



unesp **Universidade Estadual Paulista**

Faculdade de Engenharia do *Campus* de Ilha Solteira

Departamento de Engenharia Elétrica

Programa de Pós-Graduação em Engenharia Elétrica

Hélio Clementino dos Santos

Planejamento da Expansão de Sistemas de
Transmissão Considerando a Retirada de Linhas de
Transmissão

Dissertação de Mestrado

Ilha Solteira-SP
Dezembro/2007

Livros Grátis

<http://www.livrosgratis.com.br>

Milhares de livros grátis para download.

Hélio Clementino dos Santos

Planejamento da Expansão de Sistemas de
Transmissão Considerando a Retirada de Linhas de
Transmissão

Dissertação de Mestrado Submetida ao Programa de
Pós-Graduação em Engenharia Elétrica da Faculdade
de Engenharia de Ilha Solteira - UNESP

Orientador: Prof. Dr. Rubén Augusto Romero Lázaro

Ilha Solteira-SP
Dezembro/2007

FICHA CATALOGRÁFICA

Elaborada pela Seção Técnica de Aquisição e Tratamento da Informação
Serviço Técnico de Biblioteca e Documentação da UNESP - Ilha Solteira.

S237p Santos, Hélio Clementino dos
Planejamento da expansão de sistemas de transmissão considerando a retirada de linhas de transmissão / Hélio Clementino dos Santos. -- Ilha Solteira : [s.n.], 2007
108 f. : il.

Dissertação (mestrado) - Universidade Estadual Paulista. Faculdade de Engenharia de Ilha Solteira. Área de concentração: Automação, 2007

Orientador: Rubén Augusto Romero Lázaro
Bibliografia: p. 100-102

1. Sistemas de energia elétrica - Planejamento. 2. Energia elétrica - Transmissão.
3. Algoritmos genéticos.



UNIVERSIDADE ESTADUAL PAULISTA
"JÚLIO DE MESQUITA FILHO"
Campus de Ilha Solteira

CERTIFICADO DE APROVAÇÃO

TÍTULO: Planejamento da Expansão de Sistemas de Transmissão Considerando a Retirada de Linhas de Transmissão

AUTOR: HÉLIO CLEMENTINO DOS SANTOS

ORIENTADOR: Prof. Dr. RUBEN AUGUSTO ROMERO LÁZARO

DATA DA REALIZAÇÃO: 03 de dezembro de 2007

Aprovada com parte das exigências para obtenção do Título de MESTRE em ENGENHARIA ELÉTRICA pela Comissão Examinadora:

Dr. Ruben Augusto Romero Lázaro (Orientador)
Departamento de Engenharia Elétrica / Faculdade de Engenharia de Ilha Solteira

Dr. Sérgio Azevedo de Oliveira
Departamento de Engenharia Elétrica / Faculdade de Engenharia de Ilha Solteira

Dr. Antonio César Baleeiro Alves
Departamento de Engenharia Elétrica e de Computação / Universidade Federal de Goiás

Dedicatória

Dedico este trabalho:

À Jaci Pereira dos Santos, minha mãe,
por ser o alicerce dessa família.

Ao meu pai José Clementino dos Santos,
pelo suor derramado pelos filhos.

As minhas irmãs Marli, Tânia e Taísa,
pelo amor e amizade.

Ao meu filho João Vitor Cardoso
Clementino, meu renovador de energias.

À Gerônima, minha avó materna, a
mente mais brilhante que conheço.

À Valéria Faria Cardoso, pelos
ensinamentos de vida e científicos.

Aos amigos de sempre: Suzy Caetano,
Waldivino Gomes, Wagner A. Gomes,
Stone Marisco, Sérgio Marisco, Eloi
Biglia, Alexandre Senis, José Belcho e
Reginaldo Leandro.

In memoriam: João Pereira dos Santos,
Emerson Sousa Righetto e Luzia Faria
Cardoso, pelos seus exemplos de vida.

Agradecimentos

Desejo expressar meus sinceros agradecimentos:

- Ao mestre, Rubén Augusto Romero Lázaro um agradecimento muito especial por ter sido meu orientador e aceitado esse embate, pelo grande ser humano que é, pelo tempo e dedicação especialmente dedicados a este trabalho;
- Ao amigo Silvio Segura Salas, amizade construída com verdades, pelas horas de estudos, pelos ensinamentos, pelos momentos difíceis que passamos nessa jornada de estudos, trabalhos e de vida;
- Ao amigo Jáine Henrique Canossa, por vencermos juntos as batalhas da vida.
- Aos colegas do programa de pós-graduação do DEE/FEIS/UNESP;
- Aos professores do departamento de engenharia elétrica pela dedicação fervorosa ao ensino da ciência;
- Aos funcionários: Deoclécio, Beto e Cristina pelo profissionalismo;
- Ao Prof. Dr. Nery pelo apoio no início desse processo;
- Aos professores do departamento de computação da UNEMAT de Alto Araguaia-MT.

Epígrafe

Conquista é esforço contínuo!

Juizes 1,1

RESUMO

Neste trabalho é apresentada uma nova maneira de formular e resolver o problema de planejamento da expansão a longo prazo de sistemas de transmissão de energia elétrica. Tradicionalmente, o problema de planejamento da expansão de sistemas de transmissão consiste em encontrar o plano ótimo de expansão que permite que o sistema opere de forma adequada para a demanda futura de um horizonte especificado. Assim, deve-se indicar o número de linhas de transmissão que deve ser construída em cada caminho de expansão. Entretanto, existem linhas na topologia base que não ajudam no adequado funcionamento do sistema e que podem exigir a adição de novas linhas de transmissão produzindo investimentos inadequados. Esse comportamento atípico de um sistema de transmissão acontece devido à Lei de Tensões de Kirchhoff (LTK). Assim, aparecem laços em que uma linha que está no limite de sua capacidade de transmissão impede que outras linhas que se encontram no mesmo laço possam incrementar a transmissão através delas ficando subutilizadas. Sendo assim, a retirada da linha que está operando no limite pode melhorar a capacidade de transmissão do sistema. Este trabalho analisa esse problema e, portanto, apresenta a proposta de resolver o problema de planejamento de forma que seja possível adicionar linhas de transmissão com custos especificados e também que seja possível retirar linhas de transmissão da topologia base com custo zero. Dessa forma, linhas irrelevantes e que dificultam na operação do sistema elétrico e que se encontram na topologia base podem ser retiradas. O problema formulado dessa forma é resolvido usando um algoritmo genético especializado.

ABSTRACT

This work is a new way to formulate and solve the problem of planning for the long-term expansion of transmission systems of power. Traditionally, the problem of transmission expansion planning systems is to find the optimal plan for expansion that allows the operating system adequately to the demands of a future horizon specified. Thus, one should indicate the number of transmission lines that should be built in each path of expansion. Meanwhile, there are lines of the basic topology not help in the proper functioning of the system and may require the addition of new transmission lines producing inadequate investments. This atypical behavior of a system of transmission due to the Kirchhoff's Law for Voltages (LTK). Thus, ties appear in a line that is at the limit of their ability to prevent transmission to other lines that are in the same loop can increase the power flow through getting underutilized. Therefore, the withdrawal of the line that this limit can improve operating in the capacity of the transmission system. This work examines this issue and, therefore, presents a proposal to solve the problem of planning so that we can add lines with transmission costs and also specified that it is possible to draw lines of transmission of topology database with cost. Thus, lines irrelevant and hindering the operation of the electrical system and that are in the topology database can be withdrawn. The problem is formulated thus solved using a specialist genetic algorithm.

Lista de Figuras

Figura 3-1 - Duas linhas em paralelo.....	50
Figura 3-2 - Sistema de 3 barras - topologia base.....	51
Figura 3-3 - Sistema de 3 barras - topologia ótima tradicional.....	52
Figura 3-4 - Sistema de 3 barras - nova topologia ótima.....	53
Figura 3-5 - Sistema de 3 barras - nova topologia ótima.....	53
Figura 4-1 - Ilustração da recombinação.....	62
Figura 4-2 - Ilustração da Mutaç�o.....	63
Figura 4-3 - Codificaç�o do problema no AG Chu-Beasley,.....	66
Figura 4-4 - Recombinaç�o no AG Chu-Beasley.....	68
Figura 4-5 - Mutaç�o no AG Chu-Beasley.....	69
Figura 4-6 - Cumpre Crit�rio de Diversidade.....	79
Figura 4-7 - N�o cumpre o Crit�rio de Diversidade.....	79
Figura 4-8 - Diagrama de blocos do teste de substituiç�o.....	80
Figura 5-1 - Vetor de codificaç�o de uma proposta de investimento.....	82
Figura 5-2 - Vetor de codificaç�o da topologia base.....	83
Figura 5-3 - Sistema de 6 barras Garver - topologia inicial.....	83
Figura 5-4 - Vetor de codificaç�o de uma proposta t�pica no novo modelo.....	85
Figura 5-5 - Sistema de 6 barras Garver - soluç�o ótima tradicional.....	88
Figura 5-6 - Sistema de 6 barras Garver - soluç�o ótima modificada.....	90
Figura 5-7 - Sistema sul-brasileiro - topologia base.....	91
Figura 5-8 - Sistema sul-brasileiro: mostrando os novos caminhos.....	93
Figura 5-9 - Sistema sul-brasileiro: ótimo tradicional com redespacho.....	94
Figura 5-10 - Sistema Sul-Brasileiro - Planejamento Proposto.....	96
Figura A-1 - Sistema 46 barras sul-brasileiro.....	108
Figura A-2 - Sistema 6 barras - topologia base.....	110

Lista de Tabelas

Tabela 1 - Fen�meno da explos�o combinatorial.....	58
Tabela 2 - Sistema 46 barras - dados de linha.....	105
Tabela 3 - Sistema 46 barras - dados de barra (MW).....	107
Tabela 4 - Sistema 6 barras - dados de linha.....	109
Tabela 5 - Sistema 6 Barras - dados de barra (MW).....	109

CAPÍTULO 1 INTRODUÇÃO	13
CAPÍTULO 2 O PROBLEMA DE PLANEJAMENTO DE SISTEMAS DE TRANSMISSÃO	18
2.1. INTRODUÇÃO	18
2.2. MODELOS MATEMÁTICOS USADOS EM PLANEJAMENTO.....	20
2.2.1. <i>Modelo de Transportes</i>	20
<i>Modelo Matemático</i>	21
2.2.2. <i>Modelo Híbrido Não Linear</i>	22
<i>Modelo Matemático</i>	23
2.2.3. <i>Modelo Híbrido Linear</i>	25
<i>Modelo Matemático</i>	26
2.2.4. <i>Modelo DC</i>	27
<i>Modelo matemático</i>	28
<i>Modificações no Modelo Matemático</i>	29
2.3. TÉCNICAS DE SOLUÇÃO	30
2.3.1. <i>Técnicas Heurísticas</i>	30
2.3.2. <i>Técnicas Clássicas de Otimização</i>	33
2.3.3. <i>Metaheurísticas</i>	33
2.4. REVISÃO BIBLIOGRÁFICA DO PLANEJAMENTO DE SISTEMAS DE TRANSMISSÃO.....	33
CAPÍTULO 3 FORMULAÇÃO DO PROBLEMA PEST CONSIDERANDO A RETIRADA DE LINHAS	47
3.1. INTRODUÇÃO	47
3.2. MODELAGEM MATEMÁTICA.....	47
CAPÍTULO 4 METAHEURÍSTICA PARA RESOLVER O MODELO MODIFICADO DO PROBLEMA PEST	56
4.1. INTRODUÇÃO	56
4.2. ALGORITMO GENÉTICO TRADICIONAL	58
4.2.1. <i>Codificação do Problema</i>	59
4.2.2. <i>Função Objetivo e Infactibilidades</i>	59
4.2.3. <i>Operador de Seleção</i>	60
4.2.4. <i>Recombinação</i>	61
4.2.5. <i>Mutação</i>	63
4.2.6. <i>Parâmetros de Controle</i>	64
4.2.7. <i>Critério de Parada</i>	64
4.2.8. <i>Geração da População inicial</i>	65
4.3. ALGORITMO GENÉTICO DE CHU-BEASLEY	66
4.3.1. <i>Codificação do Problema</i>	66
4.3.2. <i>Função Objetivo e Infactibilidades</i>	67
4.3.3. <i>Substituição da população</i>	67
4.3.4. <i>Seleção</i>	68
4.3.5. <i>Recombinação</i>	68
4.3.6. <i>Mutação</i>	69
4.3.7. <i>Melhorando a Infactibilidade</i>	69
4.3.8. <i>Melhorando a Função Objetivo</i>	69
4.3.9. <i>O Algoritmo</i>	70
4.4. MELHORIAS NO ALGORITMO GENÉTICO DE CHU-BEASLEY	72
4.5. ALGORITMO GENÉTICO DE CHU-BEASLEY APLICADO AO PEST.....	73
CAPÍTULO 5 TESTES E RESULTADOS	81
5.1. INTRODUÇÃO	81
5.2. DETALHES DA IMPLEMENTAÇÃO COMPUTACIONAL	82
5.3. SISTEMA DE 6 BARRAS DE GARVER.....	87
5.4. SISTEMA SUL-BRASILEIRO DE 46 BARRAS.....	91
CAPÍTULO 6 CONCLUSÕES FINAIS	99
REFERÊNCIAS BIBLIOGRÁFICAS	102

APÊNDICE A	105
A.1	SISTEMA 46 BARRAS SUL-BRASILEIRO.....	105
A.2	SISTEMA 6 BARRAS GARVER	109

Capítulo 1

Introdução

O problema de planejamento a longo prazo da expansão de sistemas de transmissão de energia elétrica, que neste trabalho será chamado de “problema PEST” é um problema relevante na otimização de sistemas elétricos e de grande interesse para o mercado de energia elétrica.

Um sistema interligado de potência, responsável pela geração, transmissão e distribuição de energia elétrica, tem grande influência na economia de um país, por exigir um alto volume de recursos e por sua importância estratégica, busca-se centralizar decisões e esforços. O sistema completo é uma estrutura extremamente complexa, diversificada e distribuída. Para simplificar sua operação e planejamento, procura-se dividi-lo em partes relativamente independentes, a partir de características técnicas e funcionais, de regiões, de companhias operadoras, etc. Contudo, como o processo de decisão é relativamente centralizado, é vantajoso fazer um planejamento que leve em conta o inter-relacionamento entre estas partes.

Em geral, o problema de planejamento da expansão de sistema de energia elétrica tem sua origem na necessidade de suprir a crescente demanda de energia elétrica que ocorre com o passar dos anos. Conforme esta demanda aumenta, passa a existir a necessidade de construção de novas unidades geradoras, com o objetivo de satisfazer as novas necessidades de carga do sistema.

As decisões, dentro do processo de planejamento, estão relacionadas com a determinação das melhores unidades geradoras, das melhores rotas para a transmissão e da melhor malha para a distribuição desta energia, produzidas nas unidades geradoras. Todo este processo de decisão origina

um problema de otimização de grande porte que deve ser solucionado pelos planejadores de sistema de transmissão de energia elétrica.

Mais particularmente, em termos de características funcionais, o sistema elétrico de potência pode ser decomposto em:

- 1) Sistema de geração;
- 2) Sistema de transmissão; e,
- 3) Sistema de distribuição.

Este processo de divisão é uma simplificação e faz parte da metodologia de planejamento de sistemas complexos e de grande porte, onde a divisão é feita em relação aos seus principais agentes, ou seja:

- Planejamento do parque gerador;
- Planejamento de sistemas de transmissão; e ,
- Planejamento da rede de distribuição.

Cada uma dessas etapas de planejamento modela a rede para seus próprios propósitos.

A proposta desta pesquisa é o planejamento da expansão de sistemas de transmissão no horizonte de longo prazo com uma nova abordagem na formulação matemática do problema.

O objeto de estudo deste trabalho é o planejamento a longo prazo. Existem duas justificativas básicas para a sua importância dentro do sistema de transmissão. A primeira é de natureza prática: pode ser necessário um longo tempo para implantar uma ampliação neste sistema, por isso as decisões devem ser tomadas com uma antecedência adequada. A segunda razão é de natureza metodológica: para evitar decisões “míopes” (que ignoram os efeitos em longo prazo das decisões atuais) é necessário fazer o planejamento para um horizonte de tempo que, na prática, se aproxime de horizontes de tempo de grande duração.

Neste trabalho é levantada uma questão muito importante que ainda não foi analisada em detalhe pelos especialistas em planejamento e pela literatura especializada em planejamento da expansão de sistemas de transmissão.

Normalmente, o problema PEST consiste em determinar o plano ótimo de expansão do sistema elétrico que consiste em construir linhas de transmissão no sistema com o menor investimento, de forma que o sistema expandido opere adequadamente para uma demanda futura especificada.

Assim, são dados do sistema elétrico a topologia base (as linhas de transmissão existentes no ano base) com todos os parâmetros elétricos associados, os dados de geração e carga do horizonte de planejamento, os caminhos em que podem ser construídas linhas de transmissão, os tipos de linhas de transmissão que podem ser construídos (custo de uma linha e os parâmetros elétricos) e outras restrições operacionais e de investimento.

A resposta do problema representa o plano ótimo de expansão que indica o custo total de investimento de expansão em linhas de transmissão e as linhas que devem ser construídas (indicando o caminho, o tipo de linha a ser construída em cada caminho e o número de linhas a serem construídas).

O modelo matemático ainda considerado ideal para o problema PEST é o modelo DC. Esse modelo faz apenas o planejamento da demanda ativa e considera as duas Leis de Kirchhoff. Assim, o tipo de problema mais estudado é o problema PEST que usa o modelo DC para planejamento estático (apenas um horizonte de planejamento). Neste trabalho analisaremos esse tipo de modelo.

Nos trabalhos de planejamento de sistemas de transmissão considera-se que as linhas de transmissão existentes na topologia base formam parte do novo sistema expandido. Portanto, este sistema está formado pelas linhas de transmissão da topologia base e as linhas adicionadas no processo de otimização.

Nessa lógica, se considera que uma linha já construída ajuda no adequado funcionamento do sistema expandido. Pretendemos provar que essa premissa nem sempre é verdadeira.

Adicionalmente, mostraremos que algumas linhas de transmissão podem produzir desvios no processo de otimização do problema PEST. Sendo assim, a presença de algumas linhas de transmissão na topologia base pode produzir processos de expansão mais caros quando comparados com planos de expansão obtidos sem a presença dessas linhas na topologia base.

Em outras palavras, a presença de uma linha de transmissão na topologia base pode não ajudar no adequado funcionamento de um sistema elétrico e, pelo contrário, podem produzir comportamentos inesperados e indesejáveis.

Para identificar as linhas de transmissão que não ajudam no desempenho adequado de um sistema elétrico estamos propondo reformular o problema de planejamento da expansão de sistemas de transmissão.

Em relação ao planejamento tradicional, pretende-se encontrar um plano ótimo de expansão com a possibilidade de retirar linhas de transmissão existentes na topologia base.

Linhas existentes na topologia base podem ser retiradas com custo zero, evidentemente, considerando a expansão do sistema, já que custos de construção das linhas de transmissão e custos operacionais para remoção das mesmas não são considerados para esse caso particular. Nesse contexto, a forma de resolver esse tipo de problema deve ser analisada em detalhe. A dificuldade nessa nova formulação do problema PEST foi transferida para a técnica de solução.

Serão apresentados de forma resumida os motivos para o comportamento atípico de algumas linhas de transmissão em um sistema elétrico, isto é, os motivos pelo qual uma linha não ajuda no funcionamento adequado e, pelo contrário, dificulta na operação adequada do sistema elétrico.

A razão para esse tipo de comportamento é a Segunda Lei de Kirchhoff e a presença de laços elétricos com linhas de características muito diferentes. É muito comum a presença de uma malha elétrica (laço elétrico) formado por várias linhas de transmissão. A presença de uma linha de transmissão com pequena capacidade de transmissão chega muito rapidamente à sua capacidade máxima de transmissão.

Assim, outras linhas dessa malha elétrica podem estar operando com baixa capacidade de transmissão (por exemplo, a 30% de sua capacidade) obrigada pela necessidade de satisfazer a Lei de Tensões de Kirchhoff (LTK) na malha analisada.

Nesse contexto, a retirada da linha de pequena capacidade de transmissão pode permitir que uma linha que estava com pequeno carregamento aumente sua capacidade de transmissão (por exemplo, de 30% para 90%) e que esse incremento compense a retirada da linha e ainda permita operar o sistema elétrico de forma mais eficiente.

Existem alternativas para contornar o problema ocasionado por linhas de pequena capacidade de transmissão. Assim, por exemplo, pode-se adicionar um defasador ou um dispositivo FACTS para redirecionar o fluxo de potência ativa e permitir o funcionamento mais eficiente do sistema elétrico. Entretanto, analisamos apenas a possibilidade de retirar as linhas de transmissão que não ajuda para o funcionamento do sistema de transmissão e, esse trabalho é realizado como parte do processo de otimização.

Sugerimos resolver o novo tipo de problema PEST usando uma metaheurística que apresentou desempenho eficiente na otimização de outros problemas complexos de sistemas de energia elétrica. Essa metaheurística é um algoritmo genético especializado que foi desenvolvido usando como base uma proposta apresentada por Chu-Beasley para o problema GAP (Generalized Assignment Problem).

Capítulo 2

O Problema de Planejamento de Sistemas de Transmissão

2.1. Introdução

O objetivo do planejamento de sistemas de transmissão é determinar como ampliar a capacidade do sistema, satisfazendo a uma demanda especificada. Em planejamento de sistemas de transmissão de energia elétrica, são dados do problema: a topologia do ano base, os circuitos candidatos, os dados de geração e demanda do horizonte de planejamento, as restrições de investimento, entre outros. Desta maneira, a solução do problema deve especificar onde, quando e quantos devem ser instalados os novos equipamentos de expansão. Em planejamento estático, existe apenas um horizonte de planejamento. Uma generalização do planejamento estático é o planejamento dinâmico ou multiestágio, onde o horizonte de planejamento é separado em vários estágios.

A resolução do problema de planejamento dinâmico normalmente é muito mais complexa do que a resolução do problema de planejamento estático. Por isso, costuma-se empregar métodos de planejamento estático para auxiliar no problema de planejamento dinâmico. As formas de como as soluções do problema de planejamento estático são aproveitadas depende das dimensões do problema e da precisão desejada. Neste trabalho analisamos apenas o planejamento estático.

Levando em conta as observações anteriores, atualmente ainda considera-se o modelo matemático conhecido como fluxo de carga DC como sendo o ideal para ser usado no problema de planejamento de sistema de transmissão. Os principais motivos para esse consenso são os seguintes: 1) testes experimentais exaustivos mostraram que os resultados obtidos

usando o modelo DC apresentaram resultados muito próximos aos resultados obtidos usando o fluxo de carga AC, em relação a distribuição dos fluxos de potência ativa; e 2) existem várias técnicas de solução (algoritmos) que resolvem de maneira adequada os problemas de planejamento que usam o modelo DC.

Entretanto, nas três décadas de pesquisas realizadas em planejamento de sistemas de transmissão foram propostos vários modelos matemáticos para representar o problema de planejamento. Quatro destes modelos têm obtido destaque no campo das pesquisas: o modelo de transportes, o modelo híbrido, o modelo linear disjuntivo e o modelo DC.

Os problemas resolvidos pelos modelos matemáticos mencionados anteriormente, resultam em um problema de otimização matemática envolvendo relações algébricas lineares e/ou não lineares e com variáveis de decisão inteiras e contínuas, compondo um campo da pesquisa operacional conhecida como programação não linear inteira mista e a princípio, para resolver esses problemas, poderiam ser utilizadas as técnicas de solução de problemas de programação não linear inteira mista.

O modelo DC usa as duas Leis de Kirchhoff para realizar a modelagem matemática do problema de planejamento. O modelo disjuntivo (que considera as duas Leis de Kirchhoff eliminando as não linearidades do problema) é uma modelagem alternativa ao modelo DC em que a idéia fundamental é contornar o problema das não linearidades desta modelagem. Os modelos de transportes e híbrido são versões relaxadas (aproximadas) do modelo DC.

Deve-se observar que pesquisas recentes estão propondo usar o modelo AC já na fase de planejamento da expansão de sistemas de transmissão. Entretanto, esse tipo de proposta ainda não apresenta aceitação plena na comunidade científica. Para maiores detalhes desse tipo de proposta ver [27].

2.2. Modelos Matemáticos Usados em Planejamento

2.2.1. Modelo de Transportes

A proposta apresentada por Garver, é a primeira sistematização de modelagem matemática utilizada com muita ênfase no problema de planejamento de sistemas de transmissão, marca o início de uma sistemática de pesquisas, sugerindo modelagem diferenciada para os problemas de planejamento e de operação.

Garver sugere a utilização de modelos mais relaxados que possibilitem topologias ou configurações atrativas do crescimento do sistema elétrico, mesmo que sejam topologias aproximadas, e essa proposta fundamenta-se nos grandes problemas na utilização do modelo de fluxo de carga AC utilizado para operação como ferramenta de expansão.

Garver leva em consideração para a modelagem matemática, somente a Primeira Lei de Kirchhoff, desprezando a Segunda Lei de Kirchhoff. Evidentemente, a modelagem matemática de Garver, é uma representação menos adequada dos problemas reais e, portanto, a solução encontrada pelo modelo de transporte pode ser menos atrativa para os problemas reais.

Neste modelo objetiva-se encontrar uma configuração da rede que produza um menor investimento para o plano de expansão do sistema considerando também condições adequadas de operação do sistema elétrico, o que significa que, deve-se satisfazer a Primeira Lei de Kirchhoff, operando seus circuitos e usinas dentro de seus limites especificados.

A Primeira Lei de Kirchhoff estipula que o somatório dos fluxos de potência que entram numa barra do sistema deve ser igual ao somatório do fluxo de potência que saem dessa barra do sistema.

Modelo Matemático

A modelagem matemática do problema de planejamento de sistemas de transmissão utilizando o modelo de transportes assume a seguinte forma:

$$\begin{aligned} \text{Min } v &= \sum_{(i,j)} c_{ij} n_{ij} & (2.1) \\ \text{s.a.} & \\ S \quad f + g &= d \\ |f_{ij}| &\leq (n_{ij} + n_{ij}^0) \bar{f}_{ij} \\ 0 \leq g &\leq \bar{g} \\ 0 \leq n_{ij} &\leq \bar{n}_{ij} \\ n_{ij} &\text{ inteiro} \\ f_{ij} &\text{ irrestrito} \end{aligned}$$

Sendo que:

v	Investimento devido as adições de circuitos ao sistema
c_{ij}	Custo do circuito no caminho $i - j$
n_{ij}	Número de circuitos adicionados no caminho $i - j$
S	Matriz de incidência nó-ramo do sistema elétrico
f	Vetor de fluxos, representam o fluxo total do caminho $i - j$
g	Vetor de geração, representam o nível de geração na barra i
d	Vetor de demanda, representam a demanda na barra de carga i
n_{ij}^0	Representa o número de circuitos na configuração base no caminho $i - j$
\bar{f}_{ij}	Fluxo máximo permitido para um circuito no caminho $i - j$
\bar{g}	Vetor de capacidade máxima de geração nas barras de geração
\bar{n}_{ij}	Vetor do número máximo de adições permitidas no caminho $i - j$

O modelo matemático apresentado em (2.1) é um pouco diferente do originalmente idealizado por Garver, onde as variáveis de decisão são diferentes as apresentadas em (2.1). Conceitualmente, as duas modelagens são equivalentes.

Nesse modelo, a Primeira Lei de Kirchhoff é representada pelo conjunto de restrições $Sf + g = d$ uma equação para cada barra do sistema, as restrições $|f_{ij}| \leq (n_{ij} + n_{ij}^0) \bar{f}_{ij}$ representam as limitações da capacidade de transmissão dos circuitos e o valor absoluto se faz necessário pois os fluxos de potência podem fluir nos dois sentidos. As restrições restantes são as que representam o limite de geração e os circuitos adicionados em cada caminho candidato $i-j$. As variáveis f_{ij} são irrestritas em valor e as variáveis n_{ij} devem ser inteiras representando a maior fonte de complexidade no problema.

O modelo de transportes é um problema de programação linear inteiro misto, impondo assim um grau de complexidade para a resolução de problemas reais de sistemas elétricos de grande porte. Seu grande diferencial é que praticamente não existe diferença na resolução de problemas de sistemas conexos ou na resolução de problemas de sistemas altamente ilhados.

Por outro lado, a solução apresentada pelo modelo de transporte pode estar bem distante da solução apresentada pelo modelo DC, tida como ideal para a solução desse tipo de problema, por considerar nas restrições de operação a Segunda Lei de Kirchhoff.

2.2.2. Modelo Híbrido Não Linear

A proposta do modelo híbrido num modo geral visa atender as duas Leis de Kirchhoff para cada parcela das linhas de transmissão. Na sua concepção mais pura, a modelagem matemática para o modelo híbrido diz o seguinte: para a parcela dos circuitos existentes na configuração base do sistema elétrico, satisfazer as duas Leis de Kirchhoff; e para a parcela do sistema elétrico correspondentes aos novos caminhos que não possuam circuitos na configuração base, satisfazer unicamente a Primeira Lei de Kirchhoff.

Podemos considerar então que o modelo híbrido é um misto dos modelos DC e de transportes. Resumindo, a Primeira Lei de Kirchhoff deve

satisfazer todas as barras do sistema elétrico e a Segunda Lei de Kirchhoff somente naqueles laços que já existam na configuração base.

A idéia de utilizar o modelo híbrido é para contornar alguns problemas que apresentam o modelo de transportes e o modelo DC. No modelo de transportes, temos uma excelente flexibilidade para trabalhar com redes não-conexas, mas os resultados podem ficar muito distantes da solução ótima do modelo DC, que pode apresentar alguns problemas com redes não-conexas.

Assim, o modelo híbrido permite encontrar soluções mais próximas da solução ótima do modelo DC e com vantagem de trabalhar eficientemente na parcela correspondente às partes não-conexas do sistema. Entretanto, a complexidade do modelo híbrido é equivalente a do modelo DC, isto explica a falta de pesquisas usando o modelo híbrido de modo independente.

Modelo Matemático

A modelagem matemática do modelo híbrido apresenta a seguinte forma:

$$\begin{aligned} \text{Min } v &= \sum_{(i,j)} c_{ij} n_{ij} && (2.2) \\ \text{s.a.} &&& \\ S \quad f + g &= d && \\ f_{ij} - g_{ij} (n_{ij}^0 + n_{ij}) (q_i - q_j) &= 0 && \forall (i,j) \in \Omega_1 \quad (2.2 \text{ a}) \\ |f_{ij}| &\leq (n_{ij} + n_{ij}^0) \bar{f}_{ij} && \forall (i,j) \in \Omega \\ 0 &\leq g \leq \bar{g} && \\ 0 &\leq n_{ij} \leq \bar{n}_{ij} && \\ n_{ij} &\text{ inteiro} && \\ f_{ij} &\text{ irrestrito} && \\ q_j &\text{ irrestrito} && \forall j \in \Omega_3 \end{aligned}$$

Sendo que:

- g_{ij} Susceptância de uma linha no caminho $i - j$;
- Ω_1 Representa o conjunto de circuitos existentes na configuração base;
- Ω Representa o conjunto de circuitos candidatos a adição;

- Ω_3 Representa o conjunto de barras que fazem parte da configuração base, isto é, as barras que não estão ilhadas;
- q_j Magnitude do ângulo de tensão das barras existentes na configuração base.

No modelo matemático apresentado em (2.2), $Sf + g = d$ representa as equações equivalentes à Primeira Lei de Kirchhoff, sendo uma equação para cada barra do sistema e o conjunto de equações $f_{ij} - g_{ij}(n_{ij}^o + n_{ij})(q_i - q_j) = 0$ representa as equações correspondentes a Segunda Lei de Kirchhoff, sendo uma equação para cada caminho que apresenta pelo menos um circuito na configuração base. Esta equação (2.2 a) representa a diferença entre os três modelos matemáticos que estão sendo apresentados.

No modelo de transportes ela (2.2 a) não aparece; no modelo híbrido aparecem somente uma parcela dessas equações constituídas pelos caminhos em que existem circuitos na configuração base e no modelo DC aparecem todas as equações deste tipo, uma para cada caminho existente e/ou novos caminhos candidatos à adição de circuitos.

Após algumas manipulações algébricas pode-se chegar a uma formulação equivalente que assume a seguinte forma:

$$\begin{aligned} \text{Min } v &= \sum_{(i,j)} c_{ij} n_{ij} && (2.3) \\ \text{s.a.} &&& \\ S_2 f_2 + B_1 q_1 + g &= d && \\ |q_i - q_j| &\leq \bar{f}_{ij} && \forall (i,j) \in \Omega_1 \\ |f_{ij}| &\leq \bar{f}_{ij} n_{ij} && \forall (i,j) \in \Omega_2 \\ 0 &\leq g \leq \bar{g} && \\ 0 &\leq n_{ij} \leq \bar{n}_{ij} && \\ n_{ij} && \text{inteiro} && \\ f_{ij} && \text{irrestrito} && \forall (i,j) \in \Omega_2 \\ q_j && \text{irrestrito} && \forall j \in \Omega_3 \end{aligned}$$

Sendo que:

- Ω_2 Representa o conjunto de circuitos correspondentes aos novos caminhos;
- S_2 Matriz de incidência nó-ramo da parcela dos circuitos que não tem circuitos na configuração base ($\in \Omega_2$);
- f_2 Vetor de fluxos que pertencem a Ω_2 ;
- Matriz de susceptâncias da parcela dos circuitos adicionados a configuração base ($\in \Omega_1$);
- B_1 base ($\in \Omega_1$);
- Vetor de ângulos $q_1 \in \Omega_3$, barras conectadas na configuração base.
- q_1 Também: $\bar{f}_{ij} = \frac{\bar{f}_{ij}}{g_{ij}}$

Considerando as seguintes dimensões.

- S_2 Dimensão $n_b \times n_c$ (número de barras x número de novos caminhos), os circuitos de S_2 que correspondem aos novos caminhos, possuem seus elementos iguais a zero;
- f_2 Dimensão n_c ;
- B_1 Dimensão $n_b \times n_b$, em que, as linhas e colunas de B_1 que correspondem as barras ilhadas, possuem os seus elementos iguais a zero;
- q_1 Vetor de n_b , em que posições correspondentes às barras ilhadas tem valores iguais a zero.

2.2.3. Modelo Híbrido Linear

Neste modelo, todas as novas adições de circuitos devem cumprir somente a Primeira Lei de Kirchhoff, isto é, os circuitos adicionados em caminhos onde já existem circuitos e, onde não existem, devem satisfazer somente a Primeira Lei de Kirchhoff.

Modelo Matemático

A modelagem matemática para o modelo híbrido linear assume a seguinte forma:

$$\begin{aligned} \text{Min } v &= \sum_{(i,j)} c_{ij} n_{ij} && (2.4) \\ \text{s.a.} &&& \\ S f' + S_o f_o + g &= d && \\ f_{ij}^o - g_{ij} n_{ij}^o (q_i - q_j) &= 0 && \forall (i,j) \in \Omega_1 \\ |f_{ij}^o| \leq \bar{f}_{ij} n_{ij}^o &&& \forall (i,j) \in \Omega_1 \\ |f_{ij}'| \leq \bar{f}_{ij} n_{ij} &&& \forall (i,j) \in \Omega \\ 0 \leq g \leq \bar{g} &&& \\ 0 \leq n_{ij} \leq \bar{n}_{ij} &&& \forall (i,j) \in \Omega_T \\ n_{ij} &&& \text{inteiro} \\ f_{ij} &&& \text{irrestrito} \\ q_j &&& \text{irrestrito} \quad \forall j \in \Omega_3 \end{aligned}$$

Sendo que:

- S_o Matriz de incidência nó-ramo do sistema existente na configuração base;
- f_o Vetor de fluxos nos circuitos existentes na configuração base;
- S Matriz de incidência nó-ramo do sistema completo;
- f' Vetor de fluxos nos circuitos adicionados;
- q_j Vetor de ângulos de fase das barras conectadas a configuração base.

Após algumas manipulações algébricas é possível encontrar a seguinte formulação:

$$\begin{aligned} \text{Min } v &= \sum_{(i,j)} c_{ij} n_{ij} && (2.5) \\ \text{s.a.} &&& \\ S \quad f' + B_o q_o + g &= d && \\ |q_i - q| &\leq \bar{f}_{ij} && \forall (i,j) \in \Omega_1 \\ |f'_{ij}| &\leq \bar{f}_{ij} n_{ij} && \forall (i,j) \in \Omega \\ 0 \leq g &\leq \bar{g} && \\ 0 \leq n_{ij} &\leq \bar{n}_{ij} && \forall (i,j) \in \Omega_T \\ n_{ij} &&& \text{inteiro} \\ f_{ij} &&& \text{irrestrito} \\ q_j &&& \text{irrestrito} \quad \forall j \in \Omega_3 \end{aligned}$$

Sendo que:

B_o Matriz de susceptâncias formada pelos circuitos existentes na configuração base

2.2.4. Modelo DC

Este modelo é tido como ideal para desenvolvimento de trabalhos de planejamento de sistemas de transmissão. O modelo DC é uma generalização do modelo de fluxo de carga DC.

Nesse modelo a primeira e a Segunda Lei de Kirchhoff são consideradas. Isto significa que todas as barras do sistema elétrico têm que satisfazer a Primeira Lei de Kirchhoff e todos os laços devem satisfazer a Segunda Lei de Kirchhoff. As topologias encontradas com o modelo DC apresentam bom desempenho quando avaliadas com modelos tradicionais de operação de sistemas de energia elétrica, como o modelo de fluxo de carga AC.

Modelo matemático

$$\text{Min } v = \sum_{(i,j)} c_{ij} n_{ij} \quad (2.6)$$

s.a.

$$S f + g = d$$

$$f_{ij} - g_{ij} (n_{ij}^0 + n_{ij}) (q_i - q_j) = 0$$

$$| f_{ij} | \leq (n_{ij}^0 + n_{ij}) \bar{f}_{ij}$$

$$0 \leq g \leq \bar{g}$$

$$0 \leq n_{ij} \leq \bar{n}_{ij}$$

$$n_{ij}$$

inteiro

$$f_{ij}$$

irrestrito

$$q_j$$

irrestrito

Efetuada algumas manipulações algébricas, pode-se obter a seguinte formulação:

$$\text{Min } v = \sum_{(i,j)} c_{ij} n_{ij} \quad (2.7)$$

s.a.

$$Bq + g = d$$

$$(n_{ij} + n_{ij}^0) |q_i - q_j| \leq (n_{ij} + n_{ij}^0) \bar{f}_{ij}$$

$$0 \leq g \leq \bar{g}$$

$$0 \leq n_{ij} \leq \bar{n}_{ij}$$

$$n_{ij}$$

inteiro

$$q_j$$

irrestrito

Sendo que:

B Matriz susceptâncias da rede inicial e dos ramos candidatos;

q Vetor dos ângulos de tensão das barras do sistema elétrico.

A matriz de susceptâncias B é definida da seguinte forma:

$$B \Rightarrow \begin{cases} B_{ij} = g_{ij} (n_{ij}^0 + n_{ij}) \\ B_{ii} = - \sum_{j \in \Omega_i} g_{ij} (n_{ij}^0 + n_{ij}) \end{cases}$$

Modificações no Modelo Matemático

Na resolução de algumas técnicas pode ser mais adequado efetuar algumas modificações com o objetivo de tornar o problema modificado mais fácil de resolver usando determinados tipos de algoritmos.

A modificação mais utilizada é a inserção de geradores artificiais em todas as barras de cargas do sistema, na prática, a adição desses geradores artificiais constituem simplesmente na adição de novas variáveis ou incógnitas ao problema, ocorrendo uma alteração do problema original, obviamente tanto a solução do problema original, quanto a resolução do problema modificado deverão ser equivalentes e na solução final do problema modificado todas as variáveis artificiais inseridas no problema deverão ser iguais a zero, ou seja, os geradores artificiais deverão na solução final do problema equivaler a zero.

Segue a modelagem matemática do problema modificado:

$$\text{Min } v = \sum_{(i,j)} c_{ij} n_{ij} + a \sum_{k \in \Gamma} r_k \quad (2.8)$$

s.a.

$$\begin{aligned} S \quad & f + g + r = d \\ & f_{ij} - g_{ij} (n_{ij}^0 + n_{ij}) (q_i - q_j) = 0 \\ & |f_{ij}| \leq (n_{ij}^0 + n_{ij}) \bar{f}_{ij} \\ & 0 \leq r \leq d \\ & 0 \leq g \leq \bar{g} \\ & 0 \leq n_{ij} \leq \bar{n}_{ij} \\ & n_{ij} \quad \text{inteiro} \\ & f_{ij} \quad \text{irrestrito} \\ & q_j \quad \text{irrestrito} \end{aligned}$$

Sendo que:

- Γ Conjunto de todas as barras k em que existe demanda;
- r_k Geração artificial na barra k ;
- a Parâmetro de penalidade suficientemente grande para tornar pouco atrativas alternativas de investimentos com valores de r_k diferentes de zero.

É importante dizer que o problema modificado sempre apresenta uma solução factível trivial, não necessariamente ótima, fazendo $r_k = d_k$ e todas as outras variáveis iguais à zero; matematicamente falando, o problema ficará de maior tamanho mais se torna um problema que pode ser de mais fácil resolução.

2.3. Técnicas de Solução

2.3.1. Técnicas Heurísticas

Os métodos de solução que utilizam estas técnicas fazem o plano de expansão através de um processo passo a passo, em que, para uma dada configuração denominada configuração base ou inicial, os equipamentos que aumentam a capacidade do sistema, conforme o aumento da demanda, são adicionados um a um, ou em pequenos grupos. Assim, a configuração do sistema é modificada pela adição de um ou vários circuitos e, a configuração, então obtida, é denominada configuração corrente.

Estes métodos, geralmente fazem uma análise da sensibilidade de uma função que avalia o desempenho do sistema e custo da ampliação, em relação a adição de um equipamento específico, para escolher as “melhores” adições. Assim, em cada passo, um circuito é selecionado por um indicador de sensibilidade próprio de cada algoritmo heurístico.

Desta forma, o circuito escolhido, em cada passo, para ser adicionado à chamada configuração corrente será um circuito que corresponderá ao caminho mais atrativo identificado pela análise de sensibilidade ou indicador de sensibilidade ou ainda, índice de desempenho.

O indicador de sensibilidade, conforme já dito, é basicamente um parâmetro que de alguma maneira está relacionado com a variação da função objetivo para alguma variação dos parâmetros do sistema, considerando, como sistema, a configuração corrente. Assim, um indicador de sensibilidade possui as seguintes características:

- Identifica os caminhos mais atrativos para realizar adição de circuitos;
- É um indicador de caráter local, isto é, identifica a melhor estratégia para a configuração corrente, ao contrário de um indicador de caráter global que identificaria a melhor estratégia para a determinação da melhor configuração do sistema;
- Como os indicadores locais nem sempre coincidem com os indicadores globais, os algoritmos heurísticos construtivos, freqüentemente, não têm a capacidade de encontrar as configurações ótimas globais de sistemas reais.

A diferença fundamental de cada algoritmo heurístico está no indicador de sensibilidade usado para se determinar a solução do problema.

Os métodos com técnicas heurísticas simulam um procedimento manual clássico, definido a seguir:

Passo 1: Analisar a capacidade do sistema de atender a demanda em um novo período de planejamento;

Passo 2: Se existe alguma inadequação (sobrecargas ou cortes de carga), selecionar a adição de novos equipamentos baseado em algum critério técnico / econômico, voltar para o passo 1;

Passo 3: Se o sistema é considerado adequado, verificar se alguns dos equipamentos adicionados podem ser retirados mantendo a sua adequação;

Passo 4: Se nenhum elemento pode ser retirado, passar para o próximo período e voltar para o passo 1. O algoritmo termina quando todos os períodos de planejamento já foram estudados.

A desvantagem imediata deste tipo de método é que este procedimento não garante a otimalidade de uma solução. Os métodos que adotam técnicas heurísticas não conseguem sequer avaliar a qualidade das

soluções que encontram. Entretanto, este problema aparece em todas as técnicas de otimização de problemas complexos e multimodais.

Com relação à análise de sensibilidade, por mais sofisticados que sejam os critérios de adições de equipamentos e mesmo que testes mostrem soluções satisfatórias, na maioria das vezes, a falta de uma estrutura consistente no método de solução compromete bastante a confiabilidade nas soluções. Em termos técnicos, isto significa que é difícil determinar o domínio de aplicação das regras heurísticas.

A grande vantagem deste tipo de método de solução é a simplicidade de implementação. Em alguns casos, pode-se dizer que o método é uma tentativa do planejador de transformar seu conhecimento e desejo em um programa, adicionando alguma ferramenta matemática e contando com a lógica humana para a verificação da validade dos resultados.

Resumindo, do ponto de vista teórico, um algoritmo heurístico construtivo, nem sempre encontra a configuração ótima da expansão de um sistema elétrico. Na prática, estes algoritmos heurísticos encontram as configurações ótimas de sistemas pequenos e apenas configurações boas para sistemas elétricos de médio e grande porte. Entretanto, estes algoritmos são muito importantes pelos seguintes motivos:

- Na primeira fase de pesquisas (décadas de 60 e 70), esta era a única ferramenta que existia para solucionar os problemas de planejamento de sistemas elétricos de grande porte;
 - A maioria desses algoritmos são robustos e, simples de entender, programar e usar;
 - Os esforços computacionais destes algoritmos são muito pequenos;
 - Muitas características e propriedades destes algoritmos podem ser usadas no desenvolvimento de algoritmos mais complexos como as metaheurísticas (*simulated annealing*, algoritmo genético, busca tabu, GRASP, etc);
-

- Ainda hoje, esses algoritmos são os mais usados pelas empresas elétricas;
- Servem como algoritmos inicializadores das metaheurísticas.

2.3.2. Técnicas Clássicas de Otimização

Os métodos de otimização clássica, geralmente usando técnicas de decomposição matemática, apresentam a capacidade de encontrar a solução ótima do problema de planejamento e são muito eficientes em sistemas de pequeno e médio porte, mas, para sistemas de grande porte ainda apresentam problemas de esforço computacional e de convergência. Este tipo de técnica de solução não é usado neste trabalho e, portanto, não analisamos em detalhe este tipo de forma de otimização.

2.3.3. Metaheurísticas

As metaheurísticas são métodos de busca eficientes através do espaço de busca que devem ser caracterizadas de forma adequada, não necessariamente deve coincidir com a região factível do problema original de otimização. Estes métodos têm-se mostrado muito eficientes na solução de problemas complexos e de grande porte tais como o problema de planejamento da expansão de sistemas de transmissão. Exemplos de metaheurísticas são os métodos de *Simulated Annealing*, Algoritmos Genéticos, GRASP, entre outros. Existe uma bibliografia muito diversificada sobre a aplicação de metaheurísticas na otimização de problemas complexos no campo da pesquisa operacional e, particularmente, na otimização de sistemas de energia elétrica [13, 21, 22, 25].

Nesse trabalho usamos uma metaheurística para resolver o problema PEST, isto é, um algoritmo genético especializado. Esse tipo de algoritmo é analisado separadamente em outro capítulo.

2.4. Revisão Bibliográfica do Planejamento de Sistemas de Transmissão

Nesta seção é feita a análise de algumas propostas para a solução do problema de planejamento estático a longo prazo de sistemas de energia elétrica, indicando as suas características mais interessantes.

Em [7, 11, 21] são apresentados algoritmos com técnica de solução baseada em Busca Tabu (TS) e com o modelo DC adotado, como modelagem matemática.

Em [21] o algoritmo envolve três fases distintas: durante a primeira fase, o algoritmo TS é introduzido basicamente como um algoritmo de busca com uma memória de curto prazo, uma lista-tabu e um critério de aspiração que permite determinar dentre os movimentos permitidos, aquele mais atrativo; na segunda fase é incluído um mecanismo de diversificação, um de intensificação e um de memória a longo prazo; e finalmente, na terceira fase, são incluídos "Path Relinking", configurações elite, seleção inteligente de configuração inicial, oscilação estratégica, redução de vizinhos e versões híbridas adicionando características de outras metaheurísticas tais como: Algoritmos Genéticos e Simulated Annealing (SA).

É proposto também não apenas uma configuração inicial, mas sim uma família de configurações concorrentes mantidas durante todo o processo de otimização. Esta família de configurações é obtida ou através do Algoritmo de Garver modificado que, apesar de utilizar como modelagem matemática um modelo relaxado (modelo de transportes), possui a capacidade de localizar com precisão a maioria dos eixos de transmissão para a expansão da rede, ou randomicamente (através de uma função randômica).

Em [7], o algoritmo descrito foi dividido nas seguintes etapas: Etapa 1: nesta etapa, é obtido uma configuração inicial determinada por um conjunto de indicadores de sensibilidade; Etapa 2: com a configuração inicial determinada, é iniciada a fase de expansão; Etapa 3: com o término da fase de expansão, a fase de intensificação é iniciada. Esta etapa é subdividida em duas fases: Intensificação 1 e Intensificação 2. Etapa 4: com o término da fase de intensificação, é iniciada a fase de diversificação.

Dentro do contexto de [7], a fase de expansão é considerada a fase de busca por configurações factíveis. Desta forma, diferentes planos de expansão podem ser obtidos iniciando esta fase com configurações iniciais distintas.

Na fase de intensificação, “um movimento” consiste em trocar dois ou mais circuitos, ou seja, um circuito candidato adicionado previamente é removido e outro candidato é adicionado. Este movimento (permuta) é baseado em indicadores de sensibilidade e são permitidos somente dentro de uma região factível.

Na Intensificação 1, apenas movimentos para soluções com menores custos de investimento são permitidos e em contrapartida, na Intensificação 2, movimentos para soluções mais caras são permitidos com o objetivo de contornar soluções ótimas locais.

Na fase de diversificação, o objetivo é direcionar a busca para regiões não exploradas dentro do espaço de buscas. Nesta fase, os circuitos candidatos que apresentarem uma maior frequência na última iteração serão proibidos na próxima fase de expansão.

O algoritmo de [21] foi testado no sistema de 6 barras de Garver, no sistema de 46 barras Sul-brasileiro e no sistema de 87 barras Norte-nordeste brasileiro. O algoritmo de [7] foi testado no sistema de 46 barras Sul-brasileiro e no sistema de 79 barras Sudeste-brasileiro.

Para o sistema de 6 barras de Garver, o algoritmo de [21] determinou a família de configurações iniciais “randomicamente” pois da outra forma, a busca se tornaria trivial. Para este teste não foi permitido o redespacho da geração, tornando o problema mais difícil e sua convergência mais complicada. O algoritmo encontrou a solução ótima com o custo do investimento $v = 200$ e com as seguintes adições de circuitos:

$$n_{2-6} = 4, n_{3-5} = 1 \text{ e } n_{4-6} = 2.$$

Já para o sistema de 46 barras Sul-brasileiro, ambos os algoritmos [7,21] encontraram a solução ótima com o custo de investimento $v = 154,42$ milhões de dólares e com as seguintes adições de circuitos: $n_{20-21} = 1$, $n_{42-43} = 2$, $n_{46-6} = 1$, $n_{19-25} = 1$, $n_{31-32} = 1$, $n_{28-30} = 1$, $n_{26-29} = 3$, $n_{24-25} = 2$, $n_{29-30} = 2$ e $n_{5-6} = 2$.

Para o sistema de 79 barras sudeste-brasileiro, a melhor solução encontrada pelo algoritmo [22] prevê um investimento $v = 444,39$ milhões de dólares, com a adição de 21 circuitos.

A solução ótima para o sistema de 87 barras norte-nordeste brasileiro sem redespacho não é conhecida e a melhor configuração obtida pelo algoritmo [22] prevê um investimento de 2,574 bilhões de dólares com a adição de 107 circuitos.

O Algoritmo Genético é uma metodologia usada para resolver problemas de otimização combinatória e apresentou um grande sucesso na última década para solucionar problemas de grande porte em áreas muito diversas. O algoritmo foi, inicialmente, formulado por Holland, baseado no princípio da seleção natural que acontece na natureza e que fornece maiores chances de sobrevivência aos indivíduos melhores dotados. Matematicamente, o Algoritmo Genético pode ser considerado como uma técnica de otimização combinatória com uma alta probabilidade de encontrar a solução ótima global de problemas grandes e complexos e com muitas soluções ótimas locais.

Em [22] são descritos Algoritmos Genéticos que utilizam como modelagem matemática o modelo DC. Neste trabalho, um indivíduo representa uma e somente uma solução candidata do problema. Um gene é associado a cada caminho (existente ou candidato) através do sistema de potência.

Desta maneira, o tamanho do indivíduo corresponde ao somatório do número de caminhos (existente ou candidato). Um alelo (valor numérico de cada gene) corresponde ao número de adições em um caminho específico (existente ou candidato), sendo assim, um indivíduo com todos os genes iguais a zero representará uma rede de transmissão sem adições de circuitos. Foram implementados dois mecanismos de seleção: o primeiro chamado de "*Remainder Stochastic Sampling Without Replacement*", e o segundo chamado "*Tournament Selection*".

Os resultados obtidos usando a segunda maneira de seleção foram melhores que os encontrados quando considerado a primeira forma de

seleção. No primeiro método de seleção, para quase todos os casos testados, verificou-se uma convergência prematura.

Três técnicas de recombinação foram implementadas e testadas: (1) em um ponto; (2) em dois pontos e (3) por máscara. Não foi observada uma melhor performance quando compararam-se as três técnicas.

O mecanismo de mutação foi implementado baseado em "*Simulated Annealing*". Neste mecanismo, para cada gene, um número randômico é gerado no intervalo [0-1]. Se este número fosse menor que a taxa de mutação, o respectivo alelo do gene corrente seria trocado por outro valor randômico dentro de um intervalo específico. Se o novo indivíduo gerado por este mecanismo possuísse uma função objetivo de melhor qualidade, ou seja, possuísse uma melhor configuração, a mutação seria aceita. Em caso contrário, ela só seria aceita com alguma probabilidade que dependeria de um valor de temperatura. Esta temperatura iniciava-se com um alto valor e era vagarosamente reduzida de acordo com uma lista de resfriamento.

O algoritmo foi testado em três sistemas reais: o sistema de 46 barras sul-brasileiro, o sistema de 79 barras sudeste-brasileiro e o sistema de 171 barras colombiano.

Para o sistema de 46 barras sul-brasileiro, o algoritmo levou 23 gerações para determinar a solução ótima, com investimento de $v = 154,42$ milhões de dólares e com um tempo computacional da ordem de 1,5 min.

No caso do sistema de 79 barras sudeste-brasileiro, a melhor configuração encontrada previa um custo de investimento de 478,99 milhões de dólares e um tempo computacional gasto em torno de 46 min.

Para o sistema Colombiano, a melhor solução encontrada previa um custo de investimento de 564,72 milhões de dólares, com um tempo computacional gasto da ordem de 3h.

Uma metodologia adequada para encontrar a configuração ótima do problema de planejamento de sistemas de transmissão, quando se utiliza o

modelo de transportes, consiste em usar um algoritmo de *Branch and Bound*.

Entretanto deve ser desenvolvido um algoritmo de *Branch and Bound* eficiente e uma implementação computacional adequada para que o esforço computacional não seja proibitivo na resolução de problemas de grande porte.

Em [14] é apresentado um algoritmo especializado *Branch and Bound* que utiliza como modelagem matemática o modelo de transportes. O algoritmo é baseado numa busca em árvore, onde os nós representam os problemas candidatos e os ramos correspondem às decisões tomadas para um dado caminho.

Todas as soluções são, explícita ou implicitamente, representadas numa árvore, o que garante que todas as soluções ótimas serão obtidas pelo algoritmo.

O algoritmo parte com os procedimentos básicos: separação, relaxação e sondagem. A operação de separação consiste em dividir o problema corrente (um nó na árvore de decisão) em dois descendentes. A variável de separação é uma variável que assume um valor não inteiro em um nó corrente e pode ser forçada a assumir valores inteiros vizinhos e, em ambos os casos, uma nova restrição é então adicionada ao problema corrente.

O problema corrente é então eliminado da lista de problemas candidatos e os dois problemas descendentes são adicionados à lista (como resultado da operação de separação).

A operação de relaxação consiste em relaxar algumas restrições complicantes do problema original para torná-lo mais fácil de resolver. Assim, ao invés de se resolver um problema linear inteiro misto, resolve-se um problema linear chamado problema linear correspondente.

A operação de sondagem consiste em verificar qual dos subproblemas candidatos podem ser eliminados (ou sondados) da lista de candidatos. A seleção do subproblema candidato é feita por pseudocustos e a variável para separação é escolhida através de um parâmetro baseado na seguinte

regra empírica: escolhe-se a variável que estiver mais longe de valores inteiros, isto porque é esperado que as variáveis cujos valores correntes estejam perto de valores inteiros naturalmente tenderão para esses valores no decorrer do processo de busca, sendo assim, escolhe-se para "branching" as variáveis que estejam mais distantes de valores inteiros. Para melhorar o desempenho do algoritmo, foram utilizadas restrições de cerca.

O algoritmo foi testado em quatro sistemas: o sistema de 6 barras de Garver com redespacho, o sistema de 46 barras sul-brasileiro com e sem redespacho, o modelo reduzido do sistema sudeste-brasileiro de 78 barras sem redespacho e o sistema norte-nordeste brasileiro de 87 barras com e sem redespacho.

No sistema de 6 barras de Garver com redespacho, o algoritmo encontrou as soluções ótimas. Uma destas soluções, é a solução ótima para o modelo DC. O algoritmo convergiu após resolver 112 PPL's (problemas de programação linear) sem a utilização de restrições de cerca.

No sistema sul-brasileiro de 46 barras com redespacho, o algoritmo encontrou a solução ótima com um custo de investimento de $v = 53,334$ milhões de dólares e após a solução de 269 PPL's (sem a utilização de restrições de cerca e sem uma incumbente inicial).

Quando não se permite o redespacho, a complexidade do problema aumenta significativamente. Sem a utilização de restrições de cerca e sem a determinação de uma incumbente inicial, o algoritmo encontrou a solução ótima após 3500 PPL's. Usando as restrições de cerca e uma incumbente inicial (obtida com um método heurístico baseado no método de Garver) este número foi reduzido para 1220 PPL's. Foram encontradas soluções ótimas múltiplas com investimentos de $v = 127,012$ milhões de dólares.

Para o sistema sudeste-brasileiro, sem a inclusão de restrições de cerca, o algoritmo encontrou a solução ótima após solucionar 1.006 PPL's, com investimentos de $v = 284,1$ milhões de dólares.

No sistema de 87 barras norte-nordeste brasileiro com redespacho e com a inclusão de restrições de cerca, o algoritmo encontrou a solução ótima após 2.299.279 de PPL's. Quando as restrições de cerca não foram incluídas, o número de PPL's aumentou para 7.965.438. O investimento ótimo obtido foi de 614,9 milhões de dólares. Sem o redespacho e usando as restrições de cerca, o processo parou quando o número de PPL's bateu o limite de 100.000.000. O melhor investimento obtido foi $v = 1,194$ bilhões de dólares.

Outra alternativa para resolver o problema de planejamento de sistemas de transmissão consiste em usar técnicas de decomposição matemática que permitem decompor o problema complexo de planejamento em dois subproblemas: um subproblema de investimento também chamado mestre e um subproblema de operação chamado escravo.

A técnica de decomposição matemática usada é a Decomposição de *Benders* e os dois subproblemas, mestre e escravo, são resolvidos de maneira iterativa até que seja encontrada a solução ótima global.

O subproblema de operação é um problema de programação linear e o subproblema de investimento é um problema de programação inteira. Portanto, a complexidade do problema foi transferida para a resolução do subproblema mestre em forma iterativa.

O subproblema mestre, que é um problema de programação inteira, pode ser resolvido usando vários métodos, como por exemplo, um algoritmo de *Branch and Bound*.

Em [15], a modelagem matemática usada para a modelagem da rede é o modelo de transportes e o problema é resolvido usando a Decomposição Hierárquica de *Benders*. O problema é decomposto em dois subproblemas: o mestre e o escravo. O método hierárquico consiste em resolver o problema em dois estágios.

No primeiro estágio, o problema é resolvido relaxando a integridade das restrições (variáveis de adição de circuitos). O objetivo deste estágio é determinar um conjunto de cortes de *Benders* e uma solução relaxada do

problema original. Embora sejam aproximados, estes cortes simplificam a solução no segundo estágio.

No segundo estágio, a integridade das restrições são reintroduzidas no problema. Neste estágio, o subproblema de operação permanece relaxado e o subproblema de investimento torna-se um problema inteiro misto. Assim, o esforço computacional aumenta significativamente, pois existe a necessidade de se resolver um problema inteiro em cada iteração. A metodologia hierárquica reduz este esforço, pois os cortes de *Benders* gerados no primeiro estágio são aproveitados no segundo estágio e são boas aproximações para os cortes do problema não relaxado.

Para a solução do subproblema de investimento deste estágio é utilizado um algoritmo de *Branch and Bound*. Algumas implementações alternativas para a seleção do subproblema candidato foram testadas, pode-se utilizar a regra LIFO (*last in, first out*) ou os conceitos de pseudocustos. Para a seleção da variável de *branching*, o algoritmo pode usar o conceito de selecionar a primeira variável não inteira obtida, pode fazer a seleção através do custo ou pode, também, utilizar os conceitos de pseudocustos. Alguns conhecimentos específicos para a melhoria da eficiência do algoritmo foram implementadas, como as restrições de cerca e de caminhos.

O método foi testado em dois sistemas. O sistema de 6 barras de Garver sem redespacho e o sistema de 46 barras sul-brasileiro.

No teste do sistema de 6 barras de Garver, sem considerar as restrições de cerca, o algoritmo resolveu 121 PPL's para encontrar a solução ótima: foram gerados três cortes de *Benders* durante a fase 1 e o algoritmo de B&B foi chamado apenas uma vez durante a fase 2.

Os pseudocustos foram usados para selecionar os subproblemas candidatos e as variáveis de separação. Quando as restrições de cerca foram consideradas, nove cercas foram criadas e a solução ótima foi obtida após 87 PPL's e nenhum corte de *Benders* foi gerado. O método proposto encontrou cinco soluções alternativas, todas com investimento $v = 200$. Uma destas soluções também é factível para a modelagem DC.

O teste realizado no sistema de 46 barras sul-brasileiro com redespacho, encontrou-se um custo de investimento de $v = 53,334$ milhões de dólares.

No estágio I, 19 cortes de *Benders* foram gerados e no estágio II foram feitas 4 chamadas do algoritmo *Branch and Bound*. A melhor performance foi obtida quando o algoritmo B&B usou pseudocustos para as seleções do subproblema candidato e das variáveis de separação, onde foram resolvidos 2.285 PPL's.

Com o redespacho, o algoritmo encontrou duas soluções alternativas com custo de investimento $v = 127,212$ milhões de dólares. Neste caso, 33 cortes de *Benders* foram gerados na fase 1 e 139 na fase 2, com 82 chamadas para o algoritmo B&B.

A melhor performance foi observada quando o algoritmo utilizou para a seleção do subproblema candidato o critério LIFO e para a seleção da variável, os pseudocustos. A configuração ótima foi encontrada após a solução de 1.507.710 PPL's. Quando foram introduzidas as restrições de cerca e de caminho, o número de PPL's resolvidos caiu para 16.763 com somente 13 cortes de *Benders* gerados na fase 2.

Em [16], o problema é resolvido também por decomposição de *Benders*, mas agora ele é formulado pela modelagem (0-1) disjuntiva. Uma das dificuldades encontradas para a aplicação desta formulação foi em relação ao valor do parâmetro M.

Os valores numéricos grandes para a constante disjuntiva provocaram instabilidade numérica nos cortes de *Benders*, o que trouxe problemas de convergência para o processo de decomposição. Para contornar este problema, utilizou-se um esquema iterativo para variar o valor da constante disjuntiva com o objetivo de melhorar o condicionamento numérico dos cortes de *Benders* gerados durante o processo de decomposição.

Para tornar mais rápida a convergência, foi considerado a inclusão de outros cortes (restrições) como os cortes de *Gomory* e outros, além dos de *Benders*, no problema mestre, acerca das restrições do problema escravo.

Estes “outros cortes” foram gerados a partir de relaxações do problema escravo.

Assim, foi proposto a utilização de cortes de *Benders* gerados a partir de modelos de transportes e híbridos, que são relaxações do problema escravo formulado pelo modelo linear disjuntivo. Desta maneira, estes cortes foram usados em conjunto com os cortes de *Benders* tradicionais gerados pelo subproblema escravo e com os cortes de *Gomory*, para o problema mestre.

Esta metodologia foi testada no sistema de 46 barras Sul-brasileiro sem redespacho. A solução ótima obtida pelo método foi um custo de investimento $v = 154,4$ milhões de dólares, melhor conhecida até o momento. Com os resultados obtidos, pode-se verificar a importância da utilização dos cortes de *Gomory*, pois estes reduzem o número de problemas mestres a serem resolvidos, reduzindo o tempo de processamento em casos de difíceis soluções.

Foi verificada também a importância de um valor mínimo em conjunto com o ajuste (nas iterações iniciais) para a constante disjuntiva M , o que reduziu drasticamente o número de iterações e o tempo de processamento para atingir a convergência e se não fosse considerado os cortes de *Benders* para relaxações do problema escravo, no caso os problemas de transportes e híbrido, o processo não convergiria por falta de memória.

Um outro método classificado como uma metaheurística é o denominado GRASP (*Greedy Randomized Adaptive Search Procedure*).

O GRASP é um processo iterativo que tem duas fases associadas com cada iteração: uma fase de construção, onde uma solução viável é construída por um procedimento “guloso” aleatório e, uma fase de busca local, que busca por um mínimo local pertencente a uma dada vizinhança a partir da solução obtida pela fase de construção.

A melhor solução, considerando todas as iterações do GRASP é mantida como a resposta para o problema. Estes métodos de busca, que combinam

métodos heurísticos, têm se mostrado muito efetivos na solução de problemas difíceis e de grande porte.

Em [17], a solução do problema é baseada na metodologia metaheurística GRASP. Esta técnica heurística iterativa é associada por escolha aleatória e busca local compondo um sistema de duas fases, a fase de construção e a fase de busca local. Estas duas fases aparecem em cada iteração. Na fase de construção, é construída uma solução factível por uma técnica randômica e, a fase de busca local, é iniciada a partir da solução da fase de construção e encontra o ótimo local de uma dada vizinhança. A melhor de todas as iterações é escolhida como solução final (configuração final).

Esta metodologia foi testada em três sistemas: o sistema de 6 barras de Garver com redespacho, o sistema de 46 barras sul-brasileiro com redespacho e o sistema de 79 barras sudeste-brasileiro.

No sistema de 6 barras de Garver com redespacho, o algoritmo foi processado quatro vezes; para cada vez, os principais parâmetros eram modificados: o tamanho da lista de candidatos (randômica) e a vizinhança da fase de busca local. Para todos os casos analisados, GRASP encontrou a solução ótima.

Para o sistema de 46 barras sul-brasileiro com redespacho, GRASP encontrou a melhor solução já conhecida até o momento, com o custo de investimento previsto de $v = 70,289$ milhões de dólares.

No sistema de 79 barras sudeste-brasileiro, a melhor solução encontrada estabeleceu um custo de investimento de 512,8 milhões de dólares.

Os melhores resultados já obtidos para os sistemas testados também foram encontrados por GRASP e melhores soluções foram encontradas para o sistema sudeste-brasileiro. Para os sistemas de grande porte, o esforço computacional requerido pelo GRASP foi moderado.

Em [26] é descrito um algoritmo *Branch and Bound* que utiliza, para a representação matemática da rede, o modelo disjuntivo. Uma solução heurística é usada como incumbente inicial. Esta solução heurística é obtida através do algoritmo metaheurístico GRASP.

O algoritmo *Branch and Bound* do trabalho é resolvido pelo software XPRESS Solver (release 11). Com o software, existe a possibilidade de, além de utilizar a modelagem disjuntiva padrão, utilizar uma modelagem disjuntiva alternativa e é permitida, também, a variação do parâmetro M durante as iterações do algoritmo. O algoritmo foi testado para os sistemas de 46 barras Sul-brasileiro com e sem redespacho e para o sistema de 79 barras Sudeste-brasileiro.

Para o sistema de 46 barras sem redespacho, a melhor solução obtida por Decomposição Hierárquica de Benders e GRASP estabelece uma configuração com um custo de 154,26 milhões de dólares. Com os parâmetros de penalidade (M), da formulação disjuntiva, fixos e sem a determinação da incumbente inicial, o algoritmo demorou 4h para encontrar esta configuração.

Usando a formulação disjuntiva alternativa, com a otimização dos fatores de penalidade, a mesma solução foi obtida em 2h10min. de processamento, mostrando a superioridade desta versão quando comparada a primeira. Usando GRASP para a determinação da incumbente inicial, o algoritmo encontrou esta solução em 81 min.

No sistema de 46 barras com redespacho, a melhor solução obtida conhecida implica em um investimento de US\$ 70,289 milhões de dólares. Usando o algoritmo com a formulação padrão e com a otimização dos parâmetros de penalidade, o algoritmo demorou 33s para determinar esta solução. Usando a formulação matemática disjuntiva, o tempo de processamento passou para 57s.

Para o sistema de 79 barras Sudeste-brasileiro, a melhor solução conhecida estabelece um investimento de 422 milhões de dólares, encontrada por GRASP. Sem a determinação de uma incumbente inicial e usando a modelagem disjuntiva alternativa, não foi possível obter a solução

ótima devido ao tamanho da árvore de busca, porém, soluções sub-ótimas foram encontradas, como por exemplo, uma solução factível com um GAP de 8% (comparado com a melhor solução conhecida) foi obtida em um período de 33 min. de processamento. Com uma incumbente inicial de US\$ 423 milhões de dólares, o algoritmo B&B encontrou esta solução em 50min. e, a melhor encontrada até o momento, em 90min de processamento.

Capítulo 3

Formulação do Problema PEST considerando a retirada de linhas

3.1. Introdução

Neste capítulo é analisada a proposta inicial do novo modelo matemático do problema de planejamento da expansão de sistemas de transmissão, assim como uma proposta inicial de resolução. Deve-se observar que a maneira de resolver o problema deve produzir maiores dificuldades porque a topologia base não necessariamente é preservada. Portanto, inicialmente são apresentadas as mudanças em relação à modelagem matemática e depois alguns critérios básicos do processo de resolução.

3.2. Modelagem matemática

Um assunto que deve ser analisado com um certo cuidado é a justificativa para se retirar uma linha de transmissão que está presente na topologia base e, principalmente, os motivos e as circunstâncias que permitem concluir que uma linha de transmissão não ajuda no funcionamento adequado de um sistema elétrico.

Para entender esse problema devemos analisar as restrições de operação do sistema elétrico. Basicamente, as três restrições de operação mais importantes no funcionamento de um sistema elétrico está representado pelas duas Leis de *Kirchhoff* (a Lei de Correntes de *Kirchhoff* (LCK) e a Lei de Tensões de *Kirchhoff* (LTK)) e pela capacidade de transmissão de uma linha de transmissão.

A LCK apenas exige que a soma algébrica do fluxo de potência (ou correntes) em uma barra do sistema deve ser igual a zero. Assim, uma linha de transmissão da topologia base só pode aumentar o desempenho do sistema elétrico já que sua presença ajudaria na transmissão de fluxo de potência entre as barras do sistema elétrico aos quais se encontra conectado.

Portanto, a LCK não traz nenhuma limitação ao funcionamento de uma linha de transmissão em um sistema elétrico e ainda podemos concluir que a presença de uma linha de transmissão só pode ajudar a cumprir com a LCK em uma barra do sistema e pode melhorar o funcionamento de um sistema elétrico.

A capacidade de transmissão de uma linha de transmissão existente na topologia base produz uma restrição que em princípio não deveria prejudicar o desempenho de um sistema elétrico considerando essa restrição isoladamente.

Em outras palavras, uma linha de transmissão da topologia base mesmo com capacidade de transmissão pequena ajudaria no desempenho de um sistema elétrico e sua retirada pode produzir prejuízos ao sistema. Portanto, podemos concluir que se o modelo matemático usado for o modelo de transportes, então, a retirada de linhas de transmissão da topologia base só pode trazer prejuízos no desempenho do sistema elétrico.

Portanto, neste trabalho não podemos usar o modelo de transportes porque nesse contexto a nova proposta de resolução do problema de planejamento da expansão de sistemas de transmissão não produziria resultados diferentes ao planejamento convencional.

A LTK juntamente com a capacidade de transmissão de uma linha pode mostrar comportamentos inesperados no desempenho de um sistema elétrico.

Experimentalmente foi observado que em determinados sistemas elétricos, a retirada de uma linha de transmissão melhora o desempenho do sistema elétrico.

Este tipo de comportamento já foi observado por alguns pesquisadores e foi denominado de comportamento não coerente. Logicamente, esse tipo de problema aparece somente quando for usado o modelo DC ou AC de sistemas elétricos malhados.

Em sistemas malhados, deve-se cumprir a LTK em todas as malhas (ou laços) existentes no sistema elétrico. A exigência de satisfazer a LTK em todos os laços do sistema juntamente com a capacidade de transmissão das linhas, provoca comportamentos inesperados, porque podem aparecer laços de linhas com capacidades de transmissão muito diferentes.

Nesse contexto, uma linha com pequena capacidade de transmissão pode prejudicar o carregamento de uma de maior capacidade com a qual forma um laço elétrico. Assim, por exemplo, se duas linhas muito diferentes (uma linha de 300 MW e outra de 1200 MW) estão formando um laço elétrico juntamente com outras linhas, podem acontecer casos em que a linha de pequena capacidade de transmissão atinja rapidamente 100% de sua capacidade de transmissão (300 MW), enquanto que, a outra linha esta operando com apenas 30% da sua capacidade de transmissão (360 MW).

Sendo assim, retirada da linha de pequena capacidade de transmissão (que produz a eliminação do laço elétrico com a linha de transmissão de elevada capacidade de transmissão e da exigência da LTK) permite que a linha de elevada capacidade possa transmitir até 100% de sua capacidade (1200 MW).

Portanto, nesse seguimento do sistema elétrico o sistema opera de forma mais eficiente (a capacidade de transporte nesse seguimento pode passar de 660 MW para 1200 MW).

É mostrado a seguir dois exemplos para ilustrar esse problema.

Exemplo 1: Duas linhas em paralelo

Neste caso é mostrado um caso típico de operação de duas linhas de transmissão que se encontram operando em paralelo, mas que apresentam características diferentes e até conflitantes.

Dados:

Linha tipo 1	$g = 20.367 p.u.$	$\bar{f} = 270MW \Rightarrow \Delta q \text{ max} = 13,26\%$
Linha tipo 2	$g = 35.971 p.u.$	$\bar{f} = 1500MW \Rightarrow \Delta q \text{ max} = 41,70\%$




Figura 3-1 - Duas linhas em paralelo

Pode-se verificar que, quando as duas linhas operam em paralelo, a capacidade de transporte do sistema elétrico nesse seguimento é de apenas 747 MW. Entretanto, se for retirada a linha de 270 MW de capacidade de transporte, a linha de maior capacidade pode operar sem problemas até atingir seu limite.

Assim, a capacidade de transporte nesse setor passa a ser 1500 MW. Esse tipo de problema (duas linhas distintas operando em paralelo), na prática, existe no sistema norte-nordeste brasileiro. Entretanto, o problema mais comum acontece na operação de várias linhas que formam um laço elétrico.

Exemplo 2: Sistema elétrico de 3 barras

Neste exemplo, é mostrado um sistema elétrico de 3 barras onde acontece o problema de operação não coerente do sistema elétrico. A topologia base não opera adequadamente, isto é, produz corte de carga. Assim, deve-se fazer o planejamento ótimo desse sistema elétrico.

Dados:

$\bar{g}_{12} = 1/3, \bar{g}_{23} = \bar{g}_{13} = 1/2 \text{ p.u.}$
$\bar{f}_{12} = 35, \bar{f}_{13} = \bar{f}_{23} = 40$
$\bar{g} = 150 \text{ MW}$
$d_2 = 38 \text{ MW}, d_3 = 80 \text{ MW}$
$n_{13}^0 = 3, n_{12}^0 = 1, n_{23}^0 = 2$
$c_{12} = 3, c_{13} = c_{23} = 2$

1) **Topologia Base**




Figura 3-2 - Sistema de 3 barras - topologia base

A Figura 3-2 mostra a operação do sistema onde aparece um corte de carga de 14 MW na barra 2.

2) **Topologia Ótima Tradicional:** $n_{12} = 1 \Rightarrow v = 3$

O planejamento ótimo tradicional adiciona uma linha de transmissão no caminho 1-2 e produz um investimento ótimo mostrado na Figura 3.3. Assim, a proposta ótima do planejamento tradicional é encontrada com a construção de uma linha de transmissão. A Figura 3-3 mostra a operação ótima do planejamento tradicional.




Figura 3-3 - Sistema de 3 barras - topologia ótima tradicional

3) **Topologia Ótima com a Nova Proposta:**

O planejamento ótimo com a nova proposta é encontrado retirando duas linhas de transmissão, isto é, retirando uma linha do caminho 1-2 e outra linha do caminho 2-3. Portanto, o ótimo para o modelo modificado produz uma proposta de investimento igual a zero e sugere retirar duas linhas de transmissão sem custo.

A Figura 3.4 mostra a solução ótima da proposta de planejamento modificado. A proposta ainda encontraria uma proposta intermediária que consiste em retirar apenas a linha de transmissão do caminho 1-2, onde podemos verificar que o sistema opera sem corte de carga.




Figura 3-4 - Sistema de 3 barras - nova topologia ótima

A Figura 3.4 mostra a operação do sistema sem corte de carga e com a retirada de duas linhas de transmissão. Portanto, um algoritmo eficiente de otimização para o novo modelo deve encontrar essas duas soluções ótimas alternativas que indica que o planejamento do sistema elétrico pode ser realizado com custo de expansão zero e apenas retirando uma ou duas linhas de transmissão.




Figura 3-5 - Sistema de 3 barras - nova topologia ótima

Neste trabalho está se propondo mudar a lógica de planejamento da expansão a longo prazo de sistemas de transmissão de energia elétrica, isto é, do problema PEST. Na nova proposta é sugerido adicionar linhas de transmissão na forma tradicional mas também existe a possibilidade de retirar linhas de transmissão existentes na topologia base e a custo zero.

Neste contexto, a modelagem matemática deve ser modificada, e essa mudança depende de forma determinante da técnica de solução adotada para resolver o novo problema.

Neste trabalho pretende-se resolver o novo problema usando um algoritmo genético especializado e, portanto, a modelagem matemática não seja tão determinante.

Nossa preocupação está voltada em resolver o problema da codificação de forma eficiente, e também as decisões correlatas, como a forma adequada de identificar infactibilidades e a forma de encontrar o valor da função objetivo ou equivalente de cada proposta de solução.

Assim, não são feitas mudanças significativas na formulação matemática, apenas se caracteriza adequadamente o problema usando a informação presente na modelagem tradicional.

Neste trabalho é utilizado o modelo DC para encontrar o plano ótimo de expansão do problema PEST em que é possível retirar linhas de transmissão da topologia base a custo zero, caso esse tipo de decisão melhore o funcionamento do sistema e/ou o custo de expansão do sistema elétrico.

Assim, o modelo DC assume a seguinte forma:

$$\text{Min } v = \sum_{(i,j)} c_{ij} n_{ij} + a \sum_{r \in \Gamma} r_k \quad (3.1)$$

s.a.

$$Sf + g + r = d$$

$$f_{ij} - g_{ij} (n'_{ij} + n_{ij}) (q_i - q_j) = 0$$

$$|f_{ij}| \leq (n'_{ij} + n_{ij}) \bar{f}_{ij}$$

$$0 \leq g \leq \bar{g}$$

$$0 \leq r \leq d$$

$$0 \leq n_{ij} \leq \bar{n}_{ij}$$

$$0 \leq n'_{ij} \leq n^o_{ij}$$

$$n'_{ij} \text{ e } n_{ij} \text{ inteiros}$$

$$f_{ij} \text{ irrestrito}$$

$$q_j \text{ irrestrito}$$

Em que n'_{ij} representam novas variáveis de decisão que podem variar entre zero e n^o_{ij} . Portanto, o número de linhas retiradas em cada caminho da configuração existente é igual a $n''_{ij} = n^o_{ij} - n'_{ij}$.

A modelagem matemática apresentada em (3.1) é muito semelhante com a modelagem (2.8) para o modelo DC tradicional. A única diferença é que aparecem as novas variáveis de decisão n'_{ij} com custos iguais a zero e podem variar entre zero e n^o_{ij} . Em outras palavras, os circuitos (linhas de transmissão) existentes na topologia base são considerados como variáveis de decisão.

Alternativamente, pode-se considerar que o sistema elétrico não tem circuitos na topologia base (sistema elétrico totalmente ilhado) e podem ser adicionados dois tipos de circuitos, isto é, circuitos tipo n'_{ij} com custo igual a zero e que variam entre zero e n^o_{ij} , e circuito tipo n_{ij} , com custo igual a c_{ij} e que podem variar entre zero e \bar{n}_{ij} .

Capítulo 4

Metaheurística Para Resolver o Modelo Modificado do Problema PEST

4.1. Introdução

Neste capítulo é apresentado o algoritmo genético de Chu-Beasley modificado, que é a metaheurística escolhida para resolver o tipo de problema PEST apresentado anteriormente. Assim, inicialmente conceitua-se o algoritmo genético tradicional, o algoritmo genético especializado de Chu-Beasley e finalmente o algoritmo de Chu-Beasley modificado que é usado para resolver o problema PEST.

O algoritmo genético foi idealizado por Holland em 1975, e nessa proposta é utilizada a idéia da teoria da evolução natural e da evolução genética. Os algoritmos genéticos são técnicas computacionais inspiradas na evolução. Na natureza, os indivíduos melhores qualificados geneticamente têm maiores possibilidades de sobrevivência quando os recursos são escassos e/ou quando mudam as condições do meio ambiente.

Melhor qualificado significa, melhor capacidade de sobrevivência e, em última instância, esta qualidade ou capacidade é determinada pelo conteúdo genético de cada indivíduo.

Deve-se observar que a unidade básica de informação genética é o gene. O conjunto de genes forma o cromossomo ou conjunto de cromossomos que determina a qualidade de um indivíduo.

As mudanças e a diversidade do material genético constituem a essência da evolução. Assim, pode-se dizer que a evolução é uma consequência da ação conjunta da seleção natural e dos mecanismos que produzem a diversidade genética analisados anteriormente.

Na natureza, os indivíduos competem por problemas de alimentos, espaço, doenças e, também, de acasalamento produzindo um predomínio dos indivíduos mais qualificados. Portanto, somente os indivíduos melhor qualificados sobrevivem e se reproduzem repassando seus genes melhor qualificados para as gerações seguintes.

O processo repetido de seleção no meio de uma grande diversidade genética é a chave da evolução segundo Darwin e seus seguidores. Em outras palavras, sem essa grande diversidade genética que existe entre os indivíduos de uma população, seria difícil o processo de evolução das espécies.

Pode-se chamá-lo de algoritmo genético básico ou algoritmo genético tradicional. Independentemente da forma pela qual o algoritmo é denominado, ele deve conservar as características genéticas e as características computacionais conceituadas por Holland.

Como a principal fundamentação do algoritmo genético vem da evolução das espécies, e que indivíduos melhores qualificados terão chances maiores de sobrevivência, a adequação e suas aplicações computacionais estão voltadas para o processo de otimização, no qual, a evolução do algoritmo vai ao encontro de uma boa solução dentro das características do problema apresentado.

Como o fenômeno da explosão combinatória se apresenta nesses tipos de problemas, o algoritmo genético irá apresentar uma boa solução dentro de um espaço de busca, que obviamente, dada a particularidade da explosão combinatória, será um espaço de busca reduzido, dentro dos parâmetros pensados e especificados para cada problema em particular.

Outras duas características importantes dos algoritmos genéticos são: Recombinação e Mutação, que no processo de otimização irão determinar a seleção natural dos indivíduos. Indivíduos com melhor qualidade genética, isto é, que apresentarem melhor resultado para o processo de otimização irão sobreviver e farão com que a cada processo de iteração do algoritmo, o mesmo passe a buscar e selecionar melhores soluções ao processo até que

um critério de parada seja satisfeito para finalizar o processo de seleção da melhor solução.

Veja a tabela abaixo, a consideração de algumas variações de N produtos em um hipotético período de tempo para sua resolução.

N	EB (Espaço de Busca)	Tempo
20	2^{20}	1 segundo
40	2^{40}	2 semanas
60	2^{60}	365 séculos

Tabela 1 - Fenômeno da explosão combinatorial.

Podemos facilmente perceber o fenômeno da explosão combinatoria em que o crescimento é dado em proporções exponenciais.

Resumindo, a forma pela qual a codificação será feita determinará a melhor escolha para o tipo específico de códigos que representará os indivíduos da população.

Para os problemas PEST (planejamento da expansão do sistema de transmissão) será utilizada a codificação decimal, por ser a que melhor se adapta para a resolução desse tipo de problemas. A codificação correta do problema influenciará substancialmente na qualidade do algoritmo para resolver os problemas de otimização.

4.2. Algoritmo Genético Tradicional

O algoritmo genético usa uma população de indivíduos, que nos problemas combinatorios significa um conjunto de configurações para resolver um problema de otimização complexo. Portanto, o algoritmo genético deve fazer o seguinte:

4.2.1. Codificação do Problema

Representar adequadamente uma configuração do problema. A representação mais popular é a representação em codificação binária onde são facilmente simulados os operadores genéticos de recombinação e mutação. Poder-se-ia então gerar população inicial de maneira aleatória, ou se for o caso, poderia ser adotada alguma estratégia para a geração da população ou utilizar-se de algum algoritmo que seria o gerador os indivíduos que comporiam a população inicial do problema.

4.2.2. Função Objetivo e Inactibilidades

A qualidade de uma configuração é definida pelo valor da sua função objetivo ou o seu equivalente. Por não ser sempre possível dependendo do tipo de problema indicar uma função objetivo, deve-se então indicar um equivalente que possa determinar a qualidade de uma configuração ou ainda permitir uma comparação quantitativa entre as configurações de uma população.

A maneira pela qual se escolhe para determinar a configuração das populações no algoritmo genético, irá influenciar diretamente as inactibilidades de uma configuração, que ocorrem em função da codificação especificada, da natureza do problema e dos operadores genéticos escolhidos ou projetados.

Os seguintes casos poderão ocorrer após feita a codificação de um problema: 1) Todo e qualquer indivíduo gerado sempre será factível e os operadores genéticos geram também configurações factíveis; 2) Os indivíduos gerados na configuração inicial serão sempre factíveis, pode-se usar alguma heurística que determine isso, mas os operadores genéticos poderão gerar indivíduos inactíveis e; 3) Pode ocorrer indivíduos factíveis e inactíveis na população inicial e os operadores genéticos também irão evidentemente gerar indivíduos factíveis e inactíveis.

O primeiro caso é o sonho de qualquer pesquisador que trabalhe com algoritmos genéticos, poder sempre ter uma população sem indivíduos que gerem inactibilidades, então não há necessidade de se discutir esse caso.

O segundo caso pode ocorrer, tendo uma população inicial gerada de maneira que não se mostre infactibilidades e os operadores genéticos irão gerar infactibilidades, deve-se então encontrar uma forma para contornar essas configurações infactíveis através de alguma heurística rápida que contornaria o problema convertendo as configurações infactíveis em configurações factíveis, ou penalizar a função objetivo com as infactibilidades.

O terceiro e último caso, que é muito comum aos problemas PEST, deve ser resolvido como sugerido no segundo caso. Penalizar a função objetivo é uma estratégia muito utilizada em otimização clássica.

A função objetivo ou sua forma equivalente deve preservar a seletividade entre as configurações, isto é, deve ter a capacidade de identificar as configurações de melhor qualidade. Portanto a função objetivo deve permitir uma clara diferenciação entre as diferentes configurações da população para facilitar a seleção.

4.2.3. Operador de Seleção

O operador de seleção genético tem um papel bastante importante dentro dos algoritmos genéticos; analogamente falando, será ele quem irá proporcionar o processo de seleção natural inserido no contexto da seleção biológica, só que aqui, ele irá fazer a seleção das configurações que participaram do processo da formação da nova população.

O operador de seleção sai de cena assim que cumprir esse processo de seleção do número de descendentes que deve ter cada configuração da população corrente.

Assim, algumas configurações poderão gerar vários descendentes e outras configurações podem ser eliminadas por gerarem indivíduos de qualidade pobre para o processo de otimização.

Existem vários operadores de seleção genética tais como: seleção proporcional; seleção estocástica de resíduo, seleção determinística, seleção com limitante superior do número máximo de descendentes, seleção usando escalonamento linear, seleção usando ordenamento e seleção por torneio.

Sendo a última, a seleção por torneio, que será dado maior ênfase neste trabalho, por sua eficácia constatada em várias pesquisas desenvolvidas e também por sua simples maneira de implementação.

Nesta proposta, os descendentes são escolhidos realizando jogos, o parâmetro que irá determinar a quantidade de jogos realizados e a forma como serão feitos, pode ser definidos através de um parâmetro previamente escolhido ou através de alguma heurística para escolha dessas configurações participantes dos jogos.

Pode-se escolher o parâmetro k , que irá indicar a quantidade de configurações participantes do jogo e realizá-lo, determinando o vencedor, o valor k geralmente é pequeno, $k \in \{2,3,4\}$ e após n jogos termina o processo de seleção.

Este operador de seleção é atrativo pelo baixo custo computacional tornando-o muito rápido e eficiente e também porque pode ser utilizado tanto para os problemas de minimização quanto para os problemas de maximização usando apenas uma modificação trivial.

4.2.4. Recombinação

Seguindo o processo, configurações foram escolhidas no processo de seleção, que gerou descendentes que serão candidatos a participarem da nova população. Esses descendentes selecionados serão submetidos ao processo de recombinação.

O processo de recombinação consiste em trocar parcelas de duas novas configurações que foram selecionadas pelo operador de seleção, para formarem duas outras novas configurações candidatas; simplificando, esse processo recombina os genes de duas configurações geradoras que fornecem uma parcela do seu código genético para ser recombinado com a parcela do outro indivíduo participante no processo de recombinação.

Essas novas configurações recombinadas ainda passarão pelo processo de mutação para se transformarem em uma nova configuração da nova população.

Esse processo de recombinação tenta simular o fenômeno que ocorre na genética chamado de "crossing over". Existem várias formas de recombinação a diferença entre elas está no número de pontos de recombinação. São conhecidas como: recombinação de um ponto, de dois pontos, multiponto e uniforme.

Se for feita a opção pela forma aleatória, pode ocorrer que as configurações selecionadas devam ou não ser submetidas ao processo de recombinação.

A maneira mais simples de recombinar consiste na escolha de um ponto apenas para fazer a recombinação, esse ponto geralmente é um número aleatório escolhido entre 1 e $k-1$ (número de elementos da configuração), e esse número determina o ponto de recombinação, as parcelas que ficam à direita desse ponto são trocadas entre as configurações para formarem as duas novas configurações candidatas.

Novamente temos decisões que são de caráter aleatório, são três as decisões: 1) As duas configurações que devem ser submetidas à recombinação são escolhidas aleatoriamente; 2) O ponto de recombinação é escolhido de forma aleatória e; 3) Deve-se gerar um número aleatório p que determina se as configurações selecionadas devem ser submetidas à recombinação. A figura a seguir exemplifica a recombinação de um ponto escolhido aleatoriamente.

Neste exemplo $k = 3 \in \{1,5\}$




Figura 4-1 - Ilustração da recombinação

4.2.5. Mutação

Quando da codificação de um problema se opta pela binária, o operador de mutação simplesmente irá efetuar a troca de valor de um elemento de 0 para 1 ou vice-versa.

Nos primeiros trabalhos de algoritmos genéticos, esse operador era considerado como secundário. Entretanto, pesquisas recentes mostram que este operador é muito mais importante do que se imaginava inicialmente.

Uma taxa de mutação p_m pode ser inserida como parâmetro, e irá determinar se uma casa ou configuração será modificada. Nas primeiras propostas de algoritmos genéticos e na análise teórica, sugere-se que a mutação deve ser realizada bit a bit, casa por casa e, portanto, a decisão de mutar uma posição deve ser independente da decisão realizada em outras posições binárias de uma configuração.

Na prática, supor que seja $p_m = 0,05$ e o processo de mutação bit a bit é submetido com esta probabilidade, assim sendo, gera-se um número aleatório $p \in [0,1]$ e se esse número for menor que $p_m = 0,05$ então será realizada a mutação.




Figura 4-2 - Ilustração da Mutação

O exemplo mostrado na Figura 4-2, foi para um problema em que a codificação é binária. Quando esse tipo de codificação não ocorre e ela é diferente, estratégias de mutação deverão ser desenvolvidas levando em consideração a natureza do problema, o tipo de codificação escolhida e a essência da mutação na genética natural, isto é, são pequenas mudanças no conteúdo genético mas que produzem um genótipo que não existia, com o conseqüente aparecimento de um novo fenótipo.

4.2.6. Parâmetros de Controle

Seguem abaixo alguns parâmetros indicados nas literaturas especializadas:

Tamanho da população: $n_p \in [30,31,\dots,199,200]$.

Taxa de recombinação: $p_c \in [0,5 ; 1,0]$.

Taxa de mutação: $p_m \in [0,001 ; 0,050]$.

Os parâmetros definidos acima poderão ser adequados para cada tipo de problema, avaliando o seu comportamento para o caso em questão. Eles devem influenciar substancialmente na eficiência do algoritmo genético.

4.2.7. Critério de Parada

Vários critérios de parada poderão ser especificados, isso de acordo com a necessidade de cada problema, o algoritmo genético pode ser interrompido quando:

- 1) Quando atingir o número especificado de gerações;
- 2) Quando a incumbente (melhor solução encontrada) equivale-se a um valor pelo menos de igual qualidade que um valor previamente especificado;
- 3) Quando a incumbente não melhora durante um número especificado de gerações;
- 4) As configurações da população ficam muito homogêneas, isto é, as configurações são muito parecidas e praticamente já não existe evolução; ou,
- 5) Usando um critério que depende do tipo de problema analisado.

Quando da implementação computacional de problemas complexos, geralmente são especificados critérios de parada mais objetivos que dependem do tipo específico de problema, por exemplo, em problemas que resolvam problemas de PPL subsidiários, um critério de parada objetivo

consiste em parar o processo após resolver um número especificado de problemas de programação linear (PPL), já que na resolução desses PPL's é usado o maior esforço computacional.

4.2.8. Geração da População inicial

Na conceituação teórica dos algoritmos genéticos sugere-se que os indivíduos que irão compor a população inicial sejam gerados de maneira aleatória. Esse contexto é fundamentado na suposição de que a qualidade da população inicial tem que ser totalmente independente da solução final encontrada. Em alguns sistemas reais a geração dessa população de maneira aleatória, pode gerar soluções ótimas ou quase-ótimas, em outros casos, propostas alternativas ou heurísticas alternativas poderão ser utilizadas. Nos problemas de engenharia podemos usar as seguintes alternativas:

1. Geração da população inicial utilizando um processo aleatório controlado. Por exemplo, num problema de alocação de bancos capacitores em sistemas de distribuição, escolhe-se um número reduzido de barras, 10 de 200, por exemplo, e o processo aleatório identifica aquelas barras onde devem ser alocados bancos de capacitores e o número de bancos. Um processo totalmente aleatório produziria configurações com alocação de capacitores em muitas barras;
2. Geração da população inicial usando algoritmos heurísticos construtivos rápidos e eficientes. Para problemas muito complexos esta proposta é a melhor alternativa, gerar-se-ia configurações de boa qualidade, mas também significativamente diferentes entre elas. Vale a pena fazer a seguinte observação sobre os conceitos elementares dos algoritmos genéticos, o algoritmo é uma forma grosseira de imitar a evolução genética natural, ele não segue fielmente os conceitos da evolução genética natural.

Nesse contexto apareceu a proposta dos algoritmos genéticos modificados, que segue uma lógica diferente à lógica do algoritmo genético tradicional.

No algoritmo genético tradicional o problema é transformado para se adaptar ao algoritmo genético e no algoritmo genético modificado (chamado de programa evolutivo) é o algoritmo genético que é transformado para se adequar ao problema específico.

4.3. Algoritmo Genético de Chu-Beasley

O algoritmo genético de Chu-Beasley foi inicialmente apresentado em [28] para resolver o problema generalizado de atribuição que é um problema multirestrito, semelhante em estrutura, ao problema de planejamento de expansão de sistemas de transmissão. Entretanto, o problema generalizado de atribuição, chamado de problema GAP (Generalized Assignment Problem) é um problema de programação inteira binária. A seguir apresentam-se de forma resumida, as principais características do algoritmo apresentado em [28].

4.3.1. Codificação do Problema

As modificações mais relevantes dessa proposta estão relacionadas na forma de atualização da população corrente e a proposta de melhoria local dos descendentes gerados.

Considerando o problema GAP (Generalized Assignment Problem) com m agentes e n tarefas, a proposta de codificação do problema é muito simples, cada tarefa ocupa a mesma posição dentro do vetor de codificação e o elemento do vetor indica o agente que realizará a tarefa. No exemplo abaixo podemos observar que a tarefa 2 é realizada pelo agente 5, a tarefa 4 é realizada pelo agente 2 e assim por diante.

1	2	3	4	5	6	...				n-1	n
3	5	4	2	6	1	...	6	2	8	m	1

Figura 4-3 - Codificação do problema no AG Chu-Beasley,

Essa proposta de codificação é vantajosa porque não cresce muito com o crescimento do tamanho do problema e é representada por um vetor de tamanho n . A desvantagem é que poderá gerar configurações inactíveis.

Deve-se fazer também a seguinte observação, a proposta de codificação não tem relação com as variáveis de decisão do problema, sendo assim, o número de variáveis de decisão é igual a $n(n-1)$ e o tamanho do vetor de codificação é igual a n .

4.3.2. Função Objetivo e Inactibilidades

A função objetivo pode ser calculada facilmente para cada proposta da solução, da mesma maneira as inactibilidades. Normalmente como já vimos no algoritmo genético tradicional, a função objetivo é penalizada ou as propostas de solução inactíveis são desprezadas. Uma proposta diferente é apresentada: a função objetivo original (*fitness*) e a inactibilidade (*unfitness*) de cada proposta de solução é calculada e armazenada separadamente e usada com fins diferentes.

Quando os elementos da população corrente são todos factíveis, a função objetivo é utilizada na substituição de um elemento e também utilizada para implementar a seleção. E quando existe inactibilidades na população corrente o *unfitness* é utilizado para substituir o indivíduo da população.

4.3.3. Substituição da população

Na proposta de Chu-Beasley, a substituição da população não ocorre de maneira geracional como é feito no algoritmo genético tradicional, e nem se usa o conceito do elitismo. A proposta de substituição consiste em, a cada passo, apenas um indivíduo da população é substituído.

O descendente gerado é candidato a substituir outro indivíduo da população usando a seguinte estratégia: 1) Se o descendente gerado é inactível, deverá substituir o mais inactível, caso exista mais de um candidato; 2) Se factível, substitui o indivíduo mais inactível, mas se todos os indivíduos são factíveis, então ele substitui o de pior qualidade, desde que o descendente seja de melhor qualidade. Ele também deverá ser diferente dos demais indivíduos da população; se for igual a um indivíduo da população não ocorrerá a substituição e este descendente será descartado.

Esta proposta se mostra mais eficiente do que a do algoritmo genético tradicional, pelos seguintes motivos: 1) Permite que os indivíduos da população sejam sempre diferentes; 2) As propostas inactíveis somente são preservadas quando existem poucas propostas de soluções factíveis e eventualmente podem participar na geração de descendentes; 3) Somente há substituições de indivíduos factíveis quando aparecem propostas factíveis de melhor qualidade, preservando a qualidade da população.

4.3.4. Seleção

A seleção utilizada é a seleção por torneio com $k = 2$, é possível pensar num $k \in \{1,4\}$, dependendo da complexidade do problema, em cada jogo então, participam dois indivíduos da população corrente, sendo vencedora a topologia que apresentar a melhor solução. Publicações recentes vêm demonstrando que essa é uma das formas mais eficientes de realizar a seleção, mantendo obviamente a adequada escolha do parâmetro k .

4.3.5. Recombinação

Aqui é utilizada a recombinação de apenas um ponto, escolhe-se aleatoriamente um ponto para recombinação e gera-se o descendente com uma parcela de cada uma das topologias participantes, separadas pelo ponto de recombinação. Tradicionalmente são gerados dois novos descendentes. No algoritmo de *Chu-Beasley*, gera-se apenas um descendente, escolhido aleatoriamente, e o outro é desprezado.

Veja no exemplo abaixo com $n=12$:

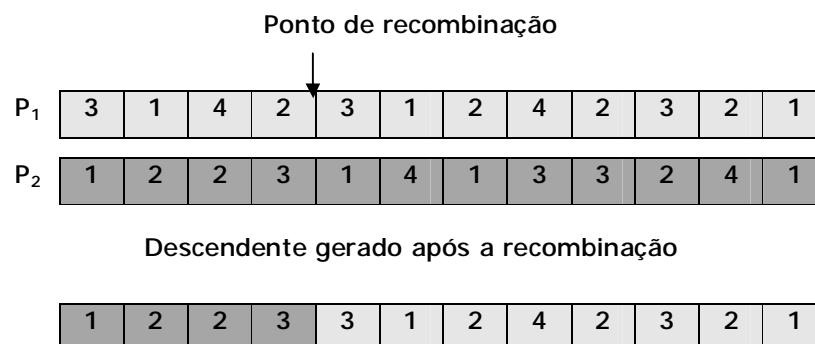


Figura 4-4 - Recombinação no AG Chu-Beasley.

4.3.6. Mutação

A mutação é realizada escolhendo aleatoriamente duas tarefas que são realizadas por dois agentes. No exemplo abaixo foram escolhidos aleatoriamente as tarefas 3 e 6, portanto, o agente 2 que realizava a tarefa 3 passará a realizar a tarefa 6 e, o agente 1 que realizava a tarefa 6 passará a realizar a tarefa 3. Para o GAP acredita-se que esse tipo de mutação é mais eficiente. O Algoritmo de *Chu-Beasley* ainda considera um processo de busca local para melhorar a qualidade do descendente gerado, podendo assim implementar uma fase de melhoria da infactibilidade do descendente e outra fase de melhoria da função objetivo do descendente.

Exemplo de mutação:

Pontos de mutação											
1	2	2	3	3	1	2	4	2	3	2	1
Descendente gerado após mutação											
1	2	1	3	3	2	2	4	2	3	2	1

Figura 4-5 - Mutação no AG Chu-Beasley.

4.3.7. Melhorando a Infactibilidade

Se após o processo de mutação o descendente gerado for infactível, então tenta-se melhorar sua infactibilidade da seguinte forma, faz-se uma varredura na seqüência de 1 a m , verificando-se a existência de um agente que possa assumir essa tarefa sem violar sua capacidade.

Caso seja encontrado um agente com sua capacidade violada então, escolhe-se aleatoriamente uma tarefa realizada por esse agente e tenta-se repassar essa tarefa para outro agente na seqüência $i+1, i+2, \dots, m, 1, 2, \dots, i-1$. A tarefa é transferida para o primeiro agente identificado com a possibilidade de realizar a tarefa escolhida sem violar sua capacidade.

4.3.8. Melhorando a Função Objetivo

Neste caso, pretende-se melhorar a função objetivo do descendente gerado. Assim, é analisada a possibilidade de que cada tarefa seja

transferida para outro agente com capacidade de realizar a tarefa com menor custo.

Para cada tarefa j é verificada a possibilidade de que essa tarefa seja realizada por outro agente com menor custo e sem violar a capacidade do agente que recebe a tarefa. Portanto, a tarefa é transferida para o agente que pode realizá-la com o menor custo e sem violar sua capacidade.

4.3.9. O Algoritmo

O Algoritmo genético de Chu-Beasley assume a seguinte forma:

- 1) Especificam-se os parâmetros de controle.
 - 2) Gera-se a população inicial aleatoriamente. Transformando a população inicial na população corrente.
 - 3) Deve-se substituir um indivíduo da população corrente:
 - a) Seleção por torneio com $k = 2$ (dois jogadores) escolhe-se duas topologias da população geradora usando apenas o *fitness*;
 - b) Recombinação de um ponto nas topologias selecionadas, escolhendo-se aleatoriamente o ponto de recombinação e escolhendo de forma aleatória apenas um descendente após a recombinação, descartando o outro descendente;
 - c) Mutação que consiste na troca de duas tarefas escolhidas de forma aleatória, onde os agentes permutam suas tarefas; se Ineficaz, tenta-se melhorar esse descendente, através do repasse de uma tarefa aleatoriamente escolhida para outro agente em condições de realizá-la sem violar sua capacidade. A análise deverá ser feita na seqüência de $1 a m$ para todos os agentes.
 - d) Tenta-se melhorar a função objetivo. Neste caso analisa-se as tarefas na seqüência de $1 a n$ e verifica-se a possibilidade de que cada tarefa seja repassada para o agente que tem a possibilidade de fazê-la e com o menor custo;
-

- 4) Atualização da população corrente: O descendente gerado pode ser incorporado na população corrente se atender as seguintes condições:
 - a) Se o descendente for igual a alguma topologia da população corrente será descartado para evitar o armazenamento de topologias repetidas na população corrente;
 - b) Se *infectível*, e se na população corrente existem topologias *infectíveis*, o descendente gerado substituirá a topologia de maior *infectibilidade*, isso se essa *infectibilidade* for maior que a do descendente gerado, senão, o descendente é descartado;
 - c) Se *factível*, deve-se substituir a topologia com maior *infectibilidade* e se todas as topologias da população são *factíveis* então o descendente gerado substituirá a topologia de pior qualidade, desde que o descendente seja de melhor qualidade, senão, o descendente é descartado.
- 5) Se critério de parada for satisfeito, parar; senão, atualizar iterações e voltar ao passo 3.

Nos testes realizados por Chu-Beasley para o problema GAP o processo termina quando a incumbente não melhora após 500.000 transições, isto é, após geração de 500.000 descendentes.

Outro parâmetro de controle utilizado no algoritmo de Chu-Beasley é a população de tamanho 100 para um problema GAP.

Esse algoritmo apresenta algumas características interessantes que provam o seu excelente desempenho. A lógica de substituição da topologia na população corrente, sempre ocorrerá quando encontrada uma solução de melhor qualidade que a topologia de pior qualidade na população corrente.

Portanto, a incumbente e as melhores topologias somente deixam a população corrente quando um descendente de melhor qualidade for encontrado.

Outro ponto é que, na fase da melhoria local ocorre com que a inactibilidade do descendente melhora, assim a estratégia da função objetivo fornece uma estratégia interessante, a qual permite uma evolução mais eficiente do algoritmo genético.

4.4. Melhorias no Algoritmo Genético de Chu-Beasley

O algoritmo genético modificado pode ainda ser melhorado através de propostas que podem ser introduzidas no algoritmo. Algumas dessas propostas são as seguintes:

1. Geração eficiente da população inicial. Em testes experimentais foi verificado que a população inicial gerada aleatoriamente geralmente está constituída por todas as propostas de solução inactíveis e, na maioria dos casos, com um nível de inactibilidade elevado. Pode-se implementar algoritmos heurísticos construtivos rápidos para gerar uma população inicial de melhor qualidade;
2. Melhoria na fase de busca local. Deve-se observar que as propostas de busca local para melhorar a qualidade do descendente gerado são muito simples. Particularmente, a fase de melhoria da inactibilidade do descendente gerado se torna pouco eficiente nas fases finais do processo. Também a fase de melhoria da função objetivo do descendente gerado pode se tornar pouco eficiente nas fases finais do processo em que pode ser muito difícil transferir uma tarefa para outro agente. Assim, por exemplo, a proposta de trocar tarefas pode ser mais eficiente em uma fase em que todos os agentes se encontram com uma taxa de ocupação perto do limite.

Para problemas complexos pode ser mais eficiente usar um tamanho de população maior porque os elementos da população sempre são diferentes.

Nesse caso, população grande significa grande diversidade de topologia. Entretanto, esse incremento da população deve ser acompanhado do aumento de jogadores na seleção por torneio. Assim, por exemplo, uma

população de tamanho 200 deve ser acompanhado de um aumento de $k = 4$ ou $k = 5$ (topologias) para implementar a seleção. Esses valores podem ser mais bem calibrados com testes experimentais.

4.5. Algoritmo Genético de Chu-Beasley aplicado ao PEST

Apresentaremos uma metaheurística que representa uma versão modificada da proposta de Chu-Beasley, essa proposta está voltada para aplicação em otimização de problemas complexos de sistemas de energia elétrica.

A metaheurística proposta sugere alterar o algoritmo de Chu-Beasley naqueles pontos onde são cruciais para uma melhoria no seu desempenho, são eles: 1) Geração da população inicial, 2) Na fase de melhoria local do descendente gerado, e 3) No incremento do controle da diversidade.

Para a geração da população inicial usaremos algoritmos heurísticos e estratégias adicionais muito simples, constituída apenas de soluções factíveis tornando a função do vetor *unfitness* na proposta original de Chu-Beasley pouco atrativa ou irrelevante.

Na fase de melhoria local pode-se usar também algoritmos heurísticos rápidos e eficientes, que na maioria dos casos eliminam totalmente as infactibilidades do descendente gerado, assim como também podem melhorar a qualidade da função objetivo. O algoritmo de Chu-Beasley não elimina totalmente as propostas infactíveis e a melhoria da qualidade também é pobre. Sendo assim, considera-se que nesse passo possam ser utilizados algoritmos heurísticos eficientes existentes na bibliografia especializada para cada tipo de problema de sistemas de energia elétrica.

Na proposta de Chu-Beasley, o controle da diversidade se limita apenas em verificar se a proposta é uma solução diferente das demais topologias da população corrente, isso frequentemente acontece da proposta ser diferente e ser restrita a pequenas diferenças e em consequência estar representando um número reduzido de regiões no espaço de busca.

Nossa proposta para contar essa problemática é bastante simples, assim um descendente pode entrar na população corrente se cumpre os seguintes requisitos: 1) Se for de melhor qualidade que a solução armazenada de pior qualidade e, 2) Se for diferente de cada um dos indivíduos da população em um número mínimo de elementos do vetor de codificação.

O descendente ainda pode ser incorporado na população se não satisfizer o critério de diversidade, desde que ele seja de melhor qualidade que todas as soluções armazenadas na população corrente, entretanto, devemos retirar todas as soluções que não satisfaçam o critério de diversidade para preservar a diversidade, isso poderá causar uma alteração no tamanho especificado da população.

Essa proposta pretende eliminar as soluções vizinhas de pior qualidade e facilitar a busca de soluções em outras regiões do espaço de busca.

A metaheurística proposta pode ser resumida nos seguintes passos:

1. Especificar os parâmetros de controle (tamanho da população, taxa de recombinação, taxa de mutação, etc.).
 2. Especificar as características genéticas do algoritmo, tais como: tipo de codificação, população inicial, manipulação de infactibilidades, escolha de seleção por torneio, etc.
 3. Encontrar uma população inicial usando algoritmos heurísticos eficientes, robustos e rápidos. A proposta de priorizar o uso de algoritmos que geram apenas soluções factíveis. Montar o *fitness* e *unfitness* da população inicial.
 4. Implementar a seleção por torneio para escolher apenas duas soluções geradoras.
 5. Implementar a recombinação e preservar apenas um descendente.
 6. Implementar a mutação do descendente preservado.
-

7. Implementar uma fase de melhoria local do descendente preservado usando algoritmos heurísticos e eficientes.
8. Decidir se o descendente melhorado pode entrar na população substituindo um elemento da população após verificar o teste de substituição de um indivíduo da população.
9. Se o critério de parada não for satisfeito voltar ao passo 4, senão, terminar o processo.

As principais mudanças apresentadas no algoritmo anterior já foram comentadas. Entretanto, deve-se especificar com maior detalhe o teste de substituição mencionado no passo 8.

Teste de Substituição:

Para que um descendente entre na população corrente deve satisfazer um teste de substituição.

Para executar o teste inicialmente percorre-se o vetor de *fitness* e armazena-se o valor do seguinte parâmetro $n_{unf} = \{0, -1, pos\}$.

Sendo que:

- $n_{unf} = 0$: Indica que não existem soluções ineficazes na população corrente;
 - $n_{unf} = -1$: Há soluções ineficazes na população corrente, e o descendente gerado é mais ineficaz, ou seja, o descendente é pior que a solução da população corrente de pior qualidade, isso indica que esse descendente deverá ser eliminado;
 - $n_{unf} = pos$: Há soluções ineficazes na população corrente, porém, o descendente gerado é menos ineficaz, ou seja, existe na população corrente indivíduo mais ineficaz que o descendente gerado; *pos* indica a posição desse indivíduo na população corrente. O descendente gerado, deverá ocupar essa posição do indivíduo na população corrente.
-

Também se percorre o vetor de *unfitness* e armazenar-se o valor dos seguinte parâmetros $n_{fit} = \{0, pos\}$.

- $n_{fit} = 0$: Indica que todas as soluções da população corrente possuem uma factibilidade melhor que a factibilidade do descendente gerado, ou seja, todos são melhores que o descendente gerado;
- $n_{fit} = pos$: Indica a posição da solução de pior qualidade na população corrente, pior que o descendente gerado, portanto, candidato a ser eliminado.

Outros parâmetros também deverão ser gerados para a realização do teste de substituição, como segue:

- n_{aux} : Vetor de dimensão n_{pop} para armanezar a posição das soluções da população corrente que não satisfazem o critério de diversidade em relação ao descendente gerado, e de acordo com o parâmetro n_{div} ;
 - n_{div} : Número de posições que irão definir o critério de diversidade, indica quantas posições o descendente gerado tem que ser diferente em relação aos indivíduos da população corrente;
 - k_n : Número de soluções da população corrente que não satisfazem o critério de diversidade;
 - n_{pop} : Especifica o tamanho da população inicial, esse valor poderá sofrer alteração no decorrer do processo de otimização;
 - n_{pc} : Especifica o tamanho da população corrente;
-

- $fit_d = 1$: Indica que a Função Objetivo do descendente gerado é melhor que todas as soluções que não cumprem com o critério de diversidade;
- $w_k = valor$: Indica se o descendente gerado é factível ($w_k = 0$) ou infactível ($w_k \neq 0$);
- n_{dif} : Vetor de dimensão n_{pop} que irá armazenar a quantidade de posições diferentes de cada indivíduo da população corrente em relação ao descendente gerado.

Com os parâmetros especificados, o teste de diversidade, que determina o processo de substituição de um indivíduo da população por um descendente assume a seguinte forma:

1. Percorrer os vetores *fitness* e *unfitness*, encontrar o valor dos parâmetros de controle e verificar se o descendente satisfaz o critério de diversidade, conforme ilustra as figuras 4-6 e figura 4-7;
 2. Se o descendente não satisfaz o critério de diversidade ($k_n \neq 0$) fazer o seguinte:
 - a) Se o descendente gerado é factível ($w_k = 0$) e a função objetivo desse descendente é melhor que todas as soluções que não satisfazem o critério de diversidade ($fit_d = 1$), então, incorporar o descendente na população; eliminar todas as k_n soluções que não satisfazem o critério de diversidade; e fazer $n_{pc} = n_{pc} - k_n + 1$ e ir ao passo 6;
 - b) Em caso contrário, eliminar o descendente gerado, ir ao passo 6.
 3. Se o descendente satisfaz o critério de diversidade ($k_n = 0$) fazer o seguinte:
-

- a) Se $n_{pc} < n_{pop}$, então, incorporar o descendente na população; e, Fazer $n_{pc} = n_{pc} + 1$ e ir ao passo 6;
 - b) Em caso contrário, ir ao passo 4.
4. Se o descendente for inactivável ($w_k \neq 0$) fazer o seguinte:
- a) Se não existem soluções inactiváveis ($n_{unf} = 0$) eliminar o descendente gerado e ir ao passo 6. Em caso contrario ir ao passo 4(b);
 - b) Se existem soluções inactiváveis, mas todas tem menor inactivabilidade que do descendente gerado ($n_{unf} = -1$) eliminar o descendente gerado e ir ao passo 6. Em caso contrário, ir ao passo 4(c);
 - c) Em caso contrário ($n_{unf} = pos$), e existe uma solução com maior inactivabilidade que do descendente gerado e localizado na posição $n_{unf} = pos$. Incorporar o descendente gerado na população retirando a solução que se encontra na posição $n_{unf} = pos$ e ir ao passo 6.
5. Se o descendente for factível ($w_k = 0$) fazer o seguinte:
- a) Se existem soluções inactiváveis ($n_{unf} = pos$) então, nesse caso substituir a solução inactivável localizado na posição $n_{unf} = pos$ pelo descendente gerado e ir ao passo 6. Em caso contrário, ir ao passo 5 (b);
 - b) Se todas as soluções factíveis são de melhor qualidade ($n_{fit} = 0$) então, eliminar o descendente gerado e ir ao passo 6. Em caso contrário, ir ao passo 5 (c);
 - c) Existe uma solução factível de pior qualidade localizada na posição $n_{fit} = pos$. Incorporar o descendente gerado na
-

população corrente trocando com a solução armazenada na posição $n_{fit} = pos$ da população e ir ao passo 6.

- Terminar o processo de substituição atualizando alguns parâmetros e a solução incumbente se for o caso.

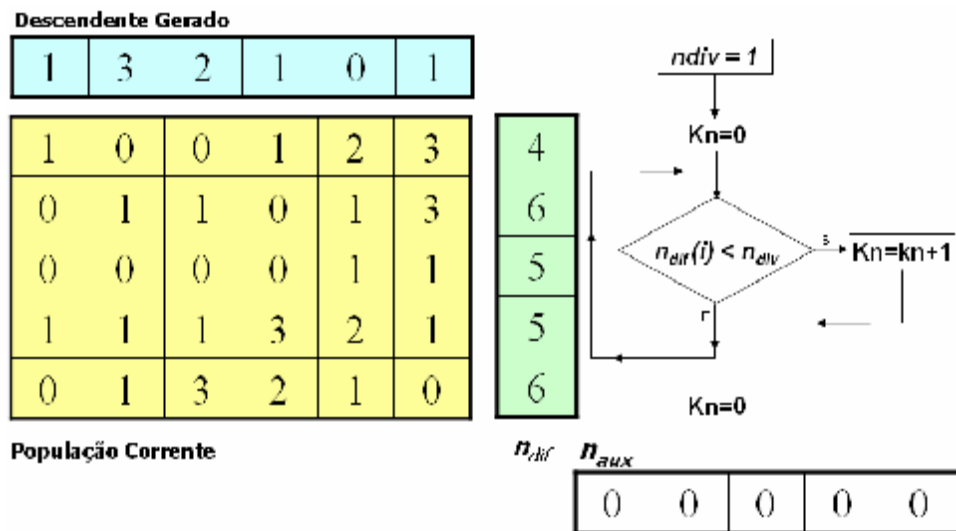


Figura 4-6 - Cumpre Critério de Diversidade.

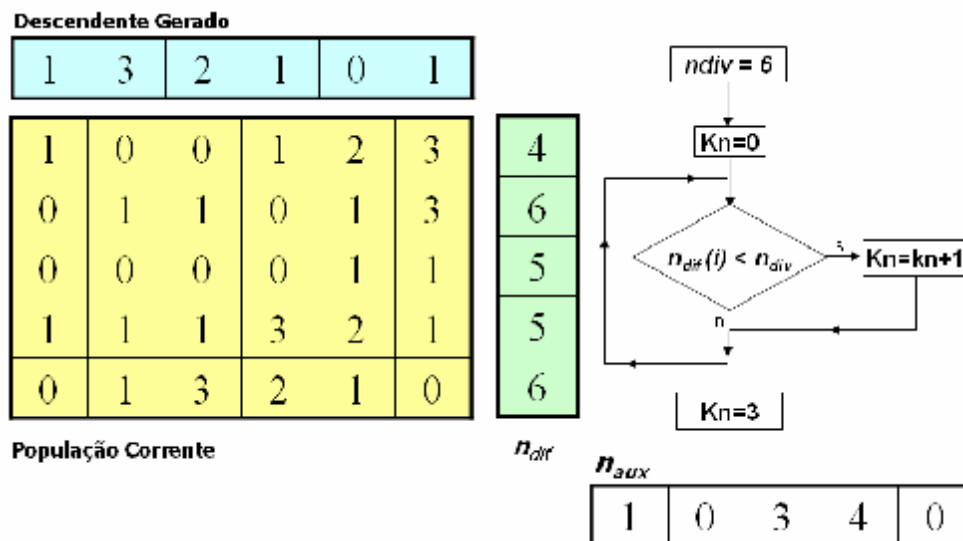


Figura 4-7 - Não cumpre o Critério de Diversidade.

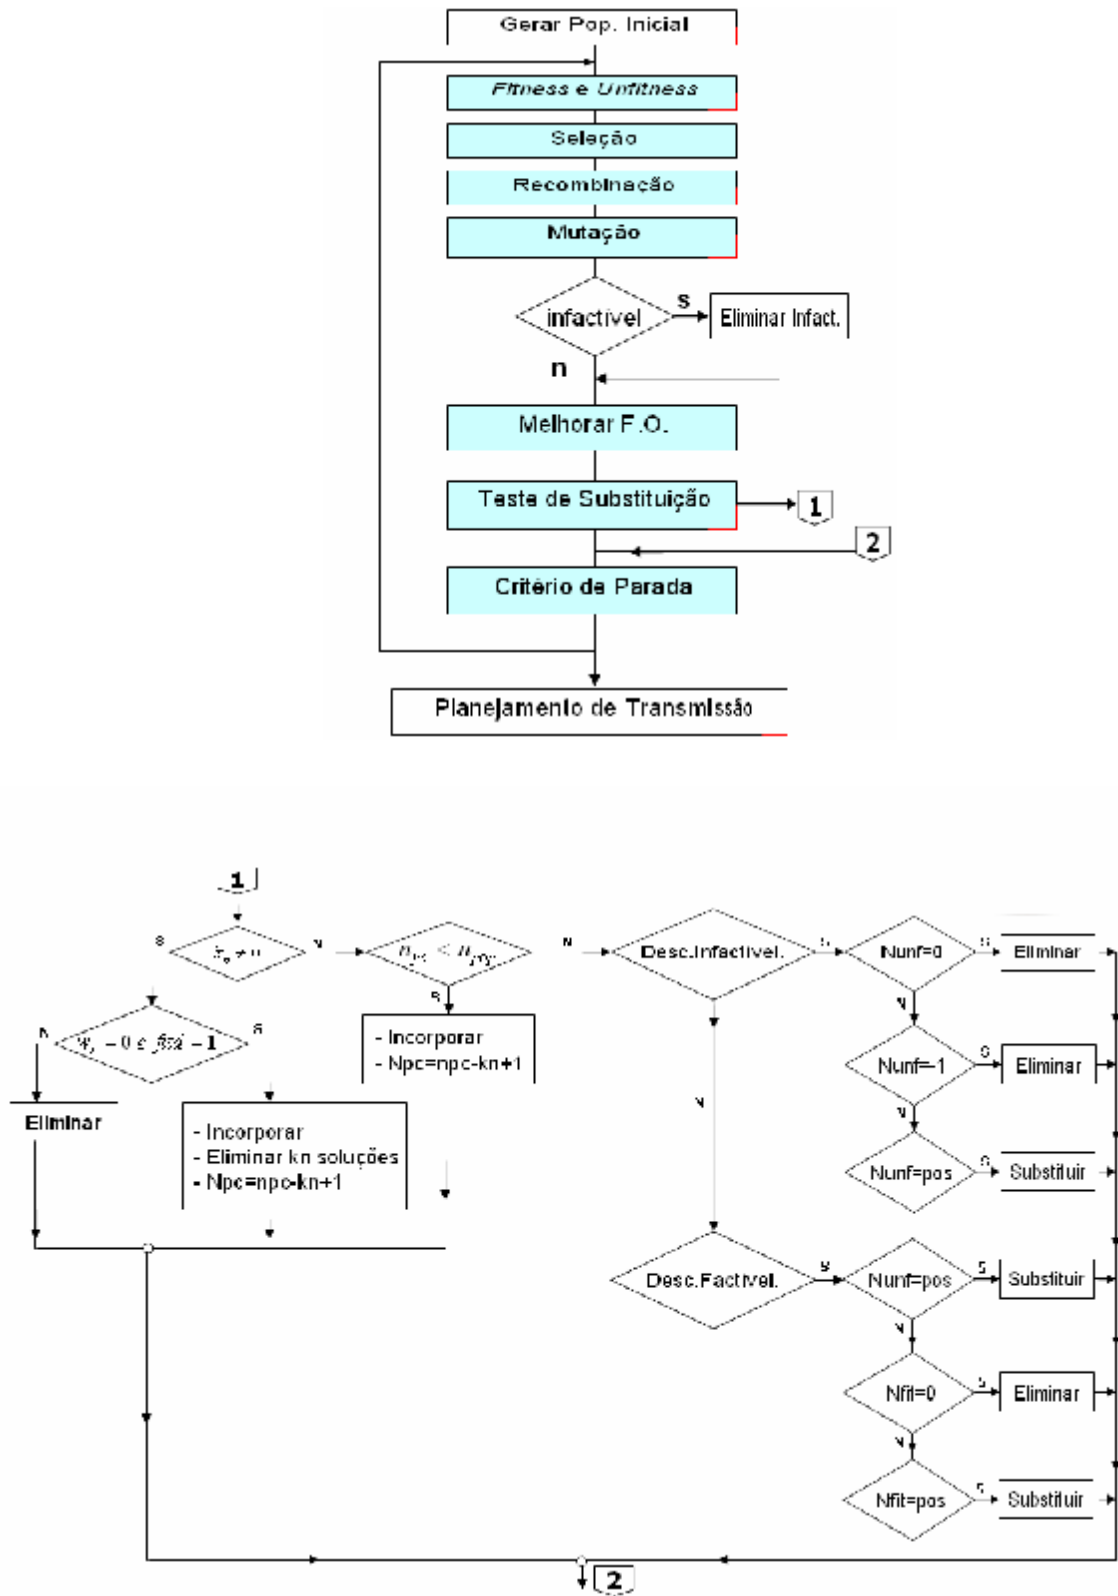


Figura 4-8 - Diagrama de blocos do teste de substituição.

Capítulo 5

Testes e Resultados

5.1. Introdução

Como já foi citado nos capítulos anteriores, essa nova proposta de planejamento é um novo paradigma em relação à forma tradicional de planejar a expansão de um sistema de transmissão de energia elétrica.

Pode-se considerar como sendo assim, pelo fato de que normalmente a expansão significa construção de novas linhas de transmissão. E as linhas de transmissão que compõem a configuração base não sofrem alterações nesse processo de expansão tradicional.

Nessa nova metodologia de planejamento, considera-se a possibilidade de subtraí-las; dessa forma, propõe-se expandir um sistema de transmissão de energia elétrica considerando a possibilidade da retirada de linhas de transmissão da configuração base.

Com uma pequena modificação na modelagem matemática, e para esse nosso caso o modelo utilizado é o DC, transfere-se a dificuldade de resolução do problema para a técnica de solução.

Para isso, usa-se um algoritmo genético especializado, o algoritmo genético de Chu-Beasley, que se mostrou mais eficiente que o algoritmo genético tradicional. Também foi implementada uma modificação no algoritmo genético de Chu-Beasley, o chamado teste de substituição, objetivando a entrada na população de um indivíduo de melhor qualidade.

Nesse capítulo, são mostrados os resultados obtidos considerando essa metodologia proposta para o planejamento da expansão de sistemas de transmissão de energia elétrica, fazendo uma analogia de resultados entre o planejamento tradicional e planejamento proposto.

5.2. Detalhes da Implementação Computacional

Um detalhe muito importante em relação à implementação computacional está relacionado com a codificação e a forma de calcular a função objetivo ou o seu equivalente em um algoritmo genético. Neste trabalho, também, deve-se especificar claramente a forma de codificação e a maneira de calcular a função objetivo entre o planejamento tradicional e o planejamento proposto, ambos os modelos são resolvidos com um algoritmo genético.

Quando é usado um algoritmo genético para resolver o problema de planejamento, a única forma de codificação eficiente mostrada na literatura especializada consiste em codificar apenas as variáveis de investimento n_{ij} .

Portanto, o valor exato das variáveis contínuas, tais como ângulos de tensão de barra e níveis de geração nas barras de geração, são encontradas resolvendo um problema de programação linear (PL).

A resolução do problema de PL nos fornece também a informação sobre a qualidade da proposta de investimento, isto é, se a expansão produz uma proposta de operação ou se essa ela é insuficiente. Essa informação aparece na forma de corte de carga. Assim, se a proposta de expansão não produz corte de carga então ela é factível, em caso contrário, é infactível.

Usaremos o sistema de 6 barras de Garver mostrado na figura 5-1 para exibir os detalhes da codificação. Assim, para uma proposta de investimento típica n^p com elementos n_{ij}^p , no planejamento tradicional o vetor de codificação de uma proposta de investimento assume a seguinte forma:

$$n^p = \begin{array}{c} \begin{array}{cccccccccccccccc} 1-2 & 1-3 & 1-4 & 1-5 & 1-6 & 2-3 & 2-4 & 2-5 & 2-6 & 3-4 & 3-5 & 3-6 & 4-5 & 4-6 & 5-6 \end{array} \\ \begin{array}{|c|c|c|c|c|c|c|c|c|c|c|c|c|c|c|} \hline 0 & 0 & 0 & 0 & 1 & 2 & 0 & 0 & 2 & 0 & 1 & 0 & 0 & 2 & 0 \end{array} \end{array}$$

Figura 5-1 - Vetor de codificação de uma proposta de investimento.

A codificação anterior representa uma proposta de investimento com a adição de um circuito entre as barras 1-6, dois circuitos entre as barras 2-3,

dois circuitos entre as barras 2-6, um circuito entre as barras 3-5 e dois circuitos entre as barras 4-6.

Deve-se observar que os elementos do vetor n^p variam entre zero e \bar{n}_{ij} e esses limites são controlados explicitamente ao gerar a população inicial e ao executar o operador de mutação.

Adicionalmente, a informação da topologia base se encontra em um outro vetor que permanece inalterável e assume a forma mostrada na Figura 5-2.

$$n^o = \begin{array}{cccccccccccccccc} 1-2 & 1-3 & 1-4 & 1-5 & 1-6 & 2-3 & 2-4 & 2-5 & 2-6 & 3-4 & 3-5 & 3-6 & 4-5 & 4-6 & 5-6 \\ \hline 1 & 0 & 1 & 1 & 0 & 1 & 1 & 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 \end{array}$$

Figura 5-2 - Vetor de codificação da topologia base.




Figura 5-3 - Sistema de 6 barras Garver - topologia inicial.

Portanto, a chamada topologia corrente, isto é, o número de linhas existentes na topologia base e na proposta de expansão corrente, é obtida da seguinte forma: $n^c = n^o + n^p$.

O vetor n^c com elementos n_{ij}^c representa a topologia corrente e essa informação é usada para resolver o problema de PPL, para verificar o corte de carga, que assume a forma da equação 5.1:

$$w = \sum r_k \quad (5.1)$$

s.a.

$$Sf + g + r = d$$

$$f_{ij} - g_{ij} n_{ij}^c (q_i - q_j) = 0$$

$$|f_{ij}| \leq n_{ij}^c \bar{f}_{ij}$$

$$0 \leq g \leq \bar{g}$$

$$0 \leq r \leq d$$

$$f_{ij} \text{ irrestrito}$$

$$q_j \text{ irrestrito}$$

Deve-se observar que o PPL mostrado em (5.1) é obtido do modelo DC apresentado em (2.8), após fixar o valor das variáveis de investimento n_{ij} . Finalmente, para encontrar a função objetivo e de forma mais geral dentro do contexto do algoritmo genético de Chu-Beasley, os valores de *fitness*, v_1 , e de *unfitness*, v_2 , assumem a seguinte forma:

$$v_1 = \sum c_{ij} n_{ij}^p$$

$$v_2 = w$$

Sendo que v_1 representa o custo de expansão em linhas de transmissão e v_2 representa o corte de carga para uma proposta de expansão especificada. Se $v_2 = 0$, a proposta é factível e, em caso contrário, é infactível.

Para resolver o problema de expansão de sistemas de transmissão modificado é utiliza-se a mesma estrutura de codificação usada para o

planejamento tradicional, com as correspondentes modificações para levar em conta as características do novo problema.

Assim, a estrutura do vetor n^o permanece inalterada e as eventuais retiradas de linhas de transmissão são incorporadas no vetor n^p . Portanto, uma proposta típica de expansão para o novo modelo de planejamento da expansão de sistemas de transmissão assume a forma da Figura 5-4.

$$n^p = \begin{array}{c} \begin{array}{cccccccccccccccc} 1-2 & 1-3 & 1-4 & 1-5 & 1-6 & 2-3 & 2-4 & 2-5 & 2-6 & 3-4 & 3-5 & 3-6 & 4-5 & 4-6 & 5-6 \\ \hline 0 & 0 & -1 & 0 & 0 & 0 & -1 & 0 & 2 & 0 & 1 & 0 & 0 & 2 & 0 \end{array} \end{array}$$

Figura 5-4 - Vetor de codificação de uma proposta típica no novo modelo.

A proposta anterior representa uma proposta de investimento com a adição de dois circuitos entre as barras 2-6, um circuito entre as barras 3-5, dois circuitos entre as barras 4-6 e a retirada de um circuito entre as barras 1-4 e um circuito entre as barras 2-4.

Adicionalmente, os elementos do vetor n^p variam entre $-n_{ij}^o$ e \bar{n}_{ij} e esses limites são controlados explicitamente ao gerar a população inicial e ao executar o operador de mutação. Portanto, a diferença fundamental entre ambas propostas é que o vetor n^p pode assumir valores negativos quando existe a proposta de retirar linhas em caminhos em que existem linhas na topologia base.

Com a adaptação do vetor de codificação n^p , a forma do vetor n^c assim como a forma do PPL a ser resolvido para verificar se a proposta gera corte de carga, permanece inalterada. Entretanto, em sistemas elétricos com um número elevado de linhas de transmissão existentes na topologia base pode aparecer problemas na resolução do PL. Esse problema pode aparecer quando o sistema se torna desconexo e aparecem dois ou mais subsistemas. Nesse caso, deve-se modificar a forma de resolver o PPL. Para os sistemas testados neste trabalho, esse problema não apareceu.

Existe ainda o problema de levar em conta a retirada de linhas de transmissão existentes na topologia base. Na formulação matemática foi

considerado que as linhas existentes podem ser retiradas a um custo de zero. Entretanto, para incentivar a retirada de linhas de transmissão irrelevantes, o *fitness* (v_1) para uma proposta de investimento foi calculado da seguinte forma:

$$v_1 = \sum c_{ij}^p n_{ij}^p$$

Em que $c_{ij}^p = c_{ij}$ quando $n_{ij}^p \geq 0$ e $c_{ij}^p = -1$ quando $n_{ij}^p < 0$. A relação anterior é equivalente a considerar as adições de novas linhas de transmissão com os custos verdadeiros de c_{ij} e a retirada de linhas de transmissão com custos iguais a -1.

Assim, existe um incentivo insignificante (lucro de uma unidade) para a retirada de linhas de transmissão. Essa estratégia é usada apenas para tornar a retirada de uma linha de transmissão mais atrativa que permanecer no sistema elétrico se essa linha de transmissão realmente é irrelevante.

Adicionalmente, a população inicial foi gerada de forma aleatoriamente controlada, mas incorporando dentro da população a solução encontrada pelo algoritmo heurístico construtivo de Villasana-Garver-Salon.

A fase de melhoria local também faz testes simples de adição e retirada de linhas de transmissão. Em uma fase futura se pretende gerar a população inteira usando algoritmos heurísticos construtivos eficientes e rápidos.

Futuramente pretende-se implementar a fase de melhoria local usando algoritmos heurísticos construtivos. Na fase de diversidade foi usada apenas a exigência de que todos os elementos da população corrente devem ser diferentes.

Esses critérios foram suficientes para resolver dois sistemas muito usados na literatura especializada. Assim, neste trabalho foram testados dois sistemas, o sistema de Garver de 6 barras e o sistema sul-brasileiro de 46 barras.

5.3. Sistema de 6 Barras de Garver

Este sistema é muito usado em trabalhos de planejamento da expansão de sistemas de transmissão e os dados completos se encontram no apêndice A. O sistema é muito pequeno e, obviamente, existe pequena probabilidade de que existam linhas de transmissão irrelevantes na topologia base. Neste caso é possível realizar dois tipos de teste. Quando existe a possibilidade de reprogramar a geração e quando não existe a reprogramação da geração.

Para o caso em que existe reprogramação da geração a solução ótima global para o planejamento tradicional produz um investimento ótimo de $v = 110$ com as seguintes adições:

$$n_{3-5} = 1, n_{4-6} = 3$$

Os testes realizados com o modelo modificado encontrou a mesma solução. Assim, ambas propostas de planejamento produzem a mesma solução final e, portanto, a nova proposta de planejamento não produz mudança na estratégia de planejamento.

Para o caso em que não existe reprogramação da geração a solução ótima global para o planejamento tradicional produz um investimento ótimo de $v = 200$, mostrada na Figura 5-5, com as seguintes adições:

- Adição de linhas de transmissão: $n_{2-6} = 4, n_{3-5} = 1, n_{4-6} = 2$




Figura 5-5 - Sistema de 6 barras Garver - solução ótima tradicional.

Os testes realizados com o modelo modificado encontraram uma solução com o mesmo custo de expansão e com as mesmas linhas adicionadas que o planejamento tradicional.

Adicionalmente, produz a retirada de uma linha de transmissão no caminho 2-4, isto é, a proposta de expansão do planejamento modificado encontrou a solução mostrada na Figura 5-6.

- Adição de linhas de transmissão: $n_{2-6} = 4$, $n_{3-5} = 1$, $n_{4-6} = 2$;
- Retirada de linhas de transmissão: $n_{2-4} = 1$.

Essa proposta de expansão é mostrada na figura 5.6.

Nos testes para o sistema de 6 barras de Garver foi usado como critério de parada do algoritmo genético o número máximo de PPL's resolvidos. Assim, o algoritmo termina após resolver 1500 PPL's.




Figura 5-6 - Sistema de 6 barras Garver - solução ótima modificada.

5.4. Sistema Sul-Brasileiro de 46 Barras

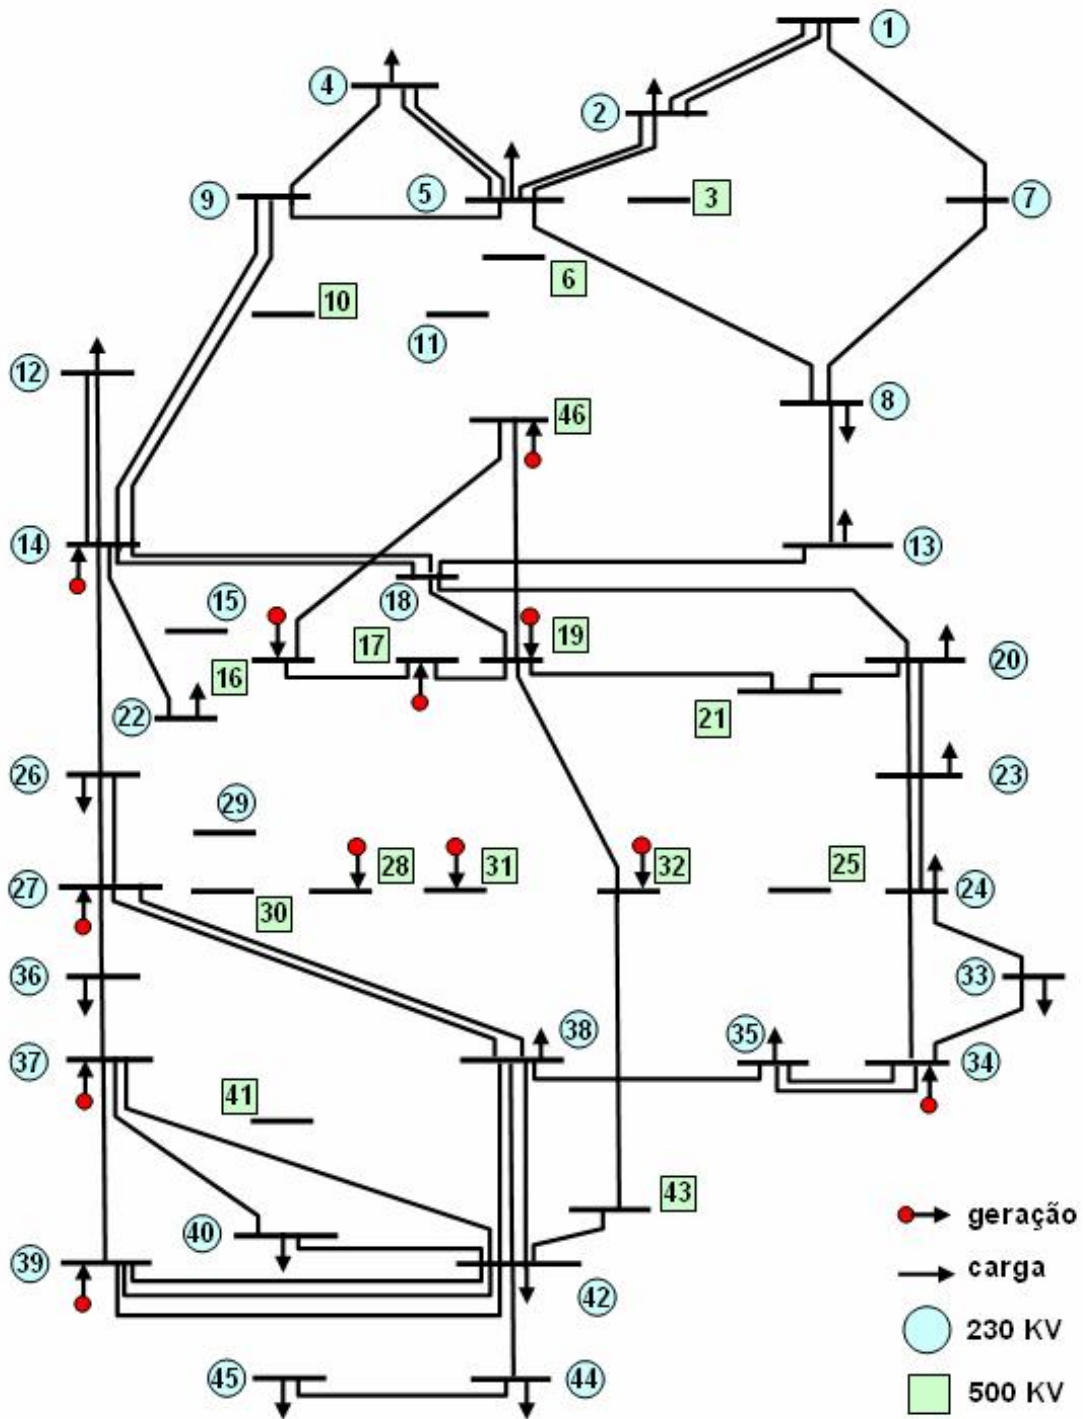


Figura 5-7 - Sistema sul-brasileiro - topologia base.

Este sistema também é muito usado em trabalhos de planejamento da expansão de sistemas de transmissão e representa o sistema com dados correspondentes à década de 80. Os dados completos se encontram no apêndice A.

Além de corresponder a um sistema real, representa um sistema de médio porte onde podem aparecer com mais frequência as diferenças entre os dois tipos de planejamento.

Neste caso, também é possível realizar dois tipos de testes. Quando existe a possibilidade de reprogramar a geração e quando não existe a reprogramação da geração. A Figura 5-7 mostra a topologia base e a Figura 5-8 mostra a topologia base e os novos caminhos para expansão, além da possibilidade de expansão em caminhos em que já existem linhas de transmissão.

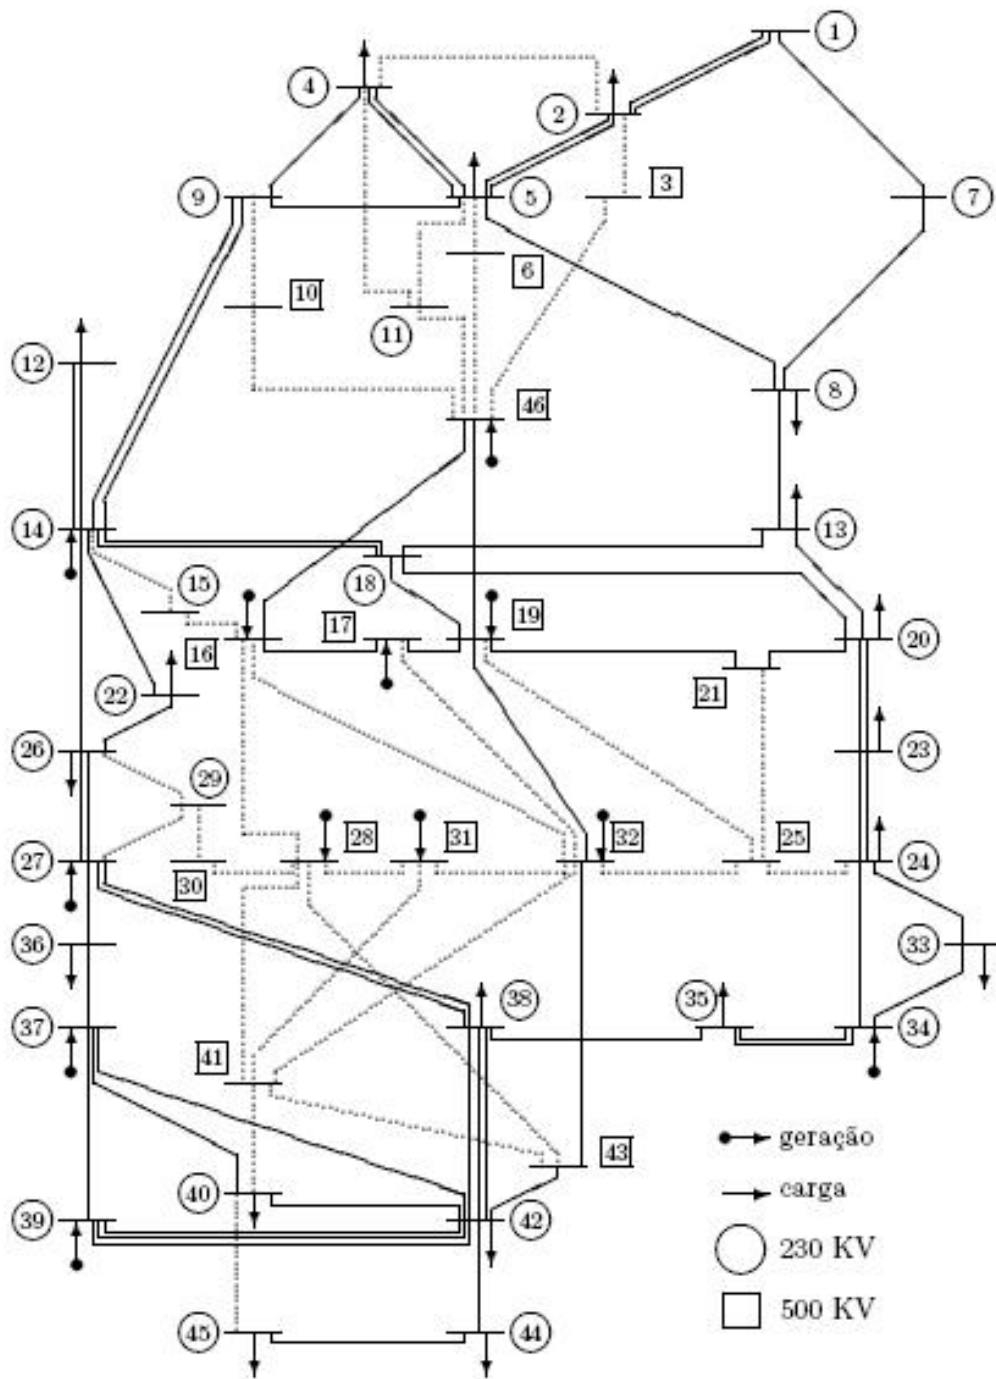


Figura 5-8 - Sistema sul-brasileiro: mostrando os novos caminhos

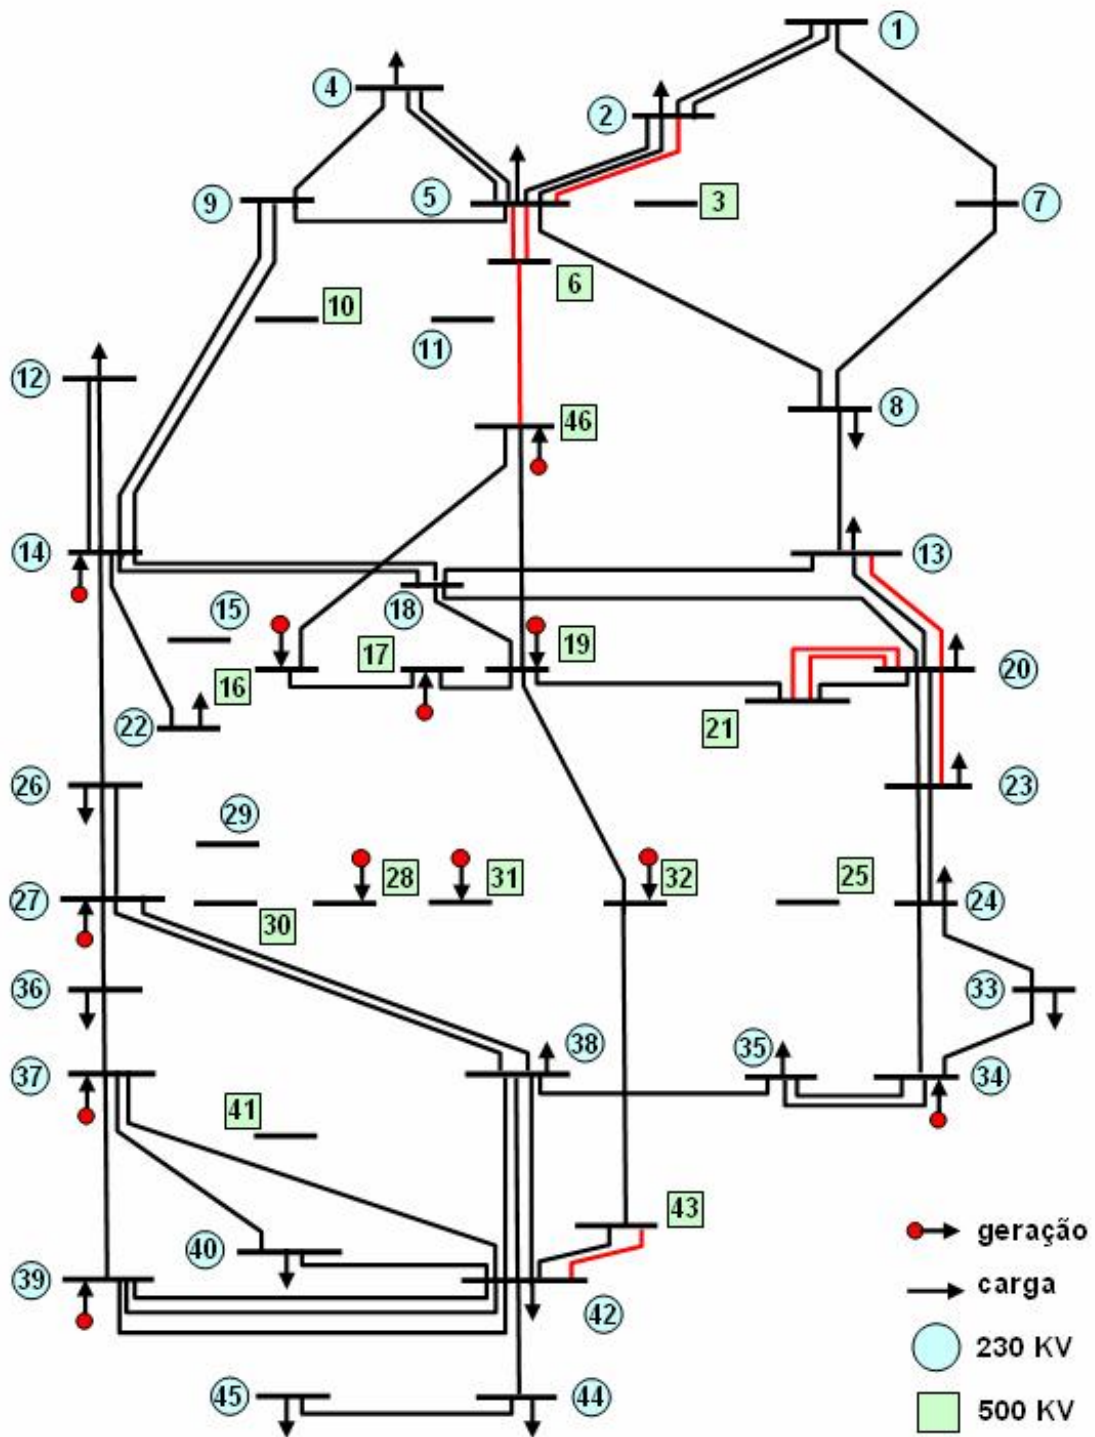


Figura 5-9 - Sistema sul-brasileiro: ótimo tradicional com redespacho.

Para o caso em que existe reprogramação da geração, a solução ótima global para o planejamento tradicional produz um investimento ótimo de $v = 72,870$ milhões de dólares com as seguintes adições:

- $n_{02-05} = 1, n_{13-20} = 1, n_{20-23} = 1, n_{20-21} = 2, n_{42-43} = 1, n_{06-46} = 1, n_{05-06} = 2$

A Figura 5-9 mostra o novo sistema expandido com o planejamento tradicional.

Os testes realizados com o modelo modificado encontraram uma solução com o menor custo de expansão que o planejamento tradicional e, de forma surpreendente, retira 20 linhas de transmissão que são consideradas irrelevantes para o caso de análise apenas da operação com o modelo DC. Assim, a nova forma de planejamento encontra uma solução com $v = 70,289$ milhões de dólares, que é apresentada na Figura 5.10.

- Adição de Linhas de Transmissão:

$$n_{13-20} = 1, n_{20-23} = 1, n_{20-21} = 2, n_{42-43} = 1, n_{06-46} = 1, n_{05-06} = 2;$$

- Retirada de Linhas de Transmissão:

$$n''_{01-07} = 1, n''_{01-02} = 2, n''_{04-09} = 1, n''_{05-09} = 1, n''_{07-08} = 1, n''_{09-14} = 2, n''_{14-18} = 1, n''_{23-24} = 1;$$

$$n''_{26-27} = 2, n''_{27-28} = 1, n''_{34-35} = 1, n''_{37-39} = 1, n''_{37-42} = 1, n''_{38-42} = 3, n''_{19-46} = 1.$$

Comparando apenas as linhas adicionadas por ambos os processos de planejamento, pode-se verificar que a proposta de planejamento modificada não adiciona a linha de transmissão no caminho 2-5.

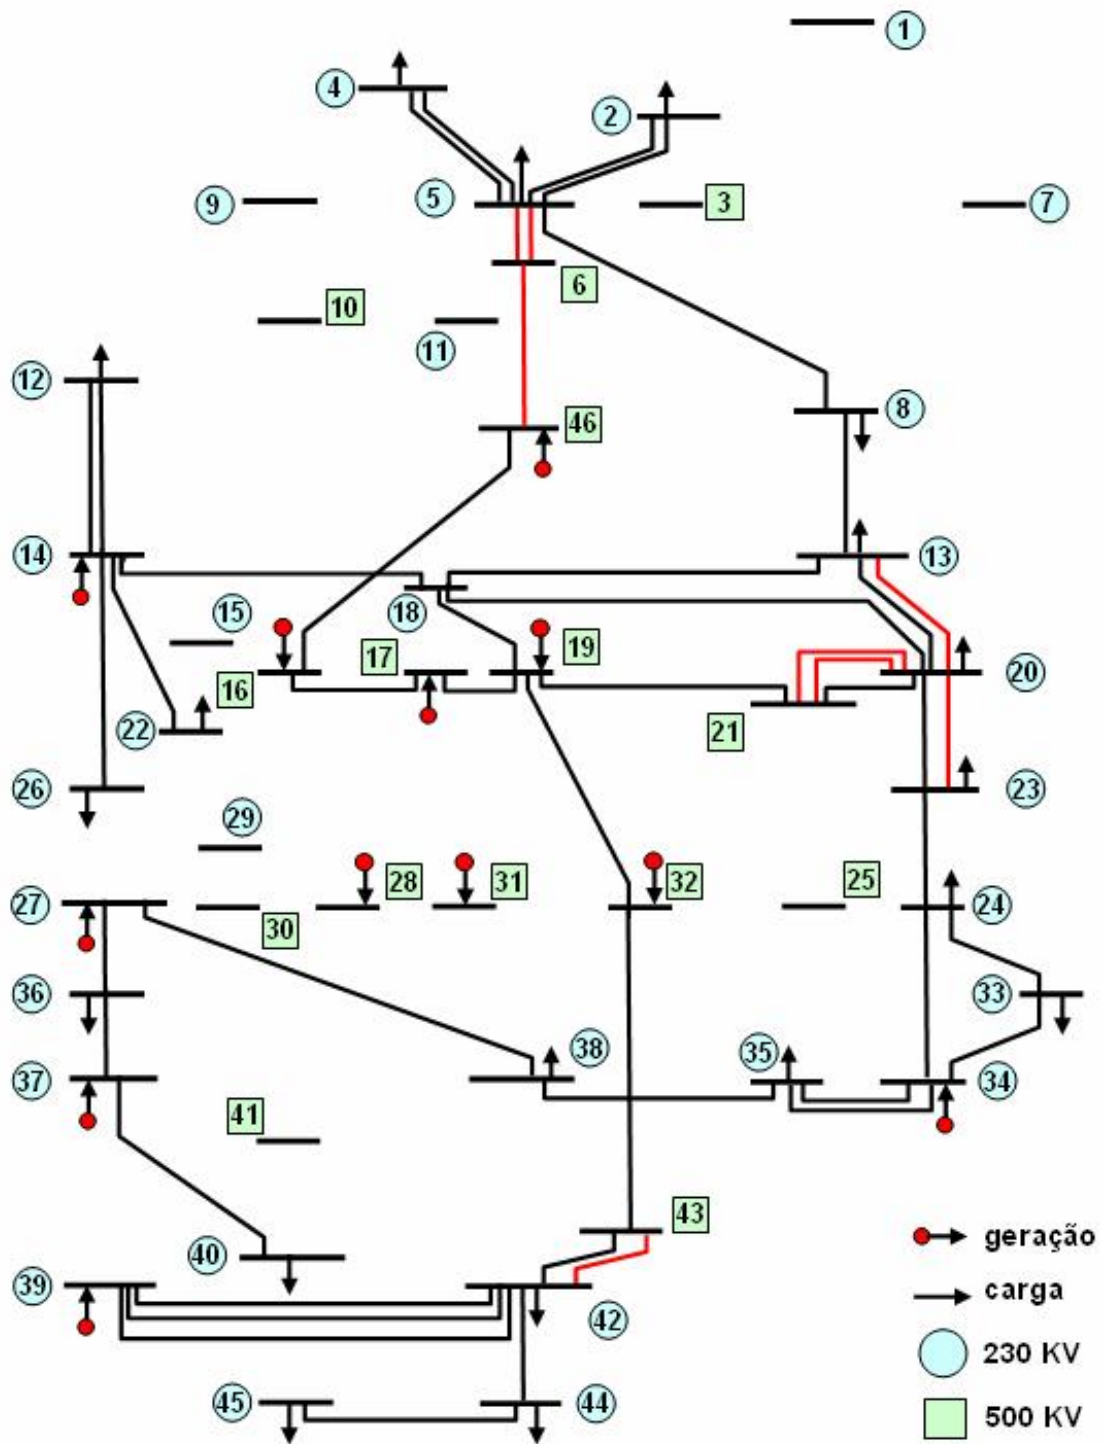


Figura 5-10 - Sistema Sul-Brasileiro - Planejamento Proposto

Existem ainda outras duas soluções com o mesmo investimento em expansão e com retirada de linhas de transmissão. Essas soluções, ligeiramente diferentes da solução anterior, produzem as seguintes retiradas de linhas de transmissão:

- Segunda solução ótima alternativa - Retirada das LT's:

$$n_{01-07}'' = 1, n_{01-02}'' = 2, n_{04-09}'' = 1, n_{05-09}'' = 1, n_{07-08}'' = 1, n_{09-14}'' = 2, n_{14-18}'' = 1, n_{23-24}'' = 1, \\ n_{26-27}'' = 2, n_{27-28}'' = 1, n_{34-35}'' = 1, n_{37-39}'' = 1, n_{37-42}'' = 1, n_{40-42}'' = 1, n_{38-42}'' = 3, n_{19-46}'' = 1$$

- Terceira solução ótima alternativa - Retirada das LT's:

$$n_{01-07}'' = 1, n_{01-02}'' = 2, n_{04-09}'' = 1, n_{05-09}'' = 1, n_{07-08}'' = 1, n_{09-14}'' = 2, n_{14-18}'' = 1, n_{23-24}'' = 1, \\ n_{26-27}'' = 2, n_{27-28}'' = 1, n_{36-37}'' = 1, n_{37-39}'' = 1, n_{37-42}'' = 1, n_{40-42}'' = 1, n_{38-42}'' = 3, n_{19-46}'' = 1$$

Neste caso foi usado como critério de parada a resolução de 4000 PPL's.

Para o caso em que não existe reprogramação da geração a solução global para o planejamento tradicional produz um investimento ótimo de $v = 154,420$ milhões de dólares com as seguintes adições:

- $n_{20-21} = 1, n_{42-43} = 2, n_{06-46} = 1, n_{19-25} = 1, n_{31-32} = 1$
- $n_{28-30} = 1, n_{26-29} = 3, n_{24-25} = 2, n_{9-30} = 2, n_{05-06} = 2$

Os testes realizados com o modelo modificado encontrou a mesma solução que o planejamento tradicional mas também, neste caso, de forma surpreendente, retira 22 linhas de transmissão que são consideradas irrelevantes para a operação com o modelo DC. Assim, a nova forma de planejamento encontra a seguinte solução:

- Retirada de linhas de transmissão:

$$n_{01-07}'' = 1, n_{01-02}'' = 2, n_{05-09}'' = 1, n_{07-08}'' = 1, n_{04-05}'' = 1, n_{08-13}'' = 1, n_{09-14}'' = 1, n_{14-18}'' = 1, \\ n_{13-20}'' = 1, n_{14-26}'' = 1, n_{22-26}'' = 1, n_{20-23}'' = 1, n_{23-24}'' = 1, n_{33-34}'' = 1, n_{34-35}'' = 1, \\ n_{35-38}'' = 1, n_{37-42}'' = 1, n_{39-42}'' = 1, n_{40-42}'' = 1, n_{38-42}'' = 2$$

Existem ainda várias soluções com o mesmo investimento em expansão e com retiradas de 22 linhas de transmissão. Essas soluções,

ligeiramente diferentes da solução anterior, produzem as seguintes retiradas de linhas de transmissão:

- Primeira solução ótima alternativa – Retirada das seguintes LT's.

$$\begin{aligned} n''_{01-07} = 1, n''_{01-02} = 2, n''_{05-09} = 1, n''_{07-08} = 1, n''_{04-05} = 1, n''_{08-13} = 1, n''_{09-14} = 1, n''_{14-18} = 1, \\ n''_{13-20} = 1, n''_{14-26} = 1, n''_{22-26} = 1, n''_{20-23} = 1, n''_{23-24} = 1, n''_{24-34} = 1, n''_{34-35} = 1, \\ n''_{35-38} = 1, n''_{39-42} = 1, n''_{40-42} = 1, n''_{38-42} = 2 \end{aligned}$$

- Segunda solução ótima alternativa – Retirada das seguintes LT's.

$$\begin{aligned} n''_{01-07} = 1, n''_{01-02} = 2, n''_{05-09} = 1, n''_{07-08} = 1, n''_{04-05} = 1, n''_{08-13} = 1, n''_{09-14} = 1, n''_{14-18} = 1, \\ n''_{13-20} = 1, n''_{14-26} = 1, n''_{22-26} = 1, n''_{20-23} = 1, n''_{23-24} = 1, n''_{24-34} = 1, n''_{33-34} = 1, \\ n''_{34-35} = 1, n''_{35-38} = 1, n''_{37-39} = 1, n''_{39-42} = 1, n''_{40-42} = 1, n''_{38-42} = 2 \end{aligned}$$

- Terceira solução ótima alternativa – Retirada das seguintes LT's.

$$\begin{aligned} n''_{01-07} = 1, n''_{01-02} = 2, n''_{05-09} = 1, n''_{07-08} = 1, n''_{04-05} = 1, n''_{08-13} = 1, n''_{09-14} = 1, n''_{14-18} = 1, \\ n''_{13-20} = 1, n''_{14-26} = 1, n''_{22-26} = 1, n''_{20-23} = 1, n''_{23-24} = 1, n''_{33-34} = 1, \\ n''_{34-35} = 1, n''_{35-38} = 1, n''_{39-42} = 1, n''_{40-42} = 1, n''_{38-42} = 2 \end{aligned}$$

Neste caso foi usado como critério de parada a resolução de 8000 PPL's.

Deve-se observar que no caso do sistema de 46 barras com reprogramação da geração foi encontrada uma solução com menor custo de expansão que no planejamento tradicional. Também em ambos os casos é muito elevado o número de linhas de transmissão que podem ser consideradas irrelevantes para a operação do modelo DC.

Capítulo 6

Conclusões Finais

Neste trabalho foi apresentada uma nova proposta de formulação para o problema de planejamento da expansão de sistemas de transmissão que apresenta a característica adicional de que é possível retirar linhas de transmissão com custo zero como parte do processo de expansão. Para levar em conta essa exigência adicional foi apresentado um novo modelo matemático que difere muito pouco do modelo de planejamento tradicional.

Para resolver o novo modelo matemático do problema de planejamento da expansão de sistemas de transmissão foi adaptado um algoritmo genético especializado já utilizado no LAPSEE (Laboratório de Planejamento de Sistemas de Energia Elétrica) para o problema de planejamento tradicional. Esse algoritmo genético especializado se mostrou eficiente e trabalhou sem problemas com os sistemas testados.

Os resultados encontrados mostram propostas de expansão surpreendentes. É particularmente importante o resultado encontrado para o sistema sul-brasileiro com reprogramação da geração. Para esse sistema, a nova proposta encontrou uma solução com custos de expansão menores que os custos de expansão correspondente ao planejamento tradicional. Adicionalmente, a nova proposta de expansão retira um número muito elevado de linhas de transmissão.

Deve-se observar que o planejamento da expansão de sistemas de transmissão é apenas uma ferramenta de análise de um sistema elétrico, e que para decisão de se retirar de fato as linhas de transmissão em um sistema real, estudos mais complexos ainda deverão ser desenvolvidos, quando o sistema for testado para outras exigências de operação tais como a análise com contingências, análise de segurança em geral, análise de curto-circuito, análise de estabilidade transitória, etc.

O sistema pode requerer algumas dessas linhas de transmissão que o planejamento modificado indica como sendo linhas de transmissão que devem ser retiradas. Portanto, a proposta de retirada deve ser assumida apenas de forma indicativa.

Existe ainda um assunto que deve merecer análise mais detalhada. Foi provado experimentalmente que o cumprimento da Lei de Tensões de Kirchhoff pelo sistema elétrico pode produzir comportamento atípico de algumas linhas de transmissão. Em outras palavras, foi provado experimentalmente que existem linhas de transmissão que não ajudam na adequada operação de um sistema elétrico.

Assim, pode-se concluir que, dentre as 20 linhas de transmissão retiradas pela proposta de expansão alternativa para o sistema sul-brasileiro com reprogramação da geração, algumas delas realmente prejudicam o desempenho do sistema elétrico.

Também é evidente que algumas linhas de transmissão foram retiradas, mas que sua retirada preserva a operação adequada do sistema elétrico, isto é, operação sem corte de carga, mas que não necessariamente prejudicam o desempenho do sistema elétrico.

Portanto, entre as linhas retiradas é muito provável que existam três tipos de linhas de transmissão: 1) linhas de transmissão que realmente prejudicam o desempenho do sistema elétrico; 2) linhas de transmissão que são indiferentes para o desempenho do sistema elétrico e; 3) linhas de transmissão que ajudam na operação adequada de um sistema elétrico mas que se fossem retiradas, o sistema é prejudicado mas ainda opera sem corte de carga.

A observação realizada anteriormente é muito importante. Assim, por exemplo, deve-se elaborar uma estratégia para identificar as linhas de transmissão retiradas pela proposta de planejamento alternativa. As linhas que foram retiradas, mas que não prejudicam o desempenho do sistema elétrico, devem ser reintroduzidas ao plano de expansão.

As linhas de transmissão que realmente prejudicam o desempenho do sistema elétrico devem ser retiradas do plano de expansão (que é equivalente a afirmar que devem permanecer desconectadas na operação).

Existem ainda formas alternativas de transformar essas linhas de transmissão indesejáveis em linhas de transmissão aproveitáveis. Uma forma de inserir essa estratégia consiste em instalar um dispositivo FACTS em algum ponto do laço em que se encontra a linha de transmissão indesejável (por exemplo, pode-se instalar um transformador defasador). Entretanto, esse assunto foge ao escopo deste trabalho.

Deve-se observar que a Lei de Tensões de Kirchhoff é uma restrição mais rigorosa no modelo AC que no modelo DC e, portanto, é plenamente possível que existam linhas de transmissão operando em um sistema elétrico que apenas prejudicam o desempenho de um sistema elétrico. Esse assunto também é um tópico que pode ser pesquisado no futuro no LAPSEE.

Finalmente, pode-se fazer o questionamento de se todas as linhas de transmissão que se encontram operando em um sistema elétrico real, satisfazendo as duas Leis de Kirchhoff para o modelo AC, ajudam na operação adequada do sistema elétrico.

Referências Bibliográficas

- [1] GARVER, Len L. Transmission network estimation using linear programming. IEEE Transactions on Power Apparatus and Systems, Seattle-WA, vol. PAS-89, n.07, p. 1688-1697, Sep. – Oct. 1970.
- [2] MONTICELLI, A. et al. Interactive transmission network planning using a least - effort criterion. IEEE Transactions on Power Apparatus and Systems, Seattle-WA, v. PAS-101, n. 10, p. 3919-3925, Oct. 1982.
- [3] PEREIRA, M. V. F.; PINTO, L. M. V. G. Application of sensitivity analysis of load supplying capability to interactive transmission expansion planning. IEEE Transactions on Power Apparatus and Systems, Seattle-WA, v. PAS-104, n. 2, p. 381-389, Feb. 1985.
- [4] VILASSANA, R.; GARVER, L. L.; SALON, S. J. Transmission network planning using linear programming. IEEE Transactions on Power Apparatus and Systems, Seattle-WA, v. PAS-104, n. 2, p.349 - 356, Feb. 1985.
- [5] PEREIRA, M. V. P. et al. Composite generation transmission expansion planning. EPRI Research Project, EPRI Rep. RP 2473–9, 1987.
- [6] ROMERO, R.; MONTICELLI, A. A Hierarchical decomposition approach for transmission network expansion planning. IEEE Transactions on Power Systems, Columbus-OH., v. 9, n.1, p. 373-380, Feb. 1994.
- [7] GALLEGO, R. A.; MONTICELLI, A.; ROMERO, R. Comparative studies of non-convex optimization methods for transmission network expansion planning. IEEE Transactions on Power Systems, Seattle-WA, v.13, n. 3, p. 822-828, Aug. 1998.
- [8] ROCHA, C. R. Algoritmo heurístico integrado aplicado ao planejamento de sistemas de transmissão a longo prazo. 1999. f. 97, Dissertação (Mestrado em Engenharia Elétrica) – Faculdade de Engenharia, Universidade Estadual Paulista - UNESP, Ilha Solteira-SP, 1999.
- [9] GROSTCHEL, M. L.; HOLLAND, O. Solution of large-scale symmetric traveling salesman problems. Mathematical Programming Journal, Berlin, v. 51, n. 1-3, p. 141-202, 1991.
- [10] BINATO, S. Expansão ótima de sistemas de transmissão através de decomposição de benders e técnicas de planos cortantes. 2000. f. 150, Tese (Doutorado em Engenharia Elétrica) – Faculdade de Engenharia de Sistemas e Computação, Universidade Federal do Rio de Janeiro - UFRJ, Rio de Janeiro-RJ , 2000.
- [11] SILVA, E. L. et. al. Transmission network expansion planning under a tabu search approach. IEEE Transactions on Power System, Seattle-WA, v.16, n.1, p.62-68, Feb. 2001.
-

- [12] SILVA, E. L.; GIL, H. A.; ORTIZ, J. M. A. Transmission network expansion planning under an improved genetic algorithm. IEEE Transactions on Power System, Seattle-WA, v.15, n.3, p.1168-1175, Aug. 2000.
- [13] GOLDBERG, D. E. Genetic Algorithms in Search, Optimization and Machine Learning. Addison Wesley, Reading, Mass., 1989
- [14] HAFFNER, S. et. al. Specialized branch and bound algorithm for transmission network expansion planning. IEE Proceedings - Generation, Transmission and Distribution, v.148, n. 5, p.482-488, Sep. 2001.
- [15] HAFFNER, S. et al. Branch and bound algorithm for transmission system expansion planning using a transportation model. IEE Proceedings - Generation, Transmission and Distribution, v.147, n. 3, p-149-156, May. 2000.
- [16] BINATO, S.; PEREIRA, M. V. F.; GRANVILLE, S. A New benders decomposition approach to solve power transmission network design problems. IEEE Transactions on Power Systems, Seattle-WA, v.16, n.2, p.235-240, May. 2001.
- [17] BINATO, S.; OLIVEIRA, G. C. Oliveira; ARAÚJO, J. L. A. Greedy randomized adaptive search procedure for transmission expansion planning. IEEE Transactions on Power Systems, Seattle-WA, v.16, n.2, p.247-253, May. 2001.
- [18] DIAZ, A. et al. Optimization heurística y redes neuronales. Madri, Editorial Paraninfo, 1996. p. 235. ISBN 84-283-2269-4
- [19] ROMERO, R. et al. Test system and mathematical models for transmission network expansion planning. IEE Proceedings – Generation, Transmission and Distribution, v. 149, n. 1, p. 27-36, Jan. 2002.
- [20] ROMERO, R. et al. Analysis of heuristic algorithms for the transportation model in static and multistage planning in network expansion systems. IEE Proceedings – Generation, Transmission and Distribution, v. 150, n.5, p. 521-526, Sep. 2003.
- [21] GALLEGO, R.; ROMERO, R.; MONTICELLI, A. Tabu search algorithm for network synthesis. IEEE Transactions on Power Systems, Lugar de publicação, v.15, n.2, p. 490-495, May. 2000.
- [22] GALLEGO, R. A.; MONTICELLI, A.; ROMERO, R. Transmission system expansion planning by an extended genetic algorithm. IEE Proceedings – Generation, Transmission and Distribution, Lugar de publicação, v. 145, n. 3, p. 329-335, May. 1998.
- [23] FANG, R.; HILL, Fang. A New strategy for transmission expansion in competitive electricity markets. IEEE Transactions on Power Systems, v. 18, n.1, p. 374-380. Feb. 2003.
-

[24] ROMERO, R. et al. **Constructive heuristic algorithm for the dc model in network transmission expansion planning**. IEE Proceedings – Generation, Transmission and Distribution, v. 152, n. 2, p. 277-282, Mar. 2005.

[25] GLOVER, F.; LAGUNA, M. **Tabu search**. Modern Heuristic Techniques for Combinatorial Problems, Blackwell Scientific Publishing, p.70-141, 1993.

[26] BAIHENSE, Laura et al. **A Mixed integer disjunctive model for transmission network expansion**. IEEE Transactions on Power Systems, Seattle-WA, v.16, n. 3, p. 560-565, Aug. 2001.

[27] RIDER, M. **Planejamento da Expansão de sistemas de transmissão usando modelos cc-ca e técnicas de programação não-linear**. Tese (Doutorado em Engenharia Elétrica e da Computação) – Faculdade de Engenharia Elétrica e da Computação, Universidade Estadual de Campinas - UNICAMP, Campinas, 2006.

[28] CHU, P. C.; BEASLEY, J. E. **A Genetic algorithm for the generalized assignment problem**, computers and operations research. Computer Ops Research, London, v. 24, n. 1, p. 17-23, 1997.

[29] ALENCAR, M.; ROMERO R. **Análise crítica do algoritmo genético de Chu-Beasley para o problema generalizado de atribuição**. XXXVI SBPO - Simpósio Brasileiro de Pesquisa Operacional, 2004, São João del Rei. Anais do XXXVI SBPO. Rio de Janeiro: SOBRAPO, 2004. v. 01, p. 01-09, 2004.

Apêndice A

Dados dos Sistemas de Testes

A.1 Sistema 46 Barras Sul-Brasileiro

Tabela 2 - Sistema 46 barras - dados de linha.

No. Da Linha	Circuito		Linhas Existentes	Reatância (p.u)	Capacidade (MW)	Custo (US\$10 ³)
1	1	7	1	0.0616	270.0	4349.0
2	1	2	2	0.1065	270.0	7076.0
3	4	9	1	0.0924	270.0	6217.0
4	5	9	1	0.1173	270.0	7732.0
5	5	8	1	0.1132	270.0	7480.0
6	7	8	1	0.1023	270.0	6823.0
7	4	5	2	0.0566	270.0	4046.0
8	2	5	2	0.0324	270.0	2581.0
9	8	13	1	0.1348	240.0	8793.0
10	9	14	2	0.1756	220.0	11267.0
11	12	14	2	0.0740	270.0	5106.0
12	14	18	2	0.1514	240.0	9803.0
13	13	18	1	0.1805	220.0	11570.0
14	13	20	1	0.1073	270.0	7126.0
15	18	20	1	0.1997	200.0	12732.0
16	19	21	1	0.0278	1500.0	32632.0
17	16	17	1	0.0078	2000.0	10505.0
18	17	19	1	0.0061	2000.0	8715.0
19	14	26	1	0.1614	220.0	10409.0
20	14	22	1	0.0840	270.0	5712.0
21	22	26	1	0.0790	270.0	5409.0
22	20	23	2	0.0932	270.0	6268.0
23	23	24	2	0.0774	270.0	5308.0
24	26	27	2	0.0832	270.0	5662.0
25	24	34	1	0.1647	220.0	10611.0
26	24	33	1	0.1448	240.0	9399.0
27	33	34	1	0.1265	270.0	8288.0
28	27	36	1	0.0915	270.0	6167.0
29	27	38	2	0.2080	200.0	13237.0
30	36	37	1	0.1057	270.0	7025.0
31	34	35	2	0.0491	270.0	3591.0
32	35	38	1	0.1980	200.0	12631.0
33	37	39	1	0.0283	270.0	2329.0
34	37	40	1	0.1281	270.0	8389.0
35	37	42	1	0.2105	200.0	13388.0
36	39	42	3	0.2030	200.0	12934.0
37	40	42	1	0.0932	270.0	6268.0

continuação

38	38	42	3	0.0907	270.0	6116.0
39	32	43	1	0.0309	1400.0	35957.0
40	42	44	1	0.1206	270.0	7934.0
41	44	45	1	0.1864	200.0	11924.0
42	19	32	1	0.0195	1800.0	23423.0
43	46	19	1	0.0222	1800.0	26365.0
44	46	16	1	0.0203	1800.0	24319.0
45	18	19	1	0.0125	600.0	8178.0
46	20	21	1	0.0125	600.0	8178.0
47	42	43	1	0.0125	600.0	8178.0
48	2	4	0	0.0882	270.0	5965.0
49	14	15	0	0.0374	270.0	2884.0
50	46	10	0	0.0081	2000.0	10889.0
51	4	11	0	0.2246	240.0	14247.0
52	5	11	0	0.0915	270.0	6167.0
53	46	6	0	0.0128	2000.0	16005.0
54	46	3	0	0.0203	1800.0	24319.0
55	16	28	0	0.0222	1800.0	26365.0
56	16	32	0	0.0311	1400.0	36213.0
57	17	32	0	0.0232	1700.0	27516.0
58	19	25	0	0.0325	1400.0	37748.0
59	21	25	0	0.0174	2000.0	21121.0
60	25	32	0	0.0319	1400.0	37109.0
61	31	32	0	0.0046	2000.0	7052.0
62	28	31	0	0.0053	2000.0	7819.0
63	28	30	0	0.0058	2000.0	8331.0
64	27	29	0	0.0998	270.0	6672.0
65	26	29	0	0.0541	270.0	3894.0
66	28	41	0	0.0339	1300.0	39283.0
67	28	43	0	0.0406	1200.0	46701.0
68	31	41	0	0.0278	1500.0	32632.0
69	32	41	0	0.0309	1400.0	35957.0
70	41	43	0	0.0139	2000.0	17284.0
71	40	45	0	0.2205	180.0	13994.0
72	15	16	0	0.0125	600.0	8178.0
73	46	11	0	0.0125	600.0	8178.0
74	24	25	0	0.0125	600.0	8178.0
75	29	30	0	0.0125	600.0	8178.0
76	40	41	0	0.0125	600.0	8178.0
77	2	3	0	0.0125	600.0	8178.0
78	5	6	0	0.0125	600.0	8178.0
79	9	10	0	0.0125	600.0	8178.0

Tabela 3 - Sistema 46 barras - dados de barra (MW).

Barra	Geração	Carga
1	0.0	0.0
2	0.0	443.1
3	0.0	0.0
4	0.0	300.7
5	0.0	238.0
6	0.0	0.0
7	0.0	0.0
8	0.0	72.2
9	0.0	0.0
10	0.0	0.0
11	0.0	0.0
12	0.0	511.9
13	0.0	185.8
14	1.257.0	0.0
15	0.0	0.0
16	2.000.0	0.0
17	1.050.0	0.0
18	0.0	0.0
19	1.670.0	0.0
20	0.0	1.091.2
21	0.0	0.0
22	0.0	81.9
23	0.0	458.1
24	0.0	478.2
25	0.0	0.0
26	0.0	231.9
27	220.0	0.0
28	800.0	0.0
29	0.0	0.0
30	0.0	0.0
31	700.0	0.0
32	500.0	0.0
33	0.0	229.1
34	748.0	0.0
35	0.0	216.0
36	0.0	90.1
37	300.0	0.0
38	0.0	216.0
39	600.0	0.0
40	0.0	262.1
41	0.0	0.0
42	0.0	1.607.9
43	0.0	0.0
44	0.0	79.1
45	0.0	86.700.000
46	70.0	0.0

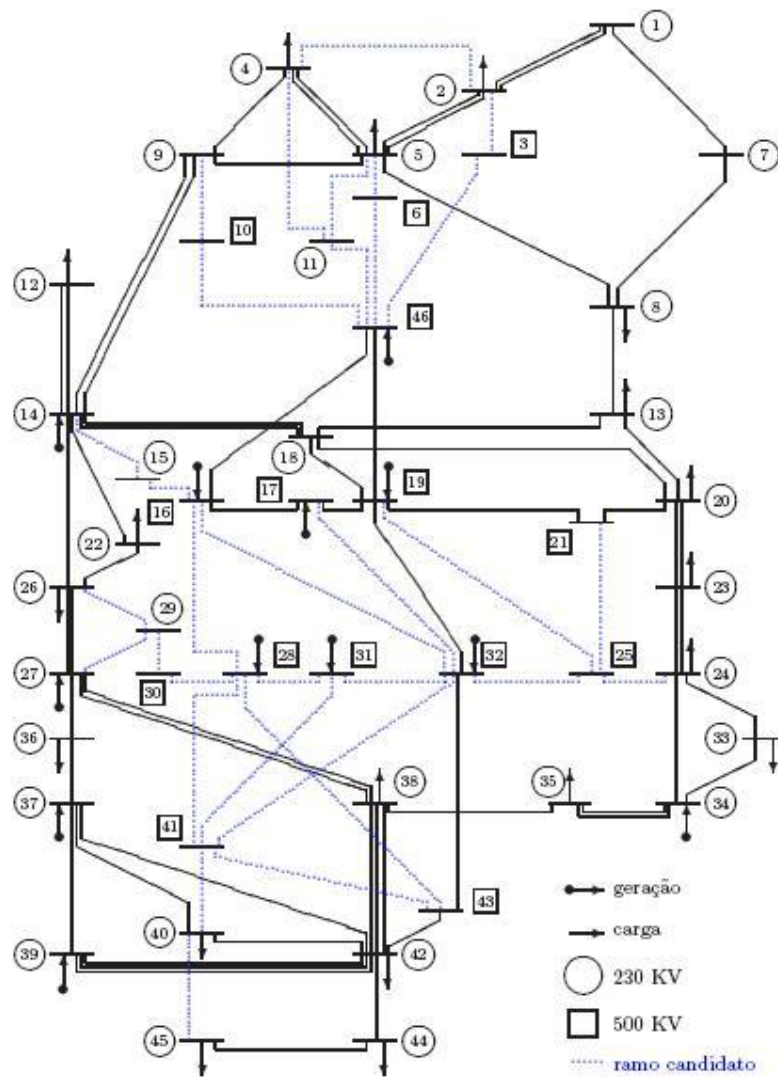


Figura A-1 - Sistema 46 barras sul-brasileiro.

A.2 Sistema 6 Barras Garver

Tabela 4 - Sistema 6 barras - dados de linha.

No. Da Linha	Circuito	Linhas Existentes	Reatância (p.u)	Capacidade (MW)	Custo (US\$10 ³)
1	1 2	1	0.40	100.0	40.0
2	1 3	0	0.38	100.0	38.0
3	1 4	1	0.60	80.0	60.0
4	1 5	1	0.20	100.0	20.0
5	1 6	0	0.68	70.0	68.0
6	2 3	1	0.20	100.0	20.0
7	2 4	1	0.40	100.0	40.0
8	2 5	0	0.31	100.0	31.0
9	2 6	0	0.30	100.0	30.0
10	3 4	0	0.59	82.0	59.0
11	3 5	1	0.20	100.0	20.0
12	3 6	0	0.48	100.0	48.0
13	4 5	0	0.63	75.0	63.0
14	4 6	0	0.30	100.0	30.0
15	5 6	0	0.61	78.0	61.0

Tabela 5 - Sistema 6 Barras - dados de barra (MW)

Barra	Geração	Carga
1	150.0	80.0
2	0.0	240.0
3	360.0	40.0
4	0.0	160.0
5	0.0	240.0
6	600.0	0.0




Figura A-2 - Sistema 6 barras - topologia base.

Livros Grátis

(<http://www.livrosgratis.com.br>)

Milhares de Livros para Download:

[Baixar livros de Administração](#)

[Baixar livros de Agronomia](#)

[Baixar livros de Arquitetura](#)

[Baixar livros de Artes](#)

[Baixar livros de Astronomia](#)

[Baixar livros de Biologia Geral](#)

[Baixar livros de Ciência da Computação](#)

[Baixar livros de Ciência da Informação](#)

[Baixar livros de Ciência Política](#)

[Baixar livros de Ciências da Saúde](#)

[Baixar livros de Comunicação](#)

[Baixar livros do Conselho Nacional de Educação - CNE](#)

[Baixar livros de Defesa civil](#)

[Baixar livros de Direito](#)

[Baixar livros de Direitos humanos](#)

[Baixar livros de Economia](#)

[Baixar livros de Economia Doméstica](#)

[Baixar livros de Educação](#)

[Baixar livros de Educação - Trânsito](#)

[Baixar livros de Educação Física](#)

[Baixar livros de Engenharia Aeroespacial](#)

[Baixar livros de Farmácia](#)

[Baixar livros de Filosofia](#)

[Baixar livros de Física](#)

[Baixar livros de Geociências](#)

[Baixar livros de Geografia](#)

[Baixar livros de História](#)

[Baixar livros de Línguas](#)

[Baixar livros de Literatura](#)
[Baixar livros de Literatura de Cordel](#)
[Baixar livros de Literatura Infantil](#)
[Baixar livros de Matemática](#)
[Baixar livros de Medicina](#)
[Baixar livros de Medicina Veterinária](#)
[Baixar livros de Meio Ambiente](#)
[Baixar livros de Meteorologia](#)
[Baixar Monografias e TCC](#)
[Baixar livros Multidisciplinar](#)
[Baixar livros de Música](#)
[Baixar livros de Psicologia](#)
[Baixar livros de Química](#)
[Baixar livros de Saúde Coletiva](#)
[Baixar livros de Serviço Social](#)
[Baixar livros de Sociologia](#)
[Baixar livros de Teologia](#)
[Baixar livros de Trabalho](#)
[Baixar livros de Turismo](#)