	2,125	1,625
Σ^*		0,270	0,360	0,000	0,000	0,050	0,000

* Soma das infactibilidades $\sum (\Delta y_{1_i} + \Delta y_{2_i})$

Tabela 22 – Sistema IEEE30 considerando a capacidade própria de geração
($t_c=0,7$ e $t_m = 0,009$)

Barra $i \in L$	Solução Real q_c (pu)	$tp = 30$	$tp = 50$	$tp = 80$	$tp = 100$	$tp = 140$	$tp = 200$
1	---	---	---	---	0,125	---	---
2	---	---	---	---	---	---	---
5	0,540	0,750	0,875	0,500	0,375	0,875	0,875
8	---	0,875	0,375	0,875	1,000	1,125	1,125
11	0,010	---	---	---	---	---	---
13	0,190	---	0,125	0,125	---	---	---
19	0,290	---	0,250	---	0,125	---	---
24	0,330	---	---	---	---	0,125	---
27	0,370	---	0,250	0,500	---	---	---
Total	1,730	1,625	1,875	2,000	1,620	2,125	2,000
Σ^*		0,350	0,100	0,000	0,390	0,000	0,000

* Soma das infactibilidades $\sum (\Delta y_{1_i} + \Delta y_{2_i})$




Gráfico 21: Considerando a capacidade própria de geração da máquina
 $t_c=0,6$ $t_m=0,006$




Gráfico 22: Considerando a capacidade própria de geração da máquina
 $tc=0,7$ $tm=0,009$

Tabela 23 – Sistema IEEE30 considerando a capacidade própria de geração
($t_c=0,8$ e $t_m = 0,03$)

Barra $i \in L$	Solução Real q_c (pu)	$tp = 30$	$tp = 50$	$tp = 80$	$tp = 100$	$tp = 140$	$tp = 200$
2	---	---	---	---	---	---	---
5	0,540	1,000	1,000	0,875	0,375	---	0,750
8	---	0,250	0,500	1,000	1,125	1,000	1,125
11	0,010	---	---	---	---	0,750	---
13	0,190	---	0,250	---	0,125	0,125	---
19	0,290	0,250	---	---	---	---	---
24	0,330	---	0,250	---	0,375	---	---
27	0,370	0,250	---	0,125	---	0,125	0,125
Total	1,730	1,750	2,000	2,000	2,000	2,000	2,000
Σ^*		0,210	0,040	0,000	0,050	0,000	0,000

* Soma das infactibilidades $\sum (\Delta y_{1_i} + \Delta y_{2_i})$

Tabela 24 – Sistema IEEE30 considerando a capacidade própria de geração
($t_c=0,9$ e $t_m = 0,006$)

Barra $i \in L$	Solução Real q_c (pu)	$tp = 30$	$tp = 50$	$tp = 80$	$tp = 100$	$tp = 140$	$tp = 200$
2	---	---	---	---	---	---	---
5	0,540	1,125	1,125	0,75	0,625	1,000	1,125
8	---	0,750	0,125	0,875	1,125	---	0,875
11	0,010	---	---	---	---	---	---
13	0,190	---	---	---	---	---	---
19	0,290	0,250	0,375	---	0,250	0,250	---
24	0,330	---	0,375	0,125	---	0,250	---
27	0,370	0,125	---	0,125	---	0,500	0,125
Total	1,730	2,250	2,000	3,620	2,000	2,000	2,125
Σ^*		0,000	0,110	0,080	0,000	0,050	0,060

* Soma das infactibilidades $\sum (\Delta y_{1_i} + \Delta y_{2_i})$




Gráfico 23: Considerando a capacidade própria de geração da máquina
 $tc=0,8$ $tm=0,03$




Gráfico 24: Considerando a capacidade própria de geração da máquina
 $tc=0,9$ $tm=0,06$

4.1.2 Comentários sobre os testes – Caso B

No caso **B**, onde são consideradas as capacidades próprias de reativos da máquina síncrona, verifica-se que, nos testes realizados e apresentados nas tabelas (13 – 24), 47,07% dos bons resultados referem-se às populações maiores ($tp=140$ e $tp=200$). Nas demais populações, os melhores resultados obtidos representaram respectivamente, $tp=100$ (20,59%), $tp=80$ (14,70%) , $tp=30$ e $tp=50$ (8,82%) cada.

As melhores soluções discretas obtidas, para os mais diversos tamanhos de população, foram referentes à tabela 16, $tc=0,7$ e $tm=0,006$, apresentando excelentes resultados para os seis tamanhos da população e representando 8,34% dos testes realizados.

Aqui, também como era de se esperar, as taxas de cruzamento e mutação, **tc** e **tm**, respectivamente, também influenciam diretamente na eficiência do algoritmo. Considerando as tabelas que apresentaram bons resultados para três tamanhos diferentes de população, 50% dos testes se efetivaram, ou seja, aqueles referentes as tabelas 14, 17, 18, 21, 22, 23, 24, cujas **tc** e **tm** podem ser observados na tabela 4.1.3: para dois tamanhos de populações, 33,37%, referentes às tabelas 13, 15, 19, 24 e para apenas um tamanho de população, apenas 8,33%, referente à tabela 20.

Para as maiores populações $tp=100$, $tp=140$ e $tp=200$, observa-se que 66,67% dos testes que apresentaram bons resultados corresponde a estes parâmetros.

Quanto aos gráficos, verifica-se que, como no caso anterior , as populações com 30 e 50 elementos apresentam maior disparidade. Não ocorrem aqueles elevados picos nos gráficos, como ocorreu no caso **A**.

Comparando os casos **A** e **B**, podemos constatar que, no total de 72 testes realizados para cada caso, 36,11%, no caso **A** e 45,83%, no caso **B**, apresentaram excelentes resultados. Essa diferença era esperada, considerando a capacidade própria de geração de reativos da máquina no caso **B**. Nos dois casos, **A** e **B**, os resultados foram



melhores nas populações maiores. Quanto à diversidade no tamanho de populações, o melhor resultado foi o obtido no caso **B**, tabela 16, com $t_c=0,7$ e $t_m=0,006$, coincidindo também com o da tabela 4 no caso **A**.

Um outro aspecto interessante é quanto ao custo de investimentos de reativos, pois em todos os testes realizados, no caso **B** a quantidade de reativos necessários é menor que no caso **A**, o que é obvio. Também a menor quantidade de reativos no caso **B** é no teste apresentada na tabela 18 ($t_c=0,9$ e $t_m=0,001$), $q_c=1,125$; e na tabela 21 ($t_c=0,6$ e $t_m=0,06$), $q_c=1,625$; nos demais testes, os valores oscilam entre 2,000, 2,125 e 2,250.



4.2- Sistema IEEE118

A rede IEEE118 [1] tem 118 barras, 168 linhas de transmissão e 9 transformadores com mudança automática de “taps”. As condições de testes adotadas foram:

- Magnitudes das tensões mantidas entre o intervalo [0,94 – 1,06] pu;
- Fontes reativas existentes no sistema foram consideradas;
- As taxas de cruzamento (**tc**) e mutação (**tm**) adotadas foram, respectivamente, de 0,8 e 0,005;
- O conjunto de barras candidatas à alocação de fontes reativas é formado pelas barras de tipo tensão controlada (PV) e a referência (Vθ). Em todas as barras do conjunto de candidatas permitiu-se alocação de equipamentos de compensação de reativos do tipo discreto.

A tabela 4.2.1 fornece os parâmetros dos transformadores com “taps” variáveis existentes;

Tabela 4.2.1 : Taps de Transformadores (IEEE 118)

TAP (Nº)	BARRAS		T_{min}	T_{max}
	K	L		
1	8	5	0.9	1.1
2	30	17	0.9	1.1
3	26	25	0.9	1.1
4	38	37	0.9	1.1
5	63	59	0.9	1.1
6	64	61	0.9	1.1
7	65	66	0.9	1.1
8	68	69	0.9	1.1
9	81	80	0.9	1.1

A tabela 4.2.2 apresenta o conjunto de barras candidatas e algumas condições de teste para o sistema IEEE118.

Os resultados obtidos com este teste encontram-se nas Tabelas 4.2.3, considerando-se a capacidade própria de geração de reativos da máquina síncrona e 4.2.4, desconsiderando-se essa capacidade.

Pode-se verificar, pelos resultados obtidos, que há um decrescimento na média da função aptidão pelo número de iterações, o que demonstra a eficiência do algoritmo. A solução do problema obtida através do algoritmo genético depende, além dos parâmetros de controle do algoritmo, da população inicial – semente, que é gerada aleatoriamente. Dessa forma, é importante, para um mesmo conjunto de parâmetros de controle do algoritmo, proceder-se a várias simulações e analisar a qualidade dos resultados obtidos, pois verificou-se que a população inicial tem influência direta na qualidade da solução. Quanto ao algoritmo utilizado, verifica-se que há a ocorrência de uma habilidade em tratar sistemas com diferentes necessidades reativas.

Tabela 4.2.2 – Conjunto de barras candidatas e algumas condições de teste para o sistema IEEE118.

Barra	$QG^{\min}(\text{pu})$	$QG^{\max}(\text{pu})$	$b^{\text{sh}}(\text{pu})$	$qc^{\max}(\text{pu})$
1	0,000	0,008	---	1,250
4	-0,100	0,300	---	1,250
5	---	---	-0,400	1,250
6	-0,005	0,030	---	1,250
8	-0,100	0,300	---	1,250
10	-0,100	0,300	---	1,250
12	-0,030	0,075	---	1,250
15	-0,005	0,023	---	1,250
17	---	---	---	1,250
18	-0,005	0,023	---	1,250
19	-0,005	0,015	---	1,250
20	---	---	---	1,250
21	---	---	---	1,250
22	---	---	---	1,250
24	-0,100	0,300	---	1,250
25	-0,100	0,300	---	1,250
26	-0,300	0,600	---	1,250
27	-0,100	0,300	---	1,250
30	---	---0	---	1,250
31	-0,100	0,300	---	1,250
32	-0,005	0,023	---	1,250
34	-0,005	0,023	0,140	1,250
36	-0,005	0,015	---	1,250
37*	---	---	-0,250	---
38	---	---	---	1,250
40	-0,100	0,300	---	1,250
42	-0,100	0,300	---	1,250
44*	---	---	0,100	---
45*	---	---	0,100	---
46	-0,100	0,300	0,100	1,250
48*	---	---	0,150	---
49	-0,100	0,300	---	1,250
54	-0,100	0,300	---	1,250
55	-0,005	0,011	---	1,250
56	-0,005	0,011	---	1,250
59	-0,100	0,300	---	1,250
61	-0,100	0,300	---	1,250
62	0,000	0,008	---	1,250
65	-0,100	0,300	---	1,250
66	-0,100	0,300	---	1,250

(*) Barras que possuem compensação reativa “shunt” mas não percentecem ao conjunto de candidatas *I*.

Tabela 4.2.2 - Continuação

Barra	$QG^{\min}(\text{pu})$	$QG^{\max}(\text{pu})$	$b^{\text{sh}}(\text{pu})$	$qc^{\max}(\text{pu})$
69	-1,000	1,000	---	1,250
70	0,000	0,008	---	1,250
71	---	---	---	1,250
72	-0,100	0,300	---	1,250
73	-0,100	0,300	---	1,250
74	0,000	0,004	0,120	1,250
76	0,000	0,008	---	1,250
77	-0,010	0,038	---	1,250
79*	---	---	0,200	1,250
80	-0,100	0,300	---	1,250
82*	---	---	0,200	---
83*	---	---	0,100	---
85	0,000	0,008	---	1,250
87	-0,100	0,300	---	1,250
89	-0,100	0,300	---	1,250
90	---	---	---	1,250
91	-0,100	0,300	---	1,250
92	0,000	0,008	---	1,250
99	-0,100	0,300	---	1,250
100	-0,100	0,300	---	1,250
103	-0,005	0,015	---	1,250
104	-0,005	0,015	---	1,250
105	-0,005	0,015	0,200	1,250
107	-0,100	0,030	0,060	1,250
110	0,000	0,001	0,060	1,250
111	-0,100	0,300	---	1,250
112	-0,100	0,300	---	1,250
113	-0,100	0,300	---	1,250
116	-0,250	0,525	---	1,250

(*) Barras que possuem compensação reativa “shunt” mas não pertencem ao conjunto de candidatas I.

Tabela 4.2.3 –Sistema IEEE118, com capacidade própria e $t_c = 0,8$ e $t_m = 0,005$.

Barra ($i \in I$)	Solução Real q_c (pu)	q_c (pu)							
		tp=220-a	tp=220-b	tp=220-c	p=280	tp=300	tp=380-a	tp=380-b	tp=380-c
01	---	---	---	0,250	0,125	---	---	---	---
08	---	---	---	---	---	---	0,125	---	---
12	---	---	---	0,250	---	---	---	---	---
15	---	0,125	0,250	---	---	---	---	---	---
17	---	---	0,125	---	---	---	---	---	---
18	---	---	---	---	---	---	---	0,375	---
21	---	---	0,250	0,125	---	---	---	---	---
24	---	---	---	---	---	---	0,250	0,500	---
27	---	0,250	---	---	---	---	---	---	---
30	---	---	0,250	---	0,375	---	---	---	0,250
32	---	---	---	---	---	0,375	---	---	---
34	---	---	---	---	0,250	---	---	---	---
36	---	---	---	0,250	0,625	0,375	0,250	---	---
38	---	---	---	0,375	---	---	---	---	0,750
42	---	---	---	---	---	0,250	---	---	---
46	---	0,750	---	---	---	---	---	---	---
49	---	---	0,750	---	---	---	1,000	1,125	0,875
54	0,540	0,375	---	---	0,375	1,125	---	---	---
55	---	---	---	0,875	1,000	---	---	---	0,250
56	---	---	0,250	0,875	---	---	---	---	0,625
59	---	---	0,750	---	---	---	0,500	1,125	---
61	---	---	0,250	---	---	---	---	---	---
65	---	---	---	---	---	---	0,250	---	---
66	---	0,625	---	---	---	---	---	---	---
69	---	---	---	---	---	---	---	0,625	---
71	---	---	---	0,125	---	---	0,125	---	---
72	---	---	---	---	---	---	---	0,250	---
73	---	---	---	---	---	0,125	---	---	---
74	---	0,750	0,125	---	---	---	---	---	---
76	0,410	0,500	0,250	---	0,500	0,875	---	0,875	0,750
77	0,250	---	---	0,125	0,375	0,125	1,000	---	---
80	---	0,875	0,125	0,875	---	---	---	0,500	---
85	0,070	---	0,750	---	---	---	---	---	---
87	---	---	0,125	---	---	---	---	---	---
89	---	---	---	---	1,125	0,375	---	---	0,125
90	---	---	0,250	---	---	0,375	0,250	---	---
91	---	---	---	---	---	---	---	0,250	0,375
92	1,020	0,375	---	---	---	---	---	---	---
100	---	---	---	0,250	0,125	0,125	---	---	---
105	---	---	---	---	---	---	0,250	---	---
107	---	---	---	---	---	0,250	---	---	---
116	---	---	---	0,250	---	---	---	---	---
Total (pu)	2,290	4,625	4,500	4,625	4,875	4,375	4,000	5,625	4,000

Tabela 4.2.4 –Sistema IEEE118, sem capacidade própria e $t_c = 0,8$ e $t_m = 0,005$.

Barra ($i \in I$)	Solução Real q_c (pu)	q_c (pu)						
		$tp=180^*$	$tp=220^{**}$	$tp=280$	$tp=300$	$tp=340$	$tp=380-a$	$tp=380-b$
01	---	---	---	0,375	---	---	---	---
04	---	---	---	0,125	---	---	---	---
06	---	---	---	---	---	0,250	---	---
12	---	---	0,375	---	---	---	0,250	0,250
15	---	---	0,500	0,375	---	0,250	---	---
17	---	0,250	---	---	---	---	---	---
20	---	---	---	0,375	---	---	---	---
21	---	---	---	---	0,375	---	---	---
22	0,560	0,250	---	---	---	---	0,500	0,875
24	0,230	0,125	---	0,625	---	0,250	---	---
25	---	0,375	0,125	---	0,625	0,125	---	---
26	---	---	---	---	---	0,375	0,125	---
27	---	0,375	---	---	---	---	---	---
32	---	---	---	---	---	---	0,250	---
34	---	0,625	---	0,250	---	0,750	---	0,625
36	0,330	---	---	---	0,625	---	---	0,250
38	---	---	0,125	---	---	---	1,000	---
40	1,270	---	0,625	1,125	0,750	---	0,875	1,125
42	0,200	---	---	0,250	---	---	0,375	---
46	0,200	0,750	---	0,125	0,500	---	0,375	---
49	3,260	0,875	---	0,625	---	---	---	0,500
54	---	0,75	0,250	0,250	0,375	0,750	1,000	0,375
55	---	---	0,875	---	0,875	0,750	0,375	---
56	---	---	0,625	0,750	---	1,000	---	0,875
59	---	0,375	---	0,500	---	0,125	0,500	---
61	---	0,625	---	1,000	---	---	---	0,875
62	---	---	0,500	0,125	1,125	---	0,875	1,000
65	---	---	---	---	0,375	---	---	---
66	---	0,875	---	0,750	0,875	0,500	0,250	---
69	---	0,750	0,500	0,375	0,250	1,000	0,875	0,750
70	---	0,250	---	0,125	---	0,250	---	---
71	---	---	---	---	0,250	---	---	---
72	---	---	---	---	---	---	0,125	---
73	---	---	0,250	---	---	---	---	---
74	---	---	0,250	---	0,500	0,250	---	---
76	0,240	0,875	1,125	0,875	---	0,750	1,000	0,625
77	---	---	---	1,000	1,125	0,250	0,875	0,375
80	---	0,875	0,750	---	0,625	---	0,250	0,875
85	1,160	1,125	1,000	---	0,250	---	0,625	1,000
87	---	---	---	---	---	0,125	---	---
89	---	---	0,500	0,500	---	0,750	---	0,125
90	0,030	0,625	---	0,125	---	---	0,750	0,250
92	0,300	---	---	0,750	---	0,375	---	0,375
100	1,750	0,375	1,000	---	1,125	0,500	0,750	---

* Não resolveu completamente o problema ($\sum y_{1_i} + y_{2_i} = 0,21 \text{ pu}$)

** Não resolveu completamente o problema ($\sum y_{1_i} + y_{2_i} = 0,53 \text{ pu}$)



Tabela 4.2.4 – Continuação

Barra ($i \in I$)	Solução Real qc (pu)	qc(pu)						
		tp=180*	tp=220**	tp=280	tp=300	tp=340	tp=380-a	tp=380-b
103	0,120	---	---	1,125	0,875	0,875	0,500	0,375
104	0,490	0,375	---	---	0,125	---	---	---
105	---	---	---	---	---	---	0,125	---
110	----	0,125	---	---	---	---	---	---
111	---	---	---	---	---	---	---	0,375
113	---	---	0,875	---	---	---	---	---
116	---	---	1,125	0,750	---	0,875	---	0,375
Total (pu)	10,140	11,625	11,375	14,000	11,625	11,125	12,625	12,625

* Não resolveu completamente o problema ($\sum y_{1i} + y_{2i} = 0,21 \text{ pu}$)

** Não resolveu completamente o problema ($\sum y_{1i} + y_{2i} = 0,53 \text{ pu}$)




Gráfico 1 : Considerando a capacidade própria de geração da máquina
 $t_c = 0,8$ $t_m = 0,005$




Gráfico 2: Desconsiderando a capacidade própria de geração da máquina
 $tc=0,8$ $tm=0,005$

4.2.1. Comentários sob os testes realizados no IEEE118

Nos resultados referentes aos testes realizados considerando-se a capacidade própria de geração de reativos da máquina síncrona, observa-se que os melhores resultados obtidos referem-se às populações maiores, ou seja, $tp=380$, onde a necessidade de reativos foi de 4,00 pu. Outra observação interessante de se fazer é que, olhando para os resultados de cada população, houve um decréscimo na quantidade de reativos a serem adquiridos. Assim, quando $tp=220$, a menor quantidade é 4,5 pu; quanto $tp=300$, essa quantidade é 4,375, e, quando $tp=380$, a quantidade decresce para 4,00. Isso demonstra a eficiência do algoritmo para populações maiores, onde há uma maior diversidade da população e, conseqüentemente, maiores chances para a efetivação dos operadores genéticos. É claro que os parâmetros devem ser ponderados, pois, aumentando o tamanho das populações, também se eleva o tempo computacional.

Nos testes realizados sem considerar a capacidade própria de geração de reativos da máquina síncrona, houve um aumento na quantidade de reativos a serem adquiridos, o que era esperado. Verifica-se também que, para as populações menores, $tp=180$ e $tp=220$. Neste caso, o problema não convergiu, e para as populações maiores, $tp=280$, $tp=340$ e $tp=380$, o melhor resultado obtido foi o de $tp=340$, onde se constata uma necessidade de reativos de 11,125, um aumento considerável com relação ao caso anterior.

Os gráficos mostram a média da função aptidão pelo número de iterações, referentes aos testes das tabelas 1 e 2, respectivamente, onde se observa a uniformidade das curvas à medida que o número de iterações aumenta. No início, o algoritmo é muito eficaz na redução da média da função aptidão, mas, à medida que os operadores genéticos e a seleção natural vão sendo aplicados, a taxa de decréscimo tende a cair, até ocorrer uma saturação na curva, não se conseguindo, a partir daí, nenhuma melhoria na qualidade de solução. O decréscimo da média da função aptidão pelo número de iterações depende do tamanho da população, do número de indivíduos da população e dos parâmetros de controle do algoritmo.

Conclusões

Apresentou-se neste trabalho um algoritmo para o planejamento de reativos em que se consideram a natureza discreta de algumas variáveis envolvidas na formulação do problema, visando obter para este soluções mais realísticas. Os estudos realizados com o Algoritmo Genético associado com Programação Linear Sucessiva na Solução do Planejamento de Reativos, na presente dissertação, levam, até então, às seguintes conclusões:

1. A concepção desta metodologia mista é adequada para a solução do problema, pois permite que as variáveis contínuas sejam tratadas pela Programação Linear - Fluxo de Carga, enquanto as variáveis discretas e de decisão sejam consideradas pelo Algoritmo Genético. Essa metodologia contorna as dificuldades de convergências da metodologia propostas por alguns autores que propõem o uso de algoritmo genético juntamente com a solução do problema de fluxo de carga tradicional;

2. Os resultados obtidos são promissores e pesquisas estão sendo realizadas com vistas a estender a metodologia para a simulação de sistemas reais, analisar-se mais criteriosamente a influência dos parâmetros de controle do algoritmo genético na qualidade da solução obtida e no desempenho computacional do algoritmo, bem como implementar melhorias no algoritmo proposto para considerar fontes reativas discretas de natureza capacitiva e indutiva. Ressalta-se que, nos testes realizados, foram consideradas todas as barras do sistema possuindo fontes reativas discretas, e, em um conjunto de testes, a

capacidade própria de geração de reativos em barras de tensão controlada foi considerada nula. Estas hipóteses são altamente restritivas para a solução do problema e limitam o desempenho de qualquer metodologia.

Nos testes envolvendo os sistema IEEE30 e IEEE118, pode-se constatar que:

1. O operador genético cruzamento tem uma grande influência no desempenho do algoritmo e no decréscimo da média da função aptidão no decorrer do processo, pois, de acordo com os resultados dos testes, quanto maior a taxa de cruzamento, **tc**, melhores os resultados obtidos, tanto quanto ao custo de investimentos de reativos quanto ao número de melhores resultados por testes, o que demonstra o quão é importante a adequação do valor desse parâmetro em função do sistema e das condições de testes que estão sendo adotadas.

2. Na mutação, apesar de ser uma operação considerada como secundária por alguns autores, verifica-se também a sua importância nos testes realizados. A combinação da mutação com a taxa de cruzamento e o tamanho da população é de importância primordial para a obtenção de melhores resultados.

3. Outro fator de importância suprema neste tipo de problema foi o número de elementos da população. Nos testes realizados, constatou-se que, com as populações maiores, obtém-se uma porcentagem maior de boas soluções discretas para o problema de planejamento de reativos com relação a todos os resultados, tanto no caso **A** como no caso **B**. Com isto, conclui-se que o número de elementos da população é um dos fatores primordiais na aplicação de Algoritmos Genéticos, pois aumenta a diversidade da população e, conseqüentemente, maiores, são as chances dos indivíduos mais capazes .

Como sugestões para futuros trabalhos, os aspectos que podem ser investigados na metodologia proposta referem-se a:

1. Considerar, na implementação do programa computacional, as barras com equipamentos de compensação de reativos discretos (bancos) e as barras com equipamentos de compensação de reativos contínuos (Compensadores Síncronos e/ou Estáticos). Esse procedimento provavelmente irá facilitar a solução do problema e, conseqüentemente, melhorar o desempenho da metodologia proposta;

2. Melhorar o programa de controle do algoritmo visando obter mais sensibilidade quanto ao esquema de geração proporcional, taxa de cruzamento, taxa de mutação, quando o algoritmo genético é aplicado da forma proposta neste trabalho para solução do problema reativo;

3. Estender a metodologia para alocação de fontes reativas indutivas de natureza discreta.

4. Implementar taxas de cruzamento e mutação variáveis durante o processo iterativo do Algoritmo Genético.

Referências Bibliográficas

- [1] Lebow, W.M. & Rouhani, R. & Nadira, R. & Usoro, P.B. & Mehra, R.K. & Sobieski, D.W. & Pal, M.K. & Bhavaraju, M.P. "Optimization of Reactive Volt-Ampere (Var) Sources in System Planning", Vol. 1: Solution Techniques, Computing Methods and Results, EL-3279, Vol.1, Final Report, November 1984.
- [2] Granville, S.E Pereira, M.V.F. & Monticelli, A.J. "An Integrated Methodology for VAR Sources Planning", IEEE Transactions on PAS, 3(2):549-557, May 1988.
- [3] Lin, W.E. & Papalexopoulos, A.D. & Tinney, W.F. "Discrete Shunt Controls in a Newton Optimal Power Flow", IEEE/PES Summer Meeting, Seattle, WA, 1992.
- [4] Granville, S. "Optimal Reactive Dispatch Trought Interior Methods", IEEE/PES Winter Meeting, Columbus, OH, January 31 - February 5, 1993.
- [5] Iba, K. "Reactive Power Optimization by Genetic Algorithm", IEEE Transactions on Power Siystems, Vol. 9, No. 2, May 1994, pp. 685-692.



- [6] Hong, Y. & Liu, C. "A Heuristic Algorithmic Approach to VAR Planning IEEE Transactions on Power Systems, Vol. 7, No. 2, May 1992, pp. 505-512.
- [7] Hsiao, Y. & Chiang, H. & Liu, C. & Chen, Y. "A Computer Package for Optimal Multi-Objective VAR Planning in Large Scale Power Systems", IEEE Transactions on Power Systems, Vol. 9, No.2, May 1994, pp. 668-676.
- [8] Mantovani, J.R.S. 'Planejamento de Reativos em Sistemas de Energia Elétrica; Solução Via Programação Linear Sucessiva Utilizando um Modelo Implicitamente Acoplado", Tese de Mestrado, FEEC - UNICAMP, 1987.
- [9] Monticelli, A.J. "Fluxo de Carga em Redes de Energia Elétrica", Editora Edgard Blücher, 1983.
- [10] Mantovani, J.R.S. "Um Modelo Heurístico para Solução do Problema de Planejamento de Reativos em Sistemas de Energia Elétrica", Tese de Doutorado, FEEC - UNICAMP, 1994.
- [11] Valença, M.M. "Um modelo de Decisão Baseado em Conjuntos Nebulosos Aplicados ao Planejamento de Operação de Sistemas de Energia Elétrica", Dissertação de Mestrado, UNICAMP, 1993.
- [12] Machado, A.P. "Avaliação Experimental do Algoritmo de Simulated Annealing Usando no Planejamento de Sistemas de Transmissão", Dissertação de mestrado, FEIS -UNESP, 1997.
- [13] M.S. Bazaraa ad C.M. Shetty: "Nonlinear Programmin - Theory and Algorithms", John Wiley & Sons, USA, 1979.
- [14] O I. Elgerd: "Introdução à Teoria de Sistemas de Energia Elétrica", McGraw-Hill, São Paulo, 1978.



- [15] Domell, H.W. & Tinney, W.F. "Optimal Power Flow Solutions" IEEE Transactions on PAS Vol. 87, No. 10: pp. 1866-1876, October, 1968.
- [16] Liu, C.W. & Hsiao, Y.J, "A Fast Global Optimization Approach to VAR Planning for the Large Scale Electric Power Systems"- IEEE/PES.
- [17] Costa, GRM - Langona, K & Alves, D.A. "O Método de Newton Modificado Associado à Função Lagrangeana Aumentada para a Resolução do Fluxo de Potência Ótima", ANAIS do XI Congresso Brasileiro de Automática, pp.173-178, São Paulo-SP.
- [18] Carvalho, R.S.O & Salgado, R. "Fluxo de Potência Ótimo Multi-Objetivo: Abordagem via Pontos Interiores", ANAIS II Congresso Chileno de Engenharia Elétrica, pp.76-81, Temuco, Chile, 1977.
- [19] Mantovani, J.R.S. & Garcia, A.V. "Planejamento de Fontes Reativas em Sistemas de Energia Elétrica Utilizando um Algoritmo de Busca Heurística", ANAIS X - Congresso Chileno de Engenharia Elétrica, pp. 22-26 Valdivia, Chile, 1993.
- [20] D.G. Luenberger "Linear and Nonlinear Programming - Addison - Wesley, USA, 1984.
- [21] Dornellas, C. R.R &, Falcão, D.M. Bombim, A. L.B, "Otimização do Despacho de Reativos Utilizando Algoritmos Genéticos", In: Congresso Brasileiro de Automática ,11°,Anais do XI congresso SBA, Vol. I, pp. 155-160, São Paulo, 2-6/set. 1996.
- [22] Srinivas, M, Patnaik, L. M., "Genetic Algorithms: A Survey", IEEE, Computer, Vol 24, No. 6, pp. 17-26, 1994.
- [23] Ribeiro Filho, J. L.& Treleven, P.C & Alippi, C. "Genetic - Algorithm Programming Environments", IEEE Computer, Vol.27, N° 6,June 1994, pp.28-43..



- [24] Gomes, J. R. & Saavedra, O. R. "Despacho de Potência Reativa Utilizando Evolução Simulada, In: Congresso Chileno de Engenharia Elétrica, 12º, Anales XII Congresso Chileno de Temuco – Chile, 1997, Vol.1, pág. 59-63.
- [25] Abdul-Rahman, K. H. & Shahidehpour, S. M. "Application of Fuzzy Sets to Optimal Reactive Power Planning with Security Constraints", IEEE Transactions on Power Systems, Vol. 9, No.2, May 1994, pp. 589-597.
- [26] Capentier, J. L. "A New Active Reactive Decoupling Process in Load Flows, Optimal Power Flow na System Control", Proc. IFAC Conference on Power Systems and Power Plan Controle, August 1986, pp.65-70.
- [27] Mantovani, J.R.S.& Garcia, A.V "A Heuristic Method for Reactive Power Planning"IEEE Transaction on Power Systems, 11(1): 68-74, February 1996.
- [28] Goldberg, D.E. Genetic Algorithm in Search Optimization and Machine Learning, Addison-Wesley, Reading, MA, 1989
- [29]Stott, B. & Alsac, ° "Experience with Successive Linear Programming for Optimal Rescheduling of Active Reactive Power", CIGRE/IFAC Symposium on Control Applications to Power System Security, Florença, 1983.
- [30] University of Washington Energy Group Power Systems Archive
- [31] C.C. Kuo, H.C. Chang: Applying a Refined Genetic Algorithm to Network Reconfiguration for Loss Reduction", IEE of Japan Power & Energy, pp37-42, 1994.
- [32] K.P. Wong, Y.W. Wong: "Combined Genetic Algorithms/Simulated Annealing/Fuzzy Set Approach to Short-Term Generation Scheduling with Take-or-Pay Fuel Contract"IEEE Transactions on Power Systems, Vol. 11, N.1, pp128-136, February 1996

- [33] L. L. Lai & J. T. Ma, Application of Evolutionary Programming to Reactive Power Planning Comparison with Nonlinear Programming Approach" IEEE Transactions on Power Systems, Vol.12, nº 1, February 1977.



Apêndice A

Lista de Figuras

- Figura 1 : Representação da Superfície Tridimensional Relativa a um problema que apresenta duas soluções ótimas locais e uma solução ótima global
- Figura 2 : Busca numa única direção de busca em várias direções
- Figura 3 : Classificação das Técnicas de buscas
- Figura 4 : O Ciclo do Algoritmo Genético
- Figura 5 : Cruzamento
- Figura 6 : Mutação
- Figura 7 : Representação Simbólica de uma barra “m” do Sistema de Energia Elétrica (a) sem compensação Reativa “shunt” e (b) com compensação Reativa “shunt”
- Figura 8 : Diagrama de blocos do algoritmo desenvolvido

**UNIVERSIDADE ESTADUAL PAULISTA - UNESP
FACULDADE DE ENGENHARIA DE ILHA SOLTEIRA
DEPARTAMENTO DE ENGENHARIA ELÉTRICA
PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA
AV. BRASIL, 56 - CAIXA POSTAL 31
15385-000 - ILHA SOLTEIRA - SP**

