



UNIVERSIDADE ESTADUAL PAULISTA

Programa de Pós-Graduação em Engenharia Elétrica

**Análise Crítica de Aspectos de Modelagem Matemática no
Planejamento da Expansão a Longo Prazo de Sistemas de
Transmissão**

Antonio Hernando Escobar Zuluaga

Ilha Solteira - SP

Dezembro - 2008

UNIVERSIDADE ESTADUAL PAULISTA JÚLIO DE MESQUITA FILHO - UNESP

FACULDADE DE ENGENHARIA CAMPUS DE ILHA SOLTEIRA

PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

Análise Crítica de Aspectos de Modelagem Matemática no Planejamento da Expansão a Longo Prazo de Sistemas de Transmissão

Candidato: Antonio Hernando Escobar Zuluaga
Orientador: Rubén Augusto Romero Lázaro
Co-orientador: José Roberto Sanches Mantovani

Tese apresentada ao Programa de Pós-Graduação em Engenharia Elétrica da UNIVERSIDADE ESTADUAL PAULISTA “JÚLIO DE MESQUITA FILHO” - UNESP, CAMPUS DE ILHA SOLTEIRA, para preenchimento dos pré-requisitos parciais para obtenção do Título de Doutor em Engenharia Elétrica.

19 de Dezembro de 2008

FICHA CATALOGRÁFICA

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

E a	<p>Escobar Zuluaga, Antonio Hernando. Análise crítica de aspectos de modelagem matemática no planejamento da expansão a longo prazo de sistemas de transmissão / Antonio Hernando Escobar Zuluaga. -- Ilha Solteira : [s.n.], 2008 224 f.</p> <p>Tese (doutorado) - Universidade Estadual Paulista. Faculdade de Engenharia de Ilha Solteira. Área de conhecimento: Automação, 2008</p> <p>Orientador: Rubén Augusto Romero Lázaro Co-orientador: José Roberto Sanches Mantovani Bibliografia: p. 77-85</p> <p>1. Sistemas de transmissão - Planejamento. 2. Otimização. 3. Algoritmos evolutivos. 4. Desplanificação.</p>
-----	--

CERTIFICADO DE APROVAÇÃO

TÍTULO: Análise Crítica de Aspectos de Modelagem Matemática no Planejamento da Expansão a Longo Prazo de Sistemas de Transmissão

AUTOR: ANTONIO HERNANDO ESCOBAR ZULUAGA

ORIENTADOR: Prof. Dr. RUBEN AUGUSTO ROMERO LAZARO

Aprovado como parte das exigências para obtenção do Título de DOUTOR em ENGENHARIA ELÉTRICA pela Comissão Examinadora:



Prof. Dr. RUBEN AUGUSTO ROMERO LAZARO
Departamento de Engenharia Elétrica / Faculdade de Engenharia de Ilha Solteira



Prof. Dr. CARLOS ROBERTO MINUSSI
Departamento de Engenharia Elétrica / Faculdade de Engenharia de Ilha Solteira



Prof. Dr. SERGIO AZEVEDO DE OLIVEIRA
Departamento de Engenharia Elétrica / Faculdade de Engenharia de Ilha Solteira



Prof. Dr. ARIIVALDO VERANDIO GARCIA
Departamento de Sistemas de Energia Elétrica / Universidade Estadual de Campinas



Prof. Dr. RAMÓN ALFONSO GALLEGO RENDÓN
Departamento de Ingeniería Eléctrica / Universidad Tecnológica de Pereira - Colômbia

Data da realização: 19 de dezembro de 2008.

Esta tese é dedicada à minha família.

Agradecimentos

A meu orientador, Rubén Augusto Romero Lázaro, minha gratidão pela excepcional formação proporcionada ao longo de meus estudos de mestrado e de doutorado. Sua amizade, perspicácia e experiência muito contribuíram para que esta tese chegasse ao final. Muito obrigado.

Aos professores do PPGEE: Sérgio Azevedo de Oliveira, Dionizio Paschoarelli Júnior, Luís Carlos Origa de Oliveira, José Carlos Rossi, José Roberto Sanches Mantovani e Antonio Padilha Feltrin, pela acolhida gentil e amável e também pela experiência profissional durante o tempo que passei no Brasil.

A meus colegas do laboratório LAPSEE.

A meu colega e amigo da Universidade Tecnológica de Pereira, Colombia, Dr. Ramón Alfonso Gallego Rendón. Minha gratidão pela excepcional formação em meus estudos de mestrado na Colombia e os conselhos em meus estudos de doutorado. Muito obrigado.

À Universidade Tecnológica de Pereira, Colombia.

A meus companheiros e amigos colombianos na UNESP que compartilharam comigo este período de muito trabalho.

A FEPISA pela ajuda financeira.

Ao professor Rubén Romero e sua esposa Lucila Reynoso e seus filhos Ivan, Ruth e Cesar Augusto, que brindaram a mim e a minha família uma sincera amizade. Obrigado pelo ambiente fraterno e pelos momentos agradáveis e descontraídos.

A meus pais Carlos e Dolly, e meus irmãos, pelo carinho e solidariedade.

A Edilma Henao (in memoriam) mãe de minha esposa Suany, pelo carinho e solidariedade.

A Suany, minha amada esposa, sempre presente, cuidadosa e amorosa, meu carinho, meu amor e meu profundo reconhecimento pela dedicação e incentivo.

A meus filhos Laura Mónica, David e Juan Pablo, meu carinho, meu amor e meu reconhecimento pela dedicação ao estudo e companhia no Brasil.

A Deus pela inspiração e alegria de viver.

*“A leitura faz o homem completo. A
conversação o torna ágil. E o
escrever o leva a ser preciso.”*
**Francis Bacon (1561–1626),
filósofo inglês.**

Resumo

Resumo da Tese apresentada ao Programa de Pós-graduação em Engenharia Elétrica da Faculdade de Engenharia Campus de Ilha Solteira-UNESP, como parte dos requisitos necessários para a obtenção do grau de Doutor em Engenharia Elétrica.

ANÁLISE CRÍTICA DE ASPECTOS DE MODELAGEM MATEMÁTICA NO PLANEJAMENTO DA EXPANSÃO A LONGO PRAZO DE SISTEMAS DE TRANSMISSÃO

Antonio Hernando Escobar Zuluaga

Dezembro / 2008

Orientador: Prof. Dr. Rubén Augusto Romero Lázaro.

Co-orientador: Prof. Dr. José Roberto Sanches Mantovani.

Área de Concentração: Sistemas de Energia Elétrica

Palavras-chave:

Planejamento de Sistemas de Transmissão, Otimização, Metaheurísticas, Algoritmos Evolutivos, Multiobjetivo, Desplanificação, Múltiplos Cenários de Geração.

Número de páginas: 224

O principal objetivo deste estudo é realizar uma análise de aspectos críticos que surgem na modelagem matemática do problema de planejamento da expansão de sistemas de transmissão a longo prazo, assim como o desenvolvimento de ferramentas computacionais para a prova de novos modelos e metodologias que possam contribuir na solução do problema de planejamento de sistemas de transmissão de energia elétrica considerando as condições dos sistemas modernos de energia elétrica. Com esta metodologia, busca-se obter uma rede de transmissão mais eficiente, e com o menor custo possível, que se adapte as novas exigências produzidas pela introdução da desregulação nos sistemas elétricos. Para isto combinam-se três aspectos: rede futura livre de congestionamento, desplanificação e incerteza na geração e na demanda futura, os quais são manipuladas desde a perspectiva mono-objetivo e multiobjetivo. A possibilidade de eliminar completamente o congestionamento na rede de transmissão é analisada através da inclusão no modelo de todos os cenários de geração factíveis futuros, e não somente alguns cenários como outros estudos. Considerar uma operação sem congestionamento para o futuro está associado a grandes custos de investimento. Para atenuar este grande custo uma opção é

incluir a possibilidade de desplanificação e a inclusão dos efeitos das incertezas presentes na geração e na demanda futura no problema de planejamento.

O problema de planejamento de sistemas de transmissão é um problema de programação não-linear inteira mista (PNLIM) quando é usado o modelo DC. Praticamente todos os algoritmos usados para resolver este problema utilizam uma sub-rotina de programação linear (PL) para resolver problemas de PL resultantes do algoritmo de solução do problema de planejamento, os quais são denominados subproblemas operativos. A resolução desses problemas de PL representa o maior esforço computacional dos algoritmos de planejamento, já que se devem resolver milhões de PL's em problemas de grande porte. O problema PNLIM é resolvido através da combinação de uma técnica metaheurística e um método de programação linear. A técnica metaheurística resolve o chamado problema de investimento. O problema de planejamento, considerando múltiplos cenários de geração, é mais complexo que o tradicional problema de planejamento, porque em cada caso, deverá ser resolvido um problema de PL para cada cenário de geração considerado. Nesta tese se aplica uma idéia de redução do espaço infinito de busca, associado aos cenários de geração factíveis existentes, por um espaço finito e reduzido de cenários, matematicamente equivalentes. Isto é feito com o propósito de reduzir o esforço computacional e tornar viável a solução do problema. Os resultados mostram a potencialidade da metodologia, e também a potencialidade de reduzir o custo de investimento ao considerar desplanificação e incerteza na geração e na demanda.

Abstract

Abstract of Thesis presented to UNESP as a partial fulfillment of the requirements for the degree of Doctor in Electrical Engineering.

CRITICAL ANALISYS OF THE MATEMATICAL MODELING OF LONG-TERM TRANSMISSION SYSTEM EXPANSION PLANNING

Antonio Hernando Escobar Zuluaga

Dezembro / 2008

Advisor: Prof. Rubén Augusto Romero Lázaro, Ph.D.

Co-Advisor: Prof. José Roberto Sanches Mantovani, Ph.D.

Area of Concentration: Electrical Energy Systems

Keywords:

Transmission System Planning, Optimization, Meta-heuristics, Evolutionary Algorithms, Multiobjective, De-planning, Multiple Generation Scenarios.

Number of pages: 224

The main goal for this study is to do an analysis of the critical issues that appear in the mathematical modeling of the transmission system expansion planning problem, when long term is considered. A methodology was developed and a computational tool, to solve the transmission expansion planning in modern electrical systems. With this methodology more efficient electrical networks are obtained, at low investment costs. This is accomplished taking into account three important aspects: open access, or congestion-free planning, uncertainty in demand and generation, and de-planning. The problem is solved using mono-objective and multi-objective methodologies. For this investigation, congestion-free transmission networks should consider all the future and feasible scenarios of generation, unlike some papers, where only a few scenarios are taken in to account. This feature is associated to high investment costs. Lower costs are often obtained by the inclusion of uncertainty in future demand and future generation.

The transmission system expansion planning problem is a no-linear integer-mixed programming problem (PNLIM) when the DC model is used. Practically, all the algorithms used in the solution process, for this problem, use one subroutine of linear programming (PL) for solved the PL problems that result during the solution process, in the denominated operative problem. The solution of the PL's is the part of the problem that requires the biggest computational effort,

because during the solution process is necessary to solve thousands or millions of PL's, for high size problems. the PNLIM problem is solved through the combination of a meta-heuristic method and a linear programming method. The meta-heuristic method solves the denominated investment problem and the PL the denominated operational problem. The transmission planning problem considering multiples generation scenarios is more complex than the traditional transmission planning problem because, in each case, is necessary to solve one PL for any generation scenario considered. The methodology applies the following idea: all the feasible and future scenarios must be reduced to an equivalent finite number of scenarios. Only thanks to this reduction is a solution possible, and the computational effort manageable. This premise is validated in this work. The results obtained show the potential of the methodology, and the application of de-planning and uncertainty in demand and generation to reduce investment costs.

Lista de Figuras

1	Tipos de codificação no algoritmo genético.	p. 58
2	Exemplo de recombinação de um único ponto.	p. 61
3	Exemplo de recombinação de dois pontos.	p. 62
4	Algoritmo Genético Simples.	p. 63
5	Proposta de codificação.	p. 66
6	Recombinação de um ponto e geração de um descendente.	p. 68
7	Mutação com $k = 1$ para um descendente.	p. 69
8	Estrutura básica do CBGA aplicado ao problema de planejamento.	p. 73
9	Custos das diferentes formas de planejamento para o sistema IEEE de 24 barras considerando reprogramação da geração.	p. 80
10	Custos das diferentes formas de planejamento para o sistema colombiano de 93 barras.	p. 87
11	Custos comparativos com e sem desplanificação.	p. 89
12	Custos comparativos com e sem desplanificação para o sistema colombiano de 93 barras.	p. 89
13	Curva de desempenho do algoritmo CBGA para o sistema IEEE de 24 barras considerando múltiplos cenários de geração.	p. 108
14	Distribuição das gerações de G_{01} e G_{02} no espaço dos cenários de geração.	p. 113
15	Distribuição das gerações de G_{22} e G_{23} no espaço dos cenários de geração.	p. 114
16	Dominância de Pareto no espaço objetivo.	p. 120
17	Fronteira Pareto-ótima para quatro diferentes cenários com dois objetivos e o mesmo espaço de soluções.	p. 123
18	Distribuição das soluções na fronteira de Pareto.	p. 124

19	Ilustração das definições de um problema de otimização multiobjetivo.	p. 124
20	Classificação das soluções em vários níveis de não-dominância.	p. 125
21	Interpretação gráfica do método da soma ponderada.	p. 129
22	Interpretação gráfica do método das ϵ -restrições.	p. 131
23	Valores de S_i para soluções dominadas e não-dominadas.	p. 137
24	Funcionamento do algoritmo NSGA-II	p. 141
25	Distância de aglomeração (<i>crowding distance</i>) para a solução i	p. 144
26	Soluções para o problema de planejamento multiobjetivo considerando múltiplos cenários de geração.	p. 147
27	Fronteira Pareto-ótima para o sistema Garver.	p. 152
28	Fronteira Pareto-ótima para o sistema IEEE de 24 barras usando $\max \{r^q\}$. . .	p. 153
29	Diagrama box-plot com distribuição dos cortes de carga para os planos de expansão da fronteira Pareto-ótima do sistema IEEE de 24 barras com $f_2 = r_{max}$	p. 156
30	Fronteira Pareto-ótima para o sistema IEEE de 24 barras usando congestionamento acumulado.	p. 157
31	Fronteira de Pareto para o sistema IEEE24 considerando MEG e incerteza na demanda e na geração.	p. 163
32	Diagrama box-plot com distribuição dos cortes de carga para os planos de expansão da fronteira Pareto-ótima do sistema IEEE de 24 barras com $f_2 = r_{max}$ e incertezas.	p. 165
33	Resultados comparativos dos diferentes tipos de planejamento.	p. 166
34	Distribuição dos cortes de carga para os planos de expansão da fronteira Pareto-ótima do sistema IEEE de 24 barras com $f_2 = r_{max}$	p. 168
35	Distribuição dos cortes de carga para os cenários 28 e 40 com $f_2 = r_{max}$. . .	p. 169
36	Melhor desempenho do algoritmo CBGA para o sistema IEEE de 24 barras considerando múltiplos cenários de geração.	p. 221
37	Curvas de desempenho do algoritmo CBGA para o sistema IEEE de 24 barras considerando mutação variável.	p. 221

38	Curvas de desempenho do algoritmo CBGA para o sistema IEEE de 24 barras considerando seleção variável.	p. 222
39	Curvas de desempenho do algoritmo CBGA para o sistema IEEE de 24 barras considerando diversidade variável.	p. 222

Lista de Tabelas

1	Geração no sistema IEEE de 24 barras.	p. 77
2	Exemplo de Cenário factível.	p. 99
3	Cenário com um gerador fora de seus limites.	p. 101
4	Cenário com todos os geradores em seus limites.	p. 101
5	Cenários extremos factíveis do sistema Garver.	p. 106
6	Cenários não extremos e factíveis gerados aleatoriamente para o sistema IEEE24.	p. 112
7	Soluções Pareto-ótimas para o sistema Garver 6 barras.	p. 152
8	Informação estatística das soluções do sistema IEEE de 24 barras.	p. 154
9	Informação estatística dos resultados para o sistema IEEE de 24 barras com $f_2 = \sum r^q$	p. 157
10	Características da fronteira de Pareto para o sistema IEEE24 considerando MEG e incertezas.	p. 164
11	Cenário de geração extremo crítico (cenário 40).	p. 167
12	Cenário de geração extremo pouco crítico (cenário 28).	p. 167
13	Cenários de geração mais críticos para as primeiras 15 configurações.	p. 170
14	Congestionamento para cenários extremos e não extremos com $f_2 = r_{max}$	p. 171
15	Dados de barras: Garver sem redespacho.	p. 186
16	Dados de ramos: sistema Garver.	p. 187
17	Dados de barras: Garver com redespacho.	p. 187
18	Dados de barras: IEEE 24.	p. 188
19	Dados de ramos: IEEE 24.	p. 189
20	Dados de barras: Colombia 2012.	p. 190

21	Dados de ramos: Colombia 2012.	p. 193
22	cenários extremos e factíveis para o sistema IEEE de 24 barras.	p. 199
23	Desempenho do algoritmo CBGA para a melhor solução do sistema IEEE de 24 barras considerando MCG.	p. 220
24	Desempenho do algoritmo CBGA usando população inicial aleatória o sis- tema IEEE de 24 barras considerando MCG	p. 223

Sumário

1	Introdução	p. 20
1.1	A importância do planejamento elétrico	p. 20
1.2	Efeito do planejamento da transmissão na eficiência do mercado elétrico . . .	p. 21
1.3	O problema de planejamento de sistemas de transmissão a longo prazo	p. 22
1.4	Motivação para estudo de planejamento da transmissão considerando múltiplos cenários de geração	p. 23
1.5	Motivação para incluir a incerteza na demanda no planejamento da transmissão	p. 24
1.6	Motivação para incluir a incerteza na geração no planejamento da transmissão	p. 25
1.7	Motivação para incluir a retirada de circuitos no planejamento da transmissão	p. 25
1.8	Revisão da literatura	p. 26
1.8.1	Principais trabalhos para a resolução do problema da expansão da transmissão tradicional	p. 26
1.8.2	Principais trabalhos para o problema da expansão da transmissão modificado	p. 27
1.8.3	Trabalhos com diferentes modelos usados para resolver o problema da expansão da transmissão	p. 28
1.8.4	Trabalhos que mostram outras formas de resolver o problema da expansão da transmissão	p. 28
1.8.5	Trabalhos que mostram outros aspectos relacionados com o planejamento da transmissão	p. 28
1.9	Organização dos capítulos	p. 29
2	Modelagem do Problema de Planejamento de Sistemas de Transmissão	p. 31

2.1	Introdução	p. 31
2.2	Referências históricas	p. 34
2.3	Modelo de transportes	p. 35
2.3.1	Modelo matemático	p. 35
2.4	Modelo híbrido não-linear	p. 37
2.4.1	Modelo matemático	p. 38
2.5	Modelo híbrido linear	p. 39
2.5.1	Modelo matemático	p. 40
2.6	Modelo DC	p. 41
2.6.1	Modelo matemático	p. 41
2.7	Modificações na modelagem básica	p. 43
2.8	O Modelo linear disjuntivo	p. 45
3	Modelagem Matemática Incluindo a Possibilidade de Retirada de Linhas de Transmissão	p. 49
3.1	Introdução	p. 49
3.2	Propostas de resolução	p. 51
3.3	Técnica de resolução	p. 54
3.3.1	Algoritmos genéticos	p. 56
3.3.1.1	Representação e codificação do indivíduo	p. 57
3.3.1.2	Geração da população inicial	p. 58
3.3.1.3	Avaliação da população	p. 59
3.3.1.4	Métodos de seleção	p. 59
3.3.1.5	Elitismo	p. 60
3.3.1.6	Operadores genéticos	p. 61
3.3.1.7	Operador recombinação	p. 61
3.3.1.8	Operador mutação	p. 62

3.3.1.9	Estrutura básica de um Algoritmo Genético	p. 62
3.3.1.10	Parâmetros dos algoritmos genéticos	p. 62
3.3.1.11	Tamanho da população	p. 63
3.3.1.12	Taxa ou probabilidade de recombinação	p. 63
3.3.1.13	Taxa ou probabilidade de mutação	p. 64
3.3.1.14	Tratamento das restrições	p. 64
3.3.2	Algoritmo genético de Chu-Beasley e sua aplicação ao problema de planejamento	p. 65
3.3.2.1	Codificação do problema	p. 65
3.3.2.2	População inicial	p. 66
3.3.2.3	Função objetivo e infactibilidade	p. 67
3.3.2.4	Seleção	p. 67
3.3.2.5	Recombinação	p. 68
3.3.2.6	Mutação	p. 68
3.3.2.7	Melhoria local de um indivíduo	p. 69
3.3.2.8	Substituição da população	p. 70
3.3.2.9	Critério de parada	p. 71
3.3.2.10	Estrutura básica do algoritmo CBGA aplicado ao problema de planejamento	p. 72
3.4	Testes e resultados usando a nova modelagem matemática	p. 72
3.4.1	Sistema IEEE de 24 barras	p. 72
3.4.2	Análise dos resultados para o sistema IEEE de 24 barras	p. 78
3.4.3	Sistema Colombiano de 93 barras e 155 ramos	p. 81
3.4.4	Análise dos resultados para o sistema Colombiano de 93 barras	p. 85
3.5	Conclusões parciais	p. 88
4	Planejamento da Transmissão Considerando Múltiplos Cenários de Geração	p. 91

4.1	Introdução	p. 91
4.2	Planejamento considerando múltiplos cenários de geração	p. 97
4.2.1	Conjectura de planejamento da expansão	p. 98
4.2.2	Cenário de geração factível	p. 98
4.2.3	Cenário de geração extremo e factível	p. 99
	Cenário extremo e factível de geração com um gerador que não se encontra em um de seus limites:	p. 100
	Cenário extremo e factível de geração com todos os geradores em um de seus limites:	p. 101
4.2.4	Modelagem do Problema de Planejamento de Sistemas de Trans- missão considerando p cenários de geração	p. 102
4.3	Técnica de resolução	p. 104
4.4	Testes e resultados usando a nova modelagem matemática	p. 105
4.4.1	Sistema Garver de 6 barras	p. 105
4.4.2	Sistema IEEE de 24 barras	p. 106
4.4.3	Prova da conjectura para o sistema IEEE de 24 barras	p. 109
	Coeficiente de variação da média:	p. 110
4.5	Conclusões parciais	p. 113
5	Otimização Multiobjetivo	p. 115
5.1	Introdução	p. 115
5.2	Definições básicas para otimização multiobjetivo	p. 118
	Definição 1	p. 119
	Definição 2	p. 119
5.3	Problema de otimização multiobjetivo	p. 119
5.4	Principais diferenças entre otimização multiobjetivo e mono-objetivo	p. 125
5.5	Classificação de métodos multiobjetivos	p. 126
5.5.1	Métodos a-priori	p. 126

5.5.2	Métodos a-posteriori	p. 127
5.5.3	Métodos iterativos	p. 127
5.6	Métodos tradicionais de otimização multiobjetivo	p. 127
5.6.1	Método da soma ponderada	p. 127
	Teorema 1:	p. 128
	Teorema 2:	p. 128
5.6.2	Método das ϵ -restrições	p. 130
	Teorema 3:	p. 130
	Teorema 4:	p. 130
	Teorema 5:	p. 130
5.6.3	Vantagens e desvantagens das técnicas tradicionais	p. 131
5.7	Algoritmos evolutivos para otimização multiobjetivo	p. 131
5.7.1	<i>Vector evaluated genetic algorithm</i> - VEGA	p. 133
5.7.2	<i>Multi-objective optimization genetic algorithm</i> - MOGA	p. 134
5.7.3	<i>Niched-Pareto genetic algorithm</i> - NPGA	p. 134
5.7.4	<i>Nondominated sorting genetic algorithm</i> - NSGA	p. 135
5.7.5	<i>Strength Pareto evolutionary algorithm</i> - SPEA	p. 136
5.7.6	<i>Distance-based Pareto genetic algorithm</i> - DPGA	p. 138
5.7.7	<i>Elitist non-dominated sorting genetic algorithm</i> - NSGA-II	p. 140
	Fast nondominated sort:	p. 142
	Operador de seleção por torneio usando distância de aglomeração ($F, <_c$):	p. 143
	Distância de aglomeração:	p. 144
5.8	Algoritmo NSGA-II modificado aplicado ao planejamento da transmissão	p. 146
	Inicialização da população:	p. 148
	Diversidade no espaço solução:	p. 148

Seleção:	p. 148
Recombinação:	p. 148
Mutação:	p. 149
Melhoramento:	p. 149
Inclusão dos indivíduos na população de descendentes:	p. 149
5.9 Testes e resultados usando o algoritmo NSGA-II modificado ao planejamento da transmissão	p. 150
5.9.1 Sistema Garver de 6 barras	p. 151
5.9.2 Sistema IEEE de 24 barras (caso 1): maior congestionamento	p. 152
5.9.3 Sistema IEEE de 24 barras (caso 2): congestionamento acumulado . .	p. 156
5.10 Planejamento da transmissão multiobjetivo considerando incertezas e múltiplos cenários de geração	p. 158
5.10.1 Modelagem do Problema de Planejamento de Sistemas de Transmissão considerando incertezas	p. 160
5.10.2 Testes e resultados em planejamento da transmissão multiobjetivo considerando incertezas e múltiplos cenários de geração	p. 161
5.11 Conclusões parciais	p. 171
6 Conclusões	p. 173
Referências	p. 177
Apêndice A - Dados dos Sistemas Testes Utilizados	p. 186
A.1 Sistema Garver de 6 barras	p. 186
A.1.1 Sistema sem redespacho	p. 186
A.1.2 Sistema com redespacho	p. 187
A.2 Sistema IEEE de 24 barras	p. 188
A.3 Sistema colombiano de 93 barras	p. 190

Apêndice B - Cenários de Geração	p. 198
---	--------

Apêndice C - Configurações da Fronteira Pareto-ótima para o Sistema IEEE de 24 Barras Obtidas Considerando Otimização Multiobjetivo e Múltiplos Cenários de Geração	p. 205
--	--------

C.1 Configurações para $f_2 = \max \{r^q\}$, seção (5.9.2).	p. 205
--	--------

C.2 Configurações para $\sum_{q=1}^p \sum_{i \in \Gamma} r_i^q$, seção (5.9.3).	p. 212
--	--------

C.3 Configurações considerando incertezas na demanda e nos limites de geração, e MEG.	p. 214
---	--------

Apêndice D - Desempenho do Algoritmo CBGA	p. 220
--	--------

D.1 Melhor desempenho do algoritmo CBGA para o sistema IEEE de 24 barras considerando MEG	p. 220
---	--------

D.2 Desempenho do algoritmo CBGA para o sistema IEEE de 24 barras considerando MEG	p. 221
--	--------

D.3 Desempenho do algoritmo CBGA usando população inicial aleatória	p. 223
---	--------

Apêndice E - Trabalhos Mais Relevantes Desenvolvidos Durante a Execução da Presente Pesquisa	p. 224
---	--------

1 Introdução

O mundo complexo dos sistemas de energia elétrica está dividido em três grandes grupos: Geradores, Consumidores e a Transmissão. Os geradores são responsáveis pela produção da energia elétrica, os consumidores demandam a energia elétrica para múltiplos usos e aplicações e o sistema de transmissão permite transferir a energia elétrica dos geradores aos consumidores. Para que geradores e consumidores possam exercer suas atividades de venda e compra de eletricidade existem agentes que regulamentam e que controlam o adequado funcionamento do sistema elétrico como: o operador do sistema, o agente responsável pelo mercado de energia elétrica, o agente responsável por regulamentar as atividades do setor e o agente regulador do sistema. Entre os problemas que os agentes devem resolver encontram-se tarefas de curto, médio e longo prazo. Entre os problemas de longo prazo encontram-se as tarefas de planejamento do sistema de geração e do sistema de transmissão, os quais permitem definir antecipadamente os custos e as localizações dos investimentos necessários para que o sistema opere adequadamente no futuro. Isto porque os tempos de construção das usinas elétricas de grande porte e das linhas de transmissão de alta tensão são longos (vários anos), e porque é conveniente aproveitar as economias de escala devido aos altos custos associados a estes investimentos. No caso de sistemas com esquema de mercado de eletricidade, o processo de planejamento do sistema de transmissão a longo prazo é de fundamental importância por seu papel determinante na eficiência do mercado futuro.

1.1 A importância do planejamento elétrico

O planejamento do setor elétrico é fundamental para assegurar a continuidade do abastecimento e/ou suprimento de energia ao menor custo, com o menor risco e com os menores impactos sócio-econômicos e ambientais para a sociedade. A falta de planejamento elétrico pode trazer consequências negativas, com reflexos em termos de elevação de custos e/ou degradação na qualidade da prestação do serviço, tais como racionamentos, excessos de capacidade instalada, produção ineficiente, etc.

Com relação aos aspectos técnicos e econômicos, deve-se destacar que o setor da energia elétrica possui segmentos com características de monopólio natural e de indústria de rede como, por exemplo, o segmento de transmissão e de distribuição. A estrutura em rede gera economias de escopo, de escala e de coordenação e requer a operação centralizada dos serviços. Existem outras especificidades adicionais, como as dificuldades técnicas e altos custos da estocagem de energia elétrica, que determinam a estruturação de produção e logística para o atendimento instantâneo da demanda. Como a eletricidade é um fluxo, o tempo e o espaço são dimensões importantes na caracterização da escala e do escopo dos processos de produção e transporte. A operação em níveis mais elevados de potência permite a exploração de economias de escala e de escopo. Isto dá origem ao chamado problema de planejamento da expansão da rede de transmissão de energia elétrica. A capacidade de transporte da rede de transmissão planejada tem impactos significativos na introdução de concorrência na cadeia de valor da indústria de eletricidade. A necessidade de planejamento também deriva do escopo e da complexidade do sistema elétrico, incluindo os diferentes atores responsáveis pela evolução do setor, tanto do lado da oferta quanto do lado da demanda. Suas decisões trazem impactos para todos os agentes e influenciam o futuro dos sistemas. Essas decisões necessitam de processos sistemáticos de apoio à decisão, em especial sobre as perspectivas de futuro.

1.2 Efeito do planejamento da transmissão na eficiência do mercado elétrico

Nos sistemas elétricos com esquemas tradicionais, tanto a operação como o planejamento da rede elétrica é feita por entidades centralizadas organizadas em estruturas verticalmente integradas. O processo de reestruturação da indústria da eletricidade produz o aparecimento de novos agentes, e novas exigências. Com a desregulação dos sistemas elétricos surgem diferentes esquemas competitivos dentro do setor elétrico mundial com características particulares para cada sistema, o que dificulta a obtenção de soluções gerais para os diferentes problemas que aparecem dentro do processo de busca de eficiência do mercado. O processo de planejamento da expansão dos sistemas de transmissão é mais complexo nos sistemas elétricos reestruturados por que nestes sistemas as decisões de novos investimentos em geração são agora baseadas nas forças do mercado e não em processos de decisão centralizados. Também, a rede de transmissão afeta a eficiência do mercado por causa do congestionamento que pode aparecer, e que não permite a programação de alguns despachos de geração, que em um sistema com mercado de eletricidade são resultado da interação entre as ofertas econômicas que fazem os agentes geradores e as necessidades de potência dos consumidores (em alguns casos os con-

sumidores apresentam suas necessidades de potência e o valor que podem pagar por ela). Em consequência, os despachos de geração horários ou diários possuem grande incerteza e existe um número muito grande de cenários factíveis.

Sempre que exista congestionamento na rede de transmissão para alguns cenários de geração factíveis, diz-se que não existem condições de livre competência ou não existem condições de competição perfeita. O planejamento da transmissão de curto prazo deve, portanto, eliminar as restrições que afetam a eficiência do mercado da rede atual e o planejamento da transmissão de longo prazo deve garantir, sempre que seja economicamente possível, uma rede de transmissão que não produza congestionamento em nenhum cenário factível de geração futuro.

Com o desenvolvimento dos esquemas de mercado se requer uma nova visão da filosofia do planejamento dos sistemas de transmissão, tanto nos modelos como nos algoritmos, exemplos disto são os trabalhos das referências (FANG; HILL, 2003; JUNIOR, 2005; LU; DONG; SAHA, 2005; TORRE; CONEJO; CONTRERAS, 2008; BALDICK; KAHN, 1993; RUDNICK; ZOLEZZI, 1999) Nesta tese são propostos vários modelos e uma metodologia para resolver o problema de planejamento da transmissão de longo prazo de tal forma que não exista congestionamento em nenhum cenário futuro e factível de geração. Este problema será denominado planejamento da transmissão considerando múltiplos cenários de geração ou expansão da transmissão livre de congestionamento.

1.3 O problema de planejamento de sistemas de transmissão a longo prazo

O problema de planejamento da transmissão consiste em determinar os reforços necessários que se devem realizar no sistema para que possa cumprir com as condições impostas pelo crescimento da carga e pela nova capacidade de geração. Ditos reforços devem ser feitos em alguns corredores da rede, e podem consistir na instalação de novos transformadores ou linhas de transmissão. Em muitos casos pode ser necessária a instalação de vários elementos em paralelo num mesmo corredor. Com os elementos de transmissão adicionados, a indústria, o setor comercial e o setor residencial asseguram o transporte da energia que requerem no futuro e reduzem o risco de racionamento, já que estes fornecem o caminho adequado para a potência requerida pelos usuários conectados ao sistema de potência.

As atividades de transmissão são definidas sobre uma base monopólica e, portanto, podem ser regulamentadas desde o ponto de vista técnico e econômico, e o problema de planejamento pode ser resolvido com a perspectiva do mínimo custo, mas, não existe garantia de que as empre-

sas de geração competitivas definam seus investimentos com base nas opções de planejamento propostas. Para resolver o problema de planejamento da transmissão são utilizadas informações relacionadas com a estrutura atual da rede, dos elementos candidatos e das características do sistema. A solução deve ser ótima do ponto de vista técnico e econômico. O problema da expansão da transmissão pode ser formulado considerando na função objetivo a minimização dos custos de investimento, a obtenção de certos níveis de confiabilidade, a minimização das perdas e a minimização da potência não fornecida aos consumidores (racionamento), entre outros aspectos. Também, o problema é chamado planejamento estático quando o plano de expansão encontrado considera um único horizonte, e planejamento multietapa quando se tem em conta vários períodos de tempo dentro dos quais se devem fazer os reforços.

O estudo a longo prazo representa uma parte importante do processo de planejamento, já que é a fase onde são valoradas novas tecnologias e técnicas de solução.

Do ponto de vista matemático, o problema de planejamento de sistemas de transmissão a longo prazo é um problema de programação não-linear inteiro misto (PNLIM). A característica de variável inteira das adições de circuitos fazem com que o problema aumente de dificuldade já que dá origem ao denominado fenômeno da explosão combinatória, que obriga o uso de métodos aproximados de otimização para resolvê-lo, em sistemas de grande complexidade matemática. As principais dificuldades na resolução deste problema estão relacionadas com a natureza combinatória do problema que normalmente leva a um número praticamente infinito de alternativas, inclusive no caso de sistemas de médio porte.

Este problema possui a propriedade de fazer parte dos denominados problemas NP-completos (*non-polynomial*) de difícil solução pelo número de alternativas de soluções presentes no espaço de busca. Além disso, é um problema multimodal, isto é, tem uma grande quantidade de ótimos locais nos quais um algoritmo pode ficar atrapado no processo de busca da solução.

1.4 Motivação para estudo de planejamento da transmissão considerando múltiplos cenários de geração

Dado que nos sistemas com restrições de transmissão se afeta a competição perfeita e, portanto, a eficiência do mercado elétrico, é importante determinar o custo associado a eliminar completamente o congestionamento, para ter uma medida do grau de adequação da rede atual às condições ideais de livre competência no futuro. Desde a perspectiva social um investimento em expansão da transmissão está economicamente justificado se o custo total do congestionamento

eliminado pelo investimento é maior do que custo do próprio investimento, portanto, o resultado obtido nem sempre é economicamente viável.

Para determinar o sistema futuro livre de congestionamento ou sem restrições de transmissão, é necessário encontrar a rede de transmissão ótima que não gere congestionamento em nenhum cenário de geração futuro factível. Para isto, é necessário incluir no processo de planejamento todos os cenários que podem ocorrer, o qual representa um número infinito de cenários. Já que é matemática e computacionalmente impossível gerar todos estes cenários, propõe-se incluir um número finito e reduzido de cenários, mas que representem os infinitos cenários factíveis. Para isto, define-se o conceito de cenários de geração factíveis extremos, a partir dos quais é possível obter um sistema sem congestionamento para todos os infinitos cenários prováveis.

1.5 Motivação para incluir a incerteza na demanda no planejamento da transmissão

A habilidade de projetar, da forma mais precisa possível a carga, é um requerimento importante para o planejamento e a operação dos sistemas elétricos de potência. Mas na prática é impossível projetar exatamente a carga para algum tempo futuro e, portanto, sempre existe algum grau de incerteza na carga projetada. Isto é particularmente certo no caso do planejamento a longo prazo, o qual considera condições que se estendem até a próxima década. A incerteza na carga tem um significativo efeito sobre os planos de expansão dos sistemas elétricos já que a incerteza pode-se traduzir em maiores investimentos, que colocam maior capacidade de geração e transmissão no futuro, e que finalmente podem ser desnecessários. A inclusão da incerteza no valor da carga futura, em cada barra do sistema elétrico, representa um recurso de grande importância prática e necessária nos estudos de planejamento a longo prazo do sistema de transmissão para evitar sobredimensionamentos que aumentam o custo e podem não ser úteis, e inclusive podem afetar negativamente a operação futura.

A incerteza na carga pode ser descrita por uma probabilidade de distribuição cujos parâmetros podem ser estimados a partir de experiências passadas e considerações futuras. Na prática, entretanto, é difícil obter suficiente informação histórica para determinar o tipo de distribuição. A prática mais comum é descrever a incerteza com uma distribuição normal e uma variância dada (BILLINTON; ALLAN, 1996). A incerteza da carga, representada por uma distribuição normal, será abordada como um intervalo discreto nesta tese para sua representação.

A incerteza na carga pode ser modelada usando uma distribuição normal e, portanto, requer-

se a geração de números aleatórios normalmente distribuídos para serem usados no processo de simulação. O valor médio que será usado para a carga é o valor máximo da carga. O intervalo de variação é assumido como sendo uma porcentagem da carga, por exemplo, mais ou menos 5%. O investimento na geração e na transmissão é incrementado, na maioria das vezes, pela incerteza na carga projetada. O efeito é pior na medida em que o tempo considerado no planejamento é maior.

1.6 Motivação para incluir a incerteza na geração no planejamento da transmissão

Igualmente á abordagem com a carga, um modelo de planejamento da expansão da geração a longo prazo, realista, tem muita incerteza também. É necessário, então, identificar as alternativas de expansão mais seguras e valorar a capacidade de geração das usinas futuras assumindo que existe certa capacidade máxima atingível também com uma incerteza associada. Isto é especialmente necessário em sistemas com mercado de eletricidade com o propósito de adequar a rede de transmissão.

Da mesma forma que com a carga, a incerteza na geração pode ser modelada usando uma distribuição normal e, portanto, se requer da geração de números aleatórios normalmente distribuídos para ser usados no processo de simulação. O valor médio que será usado para a geração é o valor máximo da geração, e o intervalo de variação se assume como uma porcentagem dela, por exemplo, mais ou menos 5%. O investimento em transmissão é incrementado na maioria das vezes pela incerteza na geração projetada. O efeito é pior na medida em que o tempo considerado no planejamento é maior.

1.7 Motivação para incluir a retirada de circuitos no planejamento da transmissão

O problema de planejamento a longo prazo de sistemas de transmissão de energia elétrica tradicional determina o plano de expansão de custo mínimo, para um período de tempo futuro, e considera que os investimentos em linhas ou transformadores realizados no passado contribuem com a solução do problema. Considerar que a rede inicial é inalterável afeta o processo de otimização, já que o espaço de soluções é mais restrito, e pode afetar a qualidade da solução. Considerar que é possível retirar linhas ou transformadores existentes na topologia inicial, melhora o desempenho do processo de otimização e, eventualmente, permite reduzir o custo da

nova rede de transmissão, pois a busca se realiza em um espaço de soluções menos restrito. Os elementos existentes na topologia inicial podem afetar a operação do sistema elétrico futuro devido a novas exigências, não previsíveis nos planos de expansão realizados anteriormente. A possibilidade de retirada de circuitos existentes ou desplanificação permite identificar elementos que diminuem a eficiência da rede futura, os quais devem ser desconectados do sistema para a operação normal. Estas linhas devem permanecer disponíveis para ser incluídas novamente quando o sistema precise delas, uma vez que podem resultar importantes em outro contexto de operação.

1.8 Revisão da literatura

Nesta seção apresentam-se os principais trabalhos consultados nesta tese.

1.8.1 Principais trabalhos para a resolução do problema da expansão da transmissão tradicional

Existem muitos modelos matemáticos tradicionalmente disponíveis para resolver o problema de planejamento da expansão da transmissão, a maioria das quais resolvem o problema do ponto de vista da minimização do custo de investimento.

Durante muito tempo, as únicas ferramentas disponíveis para resolver o problema da expansão da transmissão foram ferramentas de análise, como os fluxos de potência. A primeira aproximação na solução do problema de planejamento elétrico foi formulada em (GARVER, 1970). Neste trabalho, o problema se resolve como um problema de fluxo de carga e para sua solução, usa-se um algoritmo de programação linear, o qual determina as melhores trajetórias entre os pontos de geração e os pontos de carga. Em (KALTENBATCH; PERSON; GEHRIG, 1970), é proposto um método que combina a programação linear e a programação dinâmica. Em (DUSONCHET; EL-ABIAD, 1973), é proposta uma solução usando unicamente programação dinâmica, entretanto, a metodologia é restringida pelo grande esforço computacional que se requer. Em (MONTICELLI et al., 1982) é proposto um método heurístico construtivo baseado na análise de sensibilidade e gera-se um índice de **mínimo esforço**, o qual resulta da solução de um problema de programação linear e guia o processo de otimização.

Depois destes trabalhos surge, na literatura especializada, uma grande variedade de técnicas, as quais podem ser classificadas como: métodos de otimização matemática, tais como programação linear, (GARVER, 1970; VILLASANA; GARVER; SALON, 1985), programação não linear, (SANCHEZ et al., 2005), programação linear inteira mista, (ROMERO; MONTICELLI, 1994; AL-

GUACIL; MOTTO; CONEJO, 2003), decomposição de Benders, (ROMERO, 1989, 1993; BINATO; PEREIRA; GRANVILLE, 2001), métodos de programação dinâmica, (DUSONCHET; EL-ABIAD, 1973), algoritmos *Branch and Bound* (HAFFNER et al., 2000), e o método de ponto interior (RIDER; GARCIA; ROMERO, 2004); métodos heurísticos baseados em funções sigmóides, (OLIVEIRA et al., 2005), em funções de sensibilidade, (MONTICELLI et al., 1982; PEREIRA; PINTO, 1985), sistemas inteligentes, tais como algoritmos genéticos, (ROMERO; GALLEGO; MONTICELLI, 1998; SILVA; GIL; AREIZA, 2000), *simulated annealing*, (ROMERO; GALLEGO; MONTICELLI, 1996), busca tabu, (GALLEGO; MONTICELLI; ROMERO, 2000), *Greedy Randomized Adaptive Search Procedure* GRASP (BINATO; OLIVEIRA; ARAUJO, 2001); e outros, tais como modelos de teoria de jogos, (CONTRERAS; WU, 1999; ZOLEZZI; RUDNICK, 2002; STYCZYNSKI, 1999) e sistemas especialistas, (GALIANA; MCGILLIS; MARIN, 1992).

1.8.2 Principais trabalhos para o problema da expansão da transmissão modificado

Com a introdução de mercados baseados em bolsa e contratos bilaterais, surgem novos modelos de expansão da transmissão onde é proposto, por exemplo, a maximização do benefício social, (SHRESTHA; FONSEKA, 2004). Dentro do processo de incorporação de aspectos econômicos no planejamento da transmissão, os estudos de planejamento devem considerar diferentes cenários operacionais (FANG; HILL, 2003; JUNIOR, 2005), condições de confiabilidade e segurança (CHOI; MOUNT; THOMAS, 2007; SILVA et al., 2005; CHOI et al., 2006), restrições de mercado (LU; DONG; SAHA, 2006) condições de competência (BALDICK; KAHN, 1993; RUDNICK; ZOLEZZI, 1999; DAVID; WEN, 2001; XU; DONG; WONG, 2003), e o benefício obtido pelos diferentes agentes do mercado: geradores, carga e transmissores, (TORRE; CONEJO; CONTRERAS, 2008). Dado que um dos aspectos críticos que afeta a livre competência nos mercados elétricos é o congestionamento produzido pelas restrições da rede, existem vários estudos que analisam o problema de congestionamento em ambientes competitivos como (SCOTT; HOGAN; POPE, 1997; FANG; DAVID, 1999; METTE; KURT, 2007; PAPALEXOPOULOS, 1997) e outros que consideram o congestionamento no planejamento da transmissão como (LU; DONG; SAHA, 2005; LU et al., 2006; SHRESTHA; FONSEKA, 2006). Outro aspecto que afeta o planejamento a longo prazo da rede de transmissão é a incerteza na carga e a geração futura. Em (SILVA et al., 2006) é apresentada uma proposta para realizar o planejamento da expansão da transmissão considerando incerteza na carga futura e em (TOR; GUVEN; SHAHIDEHPOUR, 2008) é proposto um procedimento que valora o impacto na expansão da rede de transmissão das decisões potenciais de investimento em geração. Com relação ao período de tempo analisado, o planejamento pode ser realizado considerando somente um horizonte de planejamento, como no planejamento tradici-

onal, ou pode ser feito separando o período de interesse em vários intervalos de tempo, como no planejamento considerando múltiplos estágios apresentado em (HAFFNER, 2000; ESCOBAR; GALLEGO; ROMERO, 2004).

1.8.3 Trabalhos com diferentes modelos usados para resolver o problema da expansão da transmissão

Do ponto de vista do modelo matemático, no problema de planejamento, a rede de transmissão pode ser representada através do modelo de transportes, como em (HAFFNER et al., 2000), através do modelo disjuntivo, como em (BAHIENSE et al., 2001), através de modelos híbridos, como em (GALLEGO; ROMERO; ESCOBAR, 2000), através do modelo DC, como em (SANCHEZ et al., 2005), ou através do modelo AC, como em (RIDER; GARCIA; ROMERO, 2007). Em (ROMERO et al., 2002) aparece um resumo dos modelos usados.

1.8.4 Trabalhos que mostram outras formas de resolver o problema da expansão da transmissão

O desenvolvimento do processamento paralelo despertou grande interesse nos pesquisadores da otimização, por permitir encontrar respostas a problemas complexos em tempos computacionais menores. Um algoritmo que pode ser implementado utilizando processamento paralelo, para resolver o problema de planejamento, é o Algoritmo Genético (GA), como é mostrado em (DEOLIVEIRA, 2004).

Também existem propostas de otimização multiobjetivo para resolver o problema de planejamento como é mostrado em (SUN; YU, 2000).

Em (LATORRE et al., 2003) é mostrado um resumo mais detalhado de algoritmos e os modelos usados em planejamento da expansão da transmissão.

1.8.5 Trabalhos que mostram outros aspectos relacionados com o planejamento da transmissão

O problema de planejamento em esquemas desregulados está estritamente relacionado com outros aspectos que são estudados por outros grupos de pesquisadores, e que devem ser considerados também dentro das novas propostas. Os mais importantes destes são: o problema de planejamento da geração em sistemas com mercado, (BJORKVOLL et al., 2001); o estudo das incertezas a longo prazo e sua influencia nas decisões ótimas de investimento em geração, (BOT-

TERUD; ILIC; WANGENSTEEN, 2005); o problema de reestruturação de sistemas tradicionais para sua adaptação a sistemas com mercado de eletricidade, o qual inclui desde o desenvolvimento de novas instituições (HOGAN, 2005), até o desenvolvimento de novas arquiteturas de mercado, (WILSON, 2001); os problemas associados a contratos de potência em sistemas com mercado, (YINGVIVATANAPONG; LEE; LIU, 2008); valoração da geração considerando incertezas no mercado, (SUN; LIU, 2007); o problema da sensibilidade dos planos de expansão da transmissão com os parâmetros de oferta e demanda de eletricidade, (SAUMA; OREN, 2007); e o problema de um planejamento da transmissão restrito a singularidades dos estados ou dos países, mas que geram um grande impacto fora da fronteira, (CARREÑO, 2003), entre outros.

1.9 Organização dos capítulos

A estrutura deste texto é a seguinte:

O capítulo introdutório mostra um breve relato dos aspectos relacionados com o problema de planejamento dos sistemas de transmissão e, especialmente, a forma como mudou este problema com o aparecimento dos esquemas de mercado de eletricidade. Também é apresentada a motivação para estudar o problema de desplanificação e de múltiplos cenários de geração dentro do contexto de solução do problema de planejamento da rede de transmissão. Também é apresentada uma revisão da literatura especializada no desenvolvimento do trabalho.

No capítulo 2 é apresentado o problema de planejamento dos sistemas de transmissão e são apresentados os diferentes modelos matemáticos que são usados no processo de solução deste problema.

No capítulo 3 são apresentados vários modelos alternativos para incluir a retirada de circuitos existentes na topologia inicial do sistema, o que será chamado desplanificação, com o propósito de eliminar circuitos adicionados ao sistema no passado, mas que podem afetar o desempenho do sistema futuro do ponto de vista da operação e de o custo de investimento. Isto com o propósito de reduzir o efeito dos altos custos produzidos por um planejamento da transmissão que pretende obter uma rede futura livre de congestionamento. Os modelos propostos são provados em sistemas teste da literatura especializada e resolvidos usando um algoritmo genético que inclui as idéias do algoritmo proposto por Chu e Beasley em (BEASLEY; CHU, 1997) e especializações baseadas nas características das redes elétricas.

No capítulo 4 é apresentado o problema de congestionamento imprevisível que pode ocorrer na rede de transmissão futura em sistemas com mercado de eletricidade. É proposta uma forma de considerar os infinitos cenários de geração que podem surgir em um sistema com mer-

cado, para o qual são determinadas informações de demanda e geração máxima futura, além de informações da rede inicial e das grandezas desta rede. É apresentada uma proposta para determinar um número reduzido de cenários de geração que representam os infinitos cenários factíveis, com o propósito de planejar a rede de transmissão. Esta forma de representar os infinitos cenários factíveis permite obter uma rede livre de congestionamento. O problema resultante será denominado: planejamento considerando múltiplos cenários de geração. A proposta é provada no sistema teste IEEE de 24 barras, da literatura especializada, e resolvido usando um algoritmo genético modificado que inclui as idéias do algoritmo proposto por Chu e Beasley em (BEASLEY; CHU, 1997) e especializações baseadas nas características das redes elétricas.

No capítulo 5 é apresentada uma metodologia para resolver o problema de planejamento considerando, simultaneamente, múltiplos cenários de geração e algum grau de congestionamento na rede, usando técnicas de otimização multiobjetivo. Para isto é implementado um algoritmo NSGA-II modificado e especializações baseadas nas características das redes elétricas. Posteriormente, são considerados os efeitos das contingências e das incertezas em geração e carga no custo resultante. A proposta é provada no sistema teste IEEE de 24 barras da literatura especializada.

No capítulo 6 discutem-se as contribuições do trabalho realizado e apresentam-se as conclusões resultantes da experiência adquirida. Também são apresentadas algumas idéias que podem ser usadas como possíveis trabalhos futuros a serem desenvolvidos.

2 Modelagem do Problema de Planejamento de Sistemas de Transmissão

2.1 Introdução

A resolução do problema de planejamento ótimo da expansão de sistemas de transmissão compreende a implementação de dois processos consecutivos: a modelagem matemática e a técnica de solução escolhida para resolver o modelo matemático. A modelagem matemática básica do problema de planejamento de sistemas de transmissão a longo prazo é apresentada neste capítulo, em várias versões. A modelagem matemática modificada para considerar alguns aspectos específicos tratados nesta tese e as técnicas usadas para sua solução são apresentadas nos capítulos seguintes.

A modelagem matemática de um problema de otimização consiste na representação do problema através de uma função objetivo e um conjunto de restrições de igualdade e de desigualdade. Estas relacionam as variáveis de decisão através de expressões ou equações que podem assumir diferentes formas. No caso de problemas da vida real, a modelagem matemática pode ser uma representação exata ou simplificada do problema. Normalmente, conforme se implementam melhorias no modelo matemático do problema real, a técnica de solução se torna mais complexa e, também, alguns modelos se adaptam mais a certas técnicas de solução que a outras. Assim, deve existir um compromisso entre a modelagem matemática adotada e a técnica de solução escolhida. Em geral, a modelagem matemática deve representar, de maneira adequada, o problema da vida real e, além disso, permitir sua resolução através de técnicas disponíveis e com esforços computacionais aceitáveis. Com o desenvolvimento das pesquisas, das técnicas de solução e/ou computadores mais velozes é provável que modelos atualmente considerados complexos se tornem adequados no futuro. É também evidente que a técnica de solução escolhida encontra uma solução para o modelo matemático e não necessariamente para o problema da vida real.

Com relação ao planejamento a longo prazo de sistemas de transmissão, no problema real tem-se um sistema elétrico com uma topologia atual, para o qual busca-se encontrar o plano de expansão ótimo (adição de novos elementos de transmissão) para um horizonte de planejamento definido, que no caso do planejamento a longo prazo, considera condições que se estendem até a próxima década. A solução do problema especifica **onde**, **quantos** e **que** tipos de elementos de transmissão devem ser adicionados ou construídos para que o sistema opere adequadamente no futuro, em um contexto que considera um crescimento especificado da demanda existente, um crescimento especificado da geração existente, o aparecimento de nova demanda e o aparecimento de nova geração. Também, o planejamento tradicional considera que os elementos de transmissão adicionados no passado fazem parte da solução do sistema futuro. A modelagem matemática ideal para indicar a operação futura adequada teria que utilizar o fluxo de carga AC para representar a rede de transmissão, entretanto, o uso do modelo de fluxo de carga AC do sistema de transmissão para resolver o problema de planejamento da expansão de sistemas de transmissão é incipiente, isto é, praticamente não existem publicações na literatura especializada em que seja usado esse modelo (RIDER, 2006), que é usado em análise da operação dos sistemas elétricos. Na verdade, a separação de modelos para trabalhos de operação e de planejamento de sistemas elétricos aconteceu na década de 1960 quando os pesquisadores verificaram que não era possível trabalhar com o modelo de fluxo de carga AC em trabalhos de planejamento da expansão de sistemas de transmissão. Ainda hoje, a maioria dos pesquisadores concordam que o modelo DC (ou o modelo alternativo chamado de disjuntivo) é o modelo ideal para trabalhos de planejamento da expansão de sistemas de transmissão. O modelo de fluxo de carga AC ficou restrito para trabalhos de análise de operação de sistemas de energia elétrica. As dificuldades que aparecem quando se trabalha com o planejamento usando o modelo AC são:

- Não é simples trabalhar com sistemas desconexos onde o sistema apresenta um conjunto de barras isoladas ou ilhadas da parte principal do sistema, uma situação comum na fase inicial do planejamento de transmissão, quando algumas fontes de geração e algumas cargas não foram ainda conectadas eletricamente na rede. Em um sistema desconexo pode-se produzir problemas de convergência. Deve-se esclarecer que não é o modelo matemático AC que impede trabalhar com sistemas desconexos, são as propostas de programação não-linear disponíveis na literatura especializada para resolver este modelo em sistemas de grande porte que dificultam trabalhar com sistemas desconexos. No passado sempre foi difícil encontrar um algoritmo de programação não-linear que apresentasse um desempenho confiável na resolução de problemas de programação não-linear de grande porte. Geralmente, muitos métodos não convergem para determinados problemas não lineares e outros convergem para ótimos locais de pobre qualidade. Esta característica

complica ainda mais o processo de busca de boas soluções quando o modelo não-linear deve ser resolvido em um número elevado de vezes. Na atualidade existem propostas para resolver este problema usando os algoritmos de pontos interiores de ordem superior, os quais estão mostrando um desempenho superior a outras técnicas de programação não-linear (RIDER, 2006). Se requer então desenvolver técnicas de otimização eficientes na tentativa de viabilizar o uso do modelo AC no planejamento da expansão de sistemas de transmissão.

- É necessária uma definição prematura de opções do denominado problema de fornecimento de potência reativa (planejamento de reativos) o qual pode ser resolvido no futuro usando informações mais reais (o sistema planejado pode sofrer alterações por decisões de curto prazo) e aproveitando novas tecnologias. Na verdade, o problema que deve ser resolvido no longo prazo é o problema de fornecimento de potência ativa, devido aos tempos requeridos para construir grandes usinas de geração e novas linhas de transmissão de alta tensão.

Como conseqüência, a modelagem matemática conhecida como fluxo de carga DC é considerada como a modelagem ideal para ser usada no problema de planejamento de sistemas de transmissão e essa modelagem será denominada nesta tese *modelo DC*. Os principais motivos para esse consenso são os seguintes: (1) testes experimentais mostram que os resultados obtidos usando o modelo DC apresentam resultados muito próximos aos resultados obtidos usando o fluxo de carga AC em relação à distribuição dos fluxos de potência ativa na rede e com muito menor esforço computacional; e (2) existem várias técnicas de solução (algoritmos) que resolvem de maneira adequada os problemas de planejamento que usam o modelo DC, já que apesar de ser também não-linear, a não linearidade é produzida pela multiplicação de variáveis contínuas com variáveis inteiras, em algumas restrições, o que pode ser resolvido separando o problema em dois subproblemas: o subproblema de operação e o subproblema de investimento. Este aspecto será analisado posteriormente.

Em diferentes pesquisas foram propostos vários modelos matemáticos alternativos ao modelo DC para representar a rede de transmissão no problema de planejamento. Alguns desses modelos ainda são usados nos trabalhos de planejamento de sistemas de transmissão. Dentre os modelos propostos os de maior interesse são: o modelo de transportes, o modelo híbrido linear e o modelo híbrido não linear. Também, ainda são usadas variantes desses modelos e do próprio modelo DC, como o modelo disjuntivo. Neste capítulo são apresentados e discutidos esses modelos matemáticos e suas principais variantes.

Usando os modelos matemáticos mencionados anteriormente, o problema resultante é um pro-

blema de otimização matemática que envolve relações algébricas lineares e/ou não-lineares e com variáveis de decisão inteiras e reais. Assim, os problemas resultantes correspondem a um campo da pesquisa operacional conhecida como programação não-linear inteira mista. Inicialmente, para resolver esses problemas, podem ser usadas as técnicas de solução de problemas de programação linear inteira mista (PNLIM).

O disjuntivo e o modelo DC usam as duas leis de Kirchhoff para realizar a modelagem matemática do problema de planejamento. Os modelos de transportes e híbridos linear e não-linear, são versões relaxadas (aproximadas) do modelo DC considerado como o modelo ideal.

2.2 Referências históricas

O trabalho de modelagem matemática do problema da expansão de sistemas de transmissão foi realizado por vários autores. Nas pesquisas iniciais de planejamento foram usados modelos mais exatos e também modelos simplificados. Quando eram usados modelos mais exatos, como o modelo de fluxo de carga AC, tipicamente usado para analisar a operação, existia a necessidade de tomar várias decisões empíricas para contornar os problemas de convergência dos problemas de fluxo de carga resultantes. Quando eram usados modelos muito relaxados existia a necessidade de tomar decisões empíricas para completar o trabalho de planejamento. A proposta apresentada em (BALDWIN et al., 1960) faz parte dessa fase inicial de propostas de planejamento.

Garver (GARVER, 1970) fez a primeira proposta formal de uma modelagem própria para os trabalhos de planejamento, diferente da modelagem usada na operação. Esta modelagem agora é conhecida como modelo de transportes. O modelo DC foi proposto e melhorado por vários autores (DECHAMPS; JAMOULLE, 1980; MONTICELLI, 1975; WHITLEY; DARREL, 1993). O modelo híbrido também foi proposto por vários autores, mas aparece com maior destaque em (VILLASANA; GARVER; SALON, 1985). O modelo linear disjuntivo também foi proposto por vários autores simultaneamente, mas é amplamente analisado e usado em (BINATO; PEREIRA; GRANVILLE, 2001). A proposta modificada com a inclusão dos geradores artificiais na modelagem matemática foi inicialmente apresentada em (DECHAMPS; JAMOULLE, 1980) e foi amplamente usada em (GRANVILLE; PEREIRA, 1985; PEREIRA, 1985; ROMERO, 1993; GALLEGO, 1997).

A modelagem matemática, apresentada neste capítulo, não leva em conta as perdas no sistema. Os efeitos das perdas podem ser considerados de várias formas. Em (MONTICELLI, 1983) existe uma proposta para resolver o problema de fluxo de carga DC levando em conta as perdas. Essa idéia pode ser aplicada para a modelagem matemática do problema de planejamento. Em

(MEDINA, 2008) resolve-se o problema de planejamento incluindo o efeito das perdas e usando o modelo DC.

2.3 Modelo de transportes

O modelo de transportes foi a primeira proposta sistemática de modelagem matemática usado com muito sucesso no problema de planejamento de sistemas de transmissão. O modelo de transportes foi inicialmente apresentado por Garver (Garver, 1970) e representou uma proposta fundamental na pesquisa no planejamento da expansão de sistemas de transmissão porque era a única forma de otimizar o problema com as técnicas de otimização disponíveis naquela época. Esses modelos relaxados, diferentes dos usados na análise de operação, foram chamados de modelos de síntese de sistemas de transmissão. O modelo de transportes, assim como todos os modelos de síntese, faz apenas o planejamento considerando o fluxo de potência ativa e, portanto, resolve apenas o problema de capacidade de transmissão. No modelo de transportes é levada em conta a capacidade de operação de circuitos e geradores, e apenas a Primeira Lei de Kirchhoff (PLK). A primeira lei de Kirchhoff simplesmente especifica 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. Neste contexto, a modelagem matemática é um problema de programação linear inteiro misto (PLIM). Obviamente, esta modelagem matemática é uma representação menos adequada do problema real que, por exemplo, o modelo DC e, portanto, a solução encontrada pelo modelo de transportes pode ser menos adequada para o problema real.

As variáveis de decisão e a estrutura matemática do modelo de transportes apresentado originalmente por Garver na referência (GARVER, 1970) são diferentes das apresentadas no sistema de equações (2.1), mas as duas formulações são conceitualmente equivalentes.

2.3.1 Modelo matemático

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

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

Em que v é o investimento devido às adições de circuitos no sistema, c_{ij} é o custo de um circuito no caminho $i - j$, n_{ij} é o número de circuitos adicionados no caminho $i - j$, S é a matriz de incidência nó-ramo do sistema elétrico, f é o vetor de fluxos cujos elementos f_{ij} representam o fluxo total no caminho $i - j$, g é o vetor de geração cujos elementos g_i representam o nível de geração na barra de geração i , d é o vetor de demanda cujos elementos d_i representam a demanda na barra de carga i , n_{ij}^o representa o número de circuitos na configuração base no caminho $i - j$, \bar{f}_{ij} é o fluxo máximo permitido para um circuito no caminho $i - j$, \bar{g} é o vetor de máxima capacidade de geração nas barras de geração, \bar{n}_{ij} é o vetor do número máximo de adições permitidas no caminho $i - j$, e Ω é o conjunto de caminhos candidatos para adição de novos circuitos.

No modelo de transportes, o conjunto de restrições $S f + g = d$ representa as equações correspondentes a primeira lei de Kirchhoff, uma equação para cada barra do sistema; as restrições $|f_{ij}| \leq (n_{ij} + n_{ij}^o) \bar{f}_{ij}$ representam as restrições de capacidade de transmissão dos circuitos (linhas e/ou transformadores) e o valor absoluto é necessário pois os fluxos de potência podem fluir nos dois sentidos. As outras restrições são triviais e representam apenas restrições de limite de geração e de circuitos adicionados em cada caminho candidato $i - j$. Finalmente, as variáveis f_{ij} são irrestritas em valor e as variáveis n_{ij} devem ser inteiras representando a maior fonte de complexidade no problema.

Do ponto de vista da pesquisa operacional o sistema (2.1), o modelo de transportes, é um problema de programação linear inteiro misto (PLIM). A resolução do problema (2.1), isto é, encontrar a solução ótima desse problema não é simples, especialmente para sistemas elétricos de grande porte. Entretanto, se fossem permitidas adições fracionárias de circuitos (linhas de transmissão e/ou transformadores), ou seja, se for permitido que os n_{ij} assumam valores re-

ais, então o sistema (2.1) se transforma em um simples problema de programação linear (PL) mesmo para o caso de sistemas de grande porte. Assim, é evidente que a restrição n_{ij} inteiro produz a maior complexidade no problema (2.1). Estas características serão aproveitadas para desenvolver vários tipos de algoritmos para resolver o problema de planejamento de sistemas de transmissão quando é usado o modelo de transportes.

A grande vantagem do modelo de transportes é que praticamente não existe diferença entre resolver problemas de sistemas conexos e altamente ilhados. Esta característica decorre diretamente do fato de que estamos trabalhando com um modelo linear e não precisamos de referência angular. A desvantagem principal é que a solução apresentada pelo modelo de transportes pode estar distante da solução correspondente ao modelo DC, considerado como sendo modelo ideal. Em outras palavras, a solução ótima do modelo de transportes às vezes pode ficar muito afastada da solução ótima do modelo DC, pois a solução do modelo de transportes não necessariamente satisfaz a segunda lei de Kirchhoff.

2.4 Modelo híbrido não-linear

O modelo híbrido foi proposto originalmente em (VILLASANA; GARVER; SALON, 1985) em um contexto e em uma estrutura diferente à apresentada aqui. Na formulação mais pura, a modelagem matemática do modelo híbrido especifica o seguinte: a parcela do sistema elétrico correspondente aos caminhos nos quais já existem circuitos na configuração base, assim como os que são adicionados em paralelo a esses circuitos devem satisfazer as duas leis de Kirchhoff. A outra parcela correspondente aos caminhos novos em que não existem circuitos na configuração base deve satisfazer unicamente a primeira lei de Kirchhoff. Logo o modelo híbrido é uma mistura entre o modelo de transportes, e o modelo DC. Obviamente, uma vez definida a modelagem matemática desta maneira, a solução ótima encontrada também deve satisfazer as duas leis de Kirchhoff na parte do sistema onde existiam laços na configuração base e a primeira lei de Kirchhoff em todas as barras do sistema elétrico. Assim, por exemplo, se no processo de planejamento for adicionado um circuito num caminho novo, então os laços que eventualmente podem aparecer, como consequência da adição deste circuito, não estão obrigados a satisfazer a segunda lei de Kirchhoff. Aqui reside a diferença principal entre esta formulação do modelo híbrido e a proposta apresentada em (VILLASANA; GARVER; SALON, 1985) onde a modelagem híbrida é usada simplesmente como uma forma de auxílio para o indicador de sensibilidade do algoritmo heurístico proposto. O uso do modelo híbrido não-linear no problema de planejamento de sistemas de transmissão serve para contornar alguns problemas apresentados pelos modelos de transportes e DC. O modelo de transportes tem flexibilidade para trabalhar com

redes não conexas, em contraposição as soluções encontradas podem ficar muito afastadas da solução ótima do modelo DC. Por sua parte o modelo DC pode ter problemas para trabalhar com redes não conexas. Assim, o modelo híbrido permite encontrar soluções mais próximas da solução ótima do modelo DC e com a vantagem de trabalhar eficientemente na parcela correspondente às partes não conexas do sistema. A complexidade matemática deste modelo é quase equivalente ao do modelo DC. Este fato explica porque as diferentes variantes que aparecem na literatura especializada deste modelo são usadas apenas para auxiliar o processo de resolução do modelo DC em algoritmos de planejamento de sistemas de transmissão (ROMERO; MONTICELLI, 1994; VILLASANA; GARVER; SALON, 1985) ou para ajudar a construir populações iniciais de boa qualidade para ser usados em algoritmos genéticos (ESCOBAR, 2002). Entretanto, existe uma modelagem híbrida alternativa que produz uma modelagem linear que pode ser usada isoladamente no problema de planejamento de sistemas de transmissão (BINATO; PEREIRA; GRANVILLE, 2001; HAFFNER, 2000). Esta modelagem alternativa é apresentada posteriormente.

2.4.1 Modelo matemático

A formulação matemática do modelo híbrido não linear assume a seguinte forma:

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

Em que γ_{ij} é a susceptância de um circuito no caminho $i - j$, Ω_1 representa o conjunto de circuitos existentes na configuração base, Ω_2 representa o conjunto de circuitos correspondentes aos novos caminhos ($\Omega = \Omega_1 \cup \Omega_2$), Ω_3 representa o conjunto de barras que fazem parte da configuração base, isto é, as barras que não estão ilhadas, e θ_j é a magnitude do ângulo da

tensão das barras existentes na configuração base, isto é, para as barras que pertencem a Ω_3 .

No sistema (2.2), o conjunto de equações $S \ f + g = d$ representa as equações da primeira lei de Kirchhoff, uma equação por barra, para todas as barras do sistema e o conjunto de equações $f_{ij} - \gamma_{ij}(n_{ij}^o + n_{ij})(\theta_i - \theta_j) = 0$ representa as equações correspondentes à segunda lei de Kirchhoff, com uma equação para cada caminho, que apresenta pelo menos um circuito na configuração base. Este último conjunto de equações representa a diferença entre os três modelos matemáticos que estão sendo apresentados. No modelo de transportes, o conjunto de equações $f_{ij} - \gamma_{ij}(n_{ij}^o + n_{ij})(\theta_i - \theta_j) = 0$ simplesmente não aparecem, já no modelo híbrido aparecem somente uma parcela dessas equações constituídas pelos caminhos em que existem circuitos na configuração base e, finalmente, no modelo DC aparecem todas as equações desse tipo, uma para cada caminho existente e/ou novos caminhos candidatos à adição de circuitos.

A presença de todas as equações correspondentes à segunda lei de Kirchhoff no modelo DC, transforma este modelo num problema mais restrito que os outros modelos. Assim, do ponto de vista da otimização matemática, pode-se dizer que o modelo híbrido é um problema relaxado em relação ao modelo DC, isto é, um conjunto de restrições presentes no modelo DC foram eliminados no modelo híbrido. De igual maneira, o modelo de transportes é um problema relaxado em relação aos modelos híbrido e DC, pois no modelo de transportes foram eliminadas todas as restrições correspondentes à segunda lei de Kirchhoff. Uma consequência natural desse processo de relaxação é que uma solução ótima para o modelo de transportes não necessariamente é uma solução ótima para os modelos híbridos e DC. Frequentemente, uma solução ótima do modelo de transportes pode ser infactível em relação aos outros modelos. A mesma observação é verdadeira com a solução ótima do modelo híbrido em relação ao modelo DC. É um assunto aberto a análise teórica e experimental sobre a qualidade das soluções encontradas pelos modelos relaxados. A vantagem evidente dos modelos relaxados é que podem ser mais facilmente resolvidos. Uma observação importante é verificar que as equações da segunda lei de Kirchhoff, $f_{ij} - \gamma_{ij}(n_{ij}^o + n_{ij})(\theta_i - \theta_j) = 0$, são equações ou restrições não-lineares transformando o problema em não-linear e produzindo um nível de complexidade maior em relação ao modelo de transportes.

2.5 Modelo híbrido linear

Há uma forma alternativa de considerar a modelagem híbrida que pode ser mais fácil de resolver porque o problema resultante é um problema linear inteiro misto (PLIM). Nesta modelagem, usada em (BINATO; PEREIRA; GRANVILLE, 2001; HAFFNER, 2000; VILLASANA; GARVER;

SALON, 1985), todas as novas adições de circuitos devem respeitar 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. Esta modelagem é uma versão relaxada do modelo híbrido não-linear. Esta formulação híbrida deve satisfazer a primeira lei de Kirchhoff em todas as barras do sistema considerando todos os circuitos (existentes e adicionados) e deve respeitar a segunda lei de Kirchhoff somente nos laços existentes na configuração base, considerando apenas os circuitos existentes nesta. Então, existem dois sistemas superpostos, a configuração base que deve satisfazer as duas leis de Kirchhoff e uma rede completa formada pelos circuitos candidatos à adição que deve satisfazer apenas a primeira lei de Kirchhoff.

2.5.1 Modelo matemático

A formulação matemática do modelo híbrido linear assume a seguinte forma:

$$\begin{aligned}
 \min v &= \sum_{(i,j) \in \Omega} c_{ij} n_{ij} & (2.3) \\
 \text{s.a.} & \\
 & S f' + S_o f_o + g = d \\
 & f_{ij}^o - \gamma_{ij} n_{ij}^o (\theta_i - \theta_j) = 0 \quad \forall (i, j) \in \Omega_1 \\
 & |f_{ij}^o| \leq \bar{f}_{ij} n_{ij}^o \quad \forall (i, j) \in \Omega_1 \\
 & |f'_{ij}| \leq \bar{f}'_{ij} n_{ij} \quad \forall (i, j) \in \Omega \\
 & 0 \leq g \leq \bar{g} \\
 & 0 \leq n_{ij} \leq \bar{n}_{ij} \\
 & n_{ij} \quad \text{inteiro} \\
 & f_{ij} \quad \text{irrestrito} \\
 & f'_{ij} \quad \text{irrestrito} \\
 & \theta_j \quad \text{irrestrito} \quad \forall j \in \Omega_3
 \end{aligned}$$

Em que S_o é a matriz de incidência nó-ramo do sistema existente na configuração base, f_o é o vetor de fluxos nos circuitos existentes na configuração base, S é a matriz de incidência nó-ramo do sistema completo, f' é o vetor de fluxos nos circuitos adicionados, os θ_j são os ângulos de fase das barras que estão ligadas ao sistema elétrico na configuração base, Ω_1 representa

o conjunto de circuitos existentes na configuração base, Ω_2 representa o conjunto de circuitos correspondentes aos novos caminhos, $\Omega = \Omega_1 \cup \Omega_2$ e Ω_3 representa o conjunto de barras que fazem parte da configuração base.

Esta modelagem é uma versão relaxada do modelo híbrido não-linear apresentado anteriormente. Nesse contexto, o modelo híbrido linear ainda é um problema PLIM com complexidade próxima do modelo de transportes e, portanto, ainda podem ser usadas as mesmas técnicas de otimização usadas para o modelo de transportes.

2.6 Modelo DC

O modelo DC é uma generalização do modelo de fluxo de carga DC, que está amplamente desenvolvido em (MONTICELLI, 1983), e é o modelo mais explorado em planejamento da expansão de sistemas de transmissão. Este modelo é considerado o ideal a ser utilizado neste problema, e a maioria das novas técnicas de otimização são propostas para resolvê-lo. Neste modelo, tanto os circuitos existentes, na topologia inicial, como os circuitos propostos para ser adicionados ao sistema de transmissão, devem obedecer as duas leis de Kirchhoff. Assim, o modelo matemático resultante é um problema de programação não-linear inteiro misto de elevada complexidade, havendo muitas técnicas de otimização propostas para resolvê-lo, sendo atualmente ainda objeto de estudos e publicações na área de pesquisa operacional e de planejamento. O desenvolvimento de técnicas de otimização eficientes para o modelo DC representa uma das partes mais ativas de pesquisas no problema de planejamento da expansão de sistemas de transmissão na atualidade. Testes experimentais mostram que as topologias encontradas usando o modelo DC apresentam bom desempenho quando são avaliadas com os modelos tradicionais de operação de sistemas de energia elétrica, como o fluxo de carga AC.

2.6.1 Modelo matemático

O modelo DC, usado para representar a rede no problema de planejamento da expansão dos sistemas de transmissão, pode ser apresentado de diferentes formas. Uma das formulações

matemáticas que pode assumir este modelo é a seguinte:

$$\begin{aligned}
 \min v &= \sum_{(i,j) \in \Omega} c_{ij} n_{ij} & (2.4) \\
 \text{s.a.} & \\
 & S f + g = d \\
 & f_{ij} - \gamma_{ij} (n_{ij}^o + n_{ij}) (\theta_i - \theta_j) = 0 \\
 & |f_{ij}| \leq (n_{ij} + n_{ij}^o) \bar{f}_{ij} \\
 & 0 \leq g \leq \bar{g} \\
 & 0 \leq n_{ij} \leq \bar{n}_{ij} \\
 & n_{ij} \text{ inteiro} \\
 & f_{ij} \text{ irrestrito} \\
 & \theta_j \text{ irrestrito}
 \end{aligned}$$

onde todas as variáveis e parâmetros já foram especificados.

O modelo DC pode ser formulado de outra forma utilizando a seguinte relação de equivalência:

$$\bar{\phi}_{ij} = \frac{\bar{f}_{ij}}{\gamma_{ij}}$$

Usando a relação anterior e após algumas manipulações algébricas, pode-se chegar a uma formulação equivalente que assume a seguinte forma:

$$\begin{aligned}
\min v &= \sum_{(i,j) \in \Omega} c_{ij} n_{ij} & (2.5) \\
\text{s.a.} & \\
& B\theta + g = d \\
& |\theta_i - \theta_j| \leq \bar{\phi}_{ij} \quad \forall (i, j) \in \Omega_1 \\
& n_{ij} |\theta_i - \theta_j| \leq n_{ij} \bar{\phi}_{ij} \quad \forall (i, j) \in \Omega_2 \\
& 0 \leq g \leq \bar{g} \\
& 0 \leq n_{ij} \leq \bar{n}_{ij} \\
& n_{ij} \quad \text{inteiro} \\
& \theta_j \quad \text{irrestrito}
\end{aligned}$$

Em que B é a matriz de susceptâncias do sistema elétrico e θ é o vetor de ângulos de tensão de barras do sistema elétrico.

2.7 Modificações na modelagem básica

Na utilização de algumas técnicas de resolução às vezes é mais adequado realizar algumas modificações na modelagem básica dos modelos usados no problema de planejamento de sistemas de transmissão. A modificação mais usada é a utilização de geradores artificiais em todas as barras de carga. O objetivo fundamental da mudança é tornar o problema modificado mais fácil de resolver usando determinados tipos de algoritmos. Do ponto de vista matemático, os geradores artificiais constituem apenas novas variáveis (incógnitas) no problema. Portanto, o problema original fica com um número de variáveis aumentado, mas pode ser mais fácil de resolver. Logicamente, para que a solução de ambos problemas (original e modificado) sejam equivalentes, na solução final todas as variáveis correspondentes aos geradores artificiais devem ser iguais a zero.

Usando as novas variáveis r_k correspondentes aos geradores artificiais, os modelos mais usados em planejamento de sistemas de transmissão assumem a seguinte forma:

Modelo de transportes:

$$\min v = \sum_{(i,j) \in \Omega} c_{ij} n_{ij} + \alpha \sum_{k \in \Gamma} r_k \quad (2.6)$$

s.a.

$$S f + g + r = d$$

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

$$0 \leq r \leq d$$

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

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

$$n_{ij} \text{ inteiro}$$

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

Modelo híbrido:

$$\min v = \sum_{(i,j) \in \Omega} c_{ij} n_{ij} + \alpha \sum_{k \in \Gamma} r_k \quad (2.7)$$

s.a.

$$S f + g + r = d$$

$$f_{ij} - \gamma_{ij} (n_{ij}^o + n_{ij}) (\theta_i - \theta_j) = 0 \quad \forall (i, j) \in \Omega_1$$

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

$$0 \leq r \leq d$$

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

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

$$n_{ij} \text{ inteiro}$$

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

$$\theta_j \text{ irrestrito } \forall j \in \Omega_3$$

Modelo DC:

$$\begin{aligned}
\min v &= \sum_{(i,j) \in \Omega} c_{ij} n_{ij} + \alpha \sum_{k \in \Gamma} r_k & (2.8) \\
\text{s.a.} & \\
& S f + g + r = d \\
& f_{ij} - \gamma_{ij} (n_{ij}^o + n_{ij}) (\theta_i - \theta_j) = 0 \\
& |f_{ij}| \leq (n_{ij}^o + n_{ij}) \bar{f}_{ij} \\
& 0 \leq r \leq d \\
& 0 \leq g \leq \bar{g} \\
& 0 \leq n_{ij} \leq \bar{n}_{ij} \\
& n_{ij} \text{ inteiro} \\
& f_{ij} \text{ irrestrito} \\
& \theta_j \text{ irrestrito}
\end{aligned}$$

Sendo: que Γ representa o conjunto de todas as barras k em que existe demanda, r_k representa a geração artificial (ou fictícia) na barra k e α é um parâmetro de penalidade suficientemente grande para tornar pouco atrativa a alternativa de investimento com valores de r_k diferentes de zero.

Matematicamente, a inclusão das variáveis artificiais permite obter um problema de maior tamanho com um incremento das variáveis, mas freqüentemente é mais fácil de resolver, usando determinados tipos de algoritmos. É interessante observar que o modelo modificado sempre possui uma solução factível trivial, não necessariamente ótima, fazendo cada $r_k = d_k$ e todas as outras variáveis iguais a zero. Esta característica será adequadamente aproveitada nos processos de resolução implementados por alguns algoritmos nos capítulos seguintes.

2.8 O Modelo linear disjuntivo

A modelagem matemática considerada como sendo ideal é o chamado modelo DC que é um problema de programação não-linear inteiro misto (PNLIM). Entretanto, é possível transformar o modelo DC não-linear num problema equivalente cuja modelagem matemática corresponde a um “modelo linear”. Em geral, sempre é possível transformar um problema não linear quadrático com variáveis binárias e reais num problema linear com variáveis binárias e reais

usando uma transformação que permite “separar” os termos quadráticos em relações lineares. Este processo é obtido incorporando ao problema um parâmetro M de valor muito grande. Esta modelagem chamada linear disjuntiva foi proposta por vários autores. Entretanto, uma análise detalhada desta modelagem é apresentada em (BINATO; PEREIRA; GRANVILLE, 2001). A modelagem linear disjuntiva, cuja solução ótima é a mesma que o modelo DC, assume a seguinte forma:

$$\begin{aligned}
 \min v &= \sum_{(i,j) \in \Omega} c_{ij} y_{ij} + \alpha \sum_{k \in \Gamma} r_k & (2.9) \\
 \text{s.a.} & \\
 & S_o f^o + S_1 f^1 + g + r = d \\
 & f_{ij}^o - \gamma_{ij}^o (\theta_i - \theta_j) = 0 \quad \forall (i, j) \in \Omega_1 \\
 & f_{ij}^1 - \gamma_{ij}^1 (\theta_i - \theta_j) \leq M(1 - y_{ij}) \\
 & f_{ij}^1 - \gamma_{ij}^1 (\theta_i - \theta_j) \geq -M(1 - y_{ij}) \\
 & |f_{ij}^o| \leq \bar{f}_{ij} \\
 & |f_{ij}^1| \leq \bar{f}_{ij} y_{ij} \\
 & 0 \leq r \leq d \\
 & 0 \leq g \leq \bar{g} \\
 & y_{ij} \in \{0, 1\} \quad \forall (i, j) \in \Omega_T \\
 & f_{ij}^o, f_{ij}^1, \theta_j \quad \text{irrestritos}
 \end{aligned}$$

Em que y_{ij} é uma variável binária igual a 1 se é adicionado o circuito no caminho $i - j$, caso contrário é igual a 0, S_o é a matriz de incidência nó-ramo dos circuitos existentes na configuração base com fluxos f^o e S_1 é a matriz de incidência nó-ramo dos circuitos candidatos considerados como variáveis binárias e com fluxos f^1 .

Em relação ao modelo linear disjuntivo apresentado, devem-se realizar as seguintes observações:

1. O conjunto de restrições $S_o f^o + S_1 f^1 + g + r = d$ representa a primeira lei de Kirchhoff e corresponde a n_b restrições lineares, sendo n_b o número de barras do sistema.
2. O conjunto de restrições $f_{ij}^o - \gamma_{ij}^o (\theta_i - \theta_j) = 0$, representa as restrições da segunda lei de Kirchhoff para os circuitos existentes na configuração base e existe uma equação para cada caminho em que existe circuito na configuração base.

Neste contexto, γ_{ij}^o representa a susceptância equivalente dos circuitos existentes na configuração base no caminho $i - j$ e S_o é a matriz de incidência nó-ramo dos circuitos existentes na configuração base. Portanto, se existem nl_o caminhos em que existem circuitos na configuração base, a matriz S_o é de dimensão $nl_o \times nb$. Deve-se observar que se num caminho existem vários circuitos na configuração base, essa informação é armazenada em uma única coluna da matriz S_o .

3. O conjunto de restrições $f_{ij}^1 - \gamma_{ij}^1(\theta_i - \theta_j) \leq M(1 - y_{ij})$ e $f_{ij}^1 - \gamma_{ij}^1(\theta_i - \theta_j) \geq -M(1 - y_{ij})$ realmente pode ser representada da seguinte forma compactada:

$$|f_{ij}^1 - \gamma_{ij}^1(\theta_i - \theta_j)| \leq M(1 - y_{ij}) \quad (2.10)$$

e representa a segunda lei de Kirchhoff para cada circuito candidato à adição. Na modelagem existe uma restrição do tipo (2.10) para cada circuito candidato a adição. Assim, por exemplo, se num caminho $i - j$ é possível adicionar até quatro circuitos, então devem existir quatro restrições do tipo (2.10) porque cada circuito candidato à adição é considerado separadamente como uma variável binária. Logicamente, existem formas alternativas de representar as variáveis inteiras através de uma soma de variáveis binárias, na tentativa de diminuir o número de variáveis binárias. Considerando a adição de cada circuito isoladamente como uma variável binária então a matriz de incidência nó-ramo S_1 deve ter uma dimensão muito maior que a matriz S_o sendo que a mesma observação é válida para os tamanhos dos vetores f^o e f^1 .

4. É fácil verificar que a relação (2.10) representa a segunda lei de Kirchhoff para cada circuito binário candidato à adição. Assim, se um circuito no caminho $i - j$ for adicionado ao sistema, com y_{ij} , então de (2.10) verifica-se facilmente que:

$$|f_{ij}^1 - \gamma_{ij}^1(\theta_i - \theta_j)| \leq 0 \implies f_{ij}^1 - \gamma_{ij}^1(\theta_i - \theta_j) = 0$$

Relação que representa a segunda lei de Kirchhoff para o caminho $i - j$. Caso contrário, se não é adicionado um circuito no caminho $i - j$, com $y_{ij} = 0$, então a (2.10) se transforma na seguinte relação:

$$|f_{ij}^1 - \gamma_{ij}^1(\theta_i - \theta_j)| \leq M$$

Que é uma restrição trivial, sempre verdadeira, se o parâmetro M for muito grande.

O modelo linear disjuntivo apresenta algumas vantagens e desvantagens em relação ao modelo DC não-linear convencional. A principal desvantagem está relacionada com o aumento da dimensão do problema com a introdução de variáveis binárias (no modelo DC podem ser usadas as variáveis inteiras n_{ij}) e, principalmente, com a escolha ou determinação do parâmetro M grande para cada restrição que passa a representar o fator complicante na solução do modelo linear disjuntivo. A principal vantagem está relacionada com a modelagem linear e, eventualmente, podem-se desenvolver algoritmos adequados com propriedades de convergência interessantes do ponto de vista teórico. Uma análise detalhada das vantagens e desvantagens da utilização do modelo linear disjuntivo está apresentada em (BINATO; PEREIRA; GRANVILLE, 2001).

3 Modelagem Matemática Incluindo a Possibilidade de Retirada de Linhas de Transmissão

3.1 Introdução

Na modelagem matemática tradicional do problema de planejamento da expansão de sistemas de transmissão a idéia central é identificar as linhas de transmissão que devem ser **adicionadas** á topologia base para que o sistema opere de forma adequada. Nesse contexto, não existe a possibilidade de retirar linhas existentes na topologia base porque existe a suposição de que todas essas linhas ajudam a resolver adequadamente o problema. Adicionalmente, algumas linhas de transmissão podem ter sido adicionadas ao sistema no passado em outro contexto diferente ao de operação normal.

Neste capítulo são apresentados dois modelos matemáticos e uma metodologia de solução para o problema de planejamento da expansão da transmissão considerando a retirada de circuitos, o que será denominado planejamento considerando desplanificação. A idéia da desplanificação é valorar a potencialidade de obter uma melhor solução para a rede futura considerando a possibilidade de retirar da operação normal alguns circuitos existentes na topologia inicial. Não existem na atualidade trabalhos similares na literatura especializada que explorem esta possibilidade para o caso de planejamento da expansão da transmissão no longo prazo.

É conhecido, tanto formal como informalmente (FISHER; O'NEILL; FERRIS, 2008), que os operadores dos sistemas elétricos modificam a topologia da rede de transmissão para melhorar perfis de tensão (SHAO; VITTAL, 2005), incrementar a capacidade de transferência de potência (GRANELLI et al., 2006), ajustar o despacho de geração, alterar a relação produção-consumo de potência reativa, reduzir custos de operação, reduzir perdas de potência e melhorar a segurança do sistema (SCHNYDER; GLAVITSCH, 1990), entre outros. Nestes casos, algumas linhas de transmissão são temporariamente retiradas da operação, mas não devem ser retiradas permanentemente, e devem permanecer disponíveis para ser incorporadas de novo quando o sistema o

precise. Com base nesta idéia, este trabalho explora a possibilidade de retirar da operação normal alguns elementos de transmissão da rede inicial com o propósito de valorar a potencialidade de melhorar o desempenho e reduzir os custos de expansão da rede de transmissão futura.

Pode não ser evidente que a retirada de operação de alguns elementos de transmissão da rede atual possam produzir melhor desempenho na rede planejada futura, especialmente se é assumido que a rede inicial também foi obtida através de um processo de otimização. Pode-se comprovar que o planejamento da expansão da transmissão realizado, a partir da consideração de retirar da operação alguns elementos existentes, produz soluções de menor custo de investimento que o planejamento da expansão que usa todos os elementos da rede inicial. Existe uma explicação pela qual a rede de transmissão atual pode representar uma solução inicial de pobre qualidade para o novo problema: os cenários geração/carga considerados no processo de otimização. Para um sistema estudado, a rede de transmissão ótima muda, se mudam os cenários geração/carga considerados.

Testes exaustivos mostram que para um sistema elétrico, diferentes cenários de geração/carga produzem diferentes configurações ótimas da rede de transmissão. Os cenários de geração/carga futuros são incertos e não podem ser previstos com exatidão e segurança, sendo na verdade o resultado de descontinuidades, rupturas e inflexões do passado, altamente influenciado por novos fatos portadores de futuro, e resultado dos interesses e estratégias dos diversos atores, tanto do lado da oferta quanto do lado da demanda.

Deve-se esclarecer que a desplanificação é somente a primeira etapa de um processo de planejamento da expansão que deve incluir estudos adicionais de segurança, pois com a retirada de elementos pode-se diminuir a confiabilidade do sistema elétrico. Nesta tese a desplanificação somente é explorada como uma possibilidade de reduzir custos de investimento na rede futura para um sistema livre de congestionamento, neste contexto, depois da desplanificação são realizadas outras etapas nas quais são adicionados novos elementos que permitem levar a confiabilidade a níveis aceitáveis. Baseados na idéia da retirada de circuitos para melhorar a operação de curto prazo (FISHER; O'NEILL; FERRIS, 2008), nesta proposta não é considerada a opção de retirar elementos do sistema em forma definitiva. Somente se considera que os elementos são retirados temporariamente e que devem permanecer disponíveis para ser reincorporados quando o sistema precise deles.

A implementação de estratégias que consideram a retirada de operação de elementos de transmissão existentes, tem associada alguns problemas que devem ser adequadamente resolvidos. Um destes é a forma como se recuperam os custos de investimento destes elementos. Na verdade, este é um problema que já existe nos sistemas reais, nos quais os operadores modi-

ficam a topologia do sistema retirando alguns elementos como uma alternativa para melhorar algumas características operativas do sistema (FISHER; O'NEILL; FERRIS, 2008; SHAO; VITTAL, 2005; GRANELLI et al., 2006; SCHNYDER; GLAVITSCH, 1990). Portanto, a solução deste problema tem de ser gerada em um contexto mais geral.

Do ponto de vista da desplanificação podem-se analisar mecanismos de compensação sempre que a diferença entre a planificação tradicional e a planificação considerando retirada de circuitos seja maior aos custos de recuperação dos investimentos dos elementos que se devem desconectar durante longos períodos de tempo. Outro problema tem a ver com a implementação prática da conexão e desconexão destes elementos durante a operação do sistema. Este não é realmente um problema já que a tecnologia atual conta com sistemas eletrônicos e de comunicações aplicáveis a sistemas de potência que permitem esta implementação.

Do ponto de vista do problema de otimização que resulta ao considerar a desplanificação, este é um problema de programação não-linear com variáveis inteiras e contínuas, PNLIM, de difícil solução. Com o propósito de encontrar soluções de excelente qualidade em forma eficiente é necessário aplicar técnicas de solução robustas como as denominadas técnicas metaheurísticas (ROMERO; GALLEGO; MONTICELLI, 1998; GALLEGO; MONTICELLI; ROMERO, 2000; BINATO; OLIVEIRA; ARAUJO, 2001).

3.2 Propostas de resolução

A primeira proposta de modelagem matemática em que além das exigências de planejamento tradicional adicionamos a possibilidade de retirar de operação elementos de transmissão existentes na topologia base assume a seguinte forma:

$$\text{Min } v = \sum_{(i,j) \in \Omega} c_{ij} n_{ij} + \alpha \sum_{k \in \Omega_r} r_k \quad (3.1)$$

s.a.

$$Sf + g = d \quad (3.2)$$

$$f_{ij} - \gamma_{ij}(n'_{ij} + n_{ij})(\theta_i - \theta_j) = 0 \quad (3.3)$$

$$|f_{ij}| \leq (n'_{ij} + n_{ij}) \bar{f}_{ij} \quad (3.4)$$

$$\begin{aligned}
0 &\leq g \leq \bar{g} \\
0 &\leq r \leq d \\
0 &\leq n_{ij} \leq \bar{n}_{ij} \\
0 &\leq n'_{ij} \leq n^o_{ij} \\
n_{ij} &\text{ e } n'_{ij} \text{ inteiros} \\
f_{ij} &\text{ e } \theta_j \text{ irrestritos} \\
(i, j) &\in \Omega
\end{aligned}$$

Onde todas as grandezas já foram definidas anteriormente exceto a nova variável de decisão n'_{ij} . Esse tipo de variável, que modela as linhas existentes na topologia base tem custo zero e pode ter um valor máximo de n^o_{ij} .

Deve-se observar que na nova proposta de modelagem matemática não existem linhas de transmissão na topologia base, mas existe um novo tipo de linha de transmissão que pode ser adicionada com custo igual a zero. Portanto, se todas as linhas de transmissão existentes na topologia base são importantes na operação do sistema elétrico, então, na solução ótima do problema o valor das novas variáveis de decisão deve ser igual a $n'_{ij} = n^o_{ij}$. Entretanto, se alguma linha de transmissão existente na topologia base for irrelevante ou prejudica a operação adequada do sistema elétrico então na solução ótima do problema deve ser verdadeira a relação $n'_{ij} < n^o_{ij}$. Após resolver o problema podemos identificar as linhas retiradas da topologia base usando a relação $n''_{ij} = n^o_{ij} - n'_{ij}$. Nesta primeira proposta de modelagem matemática aparecem novas variáveis de decisão que não aparecem na função objetivo.

Os testes mostram que as linhas existentes na topologia base podem ser classificadas em três grupos:

1. Linhas de transmissão que são fundamentais para a operação adequada do sistema elétrico.
2. Linhas de transmissão que não são fundamentais para a operação adequada do sistema elétrico mas a permanência dessas linhas de transmissão também não prejudicam a operação adequada do sistema elétrico.
3. Linhas de transmissão que prejudicam a operação adequada do sistema elétrico.

As linhas de transmissão do segundo tipo são as problemáticas quando usamos a primeira modelagem matemática. Essas linhas podem ser retiradas ou permanecer na proposta de solução.

Deve-se observar que esse tipo de linha de transmissão gera muitas soluções ótimas alternativas para a modelagem matemática apresentada. Assim, pode-se mudar ligeiramente a modelagem matemática apresentada para identificar as linhas de transmissão do segundo tipo e para gerar soluções mais consistentes. Em consequência podem-se usar dois modelos matemáticos alternativos:

- a. Um modelo que retira todas as linhas de transmissão do segundo tipo.
- b. Um modelo que preserva na solução (e no sistema elétrico) todas as linhas de transmissão do segundo tipo.

A primeira proposta permite identificar todas as linhas de transmissão que podem ser retiradas da topologia base.

Sugere-se, então, uma segunda proposta de modelagem matemática que permite incentivar a retirada de linhas de transmissão do segundo tipo existentes na topologia base. Esta proposta de modelagem matemática assume a seguinte forma:

$$\begin{aligned}
 \text{Min } v &= \sum_{(i,j) \in \Omega} c_{ij} n_{ij} + \sum_{(i,j) \in \Omega} n'_{ij} + \alpha \sum_{k \in \Omega_r} r_k & (3.5) \\
 \text{s.a.} & \\
 Sf + g &= d \\
 f_{ij} - \gamma_{ij}(n'_{ij} + n_{ij})(\theta_i - \theta_j) &= 0 \\
 |f_{ij}| &\leq (n'_{ij} + n_{ij}) \bar{f}_{ij} \\
 0 &\leq g \leq \bar{g} \\
 0 &\leq r \leq d \\
 0 &\leq n_{ij} \leq \bar{n}_{ij} \\
 0 &\leq n'_{ij} \leq n^o_{ij} \\
 n_{ij} \text{ e } n'_{ij} &\text{ inteiros} \\
 f_{ij} \text{ e } \theta_j &\text{ irrestritos} \\
 (i, j) &\in \Omega
 \end{aligned}$$

Ao comparar esta proposta com a primeira proposta de modelagem matemática apenas muda a função objetivo (3.1). Pode-se observar que apenas mudou-se a função objetivo incluindo

as variáveis n'_{ij} com custos unitários (custos insignificantes). Assim, a nova modelagem vai incentivar a retirada de linhas de transmissão existentes na topologia base e, portanto, as linhas de transmissão consideradas do segundo tipo devem ser retiradas da solução, isto é, devem ser retiradas do sistema elétrico.

Uma terceira proposta de modelagem matemática permite preservar na solução as linhas de transmissão do segundo tipo e que podem ser de interesse na operação do sistema elétrico quando são realizadas mudanças na forma de operação desse sistema (por exemplo, pequenas mudanças na demanda ou na presença de contingências). A terceira proposta de modelagem matemática assume a seguinte forma:

$$\begin{aligned}
 \text{Min } v = & \sum_{(i,j) \in \Omega} c_{ij} n_{ij} - \sum_{(i,j) \in \Omega} n'_{ij} + \alpha \sum_{k \in \Omega_r} r_k & (3.6) \\
 \text{s.a.} & \\
 & Sf + g = d \\
 & f_{ij} - \gamma_{ij} (n'_{ij} + n_{ij}) (\theta_i - \theta_j) = 0 \\
 & |f_{ij}| \leq (n'_{ij} + n_{ij}) \bar{f}_{ij} \\
 & 0 \leq g \leq \bar{g} \\
 & 0 \leq r \leq d \\
 & 0 \leq n_{ij} \leq \bar{n}_{ij} \\
 & 0 \leq n'_{ij} \leq n^o_{ij} \\
 & n_{ij} \text{ e } n'_{ij} \text{ inteiros} \\
 & f_{ij} \text{ e } \theta_j \text{ irrestritos} \\
 & (i, j) \in \Omega
 \end{aligned}$$

Pode-se observar que apenas mudou-se a função objetivo (3.1) incluindo as variáveis n'_{ij} com custos unitários negativos (custos insignificantes). Assim, a nova modelagem vai incentivar a preservação das linhas de transmissão existentes na topologia base e, portanto, as linhas de transmissão consideradas do segundo tipo devem ser preservadas na solução, isto é, não devem ser retiradas do sistema elétrico.

3.3 Técnica de resolução

Em otimização, a escolha do método de resolução a ser utilizado depende principalmente da razão entre a qualidade da solução gerada pelo método e o tempo gasto para encontrar essa

solução. Nesse nível, a maioria dos problemas é intratável, ou seja, são problemas para os quais é improvável que se consiga desenvolver um algoritmo exato que possa ser executado em tempo razoável. Para viabilizar a obtenção de soluções é preciso utilizar, em muitos casos, métodos heurísticos. Esses métodos, quando são bem desenvolvidos e adaptados ao problema que se deseja resolver, são capazes de apresentar soluções de boa qualidade em tempo compatível com a necessidade de rapidez presente nos problemas. O desenvolvimento e sucesso dos métodos heurísticos, em especial as metaheurísticas, fomentou o interesse dos pesquisadores na aplicação desses métodos em problemas de otimização combinatória mono-objetivo e multiobjetivo, considerados difíceis computacionalmente. Os métodos heurísticos podem ser divididos em três classes que diferem basicamente na forma como exploram o espaço de soluções dos problemas. A primeira classe de heurísticas são as chamadas de construtivas. Estas heurísticas são especializadas para um dado problema e constroem uma solução pela adição de componentes da mesma através de regras específicas associadas com a estrutura do problema. A segunda classe de heurísticas são as chamadas de Busca Local ou Busca em Vizinhança. Estas heurísticas iniciam com uma solução completa do problema, e constroem uma vizinhança desta solução que contém todas as soluções alcançáveis através de uma regra de movimento que modifica a solução inicial. Dessa vizinhança, escolhe-se uma solução que possua uma avaliação melhor que a solução inicial. A solução escolhida torna-se a nova solução inicial e o processo continua até encontrar um ótimo local. Claramente, a eficiência das heurísticas de busca local depende da escolha da solução inicial e da definição de uma vizinhança que estabelece uma relação entre as soluções no espaço de decisões. Uma vez chegado ao ótimo local, essas heurísticas param e não são capazes de escapar da otimalidade local e explorar novas regiões do espaço de busca. A terceira classe de heurísticas são chamadas de metaheurísticas, que são métodos inteligentes flexíveis, pois possuem uma estrutura com componentes genéricos que são adaptados ao problema que se quer resolver. Estes métodos possuem uma certa facilidade em incorporar novas situações e exploram o espaço de soluções permitindo a escolha estratégica de soluções piores que as já encontradas, na tentativa de superar a otimalidade local. Mesmo não garantindo otimalidade global, as metaheurísticas podem encontrar uma grande quantidade de ótimos locais. Existem várias metaheurísticas que apresentam princípios e estratégias distintas, dentre elas destacam-se as seguintes. As metaheurísticas Busca Tabu e *Simulated Annealing* exploram uma vizinhança a cada iteração de acordo com suas estratégias e escolhem apenas um elemento dessa vizinhança a cada passo. Esse tipo de varredura do espaço de busca gera uma trajetória de soluções obtida pela transição de uma solução para outra de acordo com os movimentos permitidos pelo método. A metaheurística GRASP é um método de múltiplos reinícios. A cada reinício gera-se uma solução inicial através de uma heurística construtiva gulosa com aleatorie-

dade controlada na escolha dos componentes da solução. A solução inicial é usada como ponto de partida para uma busca local convencional.

As metaheurísticas baseadas em Algoritmos Genéticos e *Scatter Search*, exploram uma população de soluções a cada iteração. As estratégias de busca destes métodos permitem explorar várias regiões do espaço de soluções de cada vez. Dessa forma, ao longo das iterações não se constrói uma trajetória única de busca pois novas soluções sempre são obtidas através de combinações de soluções anteriores. Ultimamente, alguns conjuntos de estratégias básicas de metaheurísticas diferentes estão sendo combinados gerando métodos híbridos, por exemplo, métodos que misturam características de busca dos Algoritmos Genéticos com técnicas de busca local. Metaheurísticas têm sido aplicadas, com muito sucesso, para resolver problemas de otimização mono-objetivo e multiobjetivo.

3.3.1 Algoritmos genéticos

Algoritmos Genéticos (AG) foram introduzidos por John Holland em 1975 (HOLLAND, 1975) e fazem parte da área de Computação Evolutiva, que constitui uma família de métodos computacionais inspirados na evolução natural das espécies. Os AGs são métodos flexíveis e têm a capacidade de produzir soluções de boa qualidade em problemas complexos e de grande porte. Por esta razão têm sido aplicados com enorme sucesso em uma grande variedade de problemas em otimização combinatória NP-Completo e NP-Difíceis (GOLDBERG, 1989; MICHALEWICZ, 1996).

Quando são utilizados no contexto de otimização, os Algoritmos Genéticos apresentam as seguintes vantagens em relação às técnicas clássicas de programação matemática:

- Trabalham com uma codificação para as soluções potenciais;
- Empregam técnicas de transição probabilísticas sobre um conjunto de soluções, diversificando a busca;
- Não necessitam de informações adicionais, como derivadas sobre a função objetivo e dessa forma a região viável pode ser um conjunto convexo, ou até mesmo disjunto, e a função objetivo pode possuir simultaneamente variáveis reais, lógicas e inteiras, ser não-convexa e não-diferenciável;
- Diminuem o risco de apresentar, como solução, um ponto ótimo local e, portanto, são mais adequados para trabalhar com problemas multimodais;

- São de fácil implementação, possibilitam uma grande flexibilidade em relação ao tratamento da função objetivo e apresentam um bom desempenho para uma grande escala de problemas do mundo real.

Os algoritmos genéticos são indicados para problemas complexos de otimização, onde existem muitos parâmetros e variáveis; com condições e restrições de difícil modelagem matemática (problemas mal estruturados); com um grande espaço de busca; e problemas multiobjetivos, isto é, problemas onde uma coleção de objetivos devem ser minimizados (ou maximizados). Os Algoritmos Genéticos permitem ainda que estes sejam acoplados a qualquer outro método matemático que auxilie no processo de busca, originando os chamados algoritmos híbridos, melhorando seu funcionamento (GLASS; POTTS; SHADE, 1992; ISHIBUCHI; NAKASHIMA, 2000).

As principais desvantagens para a utilização de Algoritmos Genéticos são: elevado custo computacional, uma vez que necessitam de um grande número de avaliações da função objetivo para sua minimização (ou maximização); dificuldade para achar o ótimo global exato; grandes possibilidades de configurações que podem complicar a resolução do problema sob estudo. Quando um Algoritmo Genético é aplicado a um problema de otimização, cada solução do problema deve ser codificada ou representada na forma de uma estrutura finita (vetor, matriz, etc.). Em seguida, devem ser definidos os operadores genéticos de seleção, recombinação, mutação e estratégias de elitismo. Estes operadores devem ser escolhidos de acordo com as características intrínsecas do problema. Antes de aplicar um algoritmo genético, para a solução de problema de otimização, vários parâmetros devem ser especificados, tais como tamanho da população, probabilidade de recombinação e probabilidade de mutação. A Figura 4 que aparece na seção 3.3.1.9, mostra o fluxo de um algoritmo genético simples. O critério de parada é alcançado quando um número de gerações previamente definido é alcançado, quando uma solução suficientemente boa é encontrada ou quando o sistema não consegue mais evoluir. Nas próximas seções apresentam-se os vários estágios envolvidos na implementação de um algoritmo genético básico.

3.3.1.1 Representação e codificação do indivíduo

Os indivíduos com os quais o AG trabalha representam uma solução candidata à resolução do problema em questão. Encontrar a melhor representação para uma solução candidata de acordo com o problema é sempre desejável. Existem várias maneiras de representar um indivíduo em um AG. A mais simples e comumente utilizada é a representação binária de tamanho fixo, em que um indivíduo é uma cadeia de bits que assumem valores 0 ou 1. Porém, essa representação torna-se problemática quando as variáveis a serem representadas assumem valo-

res contínuos (FREITAS, 2002). Em casos em que a representação binária não é a mais natural nem a mais apropriada, outros tipos de representação podem ser utilizados de acordo com a natureza física do problema sob análise, como sugerido em (MICHALEWICZ, 1996). Na Figura 1 tem-se três exemplos de codificação usadas no AG: codificação binária, codificação decimal e codificação usando números reais.

Codificação binária:

1	0	1	0	1	0	1	0	0
---	---	---	---	---	---	---	---	---

Codificação decimal:

2	0	1	3	0	0	4	0	6
---	---	---	---	---	---	---	---	---

Codificação real:

0,1	0,2	0,0	0,9	0,4	0,0	0,3	0,0	0,1
-----	-----	-----	-----	-----	-----	-----	-----	-----

Figura 1: Tipos de codificação no algoritmo genético.

3.3.1.2 Geração da população inicial

A geração da população inicial geralmente se dá de modo aleatório. Eventualmente, pode ser vantajoso utilizar algum tipo de heurística, acrescentando alguns indivíduos sabidamente bem avaliados ou definindo uma distância mínima entre cromossomos. De modo geral, deve-se garantir a diversidade dos indivíduos, isto é, garantir que os indivíduos estejam uniformemente distribuídos por todo o espaço de busca (TELLES; BARBOSA, 1998). O tamanho da população n_{pop} indica o número de indivíduos em cada população, e em geral, permanece constante durante a evolução. Quanto maior a população, maior a diversidade de soluções e maior o custo computacional, em função do maior número de avaliações da função de aptidão. Assim, o tamanho da população influencia diretamente o desempenho dos algoritmos genéticos. Para a escolha de n_{pop} é comum utilizar alguma estratégia que relacione o tamanho da população com o tamanho do cromossomo, utilizando populações maiores para cromossomos grandes e assim garantindo uma boa diversidade.

3.3.1.3 Avaliação da população

A avaliação de um determinado indivíduo se dá utilizando a função *aptidão*, ou de adequabilidade, que fornece uma medida da qualidade da solução potencial deste indivíduo. Para problemas de otimização ela está intimamente ligada à função objetivo do problema. Em problemas de maximização, por exemplo, a função de aptidão $g(x)$ pode ser tomada como uma modificação da função objetivo $f(x)$:

$$g(x) = af(x) + b$$

sendo a e b constantes introduzidas para adequar a função objetivo para o processo de seleção. Os valores destas constantes permitem ter maior seletividade ou funções de aptidão positivas quando a função objetivo possui alguns valores negativos.

A escolha da função de *aptidão* é para a maioria das aplicações a etapa crítica do processo, pois somada à forma de codificação do indivíduo, esses dois componentes do algoritmo genético, normalmente, são os únicos com relação direta ao domínio do problema. Outro fato interessante é que a *aptidão* pode variar ao longo do processo evolutivo, de maneira dinâmica e estocástica.

3.3.1.4 Métodos de seleção

Uma vez que AGs baseiam-se no princípio da seleção natural, eles devem ser capazes de identificar os indivíduos mais aptos, para que permaneçam na população durante o processo de evolução, e os mais fracos, para que sejam excluídos do processo.

Inúmeros métodos de seleção já foram propostos e implementados na prática, entre eles, a seleção proporcional, a seleção por *ranking* e a seleção por torneio (DEB, 2001; FREITAS, 2002).

- a. **Seleção proporcional:** Na seleção proporcional, os indivíduos são preservados para a próxima geração de acordo com probabilidades proporcionais ao seu valor de função de avaliação. A implementação desse método é normalmente realizada através de um mecanismo de roleta, na qual a roleta é dividida em N partes, N correspondendo ao número de indivíduos da população, e o tamanho de cada uma das partes é proporcional à função de adaptação do indivíduo que representa. A roleta é então girada N vezes, e a cada uma delas o indivíduo indicado pelo ponteiro é selecionado e inserido na nova população. O método da roleta tem a desvantagem de possuir uma alta variância, podendo levar a um grande número de cópias de um bom cromossomo, o que faz diminuir a diversidade

da população. Esta falha pode ocasionar uma convergência prematura do algoritmo para uma solução não almejada. Por outro lado, quando a evolução está avançada, onde as aptidões não diferem muito entre si, observa-se uma estagnação do algoritmo, isto é, uma baixa pressão de seleção entre aptidões parecidas.

- b. **Seleção por *ranking*:** A seleção por *ranking* pode ser dividida em duas etapas. Na primeira, as soluções são ordenadas de acordo com seus valores da função de avaliação, em ordem crescente, se o propósito for maximizar a função de avaliação, ou em ordem decrescente, caso o objetivo seja minimizá-la. Estando a lista ordenada, a cada indivíduo é atribuído um novo valor da função de avaliação, equivalente à sua posição no *ranking*. Na segunda fase, um procedimento similar à seleção proporcional é aplicado. Quanto melhor a posição do indivíduo no *ranking*, maior sua chance de ser selecionado.
- c. **Seleção por torneio:** Este é um dos modelos mais simples para implementação computacional que apresenta bons resultados. A idéia é promover um torneio entre um grupo de k ($k \geq 2$) indivíduos selecionados aleatoriamente a partir da população atual. Assim, o indivíduo com o maior valor de aptidão no grupo é selecionado, enquanto os demais são descartados. Este método apresenta as seguintes vantagens:
 - Não acarreta convergência prematura;
 - Combate a estagnação;
 - Nenhum esforço computacional extra é necessário, tais como ordenamentos;
 - Aptidão explícita é desnecessária;
 - Inspiração biológica do processo.

3.3.1.5 Elitismo

Visando preservar e utilizar as melhores soluções encontradas na geração atual nas próximas gerações, surgiu a estratégia de elitismo. Seja n_{pop} o número máximo de indivíduos que compõem a população, em sua versão mais simples, na estratégia de elitismo conservam-se os n_{elit} melhores indivíduos da população atual, copiando-os para a próxima geração sem nenhuma alteração. Os outros ($n_{pop} - n_{elit}$) indivíduos da população são gerados normalmente, através do método de seleção e posterior aplicação dos operadores genéticos de recombinação e mutação.

Assim, as melhores soluções não são apenas passadas de uma geração para outra, mas também participam da criação dos novos membros da nova geração. A principal vantagem do

elitismo é garantir que não se perca o melhor indivíduo durante o processo evolutivo e, com isto, gerar uma seqüência monotônica, onde o resultado não piora.

3.3.1.6 Operadores genéticos

O princípio básico dos operadores genéticos é transformar a população através de sucessivas gerações, para obter um resultado satisfatório no final do processo. Deste modo, eles são extremamente necessários para que a população se diversifique e mantenha as características de adaptação adquiridas pelas gerações anteriores. Algoritmos genéticos tradicionais são normalmente constituídos de dois operadores: recombinação e mutação.

3.3.1.7 Operador recombinação

O operador de recombinação permite a troca de material genético entre dois indivíduos denominados pais, combinando informações de maneira que exista uma probabilidade razoável dos novos indivíduos produzidos serem melhores que seus pais. Este operador, também conhecido como *crossover*, pode ser utilizado de várias maneiras, sendo as mais empregadas:

- Recombinação de um único ponto:** É a forma mais simples de recombinação. De acordo com esse método, um ponto do cromossomo é sorteado aleatoriamente, e a troca de material genético feita na região á direita do ponto escolhido. A Figura 2 mostra um exemplo de dois cromossomos (escuro e claro) realizando recombinação de um único ponto para gerar um filho que possivelmente substituirá os genitores na nova população.

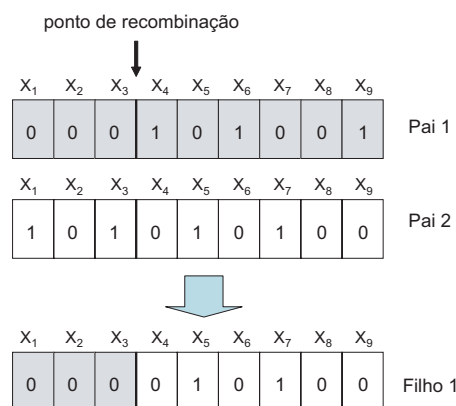


Figura 2: Exemplo de recombinação de um único ponto.

- Recombinação com múltiplos pontos de corte:** É uma generalização da idéia de troca de material genético, onde muitos pontos de recombinação podem ser utilizados. A Figura 3 ilustra o operador de recombinação com dois pontos.

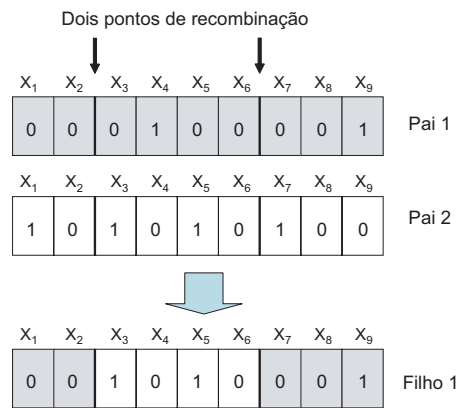


Figura 3: Exemplo de recombinação de dois pontos.

- c. **Recombinação uniforme:** Não utiliza pontos de recombinação, mas determina, através de um parâmetro global, a probabilidade de máscara, qual a probabilidade de cada variável ser herdada de cada pai.

3.3.1.8 Operador mutação

A operação mutação é utilizada para garantir uma maior varredura do espaço de busca e evitar que o algoritmo genético convirja prematuramente para mínimos locais. A mutação é efetuada alterando-se o valor de um determinado gene de um indivíduo sorteado com uma determinada probabilidade, denominada probabilidade de mutação, ou seja, vários indivíduos da nova população podem ter um de seus genes alterados aleatoriamente. O operador de mutação é aplicado aos indivíduos com uma probabilidade dada pela taxa de mutação ρ_m . Geralmente, utiliza-se uma taxa de mutação pequena (como na genética natural), pois é um operador genético secundário.

3.3.1.9 Estrutura básica de um Algoritmo Genético

Na Figura 4 é apresentada a estrutura básica de um Algoritmo Genético Simples.

3.3.1.10 Parâmetros dos algoritmos genéticos

Os parâmetros genéticos são grandezas que determinam o desempenho dos AGs, adaptando-os às características particulares de determinada classe de problemas. Entre eles os mais importantes são: tamanho da população $npop$, o número de geração $maxgen$, a probabilidade de recombinação ρ_c e a probabilidade de mutação ρ_m (MICHALEWICZ, 1996).

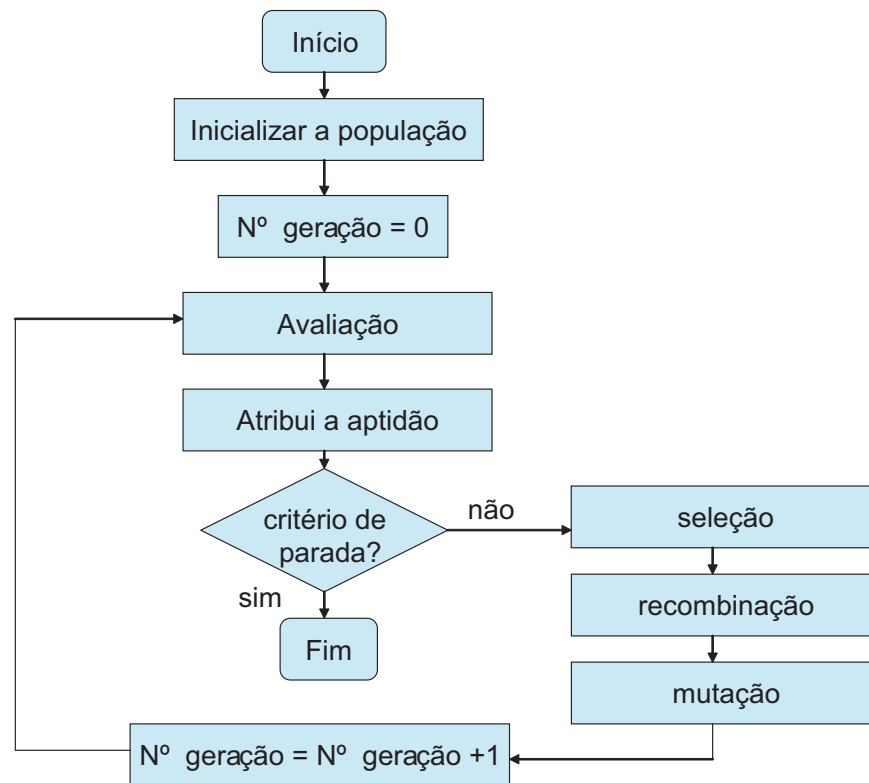


Figura 4: Algoritmo Genético Simples.

3.3.1.11 Tamanho da população

O tamanho da população indica o número de cromossomos em cada população, normalmente constante durante a evolução. Uma população pequena acarreta um fraco desempenho, podendo conduzir o algoritmo na direção de um mínimo local, enquanto que uma população grande dificulta a convergência prematura para soluções locais, mas pode resultar em um tempo computacional elevado, levando-se em consideração o número de avaliações necessárias da função objetivo.

3.3.1.12 Taxa ou probabilidade de recombinação

A probabilidade de recombinação ρ_c é uma grandeza percentual do número de indivíduos que experimentam a recombinação em relação ao número total de indivíduos de uma população. A probabilidade de recombinação afeta significativamente a convergência dos Algoritmos Genéticos, pois uma alta probabilidade de recombinação em um algoritmo genético, sem elitismo, faz com que indivíduos com alto desempenho, sejam eliminados antes de se reproduzirem. Por outro lado, uma baixa probabilidade de recombinação acarreta numa convergência muito lenta devido à baixa taxa de exploração das características genéticas. Geralmente, a taxa de

recombinação varia entre 0,5 e 0,95, mas estes números indicam apenas uma ordem de grandeza, já que existem inúmeros tipos possíveis de recombinação, os quais são limitados pela análise das características físicas do problema e do comportamento da população através do ciclo geracional do AG.

3.3.1.13 Taxa ou probabilidade de mutação

A mutação é empregada para fornecer novas informações dentro da população, prevenindo que a mesma se torne saturada com cromossomos similares. O objetivo da mutação é aumentar a diversidade populacional e possibilitar ainda uma maior varredura do espaço de busca. A taxa de mutação ρ_m indica a probabilidade ou taxa em que haverá a mutação de cromossomos nas populações ao longo da evolução. Para escolher a taxa de mutação deve-se tomar alguns cuidados, pois se a taxa escolhida for muito alta a busca pode se tornar essencialmente aleatória. Alguns pesquisadores recomendam a escolha da taxa de mutação com base no tamanho dos cromossomos e das populações. Como os demais parâmetros, a taxa de mutação ideal dependerá do problema a ser resolvido. Todavia, a maioria das taxas utilizadas varia entre 0,001 e 0,1. Jong (JONG, 1975), sugere que a taxa de mutação deva ser inversamente proporcional ao tamanho da população.

3.3.1.14 Tratamento das restrições

Na maioria das aplicações, as restrições são tratadas com funções de penalização, de modo a combinar as restrições com a função objetivo. Dessa maneira, aquele indivíduo que não atender alguma das restrições será avaliado como pouco apto (ou inapto), diminuindo (ou excluindo) a probabilidade desse indivíduo ser selecionado para a reprodução. A adoção de funções de penalização e a escolha de seus parâmetros são dependentes do problema em estudo e requerem certa experiência prévia (GALLEGO, 1997; COELLO, 2000, 2002). O modelo de planejamento da expansão da transmissão, adotado neste trabalho, visa minimizar o custo de investimento e atender a demanda futura do sistema elétrico. Estes objetivos são conflitantes, pois para obter o plano de expansão a custo mínimo algumas vezes o sistema é forçado a operar em regiões próximas a seus limites físicos e operacionais, podendo inclusive desatender alguma parcela da demanda futura. A parcela da demanda não atendida pode ser somada ao custo de investimento, na função objetivo, usando um fator de penalização, como uma alternativa para contornar o problema de tratar a infactibilidade das restrições, e resolvê-lo através de uma metaheurística evolutiva.

3.3.2 Algoritmo genético de Chu-Beasley e sua aplicação ao problema de planejamento

O algoritmo genético proposto por Chu-Beasley (CBGA), inicialmente desenvolvido para resolver o problema generalizado de atribuição (BEASLEY; CHU, 1997), é utilizado inicialmente para resolver o problema de planejamento da expansão de sistemas de transmissão incluindo a possibilidade de retirada de linhas de transmissão. No capítulo 4 é usado também para resolver o problema de planejamento considerando múltiplos cenários de geração.

O CBGA foi escolhido pelo fato do mesmo possuir em sua formulação básica algumas características que se assemelham e se enquadram no problema da expansão da transmissão. De forma geral, as principais características do CBGA que o tornam apropriado para solucionar o problema do planejamento são:

- O uso de uma função de aptidão (*fitness*) para identificar o valor da função objetivo (custo total da construção dos circuitos de uma proposta de expansão) e uma função (*unfitness*) que quantifica a infactibilidade da solução testada (corte de carga da proposta de expansão);
- Substitui na população apenas um indivíduo em cada iteração, e não toda ou quase toda a população;
- Armazena na população apenas indivíduos diferentes, o que corresponde a propostas de expansão diferentes. Isso mantém a diversidade genética da população e evita a convergência prematura.
- Realiza uma estratégia eficiente de melhoria local para cada indivíduo testado.

A seguir são apresentadas em detalhes as alterações realizadas no AGCB apresentada em (BEASLEY; CHU, 1997), para a sua adaptação ao problema da expansão de sistemas de transmissão, para que este seja resolvido de forma mais eficiente através deste algoritmo.

3.3.2.1 Codificação do problema

A proposta de codificação (forma de representar uma proposta de solução) em geral é o aspecto mais importante da estrutura de um algoritmo genético. A codificação pode facilitar ou complicar a implementação dos mecanismos de um algoritmo genético. Neste trabalho é utilizada uma codificação decimal para uma proposta de solução associada diretamente às variáveis

de decisão do problema de investimento, ou seja, o número de linhas ou transformadores a serem construídas. Para o problema estático da expansão de sistemas de transmissão, uma proposta de solução do CBGA (indivíduo) é representada por um vetor de tamanho n_l (número de ramos candidatos nos quais podem ser acrescentados novos circuitos), onde cada elemento deste vetor corresponde a um ramo do sistema em análise onde podem ser construídas novas linhas ou transformadores. O valor de cada elemento pode variar de 0 até o número máximo de linhas ou transformadores que podem ser acrescentadas no respectivo ramo. Exemplificando, na codificação mostrada na Figura 5, o ramo 4 e 9 (caminhos n_{1-5} e n_{2-6}) tem 1 nova linha, o ramo 6, 11 e 14 (caminhos n_{2-3} , n_{3-5} e n_{4-6}) tem 2 novas linhas. Este vetor pode ser usado para codificar uma proposta de solução no problema de planejamento da expansão do sistema Garver de 6 barras. Os dados de barras e de ramos deste sistema são apresentados na seção A.1 do Apêndice A.

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
0	0	0	1	0	2	0	0	1	0	2	0	0	2	0

Figura 5: Proposta de codificação.

O número de indivíduos da população no CBGA, para o problema de planejamento da expansão de sistemas de transmissão, varia em função da dimensão do sistema testado.

3.3.2.2 População inicial

Se, para resolver o problema de planejamento da expansão de sistemas de transmissão usando algoritmos genéticos, a população inicial for gerada aleatoriamente, pode ser necessário um maior esforço computacional especialmente para sistemas de médio e grande porte. Portanto, uma forma de melhorar o desempenho do AG é gerar de maneira eficiente esta população inicial (GALLEGO, 1997; ESCOBAR, 2002). Sendo assim, utilizam-se algoritmos heurísticos construtivos (AHC) baseados em índices de sensibilidade para gerar uma parte da população inicial. Foi usado um AHC do tipo proposto em (VILLASANA; GARVER; SALON, 1985), um AHC que usa o critério de *mínimo esforço* proposto em (MONTICELLI et al., 1982) e um AHC que usa o modelo de transportes (uma versão relaxada do modelo DC) como foi proposto em (GARVER, 1970), para se obter uma solução aproximada do problema, e a partir desta solução aproximada são introduzidas *perturbações* aleatórias em sua vizinhança até que uma quantidade predeterminada de soluções aproximadas seja atingida, formando-se assim a população inicial do AG.

3.3.2.3 Função objetivo e infactibilidade

Para cada indivíduo da população tanto pode ser calculada a função de aptidão (*fitness*), que representa o custo total do planejamento das linhas a serem construídas, como também pode ser calculada a infactibilidade do indivíduo (*unfitness*) que representa o corte de carga da configuração ou solução candidata. No caso do problema de planejamento, a função de aptidão é calculada através de um processo simples donde é realizada o somatório dos custos das propostas de adição associadas ao indivíduo (problema de investimento). A função de infactibilidade (*unfitness*) é determinada resolvendo o problema de operação associado às adições propostas no problema de investimento. Neste caso, determinar a infactibilidade é determinar o corte de carga produzido pela proposta de investimento, o qual requer da solução de um problema de programação linear (PL) que é resolvido usando a sub-rotina MINOS 5.4.

Na maioria dos algoritmos genéticos aplicados a problemas restritos, as infactibilidades são penalizadas na função objetivo ou as propostas de solução infactíveis são descartadas. No CBGA a função objetivo e a infactibilidade de cada indivíduo da população são calculadas e armazenadas separadamente e utilizadas para fins diferentes.

A função objetivo ou função de aptidão (*fitness*) é usada para implementar a seleção e também na substituição de um elemento na população quando todos os elementos da população são factíveis. A infactibilidade é usada para substituir um elemento da população quando existem propostas de solução infactíveis na população.

Uma das vantagens do CBGA é que não precisa se ter a preocupação de escolher o valor do fator de penalidade α porque o custo da expansão $\sum c_{ij}n_{ij}$ é armazenado separadamente do custo do corte de carga $\alpha \sum r_i$. Sendo assim, α pode ser eliminado por que aparece multiplicando apenas o corte de carga, e os valores de corte de carga aparecem apenas no vetor do *unfitness*.

3.3.2.4 Seleção

A seleção usada é aquela baseada em torneio na qual, em cada jogo, participam k indivíduos da população corrente (dois ou três). O processo se dá da seguinte forma: são sorteados, aleatoriamente, k indivíduos da população e aquele que possuir melhor função de aptidão (*fitness*) será o pai número 1 e, após isso o processo é realizado novamente para que seja determinado o pai número 2, sendo este diferente do primeiro. Selecionados os dois pais, ambos passam para a fase de recombinação.

Para problemas de grande porte pode ser mais eficiente usar um tamanho de população

maior, e nesse caso uma população maior significa maior diversidade topológica. Entretanto, um incremento na população pode ser acompanhado de um aumento de jogadores na seleção por torneio.

3.3.2.5 Recombinação

A troca de material genético ou recombinação usada é a de um ponto, na qual escolhe-se aleatoriamente um ponto de recombinação e geram-se dois descendentes com uma parcela de cada uma das topologias geradoras separadas pelo ponto de recombinação. Enquanto no algoritmo genético tradicional os dois descendentes gerados podem fazer parte da população na próxima geração, no AGCB apenas um dos descendentes pode fazer parte da população. Assim, aleatoriamente e com a mesma probabilidade ou de forma controlada, é escolhido apenas um descendente, sendo o outro eliminado. Na Figura 6 tem-se um exemplo de recombinação entre duas configurações selecionadas para recombinação, em que o segundo descendente é eliminado. O descendente escolhido está formado pelos conteúdos das posições 1 a 10, do pai 1, e pelos conteúdos das posições 11 a 15, do pai 2.



Figura 6: Recombinação de um ponto e geração de um descendente.

3.3.2.6 Mutação

No processo de mutação toma-se o filho escolhido após o processo de recombinação; e são escolhidos de forma aleatória k pontos de mutação desse filho, a decisão para aumentar

ou diminuir o número de linhas em uma unidade é feita de forma controlada usando como referência o valor do corte de carga do descendente. Se o corte de carga for maior que um parâmetro $cortemax$ a decisão de adicionar uma linha tem maior probabilidade que a decisão de retirar uma linha. Se o corte de carga é menor que o parâmetro $cortemax$, a decisão de retirar uma linha tem maior probabilidade que a decisão de adicionar uma linha. O número de linhas do filho no ponto do mutação deve estar entre zero e o número de linhas máximo permitido. A Figura 7 mostra um exemplo onde o ramo 4 (n_{1-5}) é selecionado aleatoriamente para mutação. Já que a solução antes de mutação tem corte de carga maior que o valor do parâmetro $cortemax$ a probabilidade de adicionar uma linha é maior que a probabilidade de diminuir uma linha. Desta forma, o número de linhas na posição selecionada para mutação passa de 1 para 2.

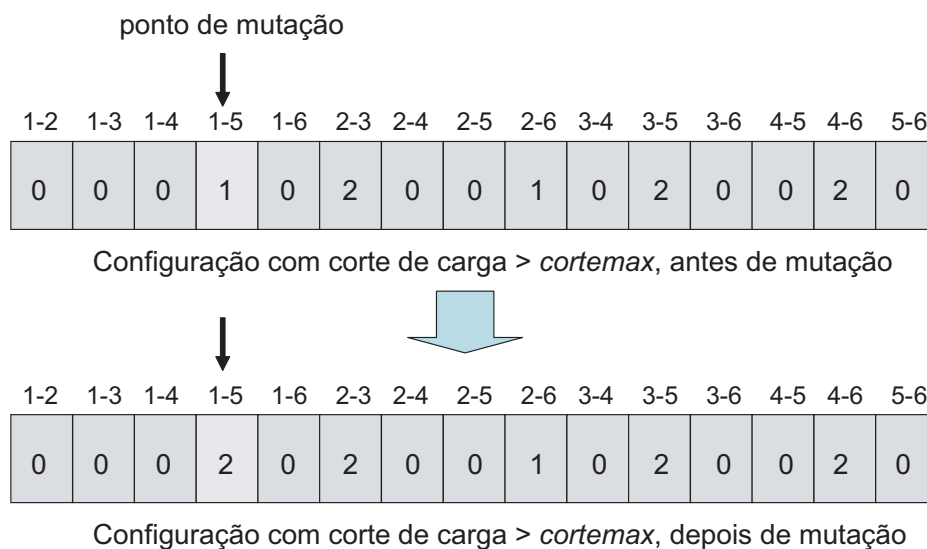


Figura 7: Mutação com $k = 1$ para um descendente.

3.3.2.7 Melhoria local de um indivíduo

A melhoria local de um indivíduo é uma das maiores contribuições do AGCB e está composta por dois tipos de melhorias: da infactibilidade e da função objetivo.

1. **Eliminando a infactibilidade:** Se o descendente gerado é infactível, isto é, apresenta corte de carga, então, elimina-se a infactibilidade com o auxílio de um algoritmo heurístico construtivo proposto por Villasana-Garver-Salon (VILLASANA; GARVER; SALON, 1985). No algoritmo Villasana-Garver-Salon, dois conceitos fundamentais são considerados: a) quando as restrições de integralidade das variáveis de investimento são relaxadas, o modelo proposto em (VILLASANA; GARVER; SALON, 1985) transforma-se em um problema

de programação linear que é usado para identificar o circuito mais adequado a ser adicionado ao sistema; e b) cada circuito adicionado cumpre as duas leis de Kirchhoff, e assim a solução final é factível para o modelo DC, em comparação com outros AHC que usam modelos relaxados (por exemplo o modelo de transportes) em que a solução final só cumpre a primeira lei de Kirchhoff (GARVER, 1970).

Considerando que o principal objetivo deste passo é eliminar a infeasibilidade do indivíduo, o AHC proposto em (VILLASANA; GARVER; SALON, 1985) acrescentará linhas ao indivíduo para eliminar a infeasibilidade, resolvendo apenas problemas de PL's em cada passo do AHC, sendo o resultado factível para o modelo DC.

2. **Melhorando a função objetivo:** Após a execução do AHC de Villasana-Garver-Salon, comentado anteriormente, algumas linhas são acrescentadas ao indivíduo que está no processo de melhoria local. Sendo este AHC um modelo aproximado, algumas linhas acrescentadas são desnecessárias e devem ser retiradas para que o indivíduo (proposta de solução) não fique muito caro. Sendo assim, faz-se uma ordenação de todas as linhas da proposta de solução por ordem decrescente de custos e faz-se a retirada uma a uma de todas as linhas. Aquela que, quando simulada sua retirada do indivíduo, não apresenta corte de carga é uma linha desnecessária e, conseqüentemente, é eliminada do mesmo. O processo é repetido para todas as linhas até não haver mais linhas desnecessárias. Permanecerão no indivíduo aquelas linhas que quando simulada a sua retirada, a proposta de solução resultante apresenta corte de carga.

3.3.2.8 Substituição da população

No AGCB em cada geração, apenas se substitui um indivíduo da população. O descendente gerado e candidato a substituir um elemento da população é incorporado na mesma através do procedimento mostrado a seguir:

- O descendente deverá substituir o elemento da população de pior qualidade desde que o descendente seja de melhor qualidade. No AGCB se apresentam os seguintes casos:
 - a. Um descendente infeasível e uma população onde existem soluções infeasíveis. Neste caso, o descendente deverá substituir ao indivíduo mais infeasível, sempre que seja mais infeasível que o descendente.
 - b. Um descendente infeasível e uma população onde não existem soluções infeasíveis. Neste caso, o descendente é descartado.

- c. Um descendente factível e uma população onde existem soluções infactíveis. Neste caso, o descendente deverá substituir ao indivíduo mais infactível.
 - d. Um descendente factível e uma população onde somente existem soluções factíveis. Neste caso, o descendente deverá substituir ao indivíduo da população com menor função de aptidão, sempre que o descendente tenha melhor função de aptidão.
- O descendente gerado deve ser diferente de todos os elementos da população para fazer parte da mesma, ou seja, deve apresentar uma configuração de construção de circuitos que não exista na população. Se ele for igual a um membro pertencente à população automaticamente será descartado.

Esta proposta apresenta mudanças conceitualmente muito simples quando comparada com o algoritmo genético tradicional. O que torna tal proposta mais eficiente são os seguintes motivos:

- Todos os planos de expansão (soluções candidatas) armazenados na população corrente são diferentes, evitando, assim a convergência prematura, muito comum em algoritmos genéticos convencionais em que não se faz uma análise das topologias geradas para evitar a repetição de topologias armazenadas.
- A fase de melhoria local, eliminação do corte de carga (infactibilidade) do descendente gerado assim como da qualidade da função objetivo, fornece uma estratégia interessante que permite uma evolução mais eficiente do algoritmo genético.
- A lógica de substituição da população corrente preserva as melhores topologias geradas, isto é, a incumbente, assim como as melhores soluções existentes na população corrente não estão sujeitas à eliminação por decisões de carácter aleatório como pode acontecer com o algoritmo genético tradicional.

Portanto, melhores topologias somente são descartadas quando aparecem descendentes de melhor qualidade. Essa estratégia é mais eficiente que a proposta de elitismo usada para preservar as melhores topologias da população corrente.

3.3.2.9 Critério de parada

O processo é interrompido se a incumbente (melhor solução encontrada no processo) não melhora após um número especificado de iterações ou se foi atingido um número máximo de gerações.

3.3.2.10 Estrutura básica do algoritmo CBGA aplicado ao problema de planejamento

A estrutura básica do algoritmo genético de Chu-Beasley é apresentada na Figura 8. O algoritmo proposto foi implementado usando Fortran 90 e a sub-rotina MINOS 5.4. Para resolver o problema do planejamento da expansão de transmissão usando desplanificação, o modelo DC e planejamento estático, foram usados dois sistemas de prova: o sistema IEEE de 24 barras e o sistema colombiano de 93 barras. Os dados elétricos dos sistemas usados estão no Apêndice A.

3.4 Testes e resultados usando a nova modelagem matemática

Para mostrar o desempenho do novo modelo matemático foram utilizados dois sistemas elétricos usados na literatura especializada, o sistema de 24 barras do IEEE (IEEE24) e o sistema elétrico colombiano de 93 barras e 155 caminhos de adição de linhas de transmissão. Os dados destes sistemas são apresentados na seção A.2 e na seção A.3 do Apêndice A, respectivamente.

3.4.1 Sistema IEEE de 24 barras

Este sistema tem 24 barras, 41 caminhos de adição de linhas de transmissão, demanda de 8.550 MW e capacidade de geração de 10.215 MW. O sistema IEEE de 24 barras é um dos sistemas mais utilizados em testes para novos modelos e técnicas de otimização do problema de planejamento da expansão de sistemas de transmissão. Neste caso, apresenta-se os resultados de dois tipos de problemas: (1) o planejamento com reprogramação da geração e (2) o planejamento de um dos quatro casos de planejamento sem reprogramação da geração mostrados em (FANG; HILL, 2003).

Para efeitos de comparação, inicialmente se resolve o problema de planejamento com reprogramação da geração considerando que as variáveis de decisão correspondentes ao número de ramos a ser adicionados são contínuas, isto é, não é considerada a condição de inteira para as variáveis, e também é considerado que não existem elementos na configuração inicial. A partir destes dados, é obtido o limite inferior para o problema considerando desplanificação e considerando a restrição de inteira para as variáveis de investimento n_{ij} . Também, com propósitos de comparação se resolve o problema de planejamento tradicional com reprogramação da geração, isto é, não é considerada a desplanificação, mas é considerada a restrição de inteira para as variáveis de investimento n_{ij} . Para este último problema, o valor obtido é a solução ótima que é conhecida na literatura especializada. Posteriormente, são considerados vários casos onde são resolvidos problemas de PNLIM considerando desplanificação, e considerando reprogramação

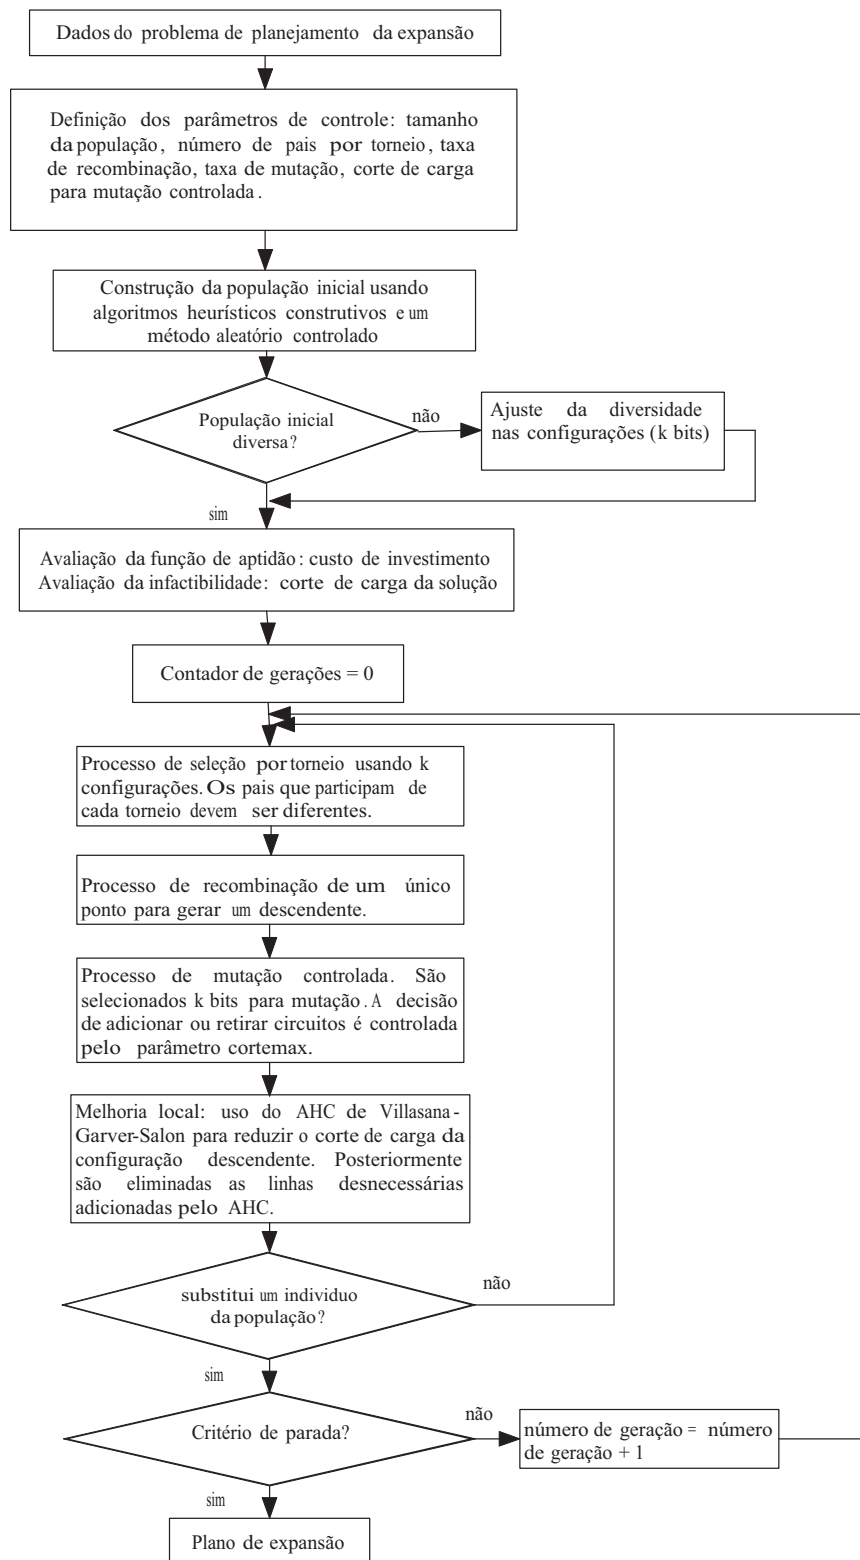


Figura 8: Estrutura básica do CBGA aplicado ao problema de planejamento.

da geração ou sem considerar reprogramação da geração. Na seqüência, se apresentam estes resultados.

Caso 1: Sistema IEEE 24 sem linhas na rede inicial, n_{ij} contínuos e com reprogramação da geração

Neste caso, o problema é resolvido usando um método de programação não linear de ponto interior de alta ordem e as restrições de inteiras para as variáveis de investimento são relaxadas. Os geradores podem assumir qualquer valor entre o limite inferior e o limite superior (reprogramação da geração). Em (ESCOBAR; BOLAÑOS; CORREA, 2008) podem-se observar aspectos relacionados com o método de solução usado, o qual não é apresentado nesta tese, já que o propósito de resolver o problema de planejamento usando um método de programação não linear, como os métodos de ponto interior de alta ordem, é de encontrar um limite inferior para medir a efetividade da metaheurística CBGA usada.

Ao usar PNL com as variáveis de investimento relaxadas, o valor obtido é maior que o valor ótimo conhecido usando programação não-linear inteira-mista (PNLIM) no problema IEEE24 porque no PNL relaxado não é considerada a rede inicial.

- Investimento de $v = 1,049.41$ milhões de dólares.

- Adição de linhas de transmissão:

$$\begin{aligned} n_{01-02} &= 0,2205; n_{01-05} = 1,2168; n_{02-04} = 1,2105; n_{02-06} = 0,6379; \\ n_{03-24} &= 1,3485; n_{06-10} = 1,6826; n_{07-08} = 2,9900; n_{09-12} = 1,3101; \\ n_{10-11} &= 0,0003; n_{10-12} = 2,1960; n_{12-13} = 1,9543; n_{12-23} = 0,8503; \\ n_{15-21} &= 1,6896; n_{15-24} = 1,0786; n_{16-17} = 0,0007; n_{16-19} = 0,3295; \\ n_{20-23} &= 0,7680; n_{06-07} = 0,0050; n_{14-23} = 1,1629; n_{19-23} = 0,7535. \end{aligned}$$

- Corte de carga = 0 MW.

Caso 2: Sistema IEEE 24 com rede inicial, n_{ij} inteiros e com reprogramação da geração

Neste caso o problema é resolvido usando o algoritmo genético de Chu-Beasley modificado, apresentado na seção 3.3.2. O algoritmo genético faz as propostas de investimento para as variáveis inteiras e a sub-rotina MINOS 5.4 resolve o problema de programação linear associado ao problema de operação resultante. Os geradores podem assumir qualquer valor entre o limite inferior e o limite superior (reprogramação da geração). No algoritmo CBGA modificado foram usados os seguintes parâmetros: tamanho de população de sessenta indivíduos, 100% da população gerada aleatoriamente, número de pais que participam do torneio $k = 3$, $\rho_c = 0,98$, $\rho_m = 0,02$, diversidade entre os indivíduos da população de 2 bits, $cortemax = 10$ MW.

O valor obtido depois de 274 gerações é o valor ótimo conhecido para o problema PNLIM IEEE24. O custo é menor que no caso 1 porque não inclui os custos das linhas da rede inicial.

- Investimento de $v = 152$ milhões de dólares.
- Adição de linhas de transmissão:
 $n_{06-10} = 1, n_{07-08} = 2, n_{10-12} = 1, n_{14-16} = 1.$
- Corte de carga = 0 MW.

Caso 3: Sistema IEEE 24 com reprogramação da geração, desplanificação e que incentiva a retirada de linhas

Neste caso foi usado o algoritmo CBGA modificado com os seguintes parâmetros: tamanho de população de cem indivíduos, 90% da população gerada aleatoriamente e 10% gerada usando AHC, $\rho_c = 0,98$, $\rho_m = 0,02$, diversidade entre os indivíduos da população de 2 bits, $cortemax = 10$ MW.

Usando a segunda modelagem matemática proposta que incentiva a retirada de linhas de transmissão existentes na topologia base, função objetivo mostrada em (3.5), considera a condição de inteiras das variáveis de decisão, e usa planejamento com reprogramação da geração, a melhor solução encontrada apresenta as seguintes características:

- Investimento de $v = 151$ milhões de dólares
- Adição de linhas de transmissão:
 $n_{11-13} = 1, n_{01-08} = 1, n_{06-07} = 1.$
- Retirada de linhas de transmissão:
 $n''_{02-06} = 1, n''_{06-10} = 1, n''_{15-16} = 1, n''_{17-18} = 1, n''_{18-21} = 2, n''_{19-20} = 1, n''_{21-22} = 1.$
- Corte de carga $w = 0$ MW.

Caso 4: Sistema IEEE 24 com reprogramação da geração, desplanificação e que incentiva a permanência das linhas

Neste caso foi usado o algoritmo CBGA modificado com os mesmos parâmetros usados no caso 3, a terceira modelagem matemática proposta que incentiva a permanência das linhas de transmissão existentes na topologia base, função objetivo mostrada em (3.6), condição de

inteiras das variáveis de decisão, e planejamento com reprogramação da geração. A melhor solução encontrada apresenta as seguintes características:

- Investimento de $v = 151$ milhões de dólares

- Adição de linhas de transmissão:

$$n_{11-13} = 1, n_{01-08} = 1, n_{06-07} = 1.$$

- Retirada de linhas de transmissão:

$$n''_{02-06} = 1, n''_{06-10} = 1, n''_{15-16} = 1.$$

- Corte de carga $w = 0$ MW.

Caso 5: Sistema IEEE 24 com rede inicial, n_{ij} inteiros e sem reprogramação da geração

Usando o algoritmo CBGA modificado com os mesmos parâmetros usados no caso 3, é resolvido um dos quatro casos de planejamento sem reprogramação da geração mostrados em (FANG; HILL, 2003). A geração usada é mostrada na Tabela 1. O problema PNLIM resultante é resolvido usando o algoritmo CBGA com os mesmos parâmetros usados no caso 3, e não é considerada a desplanificação. A resposta é melhor que a apresentada em (FANG; HILL, 2003) para este caso.

Para o problema de planejamento tradicional a melhor solução encontrada apresenta as seguintes características:

- Investimento de $v = 390$ milhões de dólares

- Adição de linhas de transmissão:

$$n_{01-05} = 1, n_{03-24} = 1, n_{06-10} = 1, n_{07-08} = 2, n_{14-16} = 1, n_{15-24} = 1, n_{16-17} = 2, \\ n_{16-19} = 1, n_{17-18} = 2$$

- Corte de carga $w = 0$ MW.

Caso 6: Sistema IEEE 24 sem reprogramação da geração, desplanificação e que incentiva a retirada de linhas

Usando o algoritmo CBGA modificado com os mesmos parâmetros usados no caso 3, a segunda modelagem matemática proposta que incentiva a retirada de linhas de transmissão existentes na topologia base, função objetivo mostrada em (3.5), considera a condição de inteiras

Tabela 1: Geração no sistema IEEE de 24 barras.

Barra	Geração (MW)	Barra	Geração (MW)
1	576	16	465
2	576	18	1.200
7	900	21	1.200
13	1.773	22	900
15	645	23	315

das variáveis de decisão, e usa planejamento sem reprogramação da geração, a melhor solução encontrada apresenta as seguintes características:

- Investimento de $v = 325$ milhões de dólares

- Adição de linhas de transmissão:

$$n_{01-05} = 1, n_{03-24} = 1, n_{04-09} = 1, n_{06-10} = 1, n_{07-08} = 2, n_{14-16} = 1, n_{16-17} = 2, n_{16-19} = 1, n_{17-18} = 1.$$

- Retirada de linhas de transmissão:

$$n''_{02-04} = 1, n''_{03-09} = 1, n''_{20-23} = 1, n''_{08-09} = 1.$$

- Corte de carga $w = 0$ MW.

Caso 7: Sistema IEEE 24 sem reprogramação da geração, desplanificação e que incentiva a permanência das linhas

Usando o algoritmo CBGA modificado com os mesmos parâmetros usados no caso 3, a terceira modelagem matemática proposta que incentiva a permanência das linhas de transmissão existentes na topologia base, função objetivo mostrada em (3.6), considera a condição de inteiras das variáveis de decisão, e usa planejamento sem reprogramação da geração, a melhor solução encontrada apresenta as seguintes características:

- Investimento de $v = 325$ milhões de dólares

- Adição de linhas de transmissão:

$$n_{01-05} = 1, n_{03-24} = 1, n_{04-09} = 1, n_{06-10} = 1, n_{07-08} = 2, n_{14-16} = 1, n_{16-17} = 2, n_{16-19} = 1, n_{17-18} = 1.$$

- Retirada de linhas de transmissão:

$$n''_{02-04} = 1, n''_{03-09} = 1, n''_{20-23} = 1.$$

- Corte de carga $w = 0$ MW.

3.4.2 Análise dos resultados para o sistema IEEE de 24 barras

Casos 1, 2, 3, e 4: planejamento considerando reprogramação da geração

Ao observar os casos onde é resolvido o problema de planejamento considerando reprogramação na geração chegam-se às seguintes conclusões:

- No caso 3 são consideradas as linhas da configuração inicial e é considerada a condição de inteira das variáveis. A melhor solução inteira obtida usando desplanificação é de 151 milhões de dólares. Ao adicionar o custo das linhas da configuração base usadas nesta solução, que é de 1.581 milhões de dólares, o valor acumulado resultante é de 1.732 milhões de dólares. O caso 2 é um caso similar ao caso 3, mas sem considerar desplanificação. A solução ótima conhecida para este caso é de 152 milhões de dólares, e utiliza toda a rede da topologia base. Neste caso, ao adicionar o custo das linhas da rede inicial, que é de 1.912 milhões de dólares, o valor acumulado resultante é de 2.064 milhões de dólares. Na prática, o benefício imediato da desplanificação é a diferença entre investimentos dos planos, isto é, (152-151) milhões de dólares, ou seja 1 milhão de dólares, mas a verdade é que o benefício pode ser maior no tempo, já que se neste sistema sempre se faz a expansão considerando desplanificação, em teoria, o benefício econômico pode estar perto da diferença entre os valores acumulados, isto é, (2.064 - 1.732) milhões de dólares, ou seja 332 milhões de dólares.
- Neste trabalho foi encontrado um valor de 151 milhões de dólares como melhor solução considerando desplanificação, a condição de inteira das variáveis e a retirada das linhas da topologia base que não ajudam e não prejudicam a operação futura. O valor acumulado adicionando o custo das linhas da rede inicial usadas neste caso foi de 1.732 milhões de dólares. Este valor resulta menor que o custo das linhas da rede da configuração base, que é de 1.912 milhões de dólares. Isto mostra a potencialidade de considerar a desplanificação no problema de planejamento da transmissão de longo prazo. Em teoria, este valor pode ser menor se compara-se com a solução do caso 1, na qual é relaxada a condição de inteira das variáveis e que mostra um valor acumulado de 1.049,41 milhões de dólares. Este valor, entretanto, não é alcançável já que representa a solução

contínua do problema inteiro-misto e representa um limite inferior para o problema com desplanificação, mas deixa aberta a possibilidade de que possam existir melhores soluções inteiras para este problema.

- Ao comparar os resultados do caso 3 e do caso 4, pode-se afirmar que as seguintes linhas ou transformadores existentes na rede inicial: $n_{02-06} = 1$, $n_{06-10} = 1$ e $n_{15-16} = 1$, devem ser obrigatoriamente desconectados da operação normal, já que reduzem o desempenho da rede futura e aumentam o custo do plano de expansão ótimo de 151 milhões de dólares para 152 milhões de dólares. Estes circuitos não devem ser retirados definitivamente do sistema e devem permanecer disponíveis para ser usados quando a rede precise delas em outro contexto de operação.
- Ao comparar os resultados do caso 3 e do caso 4, pode-se afirmar que as seguintes linhas ou transformadores existentes na rede inicial: $n_{17-18} = 1$, $n_{18-21} = 2$, $n_{19-20} = 1$ e $n_{21-22} = 1$, podem ou não ser retirados da operação normal, já que não reduzem e não melhoram o desempenho da rede futura, e não aumentam e não reduzem o custo do plano de expansão ótimo de 151 milhões de dólares. É importante que estes elementos permaneçam disponíveis na rede para que possam ser usados quando o sistema precise delas. Um aspecto importante é que estes elementos podem permanecer operando simultaneamente sem degradar a operação normal

Na Figura 9 é mostrado um gráfico comparativa dos valores obtidos para os diferentes casos estudados com reprogramação da geração no sistema IEEE de 24 barras.

Casos 5, 6 e 7: planejamento sem considerar reprogramação da geração

Ao observar os casos de planejamento sem considerar reprogramação na geração, para os quais é considerado um dos quatro casos de planejamento sem reprogramação da geração mostrados em (FANG; HILL, 2003) e cujos dados são mostrados na Tabela 1, se pode ver que:

- No caso 5 são consideradas as linhas da configuração inicial, é considerada a condição de inteira das variáveis e não é considerada a desplanificação. A melhor solução inteira obtida é de 390 milhões de dólares (melhor que a reportada em (FANG; HILL, 2003)). Ao adicionar o custo dos elementos da configuração base, que é de 1.912 milhões de dólares, o valor acumulado resultante é de 2.302 milhões de dólares. O caso 6 é similar ao caso 5, mas considerando desplanificação e usando a segunda modelagem matemática proposta, que incentiva a retirada de linhas de transmissão existentes na topologia base: função objetivo mostrada em (3.5). A melhor solução encontrada para este caso é de 325




Figura 9: Custos das diferentes formas de planejamento para o sistema IEEE de 24 barras considerando reprogramação da geração.

milhões de dólares e retira quatro circuitos da topologia base. Neste caso, ao adicionar o custo das linhas da rede inicial utilizadas, que é de 1.775 milhões de dólares, o valor acumulado resultante é de 2.100 milhões de dólares. Na prática, o benefício imediato da desplanificação é a diferença entre investimentos dos planos, isto é, (390-325) milhões de dólares, ou seja 65 milhões de dólares, mas a verdade é que o benefício pode ser maior no tempo, já que se neste sistema sempre se faz a expansão considerando desplanificação, em teoria, o benefício econômico está perto da diferença entre os valores acumulados, isto é, (2.302 - 2.100) milhões de dólares, ou seja 202 milhões de dólares. Este caso sem reprogramação mostra um maior benefício imediato que o caso com reprogramação da geração.

- O caso 7 é similar ao caso 6, mas usando a terceira modelagem matemática proposta, que incentiva a permanência das linhas de transmissão existentes na topologia base, função objetivo mostrada em (3.6). A melhor solução encontrada para este caso é de 325 milhões de dólares e retira três circuitos da topologia base e conserva o circuito do caminho 08 –

09. Neste caso, ao adicionar o custo das linhas da rede inicial utilizadas, que é de 1818 milhões de dólares, o valor acumulado resultante é de 2143 milhões de dólares. Na prática, o benefício imediato da desplanificação é a diferença entre investimentos dos planos, isto é, (390-325) milhões de dólares, ou seja 65 milhões de dólares, mas a verdade é que o benefício pode ser maior no tempo, já que se em este sistema sempre se faz a expansão considerando desplanificação, em teoria, o benefício econômico está perto da diferença entre os valores acumulados, isto é, (2302 - 2143) milhões de dólares, ou seja 159 milhões de dólares.

- Ao comparar o resultado do caso 7, onde se incentiva a permanência das linhas de transmissão irrelevantes existentes na topologia base, com o resultado do caso 6, onde se incentiva a retirada das linhas de transmissão irrelevantes existentes na topologia base, se observa que promover a permanência dos elementos irrelevantes para operação ou investimento, como o circuito 08 – 09 nesta análise, reduz o benefício econômico acumulado possível (de 202 a 159 milhões de dólares) mas permite aproveitar este elemento em outro contexto de operação do sistema.
- Os circuitos da rede inicial: $n_{02-04} = 1$, $n_{03-09} = 1$ e $n_{20-23} = 1$, devem ser obrigatoriamente retirados da operação normal do sistema para reduzir o custo do plano de expansão ótimo quando é considerada a desplanificação. Estes circuitos não devem ser retirados definitivamente do sistema e devem permanecer disponíveis para ser usados quando a rede precise delas em outro contexto de operação.
- O circuito da rede inicial $n_{08-09} = 1$ é irrelevante desde o ponto de vista da operação do sistema futuro e desde o ponto de vista de investimento. Pode ser retirado ou pode ser conservado para a operação. Também este circuito pode permanecer conectado no sistema para ser aproveitado em um outro contexto de operação ou para melhorar a segurança do sistema.

3.4.3 Sistema Colombiano de 93 barras e 155 ramos

Este sistema tem 93 barras, 155 caminhos de adição de linhas de transmissão, demanda de 14559 MW e capacidade de geração de 14559 MW. Os dados de barras e de ramos deste sistema são apresentados no apêndice A.3. Este é um sistema sem reprogramação da geração utilizado em testes para novos modelos e técnicas de otimização do problema de planejamento da expansão de sistemas de transmissão. Neste trabalho se apresentam os resultados de planejamento para este sistema com e sem desplanificação.

Para efeitos de comparação, inicialmente se resolve o problema de planejamento considerando que as variáveis de decisão correspondentes ao número de ramos a ser adicionados são contínuas, isto é, não é considerada a condição de inteira para as variáveis, e também é considerado que não existem elementos na configuração inicial. A partir destes dados é obtido o limite inferior para o problema considerando desplanificação e considerando a restrição de inteira para as variáveis de investimento n_{ij} . Também, com propósitos de comparação se resolve o problema de planejamento tradicional, isto é, não é considerada a desplanificação mas é considerada a restrição de inteira para as variáveis de investimento n_{ij} . Para este último problema, o valor obtido é a melhor solução conhecida na literatura especializada. Finalmente, são considerados dois casos onde se resolve o problema PNLIM com desplanificação. A continuação se apresentam estes resultados.

Caso 1: Sistema Colombiano sem linhas na rede inicial e os n_{ij} contínuos

Como no caso do sistema IEEE de 24 barras, o problema de planejamento para o sistema colombiano é resolvido inicialmente usando um método de programação não linear de ponto interior de alto ordem. Em (ESCOBAR; BOLAÑOS; CORREA, 2008) podem-se observar aspectos relacionados com o método de solução usado. Ao usar PNL com as variáveis de investimento relaxadas, o valor obtido é maior que o valor ótimo conhecido usando programação não linear inteira-mista no problema de planejamento do sistema elétrico colombiano, porque no PNL relaxado não é considerada a rede inicial.

- Investimento de $v = 1.848$, 7 milhões de dólares.
- Adição de linhas de transmissão:

$$\begin{aligned}
 n_{52-88} &= 0, 7076; n_{43-88} = 0, 3486; n_{57-81} = 1, 4818; n_{27-89} = 2, 0068; \\
 n_{73-89} &= 1, 6414; n_{08-67} = 0, 9314; n_{39-86} = 0, 4755; n_{25-28} = 0, 2673; \\
 n_{13-14} &= 0, 7438; n_{14-60} = 0, 8680; n_{02-04} = 0, 9623; n_{02-09} = 1, 2927; \\
 n_{02-83} &= 0, 5223; n_{15-18} = 1, 4289; n_{15-17} = 0, 2775; n_{37-61} = 0, 1085; \\
 n_{61-68} &= 1, 4098; n_{27-35} = 0, 2259; n_{38-39} = 0, 3716; n_{27-80} = 0, 2518; \\
 n_{45-50} &= 1, 1210; n_{10-78} = 0, 2530; n_{07-78} = 0, 4075; n_{30-65} = 0, 7882; \\
 n_{30-72} &= 1, 1329; n_{55-57} = 2, 5316; n_{55-84} = 0, 8333; n_{56-57} = 1, 5182; \\
 n_{77-79} &= 0, 2358; n_{01-59} = 1, 8716; n_{59-67} = 1, 7873; n_{01-03} = 2, 6672; \\
 n_{55-62} &= 3, 1372; n_{51-52} = 0, 6260; n_{41-42} = 0, 0513; n_{40-42} = 0, 3821; \\
 n_{46-53} &= 0, 2603; n_{46-51} = 0, 1338; n_{66-69} = 1, 2732; n_{09-69} = 3, 6692; \\
 n_{60-69} &= 2, 5532; n_{31-32} = 0, 5354; n_{16-23} = 0, 8771; n_{16-21} = 1, 7372; \\
 n_{31-60} &= 1, 0716; n_{31-72} = 0, 3482; n_{47-49} = 0, 2446; n_{18-58} = 0, 5424;
 \end{aligned}$$

$$\begin{aligned}
n_{18-20} &= 0, 7333; n_{18-22} = 0, 7475; n_{19-22} = 3, 4115; n_{04-05} = 0, 7911; \\
n_{05-06} &= 0, 0967; n_{17-76} = 0, 1150; n_{12-17} = 0, 1329; n_{01-71} = 0, 1879; \\
n_{01-11} &= 0, 4456; n_{04-36} = 0, 4923; n_{27-44} = 1, 4455; n_{73-74} = 0, 0943; \\
n_{29-64} &= 0, 5825; n_{04-34} = 0, 2586; n_{34-70} = 0, 5133; n_{54-63} = 3, 2046; \\
n_{48-63} &= 0, 0317; n_{67-68} = 2, 5755; n_{79-87} = 0, 1999; n_{08-87} = 0, 1999; \\
n_{39-43} &= 0, 1368; n_{23-24} = 0, 4266; n_{21-22} = 2, 5203; n_{26-28} = 0, 1986; \\
n_{28-29} &= 0, 9028; n_{33-72} = 0, 7052; n_{39-40} = 0, 6816; n_{62-73} = 2, 3006; \\
n_{49-53} &= 1, 0177; n_{45-81} = 1, 8108; n_{64-74} = 0, 1681; n_{54-56} = 2, 0251; \\
n_{72-73} &= 1, 5315; n_{19-82} = 1, 6752; n_{83-85} = 0, 6629; n_{82-85} = 1, 0767; \\
n_{19-86} &= 1, 4088; n_{68-86} = 1, 0257; n_{07-90} = 1, 2990; n_{90-91} = 0, 8269; \\
n_{85-91} &= 0, 7584.
\end{aligned}$$

- Corte de carga = 0 MW.

Caso 2: Sistema Colombiano de 93 barras com rede inicial e n_{ij} inteiros

Neste caso, o problema é resolvido usando o algoritmo genético de Chu-Beasley modificado, apresentado na seção 3.3.2, com os seguintes parâmetros: tamanho de população de 200 indivíduos, 60% da população gerada aleatoriamente e 40% da população gerada usando AHC, número de pais que participam do torneio $k = 2$, $\rho_c = 0,98$, $\rho_m = 0,02$, diversidade entre os indivíduos da população de 3 bits, $cortemax = 50$ MW. O valor obtido depois de 4530 gerações é o valor ótimo conhecido para o problema PNLIM do sistema elétrico colombiano de 93 barras. O custo é menor que no caso 1 porque não inclui os custos das linhas da rede inicial.

- Investimento de $v = 560$ milhões de dólares.
- Adição de linhas de transmissão:

$$\begin{aligned}
n_{15-18} &= 1, n_{19-82} = 2, n_{27-29} = 1, n_{29-64} = 1, n_{30-65} = 1, n_{30-72} = 1, n_{43-88} = 2, \\
n_{50-54} &= 1, n_{54-56} = 1, n_{55-57} = 1, n_{55-62} = 1, n_{55-84} = 1, n_{56-57} = 1, n_{62-73} = 1, \\
n_{68-86} &= 1, n_{72-73} = 1, n_{82-85} = 1.
\end{aligned}$$

- Corte de carga = 0,2 MW.

Caso 3: Sistema Colombiano de 93 barras com desplanificação e que incentiva a retirada de linhas

Neste caso, foi usado o algoritmo CBGA modificado com parâmetros similares aos usados no caso 2. Usando a segunda modelagem matemática proposta que incentiva a retirada de

linhas de transmissão existentes na topologia base, função objetivo mostrada em (3.5), e considerando a condição de inteiras das variáveis de decisão, a melhor solução encontrada apresenta as seguintes características:

- Investimento de $v = 528,51$ milhões de dólares

- Adição de novos elementos de transmissão:

$$n_{43-88} = 2, n_{15-18} = 1, n_{45-54} = 1, n_{57-84} = 1, n_{55-84} = 2, n_{56-57} = 1, n_{59-67} = 1, \\ n_{55-62} = 1, n_{66-69} = 1, n_{18-58} = 1, n_{18-20} = 1, n_{19-58} = 2, n_{27-64} = 1, n_{19-66} = 1, \\ n_{67-68} = 1, n_{79-87} = 2, n_{62-73} = 1, n_{54-56} = 1, n_{68-86} = 1.$$

- Retirada de linhas de transmissão:

$$n''_{19-82} = 1, n''_{25-29} = 1, n''_{13-14} = 2, n''_{13-23} = 1, n''_{14-18} = 1, n''_{14-60} = 1, n''_{02-09} = 1, \\ n''_{15-20} = 1, n''_{37-61} = 1, n''_{40-68} = 1, n''_{24-75} = 1, n''_{35-44} = 2, n''_{38-68} = 1, n''_{07-78} = 1, \\ n''_{09-77} = 1, n''_{03-06} = 1, n''_{47-52} = 1, n''_{41-42} = 1, n''_{31-34} = 1, n''_{31-33} = 2, n''_{31-72} = 1, \\ n''_{47-54} = 1, n''_{18-66} = 1, n''_{04-05} = 1, n''_{17-76} = 1, n''_{01-71} = 1, n''_{01-08} = 1, n''_{01-11} = 1, \\ n''_{27-28} = 1, n''_{26-27} = 1, n''_{64-65} = 1, n''_{29-64} = 1, n''_{33-34} = 1, n''_{08-09} = 1, n''_{39-43} = 1, \\ n''_{12-76} = 1, n''_{60-62} = 3, n''_{72-73} = 1, n''_{83-85} = 1, n''_{07-90} = 1.$$

- Corte de carga $w = 0$ MW.

Caso 4: Sistema Colombiano de 93 barras com desplanificação e que incentiva a permanência das linhas

Neste caso foi usado o algoritmo CBGA modificado com parâmetros similares aos usados no caso 2. Usando a terceira modelagem matemática proposta que incentiva a permanência das linhas de transmissão existentes na topologia base, função objetivo mostrada em (3.6), e considera a condição de inteiras das variáveis de decisão, a melhor solução encontrada apresenta as seguintes características:

- Investimento de $v = 528,51$ milhões de dólares

- Adição de novos elementos de transmissão:

$$n_{43-88} = 2, n_{15-18} = 1, n_{45-54} = 1, n_{57-84} = 1, n_{55-84} = 2, n_{56-57} = 1, n_{59-67} = 1, \\ n_{55-62} = 1, n_{66-69} = 1, n_{18-58} = 1, n_{18-20} = 1, n_{19-58} = 2, n_{27-64} = 1, n_{19-66} = 1, \\ n_{67-68} = 1, n_{79-87} = 2, n_{62-73} = 1, n_{54-56} = 1, n_{68-86} = 1.$$

- Retirada de linhas de transmissão:

$$n''_{07-78} = 1, n''_{31-34} = 1, n''_{64-65} = 1, n''_{29-64} = 1, n''_{33-34} = 1, n''_{60-62} = 3, n''_{19-82} = 1, \\ n''_{01-08} = 1, n''_{01-11} = 1, n''_{08-09} = 1, n''_{72-73} = 1.$$

- Corte de carga $w = 0$ MW.

3.4.4 Análise dos resultados para o sistema Colombiano de 93 barras

Ao comparar os resultados obtidos nos testes para o sistema elétrico colombiano, pode-se observar o seguinte:

- No caso 3 são consideradas as linhas da configuração inicial, é considerada a condição de inteira das variáveis e se incentiva a retirada de linhas de transmissão existentes na topologia base. A melhor solução inteira obtida usando desplanificação é de 528,5 milhões de dólares. Ao adicionar o custo das linhas da configuração base usadas nesta solução, que é de 2.277,7 milhões de dólares, o valor acumulado resultante é de 2.806,2 milhões de dólares. O caso 2 é um caso similar ao caso 3, mas sem considerar desplanificação. A melhor solução conhecida para este caso é de 560 milhões de dólares, e utiliza toda a rede da topologia base. Neste caso, ao adicionar o custo das linhas da rede inicial, que é de 2.731,7 milhões de dólares, o valor acumulado resultante é de 3.291,7 milhões de dólares. Na prática, o benefício imediato da desplanificação é a diferença entre investimentos dos planos, isto é, (560-528,5) milhões de dólares, ou seja 31,5 milhão de dólares, mas a verdade é que o benefício pode ser maior no tempo, já que se em este sistema sempre se faz a expansão considerando desplanificação, em teoria, o benefício econômico está perto da diferença entre os valores acumulados, isto é, (3.291,7-2.806,2) milhões de dólares, ou seja 485,5 milhões de dólares.
- Neste trabalho foi encontrado um valor de 528,5 milhões de dólares como melhor solução considerando desplanificação e a condição de inteira das variáveis. O valor acumulado adicionando o custo das linhas da rede inicial usadas no melhor caso (caso 3) foi de 2.806,2 milhões de dólares. Em teoria, este valor pode ser menor se se compara com a solução do caso 1, no qual é relaxada a condição de inteira das variáveis e que mostra um valor acumulado de 1.848,7 milhões de dólares. Este valor, entretanto, não é alcançável já que representa a solução contínua do problema inteiro-misto e representa uma limitante inferior para o problema com desplanificação, mas deixa aberta a possibilidade de que possam existir melhores soluções inteiras para este problema.

- Ao comparar os resultados do caso 3 e do caso 4, se pode afirmar que as seguintes linhas ou transformadores existentes na rede inicial:

$$n_{07-78} = 1, n_{31-34} = 1, n_{64-65} = 1, n_{29-64} = 1, n_{33-34} = 1, n_{60-62} = 3, n_{19-82} = 1, \\ n_{01-08} = 1, n_{01-11} = 1, n_{08-09} = 1 \text{ e } n_{72-73} = 1.$$

devem ser obrigatoriamente retirados ou desconectados da operação normal, já que reduzem o desempenho da rede futura e aumentam o custo do plano de expansão ótimo acima de 528,5 milhões de dólares. É importante que estes elementos permaneçam disponíveis na rede para que possam ser usados quando o sistema precise delas.

- Ao comparar os resultados do caso 3 e do caso 4, se pode afirmar que as seguintes linhas ou transformadores existentes na rede inicial:

$$n''_{25-29} = 1, n''_{13-14} = 2, n''_{13-23} = 1, n''_{14-18} = 1, n''_{14-60} = 1, n''_{02-09} = 1, n''_{15-20} = 1, \\ n''_{37-61} = 1, n''_{40-68} = 1, n''_{24-75} = 1, n''_{35-44} = 2, n''_{38-68} = 1, n''_{09-77} = 1, n''_{03-06} = 1, \\ n''_{47-52} = 1, n''_{41-42} = 1, n''_{31-33} = 2, n''_{31-72} = 1, n''_{47-54} = 1, n''_{18-66} = 1, n''_{04-05} = 1, \\ n''_{17-76} = 1, n''_{01-71} = 1, n''_{27-28} = 1, n''_{26-27} = 1, n''_{39-43} = 1, n''_{12-76} = 1, n''_{83-85} = 1, \\ n''_{07-90} = 1.$$

Podem ou não ser retirados da operação normal, já que não reduzem e não melhoram o desempenho da rede futura, e não aumentam e não reduzem o custo do plano de expansão de 528,5 milhões de dólares quando operam simultaneamente. Se todas estas linhas permanecem em operação para o novo sistema, o custo das linhas da rede inicial que são usadas é de 2.584,6 milhões de dólares, inferior ao custo das linhas da rede base que é de 2.731,7 milhões de dólares. Testes adicionais mostram que os elementos: $n_{01-08} = 1$, $n_{01-11} = 1$, $n_{08-09} = 1$, $n_{72-73} = 1$, podem ser também reincorporados para operar em condições normais mas atuando individualmente, já que podem gerar laços de tensão que prejudicam a operação conjunta.

- Uma análise da modelagem matemática usada para representar a rede de transmissão, no problema de planejamento considerando desplanificação, mostra que em algumas trajetórias fechadas conformadas por elementos mistos, isto é, elementos da rede inicial e elementos da nova rede de transmissão, a ativação da restrição angular associada a um dos elementos da rede base, produz uma operação subótima do sistema, isto quer dizer que, quando a rede opera com este elemento aparece congestionamento, e quando ele é retirado, não aparece congestionamento. Em consequência, alguns elementos da topologia base prejudicam a operação do sistema futuro, e isto é produzido pela necessidade de satisfazer a segunda lei de Kirchhoff em todos os laços do sistema. No caso do sistema

elétrico colombiano de 93 barras se encontra, por exemplo, que na melhor solução encontrada usando desplanificação deve-se retirar o elemento de transmissão existente entre as barras 19-82, ou seja, $n_{19-82} = 0$. Sem este elemento a distribuição de fluxos é tal que não se apresentam sobrecargas em nenhum circuito do novo sistema de transmissão. Esta condição implica que se deve retirar um circuito existente na topologia base, sem embargo, se este circuito existente não é retirado ($n_{19-82} = 1$), no sistema se produz uma distribuição de fluxos que coloca em seu limite de capacidade dos circuitos 27-64, 72-73, 83-85, 82-85 e ao próprio circuito 19-82, provocando congestionamento no sistema e prejudicando o atendimento total da demanda, produzindo uma demanda não atendida de 402 MW. Em outro caso, se encontra que deve-se retirar o elemento de transmissão existente na topologia base entre as barras 7-78. Um teste mostra que ao ser adicionada na melhor solução com desplanificação encontrada de 528,5 milhões de dólares produz um corte de carga de 85,4 MW, por causa do congestionamento no sistema que aparece porque a linha 7-90 atinge seu limite de capacidade. Ao eliminar a linha 7-78 da topologia base, o congestionamento desaparece e o corte de carga é 0 MW.

Na figura 10 é mostrada uma gráfica comparativa dos valores obtidos para os diferentes casos estudados para o sistema elétrico colombiano de 93 barras.

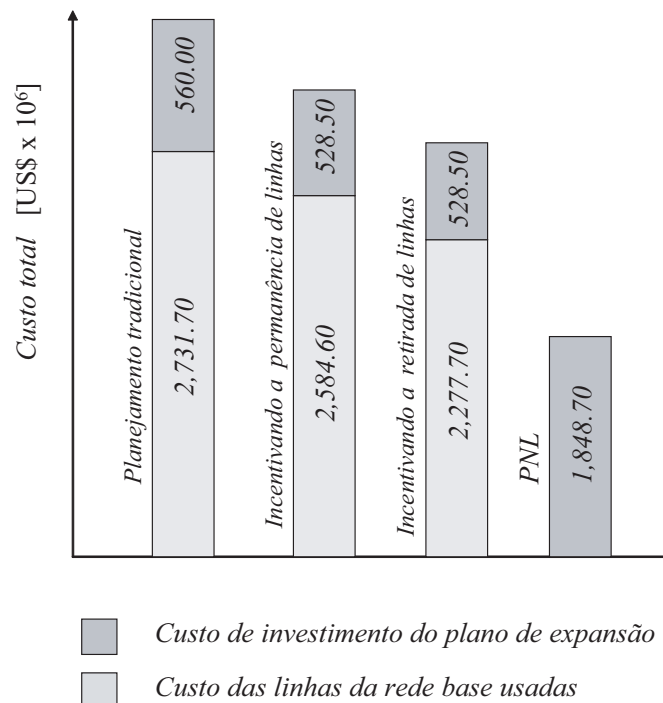


Figura 10: Custos das diferentes formas de planejamento para o sistema colombiano de 93 barras.

3.5 Conclusões parciais

- Neste trabalho, apresentam-se três formas diferentes para o modelo matemático do problema de planejamento da expansão de sistemas de transmissão considerando desplanificação. Os modelos permitem identificar um conjunto de linhas de transmissão existentes, na topologia base, que podem ser retirados da operação normal do sistema elétrico futuro. A retirada destas linhas produz planos de expansão de menor custo que os obtidos usando a estratégia de planejamento tradicional em que todas as linhas existentes na topologia base devem continuar operando no sistema elétrico expandido.
- Testes realizados em dois sistemas elétricos mostram a potencialidade de obter uma melhor solução para a rede futura considerando a possibilidade de retirar da operação normal alguns circuitos existentes na topologia inicial, já que a desplanificação permite identificar elementos de transmissão que prejudicam a operação futura de um sistema elétrico. A análise é feita em dois sistemas teste com redes de transmissão iniciais bem planejadas (as soluções iniciais também são obtidas através de um processo de otimização) e mostram uma redução do custo de expansão. No caso de redes reais que não sejam ótimas, o benefício pode ser maior.
- Na figura 11 é mostrado um gráfico comparativa dos valores associados ao planejamento da rede de transmissão usando o esquema tradicional e a nova proposta considerando a desconexão de alguns elementos da rede inicial ou desplanificação. Nesta figura, E_0 representa o ponto de referência inicial sem elementos na rede de transmissão, sem geração e sem demanda. E_t representa o sistema elétrico com um conjunto de barras de carga e geração, e um cenário geração/carga futuro t . E_{t+1} representa o sistema elétrico com o mesmo conjunto de barras do caso E_t e possivelmente algumas barras de geração ou carga novas. E_{t+1} está associado a um cenário geração/carga futuro $t + 1$ posterior ao cenário geração/carga de E_t . Usando planejamento tradicional, o plano ótimo de expansão entre os pontos E_0 e E_t minimiza o custo de investimento respeito ao cenário geração/carga associado com E_t . Se todos os elementos adicionados no plano de expansão $E_0 \rightarrow E_t$ são usados, então $E_t \rightarrow E_{t+1}$ representa o custo de plano de expansão ótimo entre os pontos E_t e E_{t+1} . Ao considerar desplanificação, algumas linhas do plano de expansão $E_0 \rightarrow E_t$ são desconectadas, e são adicionadas algumas linhas novas para atingir o ponto E_{t+1} . A nova trajetória de otimização $E_0 \rightarrow E_{t+1}$ está composta por algumas linhas do plano ótimo $E_0 \rightarrow E_t$, as quais produzem o ponto intermediário E_1 e um conjunto de linhas novas que permitem atingir o ponto E_{t+1} , associadas na trajetória $E_1 \rightarrow E_{t+1}$. Ao considerar desplanificação, o plano de expansão ótimo entre t e $t + 1$

(trajetória $E_1 \rightarrow E_{t+1}$) resulta de menor custo que o plano de expansão entre t e $t+1$ sem considerar desplanificação (trajetória $E_t \rightarrow E_{t+1}$). A figura 12 mostra o caso do sistema colombiano onde a desplanificação permite reduzir o custo do novo plano de expansão em um 94,3% (de 560 a 528,5 milhões de dólares) ao desconectar as linhas da rede base que prejudicam a operação do sistema futuro.

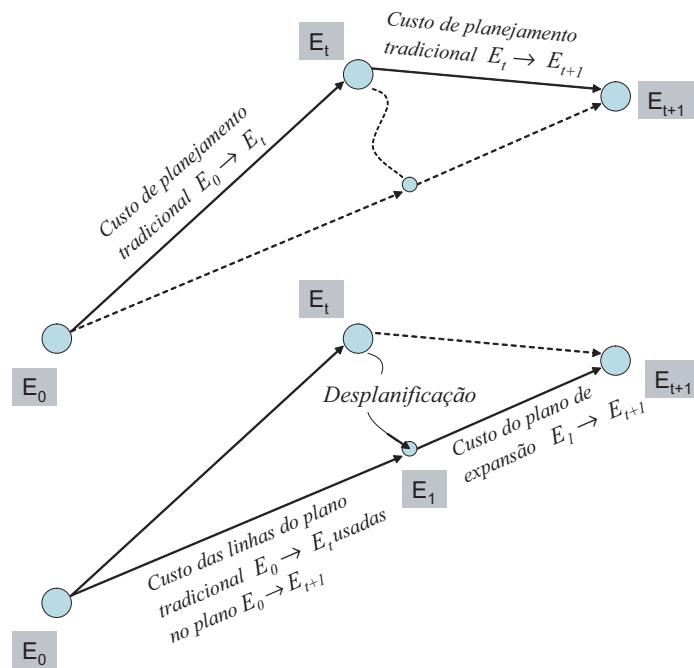


Figura 11: Custos comparativos com e sem desplanificação.

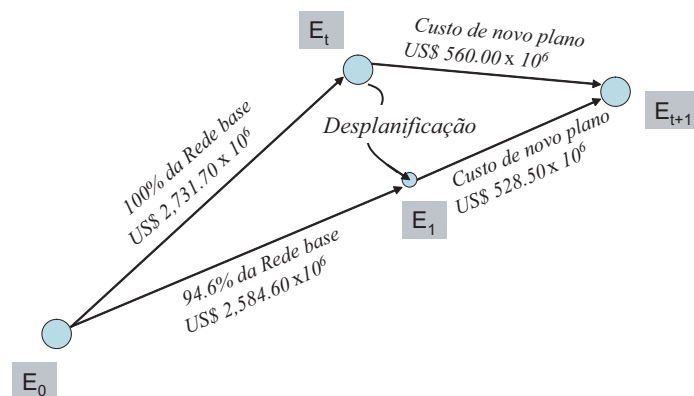


Figura 12: Custos comparativos com e sem desplanificação para o sistema colombiano de 93 barras.

- Os elementos de transmissão que são temporariamente retirados da operação, não devem ser retirados permanentemente e devem permanecer disponíveis para ser incorporados de novo quando o sistema precise delas, já que com a retirada de elementos pode-se diminuir a confiabilidade do sistema elétrico.

-
- Os resultados mostram que um número reduzido de linhas de transmissão do sistema base produzem um grande impacto no custo da expansão da rede de transmissão, e que um número grande de linhas de transmissão da rede base produzem um pequeno impacto no custo de expansão.

4 *Planejamento da Transmissão Considerando Múltiplos Cenários de Geração*

4.1 Introdução

Nos sistemas elétricos com esquemas tradicionais, tanto a operação como o planejamento da rede elétrica é feito por entidades centralizadas e organizadas em estruturas verticalmente integradas. Nestes sistemas, o problema de planejamento da transmissão consiste em determinar os reforços necessários que se devem realizar no sistema para que possa cumprir com as condições impostas pelo crescimento da carga e da nova capacidade de geração. Mas a obtenção de um sistema de transmissão que permita a programação de qualquer cenário de geração possível não é considerada. A reestruturação do setor elétrico alterou os paradigmas do planejamento e nos últimos anos forçou a que os aspectos técnicos dos sistemas elétricos se encontrem cada vez mais associados às condições impostas pelo mercado de eletricidade. Teoricamente, esta reestruturação tem como propósito permitir a competência e dar aos consumidores liberdade de eleição para lograr um aumento na qualidade do serviço e obter melhores preços do denominado produto elétrico. Um primeiro passo neste sentido se dá através da separação das atividades (geração, transmissão, distribuição e comercialização) de tal forma que as relações entre empresas sejam através de contratos comerciais. De igual forma, a planificação e a expansão em mercados competitivos devem estar caracterizadas pelo desenvolvimento com baixo custo, com níveis aceitáveis de qualidade, confiabilidade e segurança e ao mesmo tempo remunerar aos proprietários dos ativos do sistema (geradores, ativos de transmissão e interconexão).

O processo de reestruturação da indústria da eletricidade tem produzido então o aparecimento de novos agentes, e novas exigências. Com a desregulação dos sistemas elétricos surgem diferentes esquemas competitivos dentro do setor elétrico mundial com características particulares para cada sistema, o que dificulta a obtenção de soluções gerais para os diferentes problemas que aparecem dentro do processo de busca de eficiência do mercado. O processo de planeja-

mento da expansão dos sistemas de transmissão é mais complexo nos sistemas elétricos reestruturados por causa de que nestes sistemas as decisões de novos investimentos em geração são agora baseadas nas forças do mercado e não em processos de decisão centralizados. Também, a rede de transmissão afeta a eficiência do mercado por causa do congestionamento que pode aparecer, e que não permite a programação de certos despachos de geração, que em um sistema com mercado de eletricidade são resultado da interação entre as ofertas econômicas que fazem os agentes geradores e as necessidades de potência dos consumidores (em alguns casos os consumidores apresentam suas necessidades de potência e o valor que podem pagar por ela). Em consequência, os despachos de geração horários ou diários possuem grande incerteza e existe um número muito grande de cenários factíveis.

Sempre que existe congestionamento na rede de transmissão para alguns cenários de geração factíveis, diz-se que não existem condições de livre competência ou não existem condições de competição perfeita. O planejamento da transmissão de curto prazo deve portanto eliminar as restrições que afetam a eficiência do mercado da rede atual e o planejamento da transmissão de longo prazo deve garantir, sempre que seja economicamente possível, uma rede de transmissão que não produza congestionamento em nenhum cenário factível de geração futuro. Este é um novo paradigma para o planejamento da expansão dos sistemas de transmissão modernos.

No desenvolvimento das condições de competência, deve-se promover o acesso livre às redes elétricas, tanto para os geradores como para os usuários, o qual se logra através de mecanismos de tarifação e remuneração de ativos, de maneira que se incentiva a expansão e a construção de novas redes para poder transportar a energia de diferentes geradores até o usuário final. As redes de transmissão representam esta ligação e interconectam múltiplos lugares dentro de um território com o propósito de fornecer diferentes caminhos para fornecer a demanda. Neste sentido a atividade de transmissão possibilita a existência dos mercados elétricos. No caso dos geradores, a rede de transmissão oferece diferentes cenários para o despacho e permite a competência entre os agentes geradores (RUDNICK; ZOLEZZI, 1999).

Em consequência, para produzir condições de competência é necessária uma rede de transmissão que possa aproveitar a geração futura e que possa abastecer a demanda projetada sobre a base da existência de um mercado elétrico competitivo. Isso significa que para realizar o planejamento considerando este esquema deve-se ter em conta uma variedade de padrões de fluxo de potência de acordo com despachos gerados pelas variações do mercado, pela mudança dos níveis de geração e carga ao existir livre acesso e pelo estado de abastecimento dos energéticos primários (BALDICK; KAHN, 1993; LU; DONG; SAHA, 2005; TORRE; CONEJO; CONTRERAS, 2008).

Devido a reestruturação pela qual o setor elétrico vem passando em todo mundo nos últimos

anos, houve um grande aumento no interesse pelo planejamento da expansão da transmissão em um ambiente competitivo. O trabalho pioneiro nesta área de pesquisa foi realizado pelo National Grid Company (CLEOBURY, 1993). A experiência obtida com os sistemas Inglês (HENNEY, 1995) e Chileno tem promovido o interesse sobre o planejamento da transmissão em um ambiente desregulamentado e conseqüentemente o número de publicações nesta área tem aumentado bastante (BALDICK; KAHN, 1993). Trabalhos como os apresentados em (DAVID; WEN, 2001; XU; DONG; WONG, 2003; SCOTT; HOGAN; POPE, 1997) tem fornecido alguns detalhes importantes para se entender como o setor elétrico reestruturado tem afetado o planejamento da expansão da transmissão.

Conforme as novas normas regulatórias têm sido estabelecidas, a necessidade de se rever o processo de planejamento de expansão da transmissão tem se tornado bastante importante. Esta revisão conceitual deve incluir tanto os modelos como os algoritmos de solução (LATORRE et al., 2003), bem como os problemas emergentes causados pelas características especiais da atividade da transmissão de potência em um ambiente competitivo (RUDNICK; ZOLEZZI, 1999; DAVID; WEN, 2001).

Quando se deseja planejar uma rede de transmissão que não produza congestionamento em nenhum cenário provável de geração futura, não existe uma idéia exata dos cenários que devem aparecer no futuro e tampouco sobre a probabilidade de ocorrência destes cenários já que as condições de mercado que existem hoje podem mudar no futuro.

Na prática, o uso de cenários tem a finalidade de nortear as decisões. É um método de decisão sob incerteza que auxilia as ações estratégicas, inclusive na identificação de oportunidades e ameaças, forças e fraquezas e, neste sentido, permite o diagnóstico das competências a serem fomentadas. Na análise de cenários, a incerteza é criativa e faz parte do processo. A metodologia de cenários é flexível e permite uma análise qualitativa mais adequada em relação aos horizontes futuros. O uso de cenários têm o propósito de auxiliar a decisão de investimentos que envolvem incertezas e longo prazo.

O uso de cenários de geração é uma aproximação discreta das incertezas nos padrões de despachos de geração. Quanto maior a quantidade e representatividade dos cenários considerados, melhor será a aproximação. A cada cenário pode ser associada uma probabilidade de ocorrência distinta e menor que 1, e com base neste valor, modificar de alguma maneira a importância dos novos investimentos. Também pode ser selecionado um subconjunto de cenários representativos, todos com probabilidade de ocorrência igual a 1. Isso significa que a rede de transmissão deve operar adequadamente para todos estes cenários.

A definição de metodologias ou critérios para a determinação de quantos e quais cenários

possíveis de geração e carga são mais representativos foge ao escopo deste trabalho. Uma opção é obter os planos de expansão obtidos durante os estudos de planejamento da expansão da geração. Os cenários de demanda podem ser desagregações feitas sobre os cenários de demanda agregada utilizados nos estudos de planejamento da expansão da geração.

Uma alternativa interessante de uso para os cenários de geração em sistemas com usinas hidroelétricas é a possibilidade de se considerar diversos despachos, correspondentes a diferentes condições hidrológicas, representando-se assim a incerteza hidrológica. Com relação aos cenários de carga, estes podem ser utilizados para modelar diferentes patamares de carga, com probabilidades de ocorrência proporcionais aos respectivos tempos de duração na curva de carga. A consideração de mais de um patamar de carga é necessária principalmente quando se deseja considerar no modelo de otimização o custo de operação do sistema ou de perdas.

Na referência (ROMÉRO, 2007) é utilizada uma estrutura em forma de árvore para a representação dos cenários. Cada cenário corresponde a um diferente caminho desde a raiz até uma das folhas do último nível (ramo) da árvore. Cada ramo representa um período de tempo no horizonte de planejamento no qual podem ser tomadas decisões (início da construção de um reforço).

Os nós da árvore, situados no início de cada ramo, estão associados às variáveis de decisão e de operação dos respectivos cenários naquele ramo. Cada nó da árvore pode representar também pontos a partir do qual dois ou mais cenários, que eram iguais até então, deixam de ser, devido a, por exemplo, alterações no valor de cargas ou capacidades de geração, criando-se assim uma arborescência neste nó da árvore. Portanto, a estrutura da árvore depende tanto da disponibilidade de informações a respeito das incertezas futuras quanto dos momentos onde as decisões devem ser tomadas.

As variáveis de decisão de diferentes cenários devem ser iguais até um estágio *ne*, se estes cenários compartilharem o mesmo "caminho" na árvore de cenários até este ramo. Estas restrições são denominadas de restrições de não-antecipabilidade. Este nome se deve ao fato de que as decisões de investimento devem ser tomadas antes de se conhecer o valor futuro das variáveis incertas. É possível relaxar as restrições de não-antecipabilidade de modo a permitir o tratamento dos cenários de forma independente. Esta metodologia pode ser aplicada quando existe um número discreto e relativamente reduzido de cenários, os quais tem probabilidades de ocorrência diferentes e onde a soma destas probabilidades é igual a 1

Na referência (JUNIOR, 2005) é analisado o problema de planejamento da expansão com restrições de segurança e que, adicionalmente, em condições sem contingência opere adequadamente para vários planos de programação da geração. Esta proposta de expansão implica que

o sistema expandido deve operar adequadamente para vários planos de geração previamente especificados e que também possa operar adequadamente com a saída de uma linha de transmissão após realizar um remanejamento da geração. Finalmente, na referência (FANG; HILL, 2003) se analisa o planejamento da expansão apenas considerando um número reduzido e específico de planos de geração.

No novo paradigma, um sistema elétrico deve ter a capacidade de operar em várias propostas de programação da geração determinadas pelas exigências do mercado elétrico satisfazendo fundamentalmente os seguintes aspectos:

- Uma distribuidora deve ser atendida em sua demanda especificada;
- Qualquer geradora pode operar em qualquer ponto de operação respeitando seus limites;
- O sistema não deve apresentar problemas de congestionamento para nenhum plano de programação factível;
- Todas as exigências da operação integrada devem estar satisfeitas.

Note-se que algumas destas exigências são independentes e outras estão relacionadas. E para levar em conta estas exigências deve-se dispor de uma modelagem matemática adequada que leve em conta todos os cenários factíveis e futuros de geração, o que será chamado neste trabalho planejamento considerando múltiplos cenários de geração (MCG) ou planejamento livre de congestionamento.

Uma modelagem matemática que cumpra com estas condições aumenta muito o custo do plano de expansão, mas diminui o custo do despacho. Nos mercados elétricos desregulamentados, o preço da energia, o qual é determinado usando despacho por mérito (despacho de geração de menor custo), é diretamente afetado pela capacidade das linhas de transmissão, já que elas permitem ou não a plena conectividade entre os grandes centros de geração e os centros de carga. Os pontos de operação futuros são adequados se nenhum cenário apresenta corte de carga. Desde a perspectiva dos objetivos dos sistemas elétricos modernos, deve-se procurar a minimização do custo de investimento em transmissão e do custo de despacho, como é mostrado nas referências (GIL; SILVA; GALIANA, 2002; BRAGA; SARAIVA, 2005).

É evidente que o funcionamento adequado da rede de transmissão é crítico para que o mercado elétrico possa ser sustentável (DIOS; SOTO; CONEJO, 2007), isto porque o custo anual (investimento e operação) de uma rede de transmissão representa uma pequena porcentagem do custo total das transações de energia (e serviços auxiliares), e porque a rede de transmissão pode ter

uma grande repercussão nestas transações. É por isso que uma rede bem planejada é fundamental para o desenvolvimento do mercado.

Dado que nos sistemas com restrições de transmissão se afeta a competição perfeita e, portanto, a eficiência do mercado elétrico, é importante determinar o custo associado para eliminar completamente o congestionamento, para ter uma medida do grau de adequação da rede atual às condições ideais de livre competência no futuro. Desde a perspectiva social um investimento em expansão da transmissão está economicamente justificada se o custo total do congestionamento eliminado pelo investimento é maior do que o custo do próprio investimento. Portanto, o resultado obtido nem sempre é economicamente viável. Na prática é difícil comparar estas duas quantidades, já que o custo de congestionamento, um custo operacional, ocorre em cada despacho, e de outro lado o custo de investimento em transmissão, um custo de capital, está associado à vida econômica do projeto. A literatura em sistemas de potência utiliza duas medidas de congestionamento: custo de redespacho e renda de congestionamento. O custo de redespacho se refere ao custo no sistema produzido pelo congestionamento. Isto é, a diferença entre o custo total de geração sem restrições da transmissão e o custo total de geração com restrições de transmissão. Em algumas publicações, o termo custo de redespacho é também referido como **custo da geração por fora de mérito, custo de restrições, ou custo de congestionamento**. A renda de congestionamento se refere à diferença entre o pagamento total que é feito pela carga e o pagamento total que os geradores recebem.

Nos casos em que o custo de investimento resultante não seja economicamente viável, esta análise de MCG permite identificar cenários críticos de geração futura, associados a grandes investimentos em transmissão, e valorar a probabilidade de ocorrência destes cenários, assim como considerar mantê-los no conjunto de cenários representativos, reduzir seu impacto na solução ou eliminá-los completamente. Também, para cenários de geração futuros com grande probabilidade de ocorrência, permite identificar investimentos críticos que devem ser feitos no sistema de transmissão e investimentos comuns a cenários de geração críticos.

Para garantir um sistema futuro totalmente livre de congestionamento é necessário incluir no processo de planejamento, todos os cenários que podem ocorrer, o qual representa um número infinito de cenários. Já que é matemática e computacionalmente impossível gerar todos estes cenários, propõe-se incluir um número finito e reduzido de cenários, mas que representem os infinitos cenários factíveis. Para isto, define-se o conceito de cenários de geração factíveis extremos, a partir dos quais é possível obter um sistema sem congestionamento para todos os infinitos cenários factíveis.

4.2 Planejamento considerando múltiplos cenários de geração

No planejamento tradicional, quando se faz o planejamento da expansão com ou sem reprogramação da geração, então, o sistema expandido opera adequadamente para os valores de geração fixados em cada barra de geração, no caso sem reprogramação, ou nos valores determinados pela solução em cada barra de geração, no caso com reprogramação. Eventualmente, o sistema ainda pode operar adequadamente quando são realizadas pequenas alterações nos valores de geração nas barras de geração. Entretanto, se o plano de geração for significativamente diferente, então a operação do sistema geralmente apresenta problemas de congestionamento ou corte de carga. Em alguns sistemas, mesmo pequenas alterações na programação da geração produzem operação inadequada apresentando corte de carga ou problemas de congestionamento do sistema elétrico. Existem muitos motivos pelos quais o plano de geração usado em planejamento pode ser diferente da programação da geração em operação de demanda pico do sistema elétrico. Esses problemas podem aparecer mesmo no ambiente de planejamento e operação centralizada quando não existe disponibilidade de energéticos primários em uma usina (como, por exemplo, em períodos de falta de água em usinas hidrelétricas), indisponibilidade de geradores, contingências, etc. No novo ambiente de mercado elétrico competitivo esse problema pode aparecer mais frequentemente porque os planos de geração nesse ambiente são mais dinâmicos e podem mudar por critérios de mercado além dos problemas operacionais tradicionais.

No contexto anterior, a proposta é desenvolver um plano de expansão que permita que o sistema expandido opere adequadamente para mudanças do plano de geração sendo que em cada usina o ponto de geração pode ser qualquer valor entre seus limites. Nesse contexto, sempre que for realizada reprogramação de geração dentro dos limites de operação das usinas então o sistema expandido deve operar adequadamente, isso significa, sem corte de carga ou problemas de congestionamento. Logicamente essa forma de planejamento da expansão é mais confiável e de maior custo que o planejamento tradicional realizado com e sem reprogramação. Nesta parte da tese pretende-se encontrar uma proposta de expansão em que o sistema pode operar adequadamente para qualquer cenário de geração factível. Nesta proposta, o problema de planejamento da expansão da rede de transmissão é resolvido em duas etapas.

Primeira etapa: Determina a rede de transmissão de mínimo custo que satisfaça a demanda futura em qualquer cenário extremo e factível de geração.

Segunda etapa: Prova que a proposta de mínimo custo, obtida na primeira etapa não produz corte de carga em nenhum cenário factível de geração.

A primeira etapa é determinística e a segunda etapa requer o uso de conceitos estatísticos. Para

satisfazer a condição de que a rede resultante do processo de otimização não produz congestionamento em nenhum cenário factível e futuro de geração, é feita a conjectura que se apresenta a seguir.

4.2.1 Conjectura de planejamento da expansão

Se um sistema for expandido de forma que opere adequadamente (sem congestionamento ou corte de carga) para todos os planos extremos e factíveis de geração então esse sistema expandido também opera de forma adequada para qualquer plano de geração factível.

Esta conjectura parte da consideração dos seguintes aspectos: 1) Os planos de expansão associados aos cenários factíveis são menos restritos que os planos associados a cenários de geração extremos e factíveis, 2) um plano de expansão que não produz congestionamento ou corte de carga em nenhum cenário de geração extremo factível, não deve produzir congestionamento ou corte de carga em nenhum cenário de geração não extremo e factível.

A anterior conjectura possui duas implicações importantes: a primeira é que o problema pode ser matematicamente formulado e implementado computacionalmente, já que o número de cenários de geração extremos e factíveis formam um subconjunto finito e reduzido de cenários de geração, contrário ao conjunto de cenários factíveis de geração que é de tamanho infinito; a segunda implicação é que obviamente uma conjectura não tem demonstração matemática, mas deve-se validar para mostrar que é verdadeira através de testes experimentais exaustivos. Para isso, é necessário gerar um número suficientemente grande de cenários factíveis, usando critérios estatísticos, e provar que não aparece congestionamento ou corte de carga em nenhum destes cenários. A validação prática dessa conjectura faz parte deste trabalho de pesquisa.

Para que seja possível realizar o planejamento da expansão com as características descritas é necessário definir o chamado **cenário de geração factível** e o chamado **cenário de geração extremo e factível**.

4.2.2 Cenário de geração factível

Um sistema elétrico com nível de demanda total d_t opera em um cenário de geração factível se a soma das gerações programadas, respeitando os limites de geração das usinas, é igual à demanda total d_t do sistema:

$$\sum_{i=1}^{ng} g_i = d_t \quad (4.1)$$

Onde ng é o número de barras de geração do sistema.

Independentemente do número de geradores que tenha um sistema elétrico, sempre resultam infinitos cenários de geração factíveis, o que elimina a possibilidade de testar todos eles para cada plano de expansão candidato.

Em um cenário de geração factível, a soma de todas as gerações programadas deve ser igual à demanda total do sistema. No caso do sistema IEEE de 24 barras, a Tabela 2 é um exemplo de cenário factível.

Tabela 2: Exemplo de Cenário factível.

Barra	Geração (MW)	Barra	Geração (MW)
1	523,4	16	422,5
2	9,7	18	872,4
7	817,8	21	1090,4
13	1611,0	22	817,8
15	586,1	23	1799,1

Neste caso, a geração total é de 8.550 MW (igual à demanda total).

4.2.3 Cenário de geração extremo e factível

Um sistema elétrico opera em um cenário de geração extremo e factível se alguns geradores do sistema se encontram operando em seu limite superior (\bar{g}_i), outros geradores se encontram operando em seu limite inferior (\underline{g}_j) e apenas um gerador opera em algum valor entre seus limites ($\underline{g}_k \leq g_k \leq \bar{g}_k$) de tal forma que permita encontrar o balanço de potência ativa entre geração e demanda no sistema elétrico.

Um cenário de geração extremo e factível deve satisfazer as seguintes restrições:

$$d_t \geq \sum_{i \in \Omega_1} \bar{g}_i + \sum_{j \in \Omega_2} \underline{g}_j + \underline{g}_k \quad (4.2)$$

$$d_t \leq \sum_{i \in \Omega_1} \bar{g}_i + \sum_{j \in \Omega_2} \underline{g}_j + \bar{g}_k \quad (4.3)$$

Onde d_t é a demanda total do sistema, \bar{g}_i é o limite superior do gerador i , \underline{g}_j é o limite inferior do gerador j , \bar{g}_k é o limite superior do gerador livre, \underline{g}_k é o limite inferior do gerador livre, Ω_1 é o conjunto de geradores que se encontram em seu limite superior, e Ω_2 é o conjunto de

geradores que se encontram em seu limite inferior. A soma do número de geradores em Ω_1 e Ω_2 deve ser igual a $(ng - 1)$.

Em um sistema elétrico, o número de cenários de geração extremos, que é $ng \times 2^{ng-1}$, pode ou não ser igual ao número de cenários de geração extremos factíveis, isso significa que não necessariamente todos os cenários de geração extremos são factíveis. No caso do sistema IEEE de 24 barras, o qual tem 10 geradores, o número de cenários extremos é de $10 \times 2^{(10-1)} = 5.120$, e o número destes cenários que satisfazem as restrições (4.2) e (4.3) é somente 178 cenários, isso significa que somente 3,5% dos cenários extremos são factíveis. Para o problema de planejamento da transmissão livre de congestionamento, no sistema IEEE de 24 barras, a conjectura é interpretada como: *se um plano de expansão candidato não apresenta congestionamento em nenhum dos 178 cenários extremos e factíveis do sistema IEEE24, então não apresenta congestionamento em nenhum cenário de geração factível*. No contexto anterior, um sistema com ng geradores, o número de cenários extremos e factíveis é menor ou igual a $2^{ng-1} \times ng$, os quais podem ser gerados usando o seguinte procedimento:

- Separar $(n-1)$ geradores em dois subconjuntos. No primeiro subconjunto programar os geradores em seus limites superiores. No segundo subconjunto programar os geradores em seus limites inferiores. O gerador restante é programado com um valor que é a diferença entre a demanda total d_t e a soma das gerações programadas nos $(n-1)$ geradores anteriores.
- Repetir o passo anterior para todas as possíveis combinações de geradores.
- São cenários de geração extremos e factíveis todas as combinações prévias que satisfaçam às restrições (4.2) e (4.3).

Em geral, um dos geradores não opera no limite, já que tem completar o balanço de potência ativa do sistema, entretanto pode ocorrer que todos os geradores que se encontrem no limite superior ou inferior. A seguir são apresentados dois cenários de geração extremos e factíveis para o sistema IEEE de 24 barras com particularidades diferentes.

Cenário extremo e factível de geração com um gerador que não se encontra em um de seus limites: Na Tabela 3, $(n-1)$ geradores, isto é, 9 geradores se encontram em um dos limites: G_{01} , G_{02} , G_{13} , G_{16} , G_{18} , G_{21} e G_{23} se encontram em seus limites superiores, e G_{15} e G_{22} se

Tabela 3: Cenário com um gerador fora de seus limites.

Barra	Geração (MW)	Barra	Geração (MW)
1	576	16	465
2	576	18	1.200
7	780	21	1.200
13	1.773	22	0
15	0	23	1.980

encontram em seus limites inferiores. Um dos geradores: G_{07} assume o valor de 780 MW o qual se encontra entre 0 MW e 900 MW que são seus limites inferior e superior, respectivamente. Este gerador completa o balanço de potência, já que a demanda é de 8.550 MW.

Tabela 4: Cenário com todos os geradores em seus limites.

Barra	Geração (MW)	Barra	Geração (MW)
1	576	16	0
2	576	18	1.200
7	900	21	0
13	1.773	22	900
15	645	23	1.980

Cenário extremo e factível de geração com todos os geradores em um de seus limites:

No exemplo da Tabela 4 todos os geradores, isto é, os 10 geradores, encontram-se em um dos limites: G_{01} , G_{02} , G_{07} , G_{13} , G_{15} , G_{18} , G_{22} e G_{23} se encontram em seus limites superiores, e G_{16} e G_{21} se encontram em seus limites inferiores. Neste caso não é necessário que um gerador complete o balanço de potência com um valor diferente de seus valores limites, já que a soma destas gerações é igual a 8.550 MW, que corresponde ao valor da demanda total do sistema. Esta é uma particularidade que raramente ocorre quando se determinam os cenários extremos e factíveis.

Alguns cenários de geração, mesmo que sejam extremos, podem ser infactíveis porque não é possível cumprir a condição do balanço de potência ativa. Um exemplo de cenário de geração extremo e infactível é o caso em que todos os geradores se encontram em seu limite superior. Neste caso, a geração total programada resulta ser de 10.215 MW que é maior ao valor de demanda de 8.550 MW. Outro caso é quando os geradores são programados em seus limites inferiores. Neste caso, a geração total é 0 MW e a demanda 8.550 MW. Outros casos intermediários também são infactíveis.

4.2.4 Modelagem do Problema de Planejamento de Sistemas de Transmissão considerando p cenários de geração

A modelagem matemática do problema de planejamento estático de sistemas de transmissão considerando p cenários de geração no sistema e usando o modelo DC, assume a seguinte forma:

$$\begin{aligned}
 \text{Min } v = & \sum_{(i,j) \in \Omega_0} c_{ij} n_{ij} + \sum_{q=1}^p \sum_{i \in \Gamma} \alpha_i r_i^q \\
 \text{s.a. } & \\
 & S f^q + g^q + r^q = d \\
 & f_{ij}^q - \gamma_{ij} (n_{ij}^o + n_{ij}) (\theta_i^q - \theta_j^q) = 0 \\
 & |f_{ij}^q| \leq (n_{ij}^o + n_{ij}) \bar{f}_{ij} \\
 & \underline{g}_k^q \leq g_k^q \leq \bar{g}_k^q \quad (4.4) \\
 & g_i^q = \bar{g}_i \quad \forall i \in \Omega_1^q \quad (4.5) \\
 & g_j^q = \underline{g}_j \quad \forall j \in \Omega_2^q \quad (4.6) \\
 & 0 \leq r_i^q \leq d_i \\
 & 0 \leq n_{ij} \leq \bar{n}_{ij} \\
 & n_{ij} \text{ inteiro}; \quad \theta_j \text{ ilimitado} \\
 & (i, j) \in \Omega_0
 \end{aligned}$$

Onde f_{ij}^q , θ_i^q , g_i^q e r_i^q representam as variáveis de operação para o cenário de geração q dos p cenários extremos e factíveis de geração; Ω_1^q é o conjunto de geradores que se encontram no limite superior para o cenário de geração q ; Ω_2^q é o conjunto de geradores que se encontram no limite inferior para o cenário de geração q ; r_i^q representa o corte de carga na barra i e no cenário de geração q ; e Γ é o conjunto de barras de carga.

As restrições (4.4), (4.5) e (4.6) são definidas para cada cenário de geração extremo factível. As variáveis r_i^q permitem que o problema possa ser resolvido usando técnicas de otimização metaheurísticas, e α_i é um parâmetro de penalidade que penaliza, na função objetivo, qualquer corte de carga que apresente uma proposta de solução em algum cenário de geração. Este parâmetro é ajustado para que as soluções finais de grande qualidade não apresentem corte de carga. Isso significa que qualquer proposta de solução que tenha corte de carga, mesmo que seja pequeno, não será atrativa para o método de solução.

A grande diferença entre esta formulação e a formulação do planejamento básico ou tra-

dicional é que, agora, a geração é fixa e associada a p cenários extremos e factíveis, e que os p cenários de geração devem ser testados em cada proposta de expansão. Isso significa que, para cada plano de expansão candidato devem-se resolver p subproblemas de operação, que neste caso representam problemas de fluxo de carga DC ou problemas de programação linear. Em consequência, o número de variáveis de operação ($f_{ij}, \theta_i, g_i, r_i$) se incrementam p vezes, e as variáveis de operação associadas a um determinado cenário de geração ($f_{ij}^q, \theta_i^q, g_i^q, r_i^q$) se encontram relacionadas com as variáveis de operação dos outros cenários através das variáveis de investimento. O número de variáveis de investimento não muda com relação a modelagem básica. A modelagem matemática do problema de planejamento estático de sistemas de transmissão considerando p cenários de geração no sistema e usando o modelo DC, pode ser resolvido usando técnicas de otimização exatas ou técnicas de otimização metaheurísticas. Dadas as características do problema (não linear, variáveis inteiras e contínuas, e explosão combinatória de soluções candidatas) as técnicas metaheurísticas resultam mais eficientes que as exatas.

Neste trabalho, o problema de planejamento da expansão, considerando múltiplos cenários de geração, resolve-se usando um algoritmo genético que usa as idéias básicas do algoritmo proposto por Chu-Beasley (CBGA), e que foi apresentado na seção 3.3.2, com algumas especializações associadas ao problema de planejamento da expansão considerando múltiplos cenários de geração.

Quando é usada uma técnica metaheurística para resolver este problema, as variáveis n_{ij} assumem valores preestabelecidos: n_{ij}^t , e a modelagem matemática com valores fixos de n_{ij} pode-se separar em p problemas independentes. Cada problema q apresenta a seguinte forma:

$$\text{Min } w^q = \sum_{i \in \Gamma} \alpha_i r_i^q \quad (4.7)$$

s.a.

$$Sf^q + g^q + r^q = d \quad (4.8)$$

$$f_{ij}^q - \gamma_{ij}(n_{ij}^o + n_{ij}^t)(\theta_i^q - \theta_j^q) = 0 \quad (4.9)$$

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

$$\underline{g}_k \leq g_k^q \leq \bar{g}_k \quad (4.10)$$

$$g_i^q = \bar{g}_i \quad \forall i \in \Omega_1^q \quad (4.11)$$

$$g_j^q = \underline{g}_j \quad \forall j \in \Omega_2^q \quad (4.12)$$

$$0 \leq r_i^q \leq d_i \quad \forall i \in \Gamma \quad (4.13)$$

$$\theta_j^q \text{ ilimitado}$$

$$f_{ij}^q \text{ ilimitado } \forall (i, j) \in \Omega_0$$

onde w^q é o corte de carga para o plano de geração q . Cada um dos p problemas tem a mesma estrutura e somente o cenário de geração é diferente entre um problema e outro. Esta modelagem pode ser resolvida para cada cenário extremo e factível de geração de forma independente.

Uma boa solução para o problema de planejamento livre de congestionamento, não deve apresentar corte de carga para nenhum cenário extremo e factível de geração. Quando não aparece corte de carga, toda a demanda é atendida. O parâmetro α_i deve-se ajustar para que uma solução com corte de carga resulte economicamente inviável. Em consequência, é necessário ajustar os valores de α_i para que os $r^q = 0$ em todas as barras do sistema ao final do processo de otimização.

Inicialmente, o problema de planejamento com múltiplos cenários de geração é resolvido usando técnicas de solução mono-objetivo. Posteriormente, o problema é resolvido usando um enfoque multiobjetivo. A seguir explicam-se o método de solução e os resultados obtidos.

4.3 Técnica de resolução

O algoritmo genético CBGA apresentado na seção 3.3.2 com pequenas modificações, é usado para resolver o problema de planejamento da expansão de sistemas de transmissão considerando múltiplos cenários de geração. A seguir são apresentadas as características do algoritmo CBGA aplicado neste problema:

- A população inicial é a mesma população usada para o problema de planejamento da expansão tradicional.
- Deve-se determinar o número de cenários de geração extremos e factíveis do problema antes de aplicar o algoritmo CBGA.
- Para cada plano de expansão candidato, o número de cenários de geração elétrica é igual ao número q de cenários extremos factíveis do sistema e, para cada um destes cenários, é necessário resolver um problema de programação linear que determina o corte de carga (congestionamento parcial) que a proposta de investimento produz. Isto significa que, para cada solução candidata devem-se resolver q problemas de PL para determinar o congestionamento possível total (infactibilidade) associado na solução. Em consequência, a função de aptidão (*fitness*) é calculada da mesma forma e com o mesmo nível de complexidade que no problema com desplanificação. A função *unfitness* se determina resolvendo q problemas de PL, isto é, resolvendo q problemas de programação linear em lugar de um PL como no caso de desplanificação.

- Para construir uma métrica de congestionamento que agrupe os q cenários, os cortes de carga associados aos cenários de geração extremos factíveis individuais podem ser somados simplesmente ou pode-se calcular uma soma ponderada destes cortes de carga usando a probabilidade de ocorrência de cada cenário, ou pode-se considerar somente o maior valor de corte de carga nos cenários. A função *unfitness* deve-se definir dependendo da forma selecionada para construir esta métrica. Nesta tese usa-se a primeira e a terceira opção.
- O processo de seleção por torneio, recombinação e mutação controlada, são similares aos usados no problema considerando desplanificação.
- A etapa de melhoria local da solução somente considera a retirada das linhas desnecessárias usando o procedimento proposto na seção 3.3.2.7.
- A etapa de substituição de um descendente usa o procedimento proposto na seção 3.3.2.8.

4.4 Testes e resultados usando a nova modelagem matemática

Para mostrar o desempenho e os resultados da nova modelagem matemática considerando todos os cenários extremos e factíveis, usamos o sistema Garver de 6 barras e o sistema de 24 barras da IEEE. Os dados destes sistemas são apresentados nas seções A.1 e A.2 do Apêndice A.

4.4.1 Sistema Garver de 6 barras

Este sistema tem 6 barras, 15 caminhos de adição de linhas de transmissão, demanda de 760 MW e capacidade de geração de 1.110 MW. Os dados de barras e de ramos deste sistema são apresentados na seção A.1 do Apêndice A. O algoritmo CBGA usado para resolver o problema matemático resultante usa uma população de sessenta indivíduos, seleção de parentes por torneio com $k = 3$ indivíduos participantes por torneio, taxa de mutação do 2%, mutação controlada por corte de carga acumulado e recombinação de um ponto.

O sistema Garver de 6 barras tem três geradores, em consequência tem $2^{3-1} \times 3 = 12$ cenários extremos factíveis candidatos. Destes 12 possíveis cenários, somente quatro são cenários extremos e factíveis, em consequência somente quatro cenários satisfazem as restrições (4.2) e (4.3). A Tabela 5 mostra estes quatro cenários, os quais atendem á demanda total de 760 MW, e para os quais as propostas de planejamento não devem apresentar corte de carga.

Tabela 5: Cenários extremos factíveis do sistema Garver.

Cenário	Geração (MW)		
	Barra 1	Barra 3	Barra 6
1	0	160	600
2	150	10	600
3	0	360	400
4	150	360	250

Neste caso, a melhor solução que encontra o algoritmo CBGA é um plano de expansão com um investimento de US\$ 268×10^3 , sendo necessária a construção dos seguintes elementos de transmissão: $n_{02-06} = 4$, $n_{03-05} = 2$, $n_{03-06} = 1$, $n_{04-06} = 2$.

4.4.2 Sistema IEEE de 24 barras

Este sistema, já utilizado no capítulo anterior, tem 24 barras, 41 caminhos de adição de linhas de transmissão, demanda de 8.550 MW, capacidade de geração de 10.215 MW e a possibilidade de adicionar até 3 elementos de transmissão em cada caminho candidato. Os dados de barras e de ramos deste sistema são apresentados na seção A.2 do Apêndice A. O algoritmo CBGA usado para resolver o problema matemático resultante usa uma população de setenta indivíduos, seleção de parentes por torneio com $k = 4$ indivíduos participantes por torneio, taxa de mutação do 2%, mutação controlada por corte de carga acumulado e recombinação de um ponto.

O sistema IEEE de 24 barras tem 10 geradores, em consequência tem $2^{10-1} \times 10 = 5.012$ cenários extremos e factíveis candidatos. Destes 5.012 possíveis cenários, somente 178 são cenários extremos e factíveis, em consequência somente 178 cenários satisfazem as restrições (4.2) e (4.3).

Para que uma proposta de investimento seja aceitável para este sistema, o plano de expansão deve ser de custo mínimo e, além disso, não deve apresentar corte de carga em nenhum dos 178 cenários de geração extremos e factíveis. Os cenários de geração resultantes são apresentados no Apêndice B. Obviamente o esforço computacional é muito maior que o de planejamento tradicional, já que cada configuração candidata deve-se valorar para cada um destes cenários.

A melhor solução que encontra o algoritmo CBGA tem um custo de US\$ $1,330.00 \times 10^6$, usando uma população do setenta indivíduos, taxa de mutação do 2%, seleção por torneio com quatro indivíduos participando por torneio. Uma característica deste problema é que apresenta sete soluções ótimas alternativas com o mesmo valor de investimento e diferentes planos de

expansão. Na seqüência são apresentadas estas configurações.

Ótimo alternativo 1:

$$\begin{aligned} n_{01-02} = 1, n_{01-05} = 1, n_{03-24} = 1, n_{04-09} = 1, n_{05-10} = 2, n_{06-10} = 2, n_{07-08} = 2, \\ n_{08-09} = 2, n_{08-10} = 1, n_{09-12} = 1, n_{10-11} = 2, n_{10-12} = 1, n_{11-13} = 1, n_{11-14} = 1, \\ n_{12-23} = 1, n_{14-16} = 2, n_{15-21} = 1, n_{15-24} = 1, n_{16-17} = 2, n_{16-19} = 1, n_{17-18} = 1, \\ n_{20-23} = 1, n_{21-22} = 1, n_{01-08} = 1. \end{aligned}$$

Ótimo alternativo 2:

$$\begin{aligned} n_{01-02} = 1, n_{01-05} = 1, n_{03-24} = 1, n_{04-09} = 1, n_{05-10} = 2, n_{06-10} = 2, n_{07-08} = 2, \\ n_{08-09} = 2, n_{08-10} = 1, n_{09-12} = 1, n_{10-11} = 1, n_{10-12} = 2, n_{11-14} = 1, n_{12-13} = 1, \\ n_{12-23} = 1, n_{14-16} = 2, n_{15-21} = 1, n_{15-24} = 1, n_{16-17} = 2, n_{16-19} = 1, n_{17-18} = 1, \\ n_{20-23} = 1, n_{21-22} = 1, n_{01-08} = 1. \end{aligned}$$

Ótimo alternativo 3:

$$\begin{aligned} n_{01-02} = 1, n_{01-05} = 1, n_{03-24} = 1, n_{04-09} = 1, n_{05-10} = 2, n_{06-10} = 2, n_{07-08} = 2, \\ n_{08-09} = 1, n_{08-10} = 2, n_{09-11} = 1, n_{10-11} = 1, n_{10-12} = 2, n_{11-13} = 1, n_{11-14} = 1, \\ n_{12-23} = 1, n_{14-16} = 2, n_{15-21} = 1, n_{15-24} = 1, n_{16-17} = 2, n_{16-19} = 1, n_{17-18} = 1, \\ n_{20-23} = 1, n_{21-22} = 1, n_{01-08} = 1. \end{aligned}$$

Ótimo alternativo 4:

$$\begin{aligned} n_{01-02} = 1, n_{01-05} = 1, n_{03-24} = 1, n_{04-09} = 1, n_{05-10} = 2, n_{06-10} = 2, n_{07-08} = 2, \\ n_{08-09} = 1, n_{08-10} = 2, n_{09-12} = 1, n_{10-11} = 1, n_{10-12} = 2, n_{11-14} = 1, n_{12-13} = 1, \\ n_{12-23} = 1, n_{14-16} = 2, n_{15-21} = 1, n_{15-24} = 1, n_{16-17} = 2, n_{16-19} = 1, n_{17-18} = 1, \\ n_{20-23} = 1, n_{21-22} = 1, n_{01-08} = 1. \end{aligned}$$

Ótimo alternativo 5:

$$\begin{aligned} n_{01-02} = 1, n_{01-05} = 1, n_{03-24} = 1, n_{04-09} = 1, n_{05-10} = 2, n_{06-10} = 2, n_{07-08} = 2, \\ n_{08-09} = 2, n_{08-10} = 1, n_{09-11} = 1, n_{10-11} = 1, n_{10-12} = 2, n_{11-13} = 1, n_{11-14} = 1, \\ n_{12-23} = 1, n_{14-16} = 2, n_{15-21} = 1, n_{15-24} = 1, n_{16-17} = 2, n_{16-19} = 1, n_{17-18} = 1, \\ n_{20-23} = 1, n_{21-22} = 1, n_{01-08} = 1. \end{aligned}$$

Ótimo alternativo 6:

$$\begin{aligned}
n_{01-02} &= 1, n_{01-05} = 1, n_{03-24} = 1, n_{04-09} = 1, n_{05-10} = 2, n_{06-10} = 2, n_{07-08} = 2, \\
n_{08-09} &= 1, n_{08-10} = 2, n_{09-12} = 1, n_{10-11} = 2, n_{10-12} = 1, n_{11-13} = 1, n_{11-14} = 1, \\
n_{12-23} &= 1, n_{14-16} = 2, n_{15-21} = 1, n_{15-24} = 1, n_{16-17} = 2, n_{16-19} = 1, n_{17-18} = 1, \\
n_{20-23} &= 1, n_{21-22} = 1, n_{01-08} = 1.
\end{aligned}$$

Ótimo alternativo 7:

$$\begin{aligned}
n_{01-02} &= 1, n_{03-24} = 1, n_{04-09} = 1, n_{05-10} = 1, n_{06-10} = 2, n_{07-08} = 2, n_{08-09} = 1, \\
n_{08-10} &= 2, n_{09-11} = 1, n_{10-11} = 1, n_{10-12} = 2, n_{11-13} = 1, n_{11-14} = 1, n_{12-23} = 1, \\
n_{14-16} &= 2, n_{15-16} = 2, n_{15-21} = 1, n_{15-24} = 1, n_{16-17} = 1, n_{16-19} = 1, n_{17-18} = 1, \\
n_{20-23} &= 1, n_{21-22} = 1, n_{01-08} = 1, n_{02-08} = 1.
\end{aligned}$$

É interessante observar que apesar de existir um número grande de ótimos alternativos não existe uma melhor solução para este problema. A seguir é apresentada a curva de desempenho do algoritmo CBGA para o sistema IEEE de 24 barras considerando múltiplos cenários de geração. A Figura 13 mostra que o algoritmo alcança a solução de 1.330 milhões de dólares em 664 ciclos ou gerações e 556.962 PLs. O tempo de cálculo é de 44 minutos.

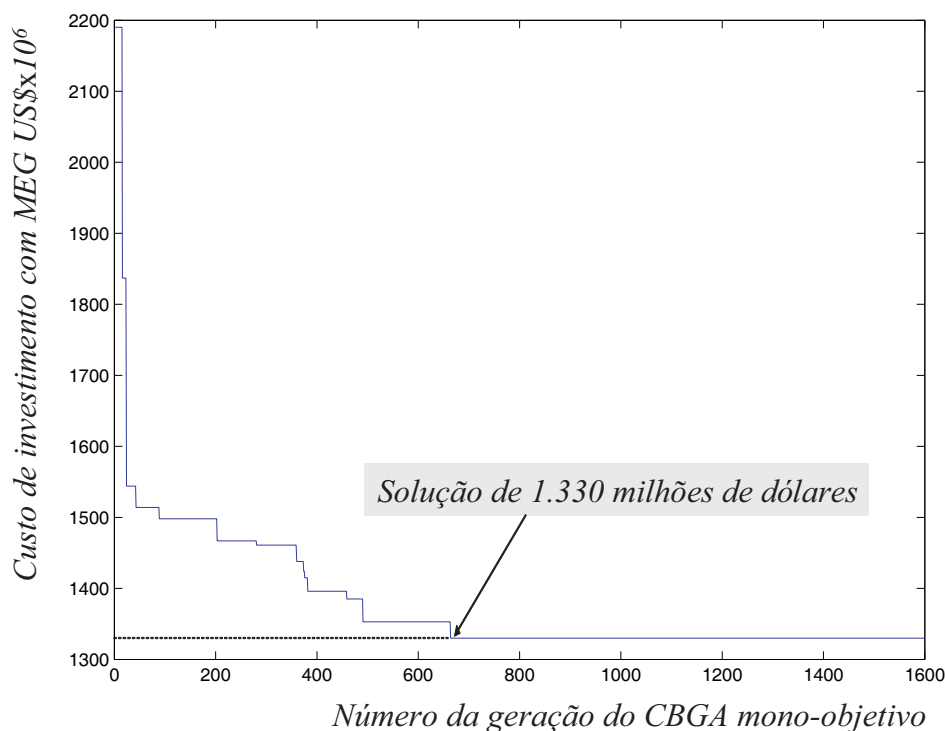


Figura 13: Curva de desempenho do algoritmo CBGA para o sistema IEEE de 24 barras considerando múltiplos cenários de geração.

Outras soluções sub-ótimas próximas da solução de 1.330 milhões de dólares são apresentadas

a seguir:

Sub-ótimo de US\$ 1333 milhões de dólares:

$$\begin{aligned} n_{01-02} = 2, n_{01-05} = 1, n_{03-24} = 1, n_{04-09} = 1, n_{05-10} = 2, n_{06-10} = 2, n_{07-08} = 2, \\ n_{08-09} = 2, n_{08-10} = 1, n_{09-12} = 1, n_{10-11} = 2, n_{10-12} = 1, n_{11-13} = 1, n_{11-14} = 1, \\ n_{12-23} = 1, n_{14-16} = 2, n_{15-21} = 1, n_{15-24} = 1, n_{16-17} = 2, n_{16-19} = 1, n_{17-18} = 1, \\ n_{20-23} = 1, n_{21-22} = 1, n_{01-08} = 1. \end{aligned}$$

Sub-ótimo de US\$ 1345 milhões de dólares:

$$\begin{aligned} n_{01-02} = 2, n_{01-03} = 1, n_{03-24} = 2, n_{04-09} = 1, n_{05-10} = 1, n_{06-10} = 2, n_{07-08} = 2, \\ n_{08-10} = 3, n_{10-11} = 2, n_{10-12} = 2, n_{11-13} = 1, n_{12-23} = 1, n_{14-16} = 2, n_{15-16} = 2, \\ n_{15-21} = 1, n_{15-24} = 1, n_{16-17} = 1, n_{16-19} = 1, n_{17-18} = 1, n_{20-23} = 1, n_{21-22} = 1, \\ n_{02-08} = 1. \end{aligned}$$

4.4.3 Prova da conjectura para o sistema IEEE de 24 barras

Uma vez obtida a solução de custo mínimo que não apresenta corte de carga para nenhum cenário extremo e factível, é necessário desenvolver uma proposta para provar a conjectura que afirma que: *se um sistema for expandido de forma que opere adequadamente (sem congestionamento ou corte de carga) para todos os planos extremos e factíveis de geração, então esse sistema expandido também opera de forma adequada para qualquer plano de geração factível.* Para isto, deve-se gerar um número grande e aleatório de cenários não extremos e factíveis e mostrar que em nenhum deles aparece corte de carga. Estes cenários devem ser gerados usando uma distribuição estatística uniforme para garantir que o espaço de cenários é adequadamente explorado. Usando o método de simulação de Monte-Carlo podem-se gerar os possíveis estados que produzem congestionamento.

O processo usado neste trabalho para gerar cenários factíveis e testar a conjectura, é o seguinte:

- Gerar um número aleatório para cada usina de geração que tenha o sistema. Uma probabilidade de distribuição uniforme é usada para gerar os números aleatórios, os quais assumem valores no intervalo [0,1].
- Cada número aleatório é multiplicado pelo valor do limite superior do gerador para ga-

rantir que a potência programada se encontre entre os valores possíveis de geração da usina. Para os sistemas teste usados nesta tese, este procedimento é suficiente, já que os limites inferiores de todas as usinas é zero.

- Para garantir o balanço de potência ativa entre geração e demanda no sistema elétrico, se aplica um passo de correção, o qual multiplica os primeiros $n - 1$ valores de geração programada por um fator proporcional ao quociente entre a demanda (fixa) e a geração total obtida aleatoriamente, sempre que não supere os limites de operação das usinas. O gerador n completa a potência demandada. Um subconjunto dos cenários não extremos e factíveis gerados é armazenado para verificar que os cenários se encontram adequadamente distribuídos no espaço de soluções factíveis, isto significa que os cenários gerados devem representar adequadamente aos infinitos cenários factíveis que podem ser programados no sistema.

Para determinar estatisticamente se o número de cenários não extremos gerados durante o processo de simulação é suficiente, é imperativo estabelecer o tamanho da população ou amostra que é necessária. Este tamanho deve ser definido de tal forma que permita supor que ao incrementar o número de casos, isto não deve mudar significativamente a inferência estatística. Existem basicamente dois critérios que podem ser usados:

- Gerar um número suficientemente grande de cenários não extremos. Neste caso fixa-se o número de simulações.
- Usar critérios que determinem a estabilidade da simulação, como o coeficiente de variação da média.

No problema IEEE de 24 barras, foram gerados inicialmente 4 milhões de cenários factíveis para testar a solução de 1.330 milhões de dólares apresentado como ótimo alternativo 1. Este valor pode ser grande, mas para conhecer o valor adequado é necessário usar algum critério estatístico. Também foi usado o chamado coeficiente de variação da média.

Coeficiente de variação da média: É uma medida da dispersão para um conjunto de dados, definida como o quociente entre o desvio-padrão amostral e a média amostral. O coeficiente de variação da média permite comparar o grau de variação de uma série de dados com respeito a outra série de dados. Desta forma, o processo de simulação pode ser terminado quando este coeficiente de variação se estabiliza. Matematicamente, o coeficiente de variação da média é definido como:

$$CV = \frac{S}{\sqrt{g^k}} \quad (4.14)$$

Onde o numerador do CV (S) é equivalente a:

$$S = \sqrt{\frac{\sum_{i=1}^N (g_i^k - \bar{g}^k)^2}{N}}$$

Na expressão anterior, N é o total de simulações realizadas, g_i^k é o valor aleatório gerado para a usina k na simulação i , e \bar{g}^k é o valor médio dos valores gerados durante as N simulações para a usina k .

Quando o valor CV se estabiliza para todos os geradores, o valor de N indica que o número de simulações é suficiente. Para encontrar o valor adequado de N , realizam-se vários experimentos para diferentes valores de N preestabelecidos. O processo de simulação para o sistema IEEE de 24 barras mostra que a partir de 120.000 simulações o critério do coeficiente de variação da média é satisfeito. Em consequência, 4 milhões de simulações pode ser considerado um número grande de cenários para a simulação.

Os resultados das simulações mostram que em nenhum dos 4 milhões de cenários não-extremos, gerados aleatoriamente e com distribuição uniforme, aparece corte de carga. Isto permite provar a conjectura para o sistema teste IEEE de 24 barras e afirmar que o plano de expansão da transmissão obtido considerando os 178 cenários extremos e factíveis, não apresenta congestionamento em nenhum cenário factível de geração que possa ser programado neste sistema.

Na Tabela 6 são mostrados alguns cenários factíveis não-extremos gerados durante o processo de simulação, e que não produz congestionamento nos planos de expansão de 1.330 milhões de dólares.

Na Tabela 6 pode-se observar que o primeiro cenário não-extremo programa as gerações nos seguintes valores: $G_{01} = 575,8$, $G_{02} = 562,0$, $G_{07} = 884,7$, $G_{13} = 1770,5$, $G_{15} = 631,0$, $G_{16} = 455,9$, $G_{18} = 885,1$, $G_{21} = 338,0$, $G_{22} = 468,5$ e $G_{23} = 1.978,5$. A somatória das gerações é igual a 8.550 MW (a demanda total) e nenhum dos valores programados se encontram nos limites. Ao resolver o problema operacional com estas gerações, não aparecem sobrecargas nos circuitos e toda a carga é atendida. O mesmo ocorre com os demais

Tabela 6: Cenários não extremos e factíveis gerados aleatoriamente para o sistema IEEE24.

Número da Barra de Geração:									
G_{01}	G_{02}	G_{07}	G_{13}	G_{15}	G_{16}	G_{18}	G_{21}	G_{22}	G_{23}
575,8	562,0	884,7	1770,5	631,0	455,9	885,1	338,0	468,5	1978,5
228,9	347,2	843,7	1456,8	632,5	456,8	953,5	982,9	861,3	1786,4
536,6	515,2	847,3	1563,7	643,7	379,0	1038,7	192,3	873,0	1960,6
147,5	85,8	693,5	1692,9	611,6	379,5	1198,6	1082,3	812,8	1845,5
395,6	407,2	728,5	1331,9	604,4	385,6	1103,7	1026,4	804,1	1762,7
552,5	426,6	11,6	1648,2	507,3	393,3	1194,6	1041,5	899,7	1874,7
492,9	555,2	876,4	1622,9	543,1	451,6	1127,7	551,5	754,7	1574,0
78,2	513,6	671,8	1765,2	582,5	462,8	1076,1	1193,1	247,2	1959,6
570,9	575,7	893,1	1765,4	632,8	461,9	1186,5	1196,8	765,3	501,5
499,3	563,1	695,0	1770,0	499,0	3,2	1133,3	1133,5	391,5	1862,1
366,5	337,6	577,3	1748,2	636,1	445,9	1198,7	548,0	724,4	1967,2
522,9	441,0	842,4	1579,0	609,5	427,2	1086,3	1189,4	30,4	1821,9
503,1	13,0	876,5	1751,7	313,0	447,3	1147,5	785,8	761,1	1951,2
124,7	565,6	431,4	1400,8	562,6	334,4	1168,5	1132,7	849,4	1980,0
534,5	573,1	842,0	1176,0	51,2	460,3	1078,0	1128,3	730,9	1975,6
6,4	571,4	900,0	1772,4	645,0	420,0	1037,2	410,6	824,2	1962,8
570,9	575,7	893,1	1765,4	632,8	461,9	1186,5	1196,8	765,3	501,5
396,8	455,9	732,1	1760,3	542,8	462,6	295,6	1150,1	773,9	1979,9
556,5	501,5	878,5	1667,2	511,2	94,1	799,2	1025,4	600,4	1916,1
24,3	450,1	817,1	1723,0	634,9	66,8	1196,7	914,1	828,9	1894,2
562,9	540,6	895,8	331,5	619,7	449,9	1165,6	1190,1	872,8	1921,1

cenários da Tabela 6 e com os 4 milhões de cenários não-extremos gerados aleatoriamente e com distribuição uniforme.

A Figura 14 mostra a distribuição das gerações programadas aleatoriamente no espaço dos cenários de geração para G_{01} e G_{02} , cujos valores limites são $G_{01max} = 576$ MW e $G_{02max} = 576$ MW. Cada ponto corresponde aos valores de potência programada para estes geradores nos primeiros 300 cenários não-extremos. A linha que une os pontos de operação indica a ordem em que são gerados estes cenários. Pode-se ver que nos primeiros 300 cenários existe já uma tendência a ocupar toda a região, e que a maior porcentagem de casos se encontra perto da região onde os geradores são programados nos limites superiores. Esta tendência tem uma explicação lógica: a demanda total é de 8.550 MW e a geração total (soma de todas as capacidades de geração) é de 10.215 MW. Em porcentagem, o excedente de geração corresponde ao 19,47 % da demanda total ou 1.665 MW. Isto significa que o 80,53 % da geração disponível deve ser programada sempre, o que obriga aos geradores a ter uma geração alta na maioria das vezes.

Outra particularidade para este sistema é que alguns geradores não podem ser programados

simultaneamente perto do limite inferior porque produzem cenários infactíveis. Por exemplo, se G_{22} e G_{23} são programados com 0 MW, é eliminada uma capacidade de geração de 900 MW + 1.980 MW = 2.880 MW. Sem esta capacidade os demais geradores somente podem atender 7.335 MW, o que resulta insuficiente para fornecer a demanda total de 8.550 MW. A Figura 15 mostra o espaço factível para estes geradores, para os primeiros 300 cenários gerados dos 120.000 que tem de ser gerados. Pode-se observar a tendência do método, usado para produzir cenários não-extremos, de gerar alternativas em todo o espaço factível.




Figura 14: Distribuição das gerações de G_{01} e G_{02} no espaço dos cenários de geração.

4.5 Conclusões parciais

- Os testes mostram que é possível realizar planeamento da expansão de sistemas de transmissão de energia eléctrica de tal forma que o sistema futuro não apresente congestionamento em nenhum cenário factível de geração, e que o número infinito de cenários possíveis que existem podem ser adequadamente representados por um número finito e reduzido de cenários factíveis.
- Pode ser observado que existe uma grande diferença entre o custo de investimento entregue pelos dois modelos de planeamento: a modelagem tradicional e a modelagem com múltiplos cenários de geração. A modelagem tradicional encontra uma solução de 152 milhões de dólares, e a modelagem com múltiplos cenários de geração encontra uma

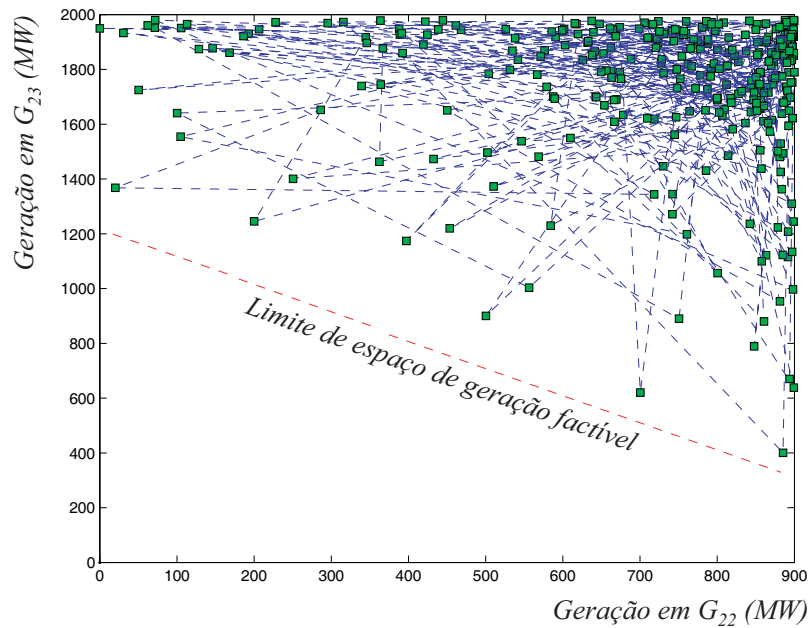


Figura 15: Distribuição das gerações de G_{22} e G_{23} no espaço dos cenários de geração.

solução de 1.330 milhões de dólares, quando são considerados os 178 cenários extremos e factíveis de geração. Estes valores somente representam custo de investimento, não incluindo o custo operacional.

- A diferença entre o planejamento tradicional e o planejamento livre de congestionamento indica que devemos fazer um grande esforço de investimento para ter um sistema eficiente do ponto de vista do mercado. No caso do sistema IEEE de 24 barras pode-se afirmar que o sistema obtido com planejamento tradicional não apresenta uma boa adequação para condições de mercado.

5 *Otimização Multiobjetivo*

5.1 Introdução

A otimização combinatória é uma disciplina de tomada de decisões no caso de problemas discretos que pode ser encontrada em diversas áreas, tais como, problemas de planejamento e programação (*scheduling*) da produção, problemas de planejamento da expansão de sistemas de transmissão ou geração de energia elétrica, problemas de corte e empacotamento, planejamento e operação de redes de telecomunicação, planejamento e operação de sistemas de distribuição de energia elétrica, problemas de localização, planejamento de rotas de transporte, dentre outras. Em muitos destes problemas surgem freqüentemente vários critérios de desempenho (funções objetivos), em geral, conflitantes entre si. Por exemplo, existem três objetivos básicos na programação de tarefas (*jobs*) na produção. O primeiro objetivo está relacionado com datas de entrega das tarefas: basicamente, não se deseja atraso em relação a estas datas, e quando o custo de estoque é relevante, tenta-se evitar que as tarefas sejam finalizadas muito antes destas datas. O segundo objetivo está relacionado com o tempo de fluxo de tarefas: deseja-se que esse tempo seja curto, ou equivalentemente, que o estoque em processamento seja baixo. O terceiro objetivo envolve a utilização dos centros de trabalho: deseja-se maximizar a utilização de equipamentos e de mão de obra. No entanto, estes objetivos são, em geral, conflitantes e o decisor deve optar por uma solução que pondere os objetivos globais. Objetivos conflitantes são mais a regra do que a exceção em diversos problemas do mundo real e a otimização multiobjetivo ou multicritério é utilizada para tratar essas situações.

Os problemas multiobjetivo distinguem-se dos problemas clássicos de otimização mono-objetivo quanto ao sentido que o conceito de solução do problema pode adquirir. Em geral, não existem soluções ótimas no sentido de minimizarem (ou maximizarem) individualmente todos os objetivos, já que é impossível melhorar um objetivo sem deteriorar algum outro. A característica principal de otimização multiobjetivo (quando todos os objetivos são de igual importância) é a existência de um conjunto grande de soluções ótimas que são superiores às demais. Estas soluções, que superam outras, são definidas no contexto da otimização multi-

objetivo como soluções não-dominadas ou soluções Pareto-ótimas. A escolha de uma solução eficiente particular depende das características próprias do problema e é atribuída ao decisor (*decision maker*). Até a década de 80, a maioria dos métodos de otimização foram propostos para a resolução de problemas de programação linear e não-linear. Métodos exatos propostos para resolver problemas de programação linear multiobjetivo, geralmente, usam métodos exatos de otimização mono-objetivo. As soluções Pareto-ótimas são obtidas resolvendo alguns problemas particulares, derivados do original, cujos ótimos globais correspondem às soluções Pareto-ótimas. Um exemplo típico é o método de escalarização das funções objetivos (ou das somas ponderadas) definido sobre o espaço das soluções factíveis do problema multiobjetivo original (WIERZBICK, 1986). Métodos deste tipo não são facilmente adaptados para resolver problemas de otimização combinatória multiobjetivo, pois estes problemas possuem um elevado grau de complexidade. Sabe-se que o problema de decisão associado aos muitos problemas de otimização combinatória mono-objetivo são NP-completos, isto é, eles não podem ser resolvidos através de algoritmos de tempo polinomial. A questão da complexidade computacional em problemas de otimização combinatória multiobjetivos envolve um outro componente relacionado com a contagem do número de soluções do problema de decisão associado (EHRGOTT, 2000). Este fator, obviamente, eleva o grau de intratabilidade de diversos problemas combinatórios.

Para gerar o conjunto das soluções Pareto-ótimas, vários problemas requerem algoritmos de tempos exponenciais, mesmo que a otimização isolada de alguns objetivos seja fácil. Assim, as técnicas metaheurísticas resultam ser as mais convenientes para tratar com esses problemas. Os métodos metaheurísticos podem ser implementados com muita flexibilidade para resolver problemas multiobjetivos de otimização combinatória e problemas de otimização não linear. Atualmente, estes métodos constituem uma das ferramentas mais ativas na pesquisa em otimização multiobjetivo. Neste contexto, resulta de fundamental importância, para os pesquisadores da área de planejamento da expansão dos sistemas de energia elétrica, a aplicação de uma ferramenta que encontre o conjunto de soluções não-dominadas e, a partir deste conjunto, determinar as soluções que melhor atendam as necessidades práticas nos setores de planejamento das empresas de energia elétrica para o problema otimização de redes de transmissão. Neste capítulo são descritos os principais conceitos envolvidos na solução e formulação de problemas de otimização multiobjetivo. Algumas técnicas de otimização que utilizam técnicas metaheurísticas para a solução de problemas multiobjetivo são brevemente revisadas. São apresentadas uma modelagem matemática e uma metodologia de solução para resolver o problema de planejamento da expansão de sistemas de transmissão de energia elétrica, considerando múltiplos cenários de geração e um enfoque de solução multiobjetivo.

Os fundamentos matemáticos da otimização multiobjetivo tiveram origem no período compreendido entre 1895 e 1906. Durante este período, Georg Cantor e Felix Hausdorff sugeriram os fundamentos básicos dos espaços dimensionais infinitos. Cantor introduz as **classes de equivalência** e as condições suficientes para a existência de uma função de utilidade. Hausdorff apresentou as primeiras idéias sobre ordenamento. Em 1944, John Von Neumann e Oskar Morgenstern apresentam o problema de otimização no contexto da economia de intercambio como uma mistura peculiar e desconcertante de vários problemas em conflito que não podia ser em nenhum caso tratado com as ferramentas matemáticas clássicas. Entretanto, foi o conceito do **máximo do vetor**, introduzido por Harold W. Kuhn e Albert W. Tucker em 1951, que demonstrou o enfoque matemático da otimização multiobjetivo (CARRIJO, 2004). Segundo Osyczka (OSYCKA, 1984), um problema de otimização multiobjetivo (também chamando de otimização multicritério, multidesempenho ou otimização vetorial) tem por finalidade encontrar um vetor de variáveis de decisão que satisfaça as restrições e otimize uma função vetorial cujos elementos representam as funções objetivo. Estas funções formam uma descrição matemática dos critérios de desempenho que geralmente estão em conflito entre eles. Por outro lado, o termo *otimizar* significa encontrar uma solução que melhor represente a solução **ótima** de todas as funções objetivo.

Provavelmente uma das pesquisas mais importantes nestes anos foi o desenvolvimento da programação por metas (*goal programming*) introduzida por Abraham Charnes e William Wagner Cooper (1961). Nos anos 60 se consolidaram as bases da teoria multiobjetivo e esta foi tomada com seriedade pelos matemáticos. A generalização dos resultados de Kuhn e Tucker, realizada por Leonid Hurwicz sobre espaços vetoriais topológicos, foi fundamental neste processo.

A aplicação da teoria multiobjetivo em áreas diferentes da economia se iniciou com o trabalho de Koopmans (1951), e com a teoria de produção de Marglin (1967) sobre o planejamento do recurso hídrico. A primeira aplicação de engenharia reportada na literatura foi o artigo publicado por Zadeh em 1963. A generalização do desenvolvimento da teoria multiobjetivo se produz nos anos 70 (Stadler, Cohon e Marks). Por outro lado, a primeira aplicação real dos algoritmos evolutivos nos problemas multiobjetivo foi realizada em 1984 por David Shaffer em sua tese doutoral. Seu algoritmo chamado VEGA (*Vector-Evaluated Genetic Algorithm*) é uma modificação simples do algoritmo genético mono-objetivo básico, e mostra que os algoritmos genéticos podem ser usados para encontrar múltiplas soluções Pareto-ótimas em poucas iterações. Depois de realizadas muitas iterações, a população se aproxima às soluções ótimas individuais. Em 1989, Goldberg propõe o uso de um algoritmo evolutivo multiobjetivo (*Multiobjective Evolutionary Algorithm*, MOEA) que usa o conceito de dominância. A partir deste traba-

lho, aparecem outras propostas como as de Fonseca e Fleming (Algoritmo Genético Multiobjetivo, 1995), Srinivas e Deb (GA de ordenamento no dominado, *Non – Dominated Sorting GA* - NSGA, 1994) e Horn, Nafploitis e Goldberg (*Niched Pareto GA* - NPGA, 1994).

A definição apresentada para otimização multiobjetivo será formalizada posteriormente, mas antes são apresentados os conceitos de maior importância relacionados com este tipo de otimização e que são a base para entender os algoritmos empregados para resolver este tipo de problemas.

5.2 Definições básicas para otimização multiobjetivo

- **Variáveis de decisão:** As variáveis de decisão formam um conjunto de n parâmetros cujos valores representam uma solução (que pode ser válida ou não) para um problema de otimização. Estes parâmetros são representados por $x_j, j = 1, \dots, n$ e de forma compacta por x :

$$x = [x_1, x_2, \dots, x_n]^T \quad (5.1)$$

- **Restrições:** As restrições são funções das variáveis de decisão que delimitam o problema e validam as soluções. Desta forma, pode-se dizer que as restrições esboçam o contorno da região onde se encontra o conjunto de soluções factíveis do problema. Estas restrições podem ser tanto de igualdade (5.2) como de desigualdade (5.3).

$$h_i(x) = 0 \quad i = 1, 2, \dots, m \quad (5.2)$$

$$g_j(x) \leq 0 \quad j = 1, 2, \dots, l \quad (5.3)$$

$$x \in S \subseteq R^n$$

O número de restrições de igualdade (m) deve ser menor que o número de variáveis de decisão (n) para que o problema tenha solução.

- **Funções objetivos:** As funções objetivos são critérios de avaliação para determinar a qualidade de uma solução. Na otimização multiobjetivo existem duas ou mais funções objetivo ($f_1(x), f_2(x), \dots, f_k(x)$) em cada problema. As funções objetivos podem ser matematicamente representadas por um vetor objetivo Z como segue:

$$Z = [f_1(x), f_2(x), \dots, f_k(x)]^T \quad (5.4)$$

- **Ponto Ótimo:** É o ponto caracterizado pelo vetor $x^* = [x_1^*, x_2^*, \dots, x_n^*]^T$ formado pelas variáveis de decisão que otimizam as funções objetivo e satisfazem as restrições.
- **Valor Ótimo:** É o valor da função objetivo $f(x^*)$ no ponto ótimo.
- **Solução Ótima:** A solução ótima para cada função j é o par formado pelo ponto ótimo e o valor ótimo $(x^*, f_j(x^*))$.
- **Convexidade:**

Definição 1 Uma função $f : \mathfrak{R}^n \rightarrow \mathfrak{R}$ é uma função convexa se para duas soluções $x^{(1)}, x^{(2)} \in \mathfrak{R}^n$, no espaço solução, a seguinte condição é verdadeira:

$$f(\lambda x^{(1)} + (1 - \lambda)x^{(2)}) \leq \lambda f(x^{(1)}) + (1 - \lambda)f(x^{(2)}) \quad (5.5)$$

Para todos os $0 \leq \lambda \leq 1$.

Esta condição permite definir as seguintes propriedades para as funções convexas:

1. Uma aproximação linear de $f(x)$ em qualquer ponto do intervalo $[x^{(1)}, x^{(2)}]$ sempre subestima o verdadeiro valor da função.
2. A matriz Hessiana de $f(x)$ é definida positiva para todo x .
3. Para uma função convexa, um mínimo local é sempre um mínimo global.

Definição 2 Um problema de otimização multiobjetivo é convexo se todas as funções objetivo são convexas e a região factível é convexa.

A convexidade de um problema multiobjetivo é importante já que existem algoritmos que podem ter bom desempenho se esta condição é satisfeita, mas podem apresentar dificuldades se os problemas não são convexas.

5.3 Problema de otimização multiobjetivo

Um problema geral de otimização multiobjetivo consiste em encontrar um vetor de variáveis de decisão (solução) que satisfaça um conjunto de restrições de igualdade e/ou de desigualdade, e otimize uma função vetorial cujos elementos representam as funções objetivos. Estas funções representam os critérios de otimalidade que, usualmente, são conflitantes. Portanto, o termo *otimizar* significa encontrar soluções com todos os valores dos objetivos que não podem ser

melhorados simultaneamente. O problema de otimização multiobjetivo composto por um conjunto de n variáveis de decisão, k funções objetivo, m restrições de igualdade e l restrições de desigualdade, pode ser matematicamente definido da seguinte maneira:

$$\min Z = [f_1(x), f_2(x), \dots, f_k(x)]^T \quad (5.6)$$

s.a.

$$h_i(x) = 0 \quad i = 1, 2, \dots, m$$

$$g_j(x) \leq 0 \quad j = 1, 2, \dots, l$$

$$x \in S \subseteq R^n$$

$$x = [x_1, x_2, \dots, x_n]^T$$

$$Z = [z_1, z_2, \dots, z_k]^T; \quad k \geq 2$$

onde, x é o vetor decisão, Z é o vetor objetivo, S denota o espaço de decisões, e $Z = f(S)$ é a imagem de S denominada espaço objetivo.

Note que, a imagem de uma solução $x = (x_1, x_2, \dots, x_n) \in S$ no espaço objetivo é um ponto $Z = (z_1, z_2, \dots, z_k) = f(x)$, tal que $z_j = f_j(x)$, $j = 1, \dots, k$. Na Figura 16 (a) mostra-se o espaço objetivo factível do problema de minimização (5.6) com dois objetivos.




Figura 16: Dominância de Pareto no espaço objetivo.

A seguir, são apresentadas definições para problemas de minimização sendo que as definições para problemas de maximização são análogas.

- **Dominância de Pareto no espaço objetivo factível Z :**

Para quaisquer dois vetores objetivos $Z^1 = (z_1^1, z_2^1, \dots, z_k^1)$ e $Z^2 = (z_1^2, z_2^2, \dots, z_k^2)$ (pontos em Z) diz-se que:

1. Z^1 domina Z^2 se $Z^1 \leq Z^2$ e $Z^1 \neq Z^2$, isto é, $\forall j, z_j^1 \leq z_j^2$ e para algum $j, z_j^1 < z_j^2$.
2. Z^1 e Z^2 são *indiferentes* (ou possuem o mesmo grau de dominância) se Z^1 não domina Z^2 nem Z^2 domina Z^1 .

Na Figura 16 (b), o ponto A domina os pontos pertencentes ao retângulo superior direito I e H (subconjunto do espaço objetivo). Os pontos pertencentes ao retângulo inferior esquerdo (B, C, D) dominam o ponto A. Os pontos E, F e G são indiferentes.

• **Dominância de Pareto no Conjunto de Soluções Factíveis S :**

Para quaisquer duas soluções $x, y \in S$ diz-se que:

1. Dados dois vetores de decisão x e $y \in S$, então, a solução x *domina* a solução y (representada como $x \prec y$) se a imagem de x domina a imagem de y , isto é, $f(x) \leq f(y)$ e $f(x) \neq f(y)$. O anterior significa que as seguintes condições são satisfeitas:
 - a. A solução x não é pior que y em todos os objetivos;
 - b. A solução x é estritamente melhor que y pelo menos em um objetivo.
2. Dados dois vetores de decisão x e $y \in S$, então, a solução x *domina fracamente* a solução y (representada como $x \preceq y$) se a imagem de x domina fracamente a imagem de y , isto é, $f_i(x) \leq f_i(y), \forall i = 1, \dots, k$.
3. x é *indiferente* com y , isto quer dizer que são vetores de decisão não-dominados entre si, se $f(x) \not\leq f(y)$ e $f(y) \not\leq f(x)$, ou $f_i(x) \not\leq f_i(y), \forall i = 1, \dots, k$. Neste caso a condição de indiferente é representada como $x \sim y$.

É importante observar que apesar da dominância ser definida no espaço das variáveis de decisão, a comparação entre as duas soluções (x e y) é realizada no espaço das funções objetivo, ou seja, o critério de dominância é verificado utilizando-se os resultados da avaliação de cada um dos objetivos.

Quando o conjunto de soluções é finito, é possível comparar as soluções duas a duas e dividir o conjunto das variáveis de decisão em soluções dominadas e não-dominadas. As soluções não-dominadas ou Pareto-ótimas são definidas conforme a seguinte definição.

• **Otimalidade de Pareto:**

1. Diz-se que $x^* \in S$ é uma *solução eficiente* (ou *Pareto-ótima*) se não existe qualquer outra solução $x \in S$ tal que x domine x^* . $Z^* = f(x^*)$ é chamado de *ponto eficiente* ou ponto Pareto-ótimo.

2. O conjunto de todas as soluções eficientes é denominado *conjunto eficiente* (ou conjunto *Pareto-ótimo*).

É importante observar que existe uma diferença entre um *conjunto de soluções não-dominadas* e um *conjunto Pareto-ótimo*. Um conjunto de soluções não-dominadas é definido no contexto de uma amostra do espaço de busca factível S , enquanto o conjunto Pareto-ótimo é definido em relação a todo o espaço de busca.

- **Fronteira de Pareto**

A imagem em Z^* do conjunto Pareto-ótimo é denominada *fronteira Pareto-ótima*. Considere um problema de otimização multiobjetivo com um vetor de funções $f(x)$ e um conjunto Pareto-ótimo P . A fronteira de Pareto, PF (*ParetoFrontier*) define-se como uma curva composta por soluções não-dominadas em um espaço contínuo, quando o espaço de busca é o espaço completo de solução S . Na Figura 16 (a), mostra-se um exemplo da *fronteira Pareto-ótima*. Os pontos pertencentes a esta fronteira são os pontos Pareto-ótimos. Note que estes pontos são indiferentes uns aos outros, isto quer dizer que, uma solução de P não é dominada por nenhuma outra solução do conjunto P . Na Figura 17 são apresentados os conjuntos ótimos de Pareto para quatro diferentes cenários com dois objetivos e para o mesmo espaço de soluções. Cada objetivo pode ser minimizado ou maximizado. Em qualquer caso, a fronteira Pareto-ótima sempre está composta por soluções existentes no contorno da região factível dos objetivos.

- **Ponto ideal:**

Um ponto $Z^o = (z_1^o, z_2^o, \dots, z_k^o) \in Z$ tal que $z_j^o = \min \{f_j(x) : x \in S\}$, $j = 1, 2, \dots, k$ é chamado *ponto ideal* (ou *ponto utópico*).

Note que, se existe o ponto ideal, então o problema estaria resolvido. Obviamente esta situação é extremamente improvável se o problema envolve objetivos conflitantes.

Na otimização multiobjetivo quando não se conhece a importância de cada um dos objetivos, todas as soluções Pareto-ótimas são igualmente importantes. Em (DEB, 2001) encontram-se duas importantes metas na busca de soluções de problemas de otimização:

1. Encontrar um conjunto de soluções o mais próximo possível da fronteira de Pareto;
2. Encontrar um conjunto de soluções com a maior diversidade possível.

A primeira meta é comum para qualquer processo de otimização, pois soluções distantes da fronteira de Pareto não são desejáveis. A segunda meta é específica para a otimização multiobjetivo.

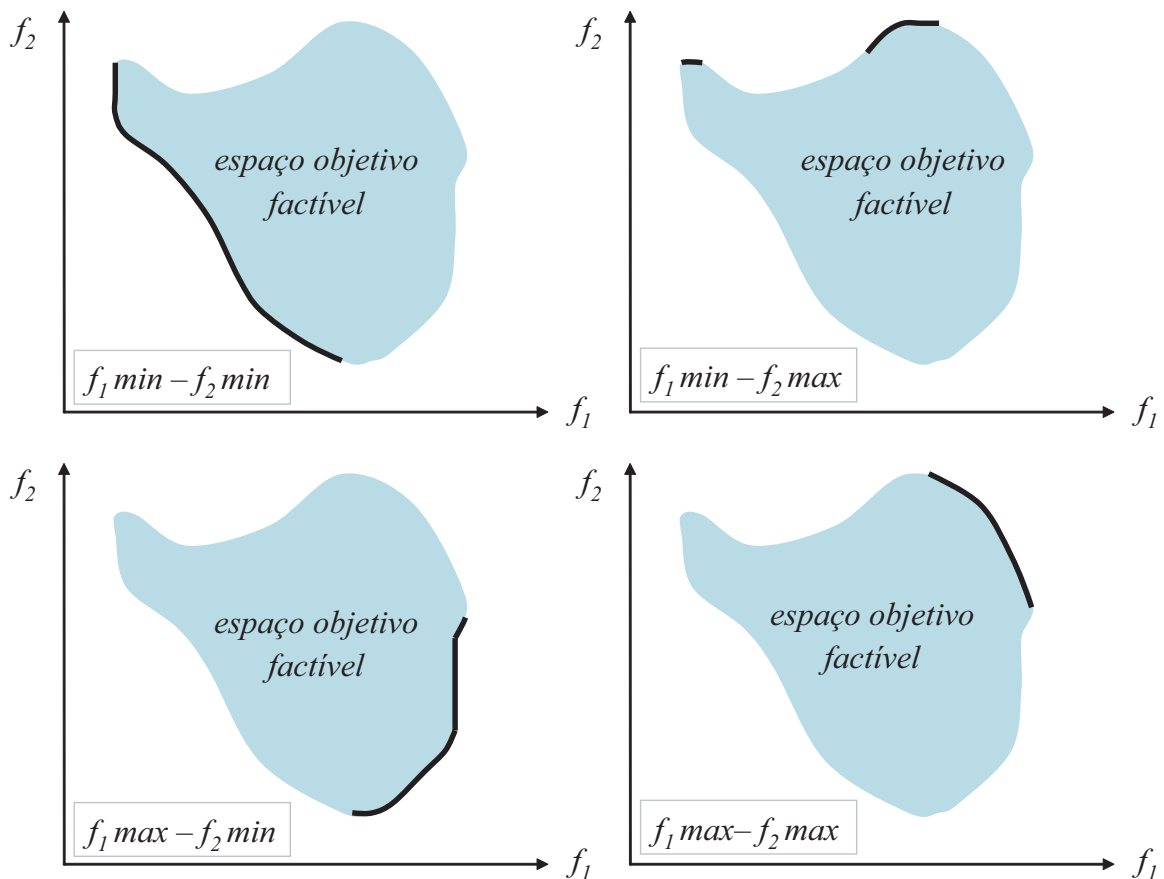


Figura 17: Fronteira Pareto-ótima para quatro diferentes cenários com dois objetivos e o mesmo espaço de soluções.

Como as soluções dos problemas de otimização multiobjetivo trabalham com os espaços das decisões e dos objetivos, é necessário assegurar a maior cobertura possível da fronteira Pareto-ótima. A diversidade das soluções na fronteira Pareto-ótima implica que o conjunto de soluções **comprometidas** é de boa qualidade em relação aos objetivos desejados. Na Figura 18 (a) ilustra-se uma boa distribuição das soluções na fronteira de Pareto, enquanto na Figura 18 (b) as soluções estão distribuídas apenas em algumas regiões.

Na Figura 19 ilustram-se as definições do problema de otimização multiobjetivo, considerando dois objetivos $(f_1(x), f_2(x))$ a serem minimizados. O ponto A apresenta um valor menor para $f_1(x)$, mas um valor maior para $f_2(x)$, se comparada com a solução do ponto B . Desta forma, a redução de uma função objetivo implica no aumento da outra e para delimitar a região Pareto-ótima utiliza-se o conceito de dominância. Os pontos pertencentes a fronteira Pareto-ótima são os pontos Pareto-ótimos. Analisando-se a Figura 19 pode-se observar que os pontos que constituem a fronteira Pareto-ótima são indiferentes uns com relação aos outros.

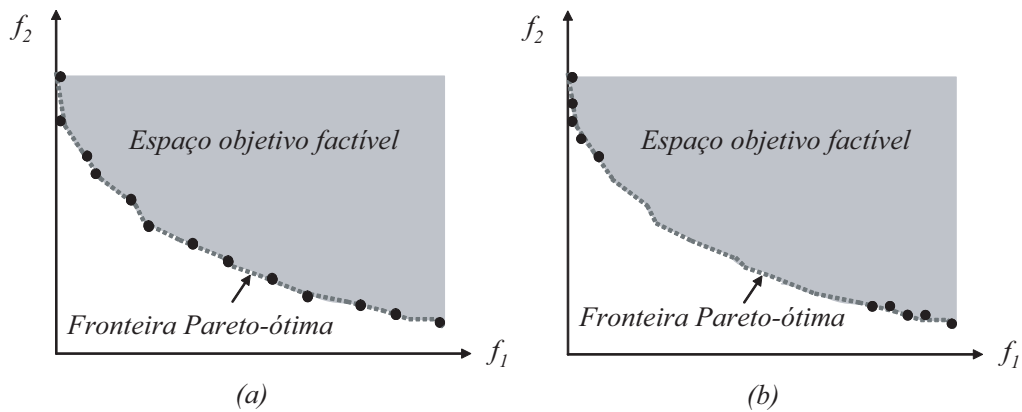


Figura 18: Distribuição das soluções na fronteira de Pareto.

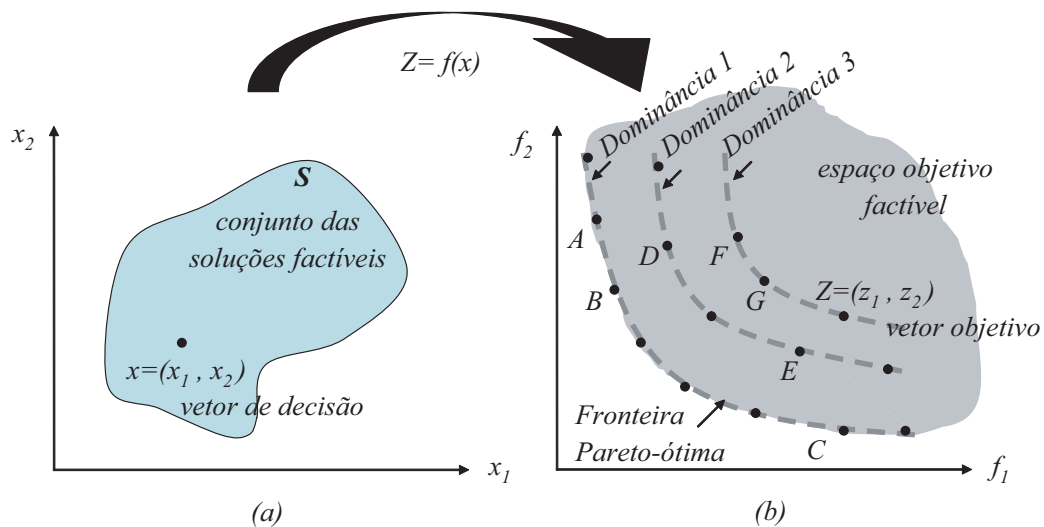


Figura 19: Ilustração das definições de um problema de otimização multiobjetivo.

• Níveis de não-dominância

Alguns métodos de otimização multiobjetivo somente procuram o melhor frente de Pareto não-dominado da população. Estes algoritmos classificam a população em dois conjuntos: o conjunto de soluções não-dominadas e o restante conjunto de soluções dominadas. Outros algoritmos classificam as soluções em vários níveis de soluções não-dominadas de acordo com a relação de dominância das soluções: F_1, F_2, \dots, F_k . Nestes casos, a população deve ser ordenada de acordo a seu nível de não-dominância F_i . Em cada conjunto F_i , todas as soluções são indiferentes (ou seja, nenhum elemento domina outro elemento do conjunto). As melhores soluções não-dominadas são chamadas soluções de nível 1 ou de frente F_1 . Para encontrar as soluções do seguinte nível de não-dominância, deve-se, temporalmente, retirar da população as soluções de nível 1 (F_1). As soluções não-dominadas resultantes do ordenamento da população realizado sem as soluções de nível 1, são denominadas soluções não-dominadas de nível 2 ou de frente F_2 . Para en-

contrar as soluções não-dominadas de nível 3, são temporalmente retiradas da população as soluções de nível 1 e 2. O procedimento continua até que são classificados todos os indivíduos da população em níveis de não-dominância F_i . É importante ter em conta que as soluções de nível 1 são melhores que as soluções de nível 2, etc. Na Figura 20 mostra-se um exemplo para o caso de um problema de minimização bi-objetivo, onde a população de pontos no espaço objetivo é classificada em $k = 4$ fronteiras F_1, F_2, F_3 e F_4 .




Figura 20: Classificação das soluções em vários níveis de não-dominância.

5.4 Principais diferenças entre otimização multiobjetivo e mono-objetivo

Segundo Deb (DEB, 2001), a otimização multiobjetivo diferencia da otimização mono-objetivo em dois importantes aspectos:

1. Nos problemas de otimização mono-objetivo tem-se como objetivo encontrar uma solução ótima global (máximo ou mínimo) enquanto nos problemas de otimização multiobjetivo pode existir mais de um ótimo global. Na otimização multiobjetivo encontrar o conjunto de soluções da fronteira de Pareto é tão importante quanto preservar a diversidade neste conjunto. Desta forma, um algoritmo eficiente para a otimização multiobjetivo deve considerar estes dois aspectos.

2. Nos problemas de otimização multiobjetivo, trabalha-se com os espaços das variáveis e dos objetivos, enquanto os problemas com um objetivo trabalham unicamente no espaço das variáveis já que procuram apenas uma solução no espaço dos objetivos. Desta forma, manter a diversidade nos espaços das variáveis e dos objetivos torna a solução dos problemas multi-objetivo mais complicadas, pois a proximidade de duas soluções no espaço das variáveis *não implica* proximidade no espaço dos objetivos.

5.5 Classificação de métodos multiobjetivos

Na solução de problemas multiobjetivos, dois aspectos importantes podem ser identificados: busca de soluções e tomada de decisões. O primeiro aspecto refere-se ao processo de otimização, no qual a região factível é direcionada para soluções Pareto-ótimas. Como no caso de otimização mono-objetivo, a busca pode tornar-se difícil devido ao tamanho e complexidade do espaço de busca, podendo inviabilizar o uso de métodos exatos. A tomada de decisões envolve a seleção de um critério adequado para a escolha de uma solução do conjunto Pareto-ótimo. É necessário que o decisor faça uma ponderação (*trade-off*) dos objetivos conflitantes. A partir do ponto de vista do *decisor*, os métodos de otimização multiobjetivos podem ser classificados em três categorias, descritos a seguir.

5.5.1 Métodos a-priori

Estes métodos são caracterizados pela participação do decisor antes do processo de busca de soluções, isto é, antes de resolver o problema. Apresenta-se a seguir dois tipos de métodos a-priori:

1. Os objetivos do problema são combinados em um único objetivo. Isto requer a determinação explícita de pesos para refletir a preferência de cada objetivo. A vantagem deste método é que podem ser aplicadas estratégias clássicas de otimização mono-objetivo sem nenhuma modificação.

2. Os objetivos são classificados em ordem decrescente de prioridade. Feito isto, o problema é resolvido para o primeiro objetivo sem considerar as outras funções objetivo. A seguir, o problema é resolvido para o segundo objetivo sujeito ao valor ótimo encontrado para o primeiro objetivo. Este processo é continuado até que o problema seja resolvido para o último objetivo sujeito aos valores ótimos dos outros objetivos. Para o caso de dois objetivos tem-se o seguinte problema:

$$\text{Minimizar } f_2(x) \text{ sujeito a } f_1(x) = f_1^*, x \in S$$

Onde f_1^* é a solução do problema:

$$\text{Minimizar } f_1(x) \text{ sujeito a } x \in S$$

5.5.2 Métodos a-posteriori

Nestes métodos, o processo de decisão é feito logo após a realização da busca de soluções. A busca é feita, considerando-se que todos os objetivos são de igual importância. Ao final do processo da busca tem-se um conjunto de soluções aproximadas ou Pareto-ótimas. A partir deste conjunto, o responsável pelas decisões deve selecionar uma solução que representa a solução adequada do problema.

5.5.3 Métodos iterativos

Nestes métodos, o responsável pela decisão intervém durante o processo de otimização (busca de soluções) articulando preferências e guiando a busca para regiões onde exista soluções de interesse.

5.6 Métodos tradicionais de otimização multiobjetivo

Desde que o economista Vilfredo Pareto introduziu, em 1896, o conceito de solução compromisso, tem-se desenvolvido um grande número de técnicas de otimização multiobjetivo, tanto tradicionais como alternativas (Algoritmos Evolutivos, *Simulated Annealing*, Busca Tabu, entre outras). A seguir, abordam-se as técnicas tradicionais.

A literatura referente aos métodos de otimização tradicionais utilizados para a solução dos problemas multiobjetivo é vasta. Uma boa revisão das técnicas de programação matemática para solução dos problemas de otimização multiobjetivo pode ser encontrada em (COELLO, 1996), entre outras. Para encontrar as soluções ótimas, os métodos clássicos convertem o problema de otimização multiobjetivo original em um problema equivalente com um único objetivo, reduzindo a otimização vetorial a um problema de otimização escalar. O problema equivalente possui algumas restrições adicionais e para resolver esse problema é necessária a definição de alguns parâmetros. Estes parâmetros são definidos durante a apresentação de dois métodos que têm sido muito aplicados para resolver os problemas de otimização multiobjetivo de diversas áreas. Estes métodos são descritos a seguir.

5.6.1 Método da soma ponderada

Este método consiste na adição de todas as funções objetivo simultaneamente, utilizando diferentes coeficientes ponderados (parâmetros) para cada objetivo. Deste modo, o problema

multiobjetivo original é transformado em um problema escalar mono-objetivo como:

$$\text{Min} \sum_{i=1}^k w_i f_i(x) \quad (5.7)$$

sendo $w_i \geq 0$ os coeficientes ponderados que representam a importância relativa dos objetivos $f_i(x)$ no problema de otimização sob estudo. Estes pesos, geralmente, são normalizados, tal que:

$$\sum_{i=1}^k w_i = 1 \quad (5.8)$$

A solução do novo problema corresponde, sob determinadas condições, a pontos do conjunto Pareto-ótimo do problema multiobjetivo original. As condições suficientes para que a solução do problema equivalente seja Pareto-ótima são dadas pelos teoremas apresentados a seguir:

Teorema 1: Se S é um conjunto convexo, $f_1(x), f_2(x), \dots, f_k(x)$ são funções convexas definidas em S e x^* é um ponto Pareto-ótimo então, existe um vetor de pesos $w \in W = \left\{ w/w \geq 0 \text{ e } \sum_{i=1}^k w_i = 1 \right\}$ tal que x^* resolve o problema (5.7).

Teorema 2: x^* é uma solução Pareto-ótima para um problema de otimização multiobjetivo convexo, se existir um vetor de pesos $w \in W$ tal que x^* resolve o problema (5.7). Então, pelo menos uma das condições abaixo é satisfeita:

- i. $w_i > 0, i = 1, 2, \dots, k$;
- ii. x^* é solução única do problema (5.7).

O Teorema 2 garante que se um problema de otimização multiobjetivo é convexo, então, qualquer solução Pareto-ótima pode ser encontrada através deste método. Para encontrar as soluções Pareto-ótimas, é necessário resolver iterativamente o problema (5.7), considerando $w_i > 0$ e diferentes valores para w_i . A definição dos pesos apropriados, de acordo com a importância dos objetivos, é uma tarefa do tomador de decisões.

Seja um problema multiobjetivo com dois objetivos e um vetor de pesos $\mathbf{w} = [w_1, w_2]^T$ para minimizar a seguinte função:

$$y = w_1 f_1(x) + w_2 f_2(x); \quad x \in S \quad (5.9)$$

Dividindo a equação (5.9) por w_2 define-se uma reta tangente (ou suporte) ao espaço objetivo factível em um ponto Pareto-ótimo. Esta reta é denominada L e descrita como segue:

$$f_2(x) = -\frac{w_1}{w_2} f_1(x) + \frac{y}{w_2} \quad (5.10)$$

sendo $-\frac{w_1}{w_2}$ a inclinação da reta L e $\frac{y}{w_2}$ a intersecção da reta L com o eixo f_2 no ponto $\frac{y}{w_2}$.

Resolver um problema multiobjetivo através do método da soma ponderada consiste em gerar diferentes retas suportes, definidas pelo vetor de pesos. Em geral, nem todos os pontos Pareto-ótimos admitem retas tangentes. Na Figura 21, ilustra-se um exemplo de um problema multiobjetivo não-convexo. Neste exemplo, a fronteira Pareto-ótima está dividida em 3 regiões (BD , DG e GH). Na região DG , os pontos C e F não possuem retas tangentes, isto é, estes pontos não podem ser encontrados pela minimização da função y (equação 5.9).

Em outras palavras, pode-se dizer que, para qualquer reta tangente a um ponto na região DG , existirá uma outra reta tangente às regiões BD ou GH com um valor menor para a função y .

A principal desvantagem deste método é que ele não consegue gerar todas as soluções Pareto-ótimas quando o espaço objetivo é não-convexo, conforme ilustrado na Figura 21.

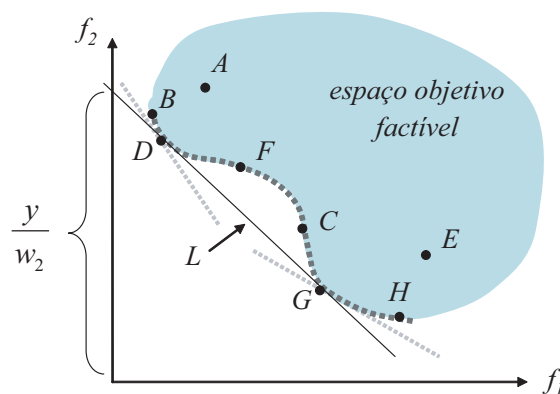


Figura 21: Interpretação gráfica do método da soma ponderada.

5.6.2 Método das ϵ -restrições

Haimes e colaboradores (HAIMES; LASDON; WISMER, 1971) apud (DEB, 2001) sugeriram reformular um problema multiobjetivo considerando qualquer um dos objetivos, e mantendo restritos os demais objetivos com valores definidos pelo decisor, isto é, o método consiste na minimização do objetivo com maior prioridade sujeito à limitação dos demais objetivos. Sendo f_1 o objetivo de maior importância, o problema pode ser formulado como segue:

$$\begin{aligned} \min \quad & Z = f_1(x) & (5.11) \\ \text{s.a.} \quad & \\ & f_i(x) \leq \epsilon_i; \quad i = 2, \dots, k \\ & x \in S \end{aligned}$$

sendo ϵ_i os limitantes superiores dos objetivos i , $i = 2, 3, \dots, k$.

Este método baseia-se nos Teoremas a seguir:

Teorema 3: Se x^* é uma solução Pareto-ótimo para um problema multiobjetivo, então, existem inteiros $i = 1, 2, \dots, k$ e reais ϵ_i , tais que x^* resolvem o problema (5.11).

Teorema 4: Se x^* é solução única de (5.11), para algum $i = 1, 2, \dots, k$, então, x^* é uma solução Pareto-ótima.

Teorema 5: Se x^* é Pareto-ótima, então, x^* resolve o problema (5.11), $\forall i$.

Na Figura 22 ilustra-se um exemplo hipotético deste método considerando-se um problema com dois objetivos (f_1 e f_2). Neste exemplo, mostra-se a importância de uma seleção adequada do limitante superior. A reta $\epsilon_2 = k$ limita o espaço das soluções e os pontos C, D, E são soluções factíveis, e os pontos A e B são soluções infactíveis do problema.

Na Figura 22 mostra-se claramente que se o limite superior não é selecionado adequadamente, $\epsilon_2 = k'$, o subespaço obtido pelas restrições pode ser vazio, isto é, o problema (5.11) não possui solução.




Figura 22: Interpretação gráfica do método das ϵ -restrições.

5.6.3 Vantagens e desvantagens das técnicas tradicionais

A principal vantagem das técnicas tradicionais são as provas de convergências que garantem encontrar as soluções Pareto-ótimas. Por outro lado, verifica-se que nos métodos apresentados nas seções anteriores, que o problema multiobjetivo original é transformado em um problema de otimização mono-objetivo. Esta transformação é efetuada através da introdução de parâmetros adicionais que afetam diretamente os resultados obtidos. Além disso, uma distribuição uniforme destes parâmetros adicionais não garante a diversidade das soluções Pareto-ótimas.

Nas seções anteriores foram introduzidas as noções básicas de otimização multiobjetivo. Apresentou-se o modelo geral para um problema multiobjetivo e as principais diferenças entre os problemas de otimização multiobjetivo e mono-objetivo, assim como, as técnicas tradicionais mais utilizadas em diversas áreas. Nas seguintes seções são apresentados os Algoritmos Evolutivos Multiobjetivo, enfatizando as características que permitem empregá-los com sucesso, na resolução do problema de Planejamento da Expansão de Sistemas de Transmissão de Energia Elétrica considerando desplanificação e múltiplos cenários de geração.

5.7 Algoritmos evolutivos para otimização multiobjetivo

Esta seção enfoca-se a aplicação dos Algoritmos Evolutivos, em particular os Algoritmos Genéticos, para a solução dos problemas de otimização multiobjetivo. São apresentados os conceitos e os principais aspectos práticos para implementação de algoritmos genéticos, dedicados à solução de problemas físicos reais.

Desde que Rosenberg mencionou em 1967 o potencial dos Algoritmos Evolutivos (AEs) para resolver os problemas de otimização multiobjetivo, tem-se observado um grande interesse

por parte dos pesquisadores no desenvolvimento de conceitos teóricos de algoritmos evolutivos multiobjetivo. Este interesse justifica-se devido ao fato de que os problemas do mundo real, normalmente, admitem diferentes funções objetivo, em geral conflitantes entre si. Por outro lado, a grande expansão na utilização dos AEs para resolver os problemas multiobjetivo garantiu a esta área uma linha de pesquisa própria, denominada otimização evolutiva multiobjetivo.

Os métodos baseados em metaheurísticas realizam um conjunto de transições através do espaço de soluções do problema e, nesse processo de transições, deve-se passar pela solução ótima ou soluções quase ótimas de problemas complexos. Esta característica torna os AEs apropriados para a resolução dos problemas multiobjetivos, principalmente quando se deseja conhecer o conjunto das soluções Pareto-ótimas, além disso, estes métodos são flexíveis, de fácil implementação e têm a capacidade de encontrar soluções de boa qualidade em problemas complexos.

Os principais objetivos das metaheurísticas de otimização multiobjetivo são:

- Orientar a busca na direção da região ou conjunto Pareto-ótimo;
- Manter a diversidade da população na fronteira de Pareto.

A maioria das publicações envolvendo a solução de problemas de otimização multiobjetivo através de metaheurísticas são baseadas em Algoritmos Genéticos (AGs). Segundo (JONES; MIRRAZAVI; TAMIZ, 2002) cerca de 70% das metaheurísticas aplicadas ao problema de otimização multiobjetivo apresentadas na literatura são algoritmos evolutivos, enquanto 24 % são baseadas no método Simulated Annealing e apenas 6% referem-se a Busca Tabu. Esta preferência deve-se ao fato dos AGs trabalharem com uma população de soluções que podem conter informações sobre várias regiões do espaço de busca. Desta forma, os AGs oferecem maiores possibilidades para encontrar o conjunto Pareto-ótimo ou uma aproximação dele (ARROYO, 2002). O primeiro algoritmo genético, para o tratamento de problemas multiobjetivos (*Vector Evaluated Genetic Algorithm*, VEGA), foi apresentado em (SHAFFER, 1984). Atualmente, existem inúmeros trabalhos publicados envolvendo os Algoritmos Evolutivos Multiobjetivos (MOEA). Nesta seção, são apresentadas as características fundamentais das principais pesquisas e/ou implementações desenvolvidas para aplicação de MOEA em problemas de engenharia. Informações mais detalhadas sobre cada técnica podem ser encontradas no livro publicado por Coello, Van Veldhuizen e Lamont em 2002 (COELLO, 2002).

Nos últimos anos muitos pesquisadores têm modificado as idéias iniciais sobre AGs propostas por Goldberg (GOLDBERG, 1989) para tratamento de problemas multiobjetivos, bem como

nas implementações para solução de problemas mais complexos do mundo real. Assim, atualmente existem inúmeras implementações de algoritmos evolutivos multiobjetivos e, por este motivo, a enumeração de todas as pesquisas que contribuíram para o desenvolvimento desta área é uma tarefa impossível. Na seqüência serão apresentadas as características fundamentais apenas das principais pesquisas e/ou implementações no campo dos algoritmos evolutivos multiobjetivo.

5.7.1 *Vector evaluated genetic algorithm* - VEGA

Tido como o pioneiro na implementação de algoritmos evolutivos para solução de problemas multiobjetivo, em 1984 Schaffer desenvolveu o chamado *Vector Evaluated Genetic Algorithm*, mais conhecido como VEGA, o qual é um algoritmo evolutivo multimodal e que foi o primeiro dos algoritmos multiobjetivo em usar soluções não-dominadas. Schaffer modificou o software de domínio público GENESIS, através da criação de melhorias no procedimento de seleção original que faz com que o procedimento seja repetido para cada objetivo separadamente, contemplando desta forma a natureza multiobjetivo do problema, até atingir-se um determinado número predefinido de indivíduos para cada objetivo.

Nesta proposta, o algoritmo valora um vetor objetivo, no qual, cada elemento do vetor representa as k funções objetivo do problema, e não uma função escalar, como na otimização mono-objetivo. A população de pais potenciais é dividida em k partes de igual tamanho, e cada parte i é construída com indivíduos que são selecionados da população atual de acordo com o objetivo i . Em seguida, estes indivíduos são randomicamente sorteados para as etapas de recombinação e mutação. O método foi implementado em combinação com o procedimento de seleção proporcional à aptidão dos indivíduos. O algoritmo privilegia as soluções que são boas em relação às funções objetivo individuais. Para encontrar soluções *trade off* intermediárias, é permitida a recombinação entre duas soluções quaisquer da população, de tal forma que a recombinação entre duas soluções, cada uma correspondente a um objetivo diferente, possa ajudar a encontrar descendentes que permitam um bom compromisso entre os objetivos. Neste método, as soluções obtidas têm a tendência a estar próximas as melhores soluções individuais de cada objetivo, o qual pode ser interessante em algumas aplicações. Já que cada solução não é valorada para os $(i - 1)$ objetivos restantes, as soluções próximas aos ótimos individuais podem ser preferidas sobre as soluções que levam em conta os compromissos entre os objetivos.

Com respeito à complexidade computacional, este algoritmo é similar ao algoritmo genético mono-objetivo. O VEGA é um algoritmo que usa uma idéia simples e é fácil de implementar. Somente são requeridas pequenas mudanças sobre o algoritmo genético mono-objetivo para que

assuma a forma multiobjetivo. A principal dificuldade deste algoritmo é que encontra soluções muito próximas as soluções ótimas individuais.

5.7.2 Multi-objective optimization genetic algorithm - MOGA

Este algoritmo foi proposto por Fonseca e Fleming em 1993, e utiliza as idéias do algoritmo genético e um procedimento de ordenamento não-dominado das funções de aptidão. Este procedimento consiste em avaliar a população utilizando os critérios de dominância apresentados a seguir:

- i. Os indivíduos não-dominados recebem uma posição ou ordem 1;
- ii. Os outros indivíduos são posicionados segundo as suas ordens de não-dominância em relação ao restante da população, isto é, para cada indivíduo, o número de soluções que o dominam estritamente é primeiramente determinado na população, logo, a posição no ordenamento deste indivíduo será este número acrescido da unidade.

Assim sendo, no final deste procedimento de ordenamento poderão existir muitos indivíduos compartilhando a mesma posição no ordenamento. Este ordenamento é utilizado no procedimento de seleção para escolher ou remover blocos de soluções representados pelos indivíduos e suas respectivas funções de aptidão, até escolher os indivíduos mais aptos para a reprodução. Este tipo de atribuição de aptidão por blocos pode acarretar uma grande pressão de seleção causando convergência prematura do algoritmo. Para distribuir a população, através da região ótima de Pareto e compartilhar os valores da função de aptidão, aplica-se um método de formação de nichos. Esta estratégia mantém a diversidade nos valores da função de aptidão, mas pode não garantir a diversidade no conjunto das variáveis. Assim, o MOGA pode não estar apto a achar as múltiplas soluções em problemas em que diferentes pontos ótimos de Pareto correspondem aos mesmos valores de aptidões. O destaque relevante deste trabalho é o ordenamento dos indivíduos por critérios de dominância.

5.7.3 Niche-Pareto genetic algorithm - NPGA

Este algoritmo foi proposto por Horn et al. em 1994. O NPGA é um algoritmo genético geracional com sobreposição, isto é, nem todos os indivíduos são substituídos de uma geração para outra. Este algoritmo utiliza um esquema de seleção baseada em torneio e em dominância de Pareto. Neste processo de busca de soluções não-dominadas, dois indivíduos são escolhidos aleatoriamente e comparados com um subconjunto da população (usualmente 10% da

população). Quando ambos competidores são dominados ou não dominados, um contador de nicho é criado para cada indivíduo na população inteira. O contador é baseado no número de soluções na população com uma certa distância do indivíduo. Assim, a solução que apresentar o menor contador de nicho é selecionada.

No processo de seleção, se um dos indivíduos em competência é dominado por algum outro indivíduo da subpopulação, o último é escolhido como o vencedor do torneio. Se os dois indivíduos são dominados (ou não-dominados) o resultado do torneio é definido por uma medida de separação de cada indivíduo respeito aos outros indivíduos.

Este algoritmo não requer a definição de uma função de aptidão para cada solução, já que a seleção por torneio é de natureza estocástica com prioridade das soluções não dominadas, e quando não existe dominância, as soluções das regiões menos ocupadas são selecionadas. Desta forma se favorece as soluções mais próximas a fronteira Pareto-ótima e a diversidade é garantida.

5.7.4 *Nondominated sorting genetic algorithm - NSGA*

O algoritmo NSGA foi proposto por Srinivas e Deb com o objetivo de trabalhar com os conceitos de dominância e manutenção da diversidade da população simultaneamente. Neste algoritmo utiliza-se um esquema de seleção baseada por ordenamento para privilegiar as soluções não-dominadas correntes, juntamente com um método voltado para a criação de nichos para manter a diversidade da população. A diferença desta implementação, em relação a um algoritmo genético simples, está apenas no modo com que o operador de seleção é empregado. Tanto o operador de recombinação quanto o operador de mutação são normalmente utilizados como nos algoritmos genéticos convencionais.

Este algoritmo difere do algoritmo genético mono-objetivo apenas na maneira como o método de seleção trabalha, uma vez que os operadores recombinação e mutação permanecem idênticos. Antes do procedimento de seleção ser aplicado, a população é classificada com base na definição de pontos eficientes. Os indivíduos eficientes presentes na população corrente são ordenados com base no nível de não-dominância dos indivíduos, isto é, todas as soluções não-dominadas da população corrente recebem valores altos de aptidão. Esta aptidão é a mesma para todos os indivíduos não-dominados, garantindo, assim, que todos possuam um mesmo potencial reprodutivo.

A diversidade na população é obtida procurando que as soluções não-dominadas compartilham os seus valores de aptidão segundo suas distâncias Euclidianas (também pode ser adotada

a distância de Hamming - número de bits diferentes entre dois indivíduos). Finalmente, divide-se o valor da aptidão de cada indivíduo pelo contador de nichos que é proporcional ao número de vizinhos ao seu redor. Este procedimento proporciona a co-existência de pontos ótimos múltiplos na população. O pior valor de aptidão compartilhada na solução da primeira fronteira não-dominada é, então, guardado para uso posterior.

Após a execução do compartilhamento e as modificações das aptidões, os indivíduos não-dominados são ignorados, temporariamente, para processar o resto dos indivíduos da população. O procedimento para determinar novas soluções não-dominadas (segundo nível) é novamente executado, sendo que agora eles recebem um valor de aptidão um pouco menor que o pior valor de aptidão compartilhada no nível anterior. Novamente, o procedimento de compartilhamento é executado entre as soluções não-dominadas do segundo nível e as novas aptidões são calculadas como antes. Este processo é repetido até que todos os membros da população tenham um valor de aptidão compartilhada. A recombinação da população é efetuada utilizando-se a aptidão compartilhada, ou seja, como o primeiro nível de soluções não-dominadas possui as mais altas aptidões, um maior número de cópias dos seus indivíduos será realizado e levará a busca para a fronteira ótima de Pareto. A característica mais importante deste trabalho é que praticamente qualquer número de objetivos pode ser usado para os dois tipos de problemas: maximização ou minimização, bastando mudar o modo como os indivíduos não-dominados são identificados.

5.7.5 *Strength Pareto evolutionary algorithm - SPEA*

O SPEA foi proposto por Zitzler e Thiele em 1998, com o objetivo de introduzir o elitismo nos algoritmos evolutivos multiobjetivos. Inicialmente é gerada uma população aleatória (P_0) de dimensão N e um conjunto externo vazio (P_e). O conceito do SPEA une todas as potencialidades de diversos algoritmos em um único. Ele é caracterizado por armazenar no conjunto externo P_e todas as soluções não dominadas encontradas da primeira à última geração do algoritmo. No caso desse conjunto exceder um número máximo de indivíduos \bar{N} , um algoritmo de agrupamento é utilizado para reduzir o tamanho do conjunto. Quanto ao mecanismo de atribuição de função de avaliação, o algoritmo trabalha em dois estágios.

1. Ordenação dos elementos do conjunto P_e : A cada solução i pertencente a P_e , um valor real S_i entre $[0,1)$, denominado *strength*, é atribuído. O valor de S_i é proporcional ao número de indivíduos da população atual P_0 que são dominados pelo indivíduo i . Portanto, sendo n_i o número de indivíduos de P_0 que são dominados por i e N o número de indivíduos na população P_0 ,

$$S_i = \frac{n_i}{N + 1} \quad (5.12)$$

A função de avaliação de cada indivíduo i é equivalente a seu S_i .

2. A função de avaliação de cada indivíduo j pertencente a P_0 é equivalente a soma de todas as *strengths* de todos os indivíduos i de P_e que dominam j somado de 1. A maneira como a função de avaliação é atribuída a cada um dos indivíduos e seus efeitos podem ser claramente visualizados na Figura 23, que representa um problema multiobjetivo do tipo max-max com duas funções f_1 e f_2 .

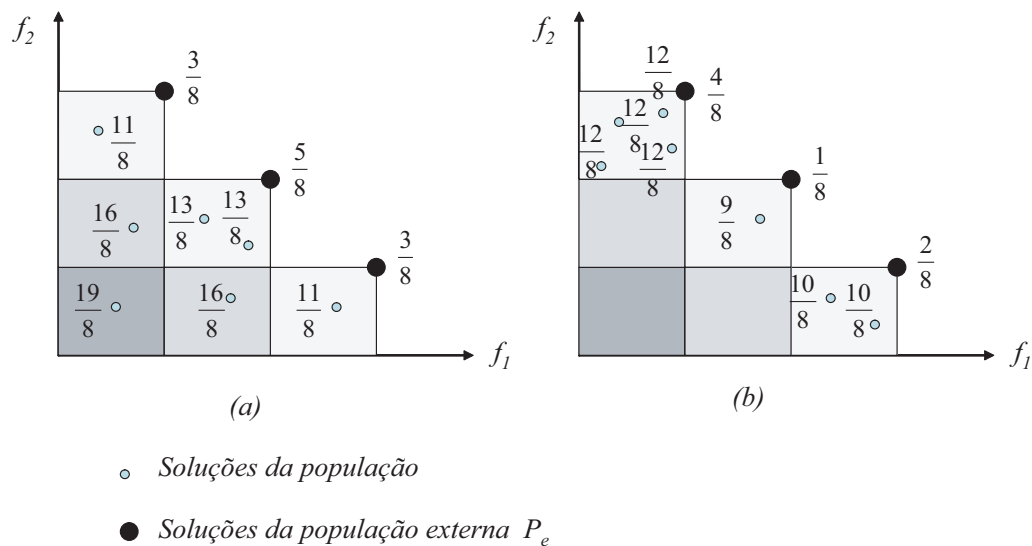


Figura 23: Valores de S_i para soluções dominadas e não-dominadas.

Na Figura 23, o espaço de objetivos, coberto por três soluções não-dominadas, é dividido em três áreas distintas, representadas por retângulos. Cada subconjunto de P_e define uma área dominada por todos seus elementos. O retângulo mais escuro, no canto inferior esquerdo do gráfico, agrupa indivíduos dominados por todas as soluções não-dominadas encontradas, enquanto a área mais clara, no canto superior esquerdo é dominada apenas por uma dessas soluções.

Cada uma dessas áreas é considerada pelo algoritmo como um nicho, e o objetivo do método é distribuir os indivíduos através de todas essas áreas de forma que:

1. As áreas mais claras, dominadas por poucas soluções, contenham mais indivíduos que as áreas escuras, dominadas por mais soluções.

2. Uma área englobe tantos indivíduos quanto outra área dominada pelo mesmo número de soluções não dominadas.

Esse mecanismo seleciona intuitivamente soluções próximas à frente de Pareto, distribuindo-as em torno de sua superfície. A Figura 23 (a) ilustra o primeiro dos objetivos a serem alcançados pelo método: as funções de avaliação dos indivíduos nas áreas mais claras possuem valores superiores ao do restante da população. A Figura 23 (b) permite a visualização do princípio da força (*strength*): indivíduos com mais vizinhos em seu nicho são penalizados devido ao alto valor de força da solução não-dominada a eles associada. Quanto mais forte a solução não-dominada, menores os valores das funções de avaliação dos indivíduos por ela dominados.

Segundo (COELLO, 2002), o SPEA pertence ao que ele considera a segunda geração de técnicas para o desenvolvimento de algoritmos multiobjetivos. A segunda geração é caracterizada por primar pela eficácia dos métodos, em que é comum a presença de populações externas e a busca por soluções não dominadas e, ao mesmo tempo, bem distribuídas por todo o frente de Pareto.

Um estudo realizado por Zitzler compara o desempenho de alguns algoritmos genéticos multiobjetivos, entre eles, VEGA, MOGA, NPGA, NSGA e SPEA. Algumas métricas são utilizadas para comparar as soluções encontradas pelo algoritmo, sempre levando em conta a distância entre a frente de Pareto encontrada e a frente de Pareto ideal, a distribuição das soluções na frente de Pareto e o tamanho do intervalo de valores que cada um dos objetivos é capaz de cobrir.

De acordo com essas métricas, os algoritmos foram testados, e uma hierarquia entre eles foi encontrada. O SPEA foi considerado o mais eficaz deles, seguido pelo NSGA e VEGA.

5.7.6 *Distance-based Pareto genetic algorithm - DPGA*

O algoritmo DPGA (*Distance-Based Pareto Genetic Algorithm*) foi proposto por Osyczka e Kundu em 1995. Este algoritmo trata de obter convergência do processo para a frente de Pareto-ótima conservando a diversidade da população, através do uso de uma métrica. O algoritmo tem duas populações: uma população padrão P_t sobre a qual se aplicam os operadores genéticos e outra população elite E_t que contem todas as soluções não-dominadas encontradas até o momento.

A população inicial P_0 de tamanho N é gerada randomicamente (ou com algum critério dependendo da aplicação). Para o primeiro membro da população, é definido um valor ar-

bitrário positivo de função de aptidão *fitness* F_1 . Esta solução é automaticamente adicionada na população elite E_0 . Depois, para cada solução é calculada uma função de aptidão *fitness* baseada na distância até o conjunto elite (este conjunto está conformado por $E_t = \{e^{(k)} : k = 1, 2, \dots, K\}$ onde K é o número de soluções no conjunto elite. Cada solução elite $e^{(k)}$ tem \mathcal{M} valores de função objetivo, o $e^{(k)} = (e_1^{(k)}, e_2^{(k)}, \dots, e_{\mathcal{M}}^{(k)})^T$. A distância de uma solução x ao conjunto elite é calculada como:

$$d^{(k)}(x) = \sqrt{\sum_{m=1}^{\mathcal{M}} \left(\frac{e_m^{(k)} - f_m(x)}{e_m^{(k)}} \right)^2} \quad (5.13)$$

Para a solução x o $d^{(k)}(x)$ mínimo é calculado como:

$$d^{\min} = \min_{k=1}^K d^{(k)}(x)$$

Tem-se em conta o índice k^* associado com a mínima distância. Depois disto, se a solução x é uma solução não dominada com respeito ao conjunto elite existente, é aceita dentro do conjunto dominado e seu *fitness* é calculada como a soma do valor *fitness* do indivíduo da população elite com distância mínima (associada na solução x) e sua própria distância mínima:

$$F(x) = F(e^{(k^*)}) + d^{\min} \quad (5.14)$$

O conjunto de soluções elite é atualizado eliminando as soluções dominadas por x , se existe alguma. Por outro lado, se a solução x é dominada por alguma solução elite, esta não é aceita no conjunto elite e seu *fitness* é calculado como:

$$F(x) = \max [0, (F(e^{(k^*)}) - d^{\min})] \quad (5.15)$$

Desta forma, na medida em que a função *fitness* ou de aptidão dos indivíduos da população vai sendo valorada, o conjunto elite vai sendo atualizado. Ao final de uma geração, quando todos os N indivíduos da população são valorados, a máxima função de aptidão (*fitness* F_{\max}) entre as soluções elite é calculada, e a função de aptidão das soluções elite existentes é igualada a F_{\max} . Ao final de uma geração do algoritmo, os operadores de seleção, recombinação e mutação são usados para criar uma nova população.

A solução não-dominada que está na maior distância das soluções elite, obtém uma alta (melhor) função de aptidão (*fitness*). Isto quer dizer que, se a nova solução domina alguns

indivíduos do conjunto elite, o processo promove as soluções mais próximas ao conjunto ótimo de Pareto. Uma grande distância, neste caso, indica que a solução se encontra longe do conjunto elite, mas está mais perto do conjunto ótimo de Pareto. Se a nova solução se encontra no mesmo frente de Pareto que o conjunto elite, a função de aptidão ajuda a manter a diversidade entre os indivíduos deste conjunto.

5.7.7 *Elitist non-dominated sorting genetic algorithm - NSGA-II*

O algoritmo NSGA II foi desenvolvido em 2000 (DEB et al., 2000b). Deb *et al* propuseram uma nova versão do *Nondominated Sorting Genetic Algorithm* (NSGA). A idéia principal deste algoritmo é a ordenação por elitismo, ou seja, os melhores indivíduos de uma geração serão necessariamente selecionados para a próxima geração, preservando as melhores soluções encontradas até o momento. Esta nova versão apresentou-se mais eficiente que o NSGA. Esta versão usa o elitismo e um operador de comparação de vários indivíduos que fornece diversidade sem especificação de parâmetros adicionais. De acordo com (CHEUNG, 2004), em se tratando de complexidade computacional, o NSGA II contém um algoritmo de classificação não dominada com menor complexidade computacional frente ao NSGA e o SPEA. Já o elitismo no NSGA II, é garantido através da preservação das melhores soluções (frentes não dominadas) na população posterior. Em geral, o procedimento desenvolve-se da seguinte forma, uma população derivada Q_t (filha) da população corrente P_t (pai) e de tamanho N , é criada utilizando a seleção por torneio e o conceito de distância de aglomeração, seguida da recombinação e mutação. Após este procedimento, esses dois conjuntos de mesma dimensão N (pai e filha) são unidos em uma única população R_t de tamanho $2N$ e aplica-se a classificação não dominada em frentes de dominância. Inicia-se, então, o processo de preenchimento de uma nova população, colocando as melhores frentes não-dominadas nesse novo conjunto R_t , garantindo dessa forma o elitismo.

Ressalta-se que nem todas as frentes podem ser incluídas na nova população. Assim, os autores propuseram um método, que combina as frentes não incluídas no conjunto, para compor os últimos espaços da população. Este método é denominado distância de aglomeração (*crowding distance*). Com a utilização dessa técnica para alocação de soluções na população, é garantida a diversidade da população e eliminada a subjetividade associada com a introdução do parâmetro de compartilhamento utilizado nos métodos não-elitistas, pois diferentes soluções podem ter chances de pertencer à nova população.

Antes do procedimento de seleção ser aplicado, a população é ordenada com base na não-dominância dos indivíduos, isto é, todos os indivíduos não-dominados da população recebem valores altos de aptidão. Esta aptidão é a mesma para todos os indivíduos na mesma faixa

de dominância. Os melhores indivíduos não-dominados irão necessariamente para a próxima geração, iteração do algoritmo. Já os indivíduos na segunda faixa de não-dominância em diante são alocados conforme a necessidade de novos pais para a próxima geração. Na Figura 24 está uma representação gráfica do funcionamento do algoritmo, conforme (DEB et al., 2000a).

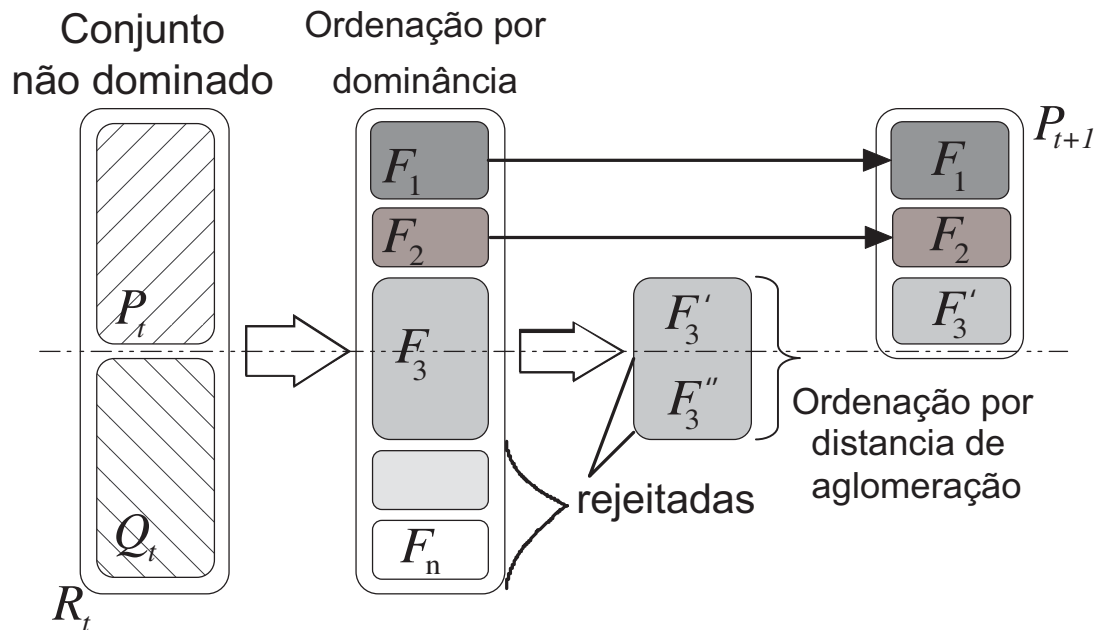


Figura 24: Funcionamento do algoritmo NSGA-II

A partir da geração inicial composta por P_t e Q_t as soluções são ordenadas de acordo com o frente de Pareto ao que pertencem. Inicialmente são selecionadas as soluções não dominadas F_1 , logo são selecionadas as soluções do segundo frente F_2 , do terceiro frente F_3 até F_n . As soluções são ordenadas por dominância. Como a população R_t é de tamanho $2N$, e somente N indivíduos conformam a nova população P_{t+1} , somente as soluções dos frentes F_1 e F_2 da Figura 24 podem fazer parte da nova população. Algumas soluções do frente F_3 serão selecionadas para a nova população e outras não serão selecionadas. Para definir quais soluções de F_3 são passadas para a próxima geração, é usado um critério de desempate entre as soluções chamado distância de aglomeração. A distância de aglomeração serve para manter a diversidade na população das soluções não-dominadas dentro do mesmo frente de Pareto.

O algoritmo NSGA-II inicialmente gera uma população (randomicamente ou através de uma técnica de inicialização) de pais P_0 . A população é ordenada de acordo a os níveis de não dominância (ordenamento dos frentes de Pareto, F_1, F_2, \dots, F_n). A cada solução é associada uma função de aptidão (*fitness*) de acordo a seu nível de não-dominância (1 é o melhor nível).

Os mecanismos de seleção por torneio, de recombinação e de mutação são usados para gerar a nova população de descendentes Q_0 de tamanho N . Os passos do **algoritmo NSGA-II** são descritos a seguir:

1. Combinar as populações de pais e descendentes para gerar $R_t = P_t \cup Q_t$. Fazer o ordenamento não dominado a R_t e identificar os frentes $F_i, i = 1, 2, \dots, n$.
2. Fazer $P_{t+1} = \emptyset$, e $i = 1$.
3. Enquanto $|P_{t+1}| + |F_i| \leq N$ fazer $P_{t+1} = P_{t+1} \cup F_i$ e $i = i + 1$.
4. Se $|P_{t+1}| + |F_i| > N$, realizar um ordenamento por distância de aglomeração ($F_i, <_c$), o qual se apresenta posteriormente, e incluir em P_{t+1} as $(N - |P_{t+1}|)$ soluções mais esparsas usando os valores de distância de aglomeração associadas ao frente F_i .
5. Gerar a população de descendentes Q_{t+1} a partir de P_{t+1} usando seleção por torneio com distância de aglomeração, recombinação e mutação.

No passo 4, o ordenamento das configurações do último frente que não pode ser introduzido totalmente na nova população é realizado usando o critério de distância de aglomeração. Os indivíduos são ordenados de forma descendente de acordo com a magnitude desta distância.

Fast nondominated sort: Deb et al. (2000) propõem um algoritmo para classificar uma população $P_t \cup Q_t$ de soluções (considerando os vetores objetivos). Este algoritmo é denominado *fast nondominated sort* e é uma versão melhorada da ordenação usada no algoritmo genético de Srinivas e Deb (1995). Neste algoritmo, em primeiro lugar, para cada solução x de uma população $P_t \cup Q_t$ determinam-se: (i) n_x , o número de soluções que dominam x , e (ii) S_x , o conjunto de soluções dominadas por x . Em seguida, identificam-se todas as soluções com $n_x = 0$ (soluções não dominadas), e estas são armazenadas em um conjunto F_1 , que constitui a fronteira atual. Para cada solução y dominada por alguma solução x da fronteira atual, o valor de n_y é diminuído em uma unidade ($n_y = n_y - 1$). Então, as soluções y que tenham $n_y = 0$ são armazenadas num novo conjunto F_2 (fronteira atual). Este processo continua até que todas as soluções possuam $n_y = 0$, isto é, até que todas as soluções sejam armazenadas numa fronteira. A seguir, é apresentado o pseudocódigo do algoritmo *fast nondominated sort* aplicado a uma população $P_t \cup Q_t$.

Entrada: $P_t \cup Q_t$ (população de soluções)

Saída: F_1, F_2, \dots, F_K (população classificada em K sub-populações ou frentes)

1. Para cada solução $x \in P_t \cup Q_t$ faça
 - Para cada solução $y \in P_t \cup Q_t$ faça
 - Se x domina y então $S_x = S_x \cup \{y\}$ (S_x é o conjunto de soluções dominadas por x).
 - Senão, se y domina x então $n_x = n_x + 1$.
 - Se $n_x = 0$ (n_x é o número de soluções que dominam x) então $F_1 = F_1 \cup \{x\}$.
 - $j = 1$.

2. Enquanto $F_j \neq \emptyset$ faça
 - $F_{j+1} = \emptyset$.
 - Para cada $x \in F_j$, faça
 - Para cada $y \in S_x$, faça
 - $n_y = n_y - 1$. Se $n_y = 0$ então $F_{j+1} = F_{j+1} \cup \{y\}$.
 - $j = j + 1$.

Operador de seleção por torneio usando distância de aglomeração ($F, <_c$): O operador de comparação para distância de aglomeração ($<_c$), compara duas soluções e define o vencedor do torneio. Assume-se que cada solução i tem dois atributos:

1. Um valor F_i de não dominância na população, como foi mostrado na Figura 20.
2. Uma distância de aglomeração (d_i) local na população.

A distância de aglomeração d_i de uma solução i é uma medida do espaço de busca vizinho de i que não está ocupado por outra solução na população. Usando estes atributos, pode-se definir o operador de seleção por torneio para distância de aglomeração da seguinte forma:

Uma solução i é melhor que outra solução j se uma das seguintes condições são satisfeitas:

1. A solução i se encontra em um melhor frente de Pareto, isto quer dizer que $F_i < F_j$.
2. As soluções se encontram na mesma fronteira mas a solução i tem melhor distância de aglomeração, isto quer dizer que $F_i = F_j$ e $d_i > d_j$.

A primeira condição se cumpre quando a solução selecionada se encontra em uma melhor fronteira de Pareto. A segunda condição é importante quando as soluções se encontram no mesmo frente já que a decisão é tomada com base na distância de aglomeração. Neste caso, a solução mais distante das demais é selecionada como a melhor.

Distância de aglomeração: Para ter uma idéia da proximidade das outras soluções respeito a uma solução particular i , é definida a distância média de duas soluções a cada lado da solução i respeito de cada um dos objetivos. Esta distância permite estimar o perímetro do cuboide formado ao usar os vizinhos mais próximos como os vértices, como é mostrado na Figura 25.




Figura 25: Distância de aglomeração (*crowding distance*) para a solução i .

A seguir se apresenta o procedimento para determinar as distâncias de aglomeração de cada ponto ou solução do conjunto F .

1. Definir o número de soluções em F como $l = |F|$. Para cada i no conjunto definir $d_i = 0$.
2. Para cada função objetivo $m = 1, 2, \dots, \mathcal{M}$, ordenar o conjunto de acordo ao pior valor de f_m ou, encontrar o vetor de índices ordenados: $I^m = \text{sort}(f_m, >)$.
3. Para $m = 1, 2, \dots, \mathcal{M}$, definir uma alta distância para as soluções extremas, isto é, $d_{I_1^m} = d_{I_l^m} = \infty$, e para as demais soluções $j = 2$ até $(l - 1)$, calcular:

$$d_{I_j^m} = d_{I_j^m} + \frac{f_m^{(I_{j+1}^m)} - f_m^{(I_{j-1}^m)}}{f_m^{\max} - f_m^{\min}}$$

O índice do j -th indivíduo da população já ordenada é chamado I_j , em conseqüência, I_1 e I_l são os índices da pior e da melhor função objetivo, respectivamente. A equação anterior representa a metade do perímetro do cuboide formado com as soluções vizinhas de i e que contém a solução i (Figura 25). Para a mesma fronteira de Pareto, são melhores as soluções com maior valor de $d_{I_i^m}$.

A seguir é mostrado o algoritmo NSGA-II básico.

Algoritmo NSGA-II básico:

Entrada de dados: Tamanho da população de pais P_t : N , tamanho da população de descendentes Q_t : N , taxa de recombinação ρ_c , taxa de mutação ρ_m , número limite de gerações $maxgen$.

Saída: soluções da fronteira Pareto-ótima.

Gerar aleatoriamente a população inicial P_0 de tamanho N .

Faça $Q_0 = \emptyset$, $R_0 = P_0 \cup Q_0$ e $t = 0$.

Enquanto não seja cumprido o critério de parada, faça:

 Usando o algoritmo *fast nondominated sort*, faça a classificação das soluções em R_t em frentes de dominação (atribuição da aptidão para as soluções de R_t).

 Geração da nova população P_{t+1} :

 Faça $i = 1$ e $P_{t+1} = \emptyset$.

 Enquanto $|P_{t+1}| + |F_i| < N$ faça $P_{t+1} = P_{t+1} \cup F_i$ e faça $i = i + 1$

 Ordenar as soluções da frente F_i usando o critério de distância de aglomeração.

 Adicionar as melhores soluções de F_i na população P_{t+1} até obter uma população de tamanho N .

 Aplicar os operadores genéticos para gerar Q_{t+1} :

 Enquanto $|Q_{t+1}| < N$ faça:

 Aplicar o operador de seleção por torneio usando distância de aglomeração sobre os indivíduos da população P_{t+1} .

 Aplicar o operador de recombinação usando taxa de recombinação ρ_c .

 Aplicar o operador de mutação usando taxa de mutação ρ_m .

 Faça $R_{t+1} = P_{t+1} \cup Q_{t+1}$

$t = t + 1$ (nova geração).

5.8 Algoritmo NSGA-II modificado aplicado ao planejamento da transmissão

No problema de planejamento dos sistemas de transmissão de energia elétrica são procurados dois objetivos fundamentais: o plano de expansão deve ser de custo mínimo, e deve-se atender toda a demanda futura do sistema. No problema com múltiplos cenários de geração,

a existência de corte de carga ou potência não-atendida, para uma configuração dada, indica a existência de congestionamento para algum ou alguns cenários de geração factíveis futuros, e não desatenção de carga nas barras do sistema, sempre que o corte de carga existente possa ser eliminado através de uma mudança no despacho de geração. Os testes feitos no problema de planejamento da transmissão considerando p cenários de geração sobre o sistema IEEE de 24 barras, mostram que existem soluções que apresentam algum valor de corte de carga em k cenários factíveis futuros (com $k < p$) e não apresentam corte de carga nos $p - k$ cenários restantes. Isto quer dizer que, no caso de usar esta configuração como solução, nos k cenários que apresentam congestionamento o corte de carga pode ser eliminado através de uma mudança no despacho de geração, usando algum dos $p - k$ cenários onde toda a carga é atendida. Assim, o corte de carga para um problema de planejamento da transmissão sem múltiplos cenários de geração representa potência não-atendida, e o corte de carga para um problema considerando múltiplos cenários de geração pode representar somente a possibilidade de congestionamento em alguns cenários factíveis futuros, já que não existe certeza que estes cenários sejam programados. A partir desta idéia se realiza uma proposta de otimização multiobjetivo para o problema de múltiplos cenários de geração onde são aceitas soluções com corte de carga em alguns cenários, sempre que para a solução existam outros cenários de geração que não apresentem corte de carga. O que se procura é encontrar soluções de menor custo permitindo algum grau de congestionamento em alguns cenários de geração, mas para as quais este congestionamento possa ser eliminado através de um redespacho de geração.

O problema multiobjetivo proposto tem então duas funções objetivo: a minimização do custo de investimento e a minimização do congestionamento futuro. Não é possível associar ao congestionamento um custo de congestionamento já que este custo somente pode ser calculado no futuro com o aparecimento de cenários reais de geração para os quais existam limitações de transmissão é seja necessário fazer um redespacho considerando as usinas de geração disponíveis. Desta forma, o conceito de *corte de carga* pode ser interpretado como *possibilidade de congestionamento* neste problema.

A idéia da otimização multiobjetivo considerando a possibilidade de congestionamento como uma função objetivo a minimizar é consequência dos altos custos associados na planificação mono-objetivo de sistemas de transmissão considerando múltiplos cenários de geração. Como foi mostrado na seção (4.4.2), o custo associado a eliminar completamente o congestionamento no sistema futuro para o sistema teste IEEE de 24 barras, usando o algoritmo CBGA mono-objetivo, é de US\$ 1330×10^6 , isto é, 8,75 vezes o custo de planejamento tradicional para este sistema. Com a otimização multiobjetivo se procura reduzir este custo.

Nesta seção propõe-se um esquema de planejamento multiobjetivo que permite planos de expansão ineficazes sempre que a demanda não atendida seja pequena comparada com a demanda total do sistema, como se mostra na Figura 26. Nesta figura, as soluções C e D são de interesse já que apresentam um congestionamento possível baixo e permitem reduzir o custo de investimento respeito a solução mono-objetivo, as soluções A e B são descartadas porque apresentam um congestionamento possível alto. Esta proposta multiobjetivo tem dois objetivos: minimizar o custo do plano de expansão ($f_1 = \sum_{(i,j) \in \Omega} c_{ij} n_{ij}$), e minimizar o congestionamento possível. O segundo objetivo pode ser considerado como o somatório dos cortes de carga que aparecem nos p cenários ($\sum_{q=1}^p \sum_{i \in \Gamma} r_i^q$, onde Γ é o conjunto de barras de carga), ou como o máximo corte de carga que aparece em um dos p cenários de geração ($f_2 = \max \{r^q\}$, $q = 1, \dots, p$, onde r^q é igual a $\sum_{i \in \Gamma} r_i^q$ para o cenário q). Os p cenários são considerados equiprováveis.

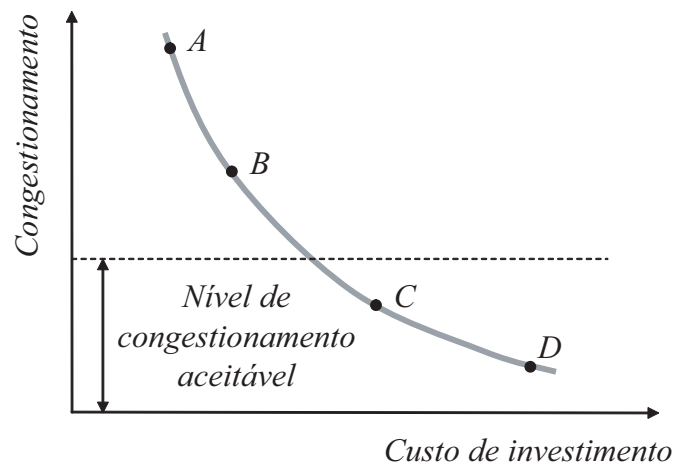


Figura 26: Soluções para o problema de planejamento multiobjetivo considerando múltiplos cenários de geração.

Neste trabalho, é usado um algoritmo NSGA-II modificado. A diferença do NSGA-II básico, o NSGA-II modificado usa uma população inicial gerada usando soluções elite obtidas usando o algoritmo CBGA mono-objetivo para este problema. Também o algoritmo modificado usa mutação controlada, uma etapa de melhoramento dos indivíduos gerados, uma população de descendentes Q_t de tamanho menor que N e adicionalmente preserva a diversidade no espaço dos objetivos, preserva a diversidade no espaço solução usando o critério de k bits diferentes. Os melhores resultados foram obtidos gerando somente um descendente, usando a lógica do algoritmo CBGA. Neste caso, a população R é de tamanho $N + 1$ (e não de tamanho $2N$ como no algoritmo NSGA-II básico).

As principais características do algoritmo NSGA-II modificado são as seguintes:

Inicialização da população: A população inicial é gerada usando uma combinação de soluções aleatórias, soluções obtidas usando o algoritmo CBGA mono-objetivo descrito na seção (3.3.2) e alguns soluções do problema de planejamento tradicional sem considerar múltiplos cenários de geração. A população aleatória é gerada de forma controlada, de tal forma que o número de circuitos adicionados não seja grande comparado com o número de caminhos de transmissão candidatos.

Diversidade no espaço solução: Tanto no processo de geração da população inicial como no processo de modificação dos indivíduos da população P , é verificado que todos os indivíduos sejam diferentes. Neste caso, é aplicada a exigência de que cada solução seja diferente das demais em k bits. O valor de k pode assumir os valores 1, 2 ou 3.

Seleção: É usado o operador de seleção por torneio usando distância de aglomeração, apresentado na seção (5.7.7). São realizados dois torneios entre os indivíduos da população P . No processo são selecionados aleatoriamente n_s indivíduos da população P para realizar cada torneio é definir um vencedor. O valor de n_s pode ser 1,2,3 ou 4. Em cada torneio o indivíduo vencedor é selecionado usando a lógica do algoritmo NSGA-II básico, isto é, uma solução i é melhor que outra solução j se uma das seguintes condições são satisfeitas: a solução i se encontra em um melhor frente de Pareto ($F_i < F_j$) ou as soluções se encontram no mesmo frente mas a solução i tem melhor distância de aglomeração ($F_i = F_j$ e $d_i > d_j$). Neste último caso, a solução mais distante das demais é selecionada como a melhor.

Recombinação: O operador de recombinação permite o intercambio das informações entre os dois indivíduos vencedores dos torneios realizados na etapa de seleção. O método usado é o método de recombinação de um ponto. Assim, é selecionado aleatoriamente um valor entre 1 e $nl - 1$, sendo nl o número de posições dos vetores usados para codificar as soluções. Após selecionar o ponto de recombinação, trocam-se os conteúdos das posições existentes no lado esquerdo dos vetores. Os vetores resultantes contem parte de sua informação inicial e parte da informação do outro vetor. A taxa de recombinação ρ_c define o número de recombinações que são realizadas.

Mutação: Uma vez aplicado o operador de seleção é aplicado o operador de mutação, o qual consiste em selecionar aleatoriamente n_m posições para mutação, onde n_m é proporcional na taxa de mutação utilizada ρ_m . A mutação consiste em alterar o conteúdo das posições selecionadas em forma controlada, isto é, resolve-se o subproblema operativo associado na configuração

antes da mutação e, privilegia-se a possibilidade de adicionar circuitos, se o corte de carga associado é maior que um valor $cortemax$, e privilegia-se retirar circuitos se o corte de carga associado é menor que $cortemax$. O valor do parâmetro $cortemax$ é definido no intervalo 10 MW a 100 MW.

Melhoramento: Depois de realizado o processo de mutação, sobre os indivíduos descendentes é realizada uma etapa de melhoramento, a qual consiste em determinar que não existam circuitos redundantes. Se existem circuitos redundantes, estes são retirados. Neste processo, os circuitos são ordenados em ordem crescente de custo, e logo são retirados um a um usando este ordem. Através deste procedimento, conserva-se o valor do corte de carga das soluções candidatas e o valor de investimento pode ser reduzido.

Inclusão dos indivíduos na população de descendentes: Antes de incluir os descendentes na população Q_t é verificado que satisfaça o critério de diversidade, isto é, deve ter k bits diferentes respeito aos demais indivíduos da população. Se esta condição é cumprida, o indivíduo é incluído na população Q_t . Os novos indivíduos gerados podem passar para a próxima geração se cumprem ademais os critérios da frente de Pareto e distância de aglomeração.

A seguir é mostrado o algoritmo NSGA-II modificado.

Algoritmo NSGA-II modificado:

Entrada de dados: Tamanho da população de pais P_t : N_p , tamanho da população de descendentes Q_t : N_q , número de bits para diversidade n_b , taxa de recombinação ρ_c , taxa de mutação ρ_m , corte de carga para mutação controlada $cortemax$, limite de congestionamento permitido $congmax$, número limite de gerações $maxgen$.

Saída: soluções da fronteira Pareto-ótima limitada a $congmax$.

Gerar a população inicial P_0 de tamanho N_p usando soluções geradas aleatoriamente e soluções obtidas usando CBGA mono-objetivo .

Faça $Q_0 = \emptyset$, $R_0 = P_0 \cup Q_0$ e $t = 0$.

Enquanto não seja cumprido o critério de parada (número limite de gerações) , faça:

Verificar diversidade no espaço solução usando critério de número de bits.

Modificar as soluções que sejam necessárias para garantir diversidade.

Calcular os valores das funções objetivo: custo de investimento e congestionamento

usando as relações: $f_1 = \sum_{(i,j) \in \Omega} c_{ij} n_{ij}$ e $f_2 = \max \{r^q\}$, $q = 1, \dots, p$. Para calcular f_2 devem ser resolvidos p problemas de programação linear, onde p é o número de cenários de geração extremos e factíveis considerados.

Usando o algoritmo *fast nondominated sort*, faça a classificação das soluções em R_t , em frentes de dominação (atribuição da aptidão para as soluções de R_t) eliminando as soluções que não satisfaçam o limite *congmax* nas últimas gerações.

Geração da nova população P_{t+1} :

Faça $i = 1$ e $P_{t+1} = \emptyset$.

Enquanto $|P_{t+1}| + |F_i| < N$ faça $P_{t+1} = P_{t+1} \cup F_i$ e faça $i = i + 1$.

Ordenar as soluções do frente F_i usando o critério de distância de aglomeração.

Adicionar as melhores soluções de F_i na população P_{t+1} até obter uma população de tamanho N_p .

Aplicar os operadores genéticos para gerar Q_{t+1} :

Enquanto $|Q_{t+1}| < N_q$ faça:

Aplicar o operador de seleção por torneio usando distância de aglomeração sobre os indivíduos da população P_{t+1} .

Aplicar o operador de recombinação de um ponto usando a taxa ρ_c .

Aplicar o operador de mutação controlada usando a taxa de mutação ρ_m .

Aplicar a etapa de melhoramento usando eliminação de elementos redundantes.

Faça $R_{t+1} = P_{t+1} \cup Q_{t+1}$

$t = t + 1$ (nova geração).

5.9 Testes e resultados usando o algoritmo NSGA-II modificado ao planejamento da transmissão

Para mostrar os resultados do enfoque multiobjetivo no problema de planejamento da transmissão considerando múltiplos cenários de geração, são usados dois sistemas elétricos da literatura especializada, o sistema Garver de 6 barras e o sistema de 24 barras do IEEE (IEEE24). Os dados destes sistemas são apresentados nas seções A.1 e A.2 do apêndice A. Para resolver o problema de otimização multiobjetivo foi usado o algoritmo NSGA-II modificado, apresentado na seção (5.8). Através deste algoritmo são encontradas soluções de menor custo que a melhor solução mono-objetivo com algum grau de congestionamento. O conjunto de soluções obtidas são ordenadas em relação a seu nível de não-dominância, e se apresentam as soluções da fronteira Pareto-ótima que apresentem uma possibilidade de congestionamento menor que o maior

valor permitido *congmax*.

O problema de planejamento da transmissão multiobjetivo é resolvido então considerando incertezas na demanda das barras e na geração limite com o propósito de comparar estas soluções com as obtidas usando demanda e geração determinística. Este teste é importante, pois permite incorporar, ao modelo matemático do problema, os efeitos das incertezas dos modelos econométricos usados para realizar as projeções de demanda e da capacidade limite de geração. A inclusão das incertezas permite encontrar planos de expansão mais econômicos que os obtidos usando informação determinística, como foi mostrado em (SILVA et al., 2006).

5.9.1 Sistema Garver de 6 barras

Este sistema tem 6 barras, 15 caminhos de adição de linhas de transmissão, demanda de 760 MW e capacidade de geração de 1.110 MW. Os dados de barras e de ramos deste sistema são apresentados na seção A.1 do Apêndice A. Como foi apresentado na seção (4.4.1) o sistema Garver possui 12 cenários extremos factíveis candidatos, e destes 12 possíveis cenários, somente 4 são cenários extremos e factíveis. A Tabela 5 da seção (4.4.1) mostra estes 4 cenários. O algoritmo NSGA-II modificado é usado para resolver o problema de planejamento da transmissão considerando múltiplos cenários de geração multiobjetivo. Neste teste é usado um tamanho de população N_p de 80 indivíduos, $N_q = 10$ e $N_q = 1$, seleção por torneio com $k = 3$ indivíduos participantes por torneio, taxa de mutação do 2%, mutação controlada por corte de carga, recombinação de um ponto com $\rho_c = 98\%$, função objetivo associada á possibilidade de congestionamento considerada como o somatório dos cortes de carga que aparecem nos 4 cenários extremos factíveis ($f_2 = \sum r^q$, $q = 1, \dots, 4$) e o parâmetro *congmax* igual ao 10 % da demanda total do sistema.

Neste caso, a melhor fronteira Pareto-ótima que encontra o algoritmo NSGA-II modificado é apresentada na Figura 27.

As soluções associadas a esta fronteira Pareto-ótima são apresentadas na Tabela 7, nesta tabela aparece a solução do planejamento básico sem reprogramação da geração para este sistema, que apresenta um valor de 200, e que ao considerar múltiplos cenários de geração apresenta uma possibilidade de congestionamento de 70 MW. Também aparece a solução encontrada usando otimização mono-objetivo e múltiplos cenários de geração, e que foi mostrada na seção (4.4.1), que apresenta um custo de investimento de 268 e não produz congestionamento em nenhum cenário de geração factível. Esta solução é um extremo da fronteira Pareto-ótima.

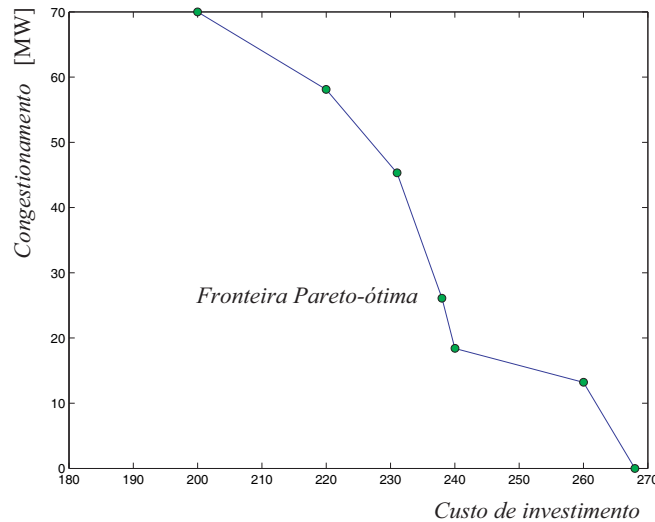


Figura 27: Fronteira Pareto-ótima para o sistema Garver.

Tabela 7: Soluções Pareto-ótimas para o sistema Garver 6 barras.

Custo	r_g [MW]	Configuração
268	0,0	$n_{2-6} = 4, n_{3-5} = 2, n_{3-6} = 1, n_{4-6} = 2$
260	13,2	$n_{1-5} = 4, n_{2-3} = 2, n_{2-6} = 1, n_{3-5} = 2, n_{4-6} = 2$
240	18,4	$n_{2-3} = 1, n_{2-6} = 4, n_{3-5} = 2, n_{4-6} = 2$
238	26,1	$n_{2-6} = 3, n_{3-5} = 2, n_{3-6} = 1, n_{4-6} = 2$
231	45,3	$n_{2-6} = 3, n_{3-5} = 1, n_{4-6} = 2, n_{5-6} = 1$
220	58,1	$n_{2-3} = 1, n_{2-6} = 4, n_{3-5} = 1, n_{4-6} = 2$
200	70,0	$n_{2-6} = 4, n_{3-5} = 1, n_{4-6} = 2$

5.9.2 Sistema IEEE de 24 barras (caso 1): maior congestionamento

Este sistema tem 24 barras, 41 caminhos de adição de linhas de transmissão, demanda de 8.550 MW e capacidade de geração de 10.215 MW. Os dados de barras e de ramos deste sistema são apresentados na seção A.2 do Apêndice A. Como foi apresentado na seção (4.4.2), o sistema IEEE de 24 barras tem 5.120 cenários extremos factíveis candidatos, e destes 5.120 possíveis cenários, somente 178 são cenários extremos e factíveis. No apêndice B mostram-se estes 178 cenários. O algoritmo NSGA-II modificado é usado para resolver o problema de planejamento da transmissão multiobjetivo considerando múltiplos cenários de geração. Neste teste é usado um tamanho de população N_p de 100 indivíduos, $N_q = 10$ e $N_q = 1$, seleção por torneio com $k = 3$ indivíduos participantes por torneio, taxa de mutação de 2%, mutação controlada por corte de carga, recombinação de um ponto com $\rho_c = 100\%$, função objetivo associada na possibilidade de congestionamento considerada como o máximo corte de carga que aparece

em um dos 178 cenários de geração extremos factíveis ($f_2 = \max \{r^q\}$, $q = 1, \dots, 178$) e o parâmetro *congmax* igual ao 5 % da demanda total do sistema.

Neste caso, a melhor fronteira Pareto-ótima que encontra o algoritmo NSGA-II modificado é apresentada na Figura 28.

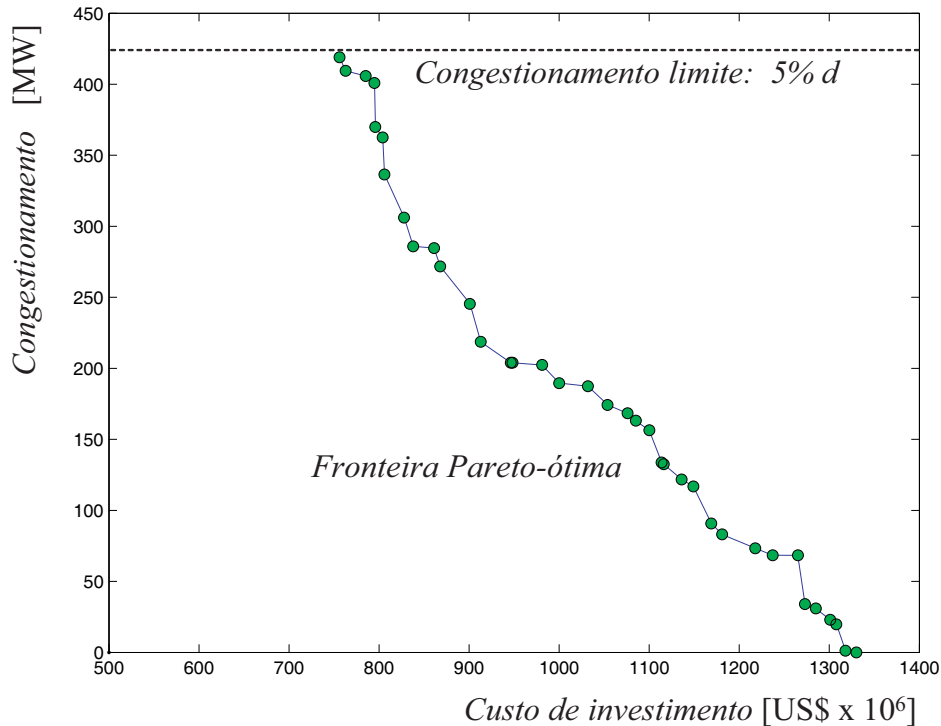


Figura 28: Fronteira Pareto-ótima para o sistema IEEE de 24 barras usando $\max \{r^q\}$.

As soluções associadas a esta fronteira Pareto-ótima são apresentadas na Tabela 8.

O valor extremo da fronteira Pareto-ótima associado ao sistema livre de congestionamento (corte de carga igual a zero) corresponde na solução ótima encontrada usando o algoritmo mono-objetivo no problema de planejamento da transmissão considerando múltiplos cenários de geração. Também são encontradas outras soluções que representam planos de expansão de menor custo de investimento e que apresentam algum nível de possibilidade de congestionamento. O plano de menor custo encontrado foi de US\$ 756.00×10^6 com uma possibilidade de congestionamento para o pior cenário de 418,99 MW. A Tabela 8 mostra os valores de custo de investimento, o maior corte de carga apresentado nos cenários onde ocorre congestionamento, o valor médio dos cortes de carga nos cenários onde ocorre congestionamento, o desvio padrão dos cortes de carga que aparecem e o número de cenários nos quais aparece corte de carga. As configurações associadas nas soluções da fronteira Pareto-ótima são mostradas na seção C.1 do Apêndice C.

Tabela 8: Informação estatística das soluções do sistema IEEE de 24 barras.

No.	Custo [US\$ $\times 10^6$]	$\max \{r^q\}$ (MW)	r_{med} (MW)	Desv. Pad.	$NE_{r \neq 0}$
1	1,330.00	0,00	0,00	0,00	0
2	1,318.00	1,49	0,00	0,09	1
3	1,308.00	21,75	0,20	1,90	2
4	1,301.00	23,19	0,33	2,54	4
5	1,285.00	31,07	0,31	2,74	4
6	1,273.00	33,97	0,95	4,59	13
7	1,265.00	68,38	7,67	19,01	30
8	1,237.00	68,39	8,00	18,94	42
9	1,218.00	73,37	8,01	19,68	33
10	1,181.00	83,01	19,48	26,71	76
11	1,169.00	90,92	19,76	27,95	75
12	1,149.00	116,72	25,39	34,50	76
13	1,136.00	116,81	31,55	39,21	82
14	1,116.00	124,89	29,66	39,20	79
15	1,114.00	126,16	29,75	39,26	79
16	1,100.00	156,46	56,70	43,77	147
17	1,085.00	162,84	33,98	44,94	95
18	1,076.00	167,92	37,77	48,46	97
19	1,054.00	173,98	36,51	49,01	95
20	1,032.00	187,31	40,31	54,58	80
21	1,000.00	189,43	41,65	55,07	81
22	981.00	202,09	38,37	50,76	83
23	948.00	203,65	41,03	51,82	98
24	946.00	203,70	43,34	55,65	84
25	913.00	209,52	72,51	83,99	98
26	901.00	248,43	46,21	58,31	84
27	868.00	269,03	87,30	96,44	136
28	861.00	292,46	150,99	97,91	166
29	838.00	292,65	150,95	97,48	166
30	828.00	305,82	140,97	96,79	159
31	806.00	333,85	142,54	94,95	166
32	804.00	362,47	130,65	97,90	159
33	796.00	369,98	131,13	99,86	159
34	795.00	400,76	164,98	93,84	170
35	785.00	401,21	181,15	142,67	159
36	763.00	409,41	182,57	141,51	166
37	756.00	418,99	168,65	106,98	168

Na Tabela 8 pode-se observar que o valor médio dos possíveis congestionamentos (cortes de carga) não é proporcional ao valor do maior congestionamento possível. Por exemplo, o plano de expansão No. 16 apresenta menor valor de $\max \{r^q\}$ que o plano de expansão No. 22 (156,46 MW < 202,09 MW), mas apresenta maior valor de r_{med} (56,70 MW > 38,37 MW). Isto

quer dizer que, de acordo com a métrica usada para a função objetivo f_2 , os valores associados e as soluções da fronteira Pareto-ótima podem mudar. Também se pode observar que o plano de expansão No. 26 apresenta maior $\max\{r^q\}$ que o plano No. 16 (248,43 MW > 156,46 MW) mas somente apresenta congestionamento em 84 dos 178 planos de expansão extremos factíveis, e o plano No. 16 apresenta congestionamento em 147 dos 178 cenários de geração extremos factíveis. Em geral, a função objetivo f_2 pode ser o valor de $\max\{r^q\}$, o valor de r_{med} , o valor do desvio padrão, o valor do número de cenários onde ocorre congestionamento ou uma combinação destes.

Na Figura 29 mostra-se um diagrama *box – plot* que proporciona uma idéia da distribuição dos cortes de carga ou possíveis congestionamentos para cada cenário de geração e para cada plano de expansão da fronteira Pareto-ótima.

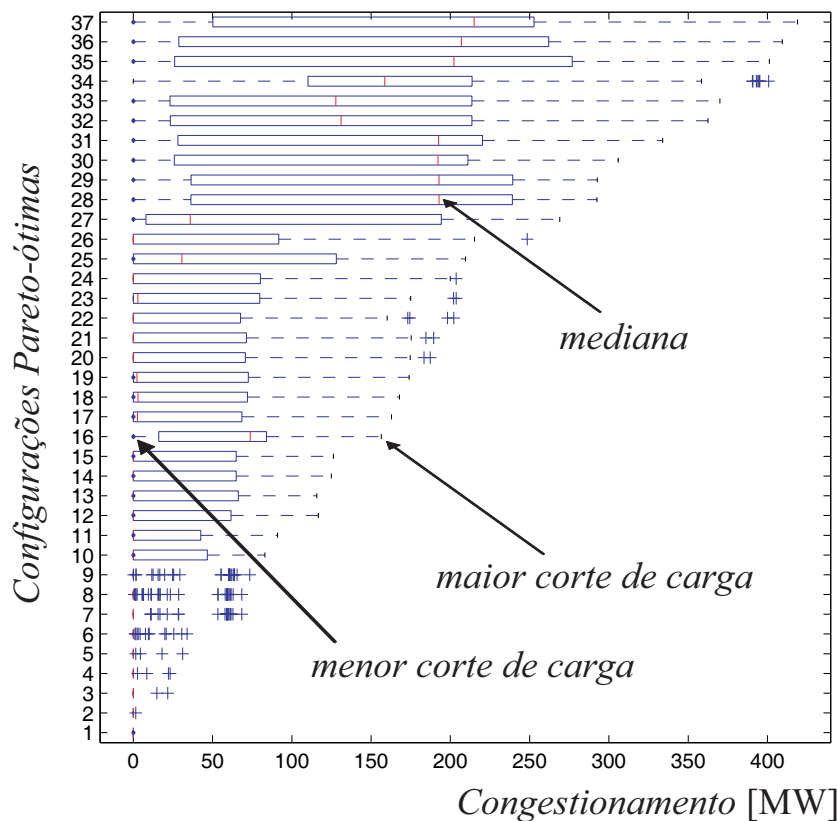


Figura 29: Diagrama box-plot com distribuição dos cortes de carga para os planos de expansão da fronteira Pareto-ótima do sistema IEEE de 24 barras com $f_2 = r_{max}$.

Pode-se observar que em todos os casos o menor corte de carga é zero. Isto é, para todos os planos de expansão existem cenários de geração onde não aparece congestionamento e um redespacho pode eliminar o congestionamento. Também pode-se observar que para os primeiros nove planos de expansão (Plano No. 1 ao plano No. 9) que não apresentam congestionamento ou apresentam congestionamento pequeno, o *box – plot* apresenta os cortes de

carga associados como atípicos ou *outliers*. Do plano No.10 em adiante, pode-se observar que existem configurações para as quais o valor da mediana (quartil Q2) é próximo a zero, indicando que uma grande quantidade de cenários de geração não apresentam congestionamento (50% dos casos ou mais). Também, pode-se observar que os planos de expansão Nos. 28, 29, 30 e 31 apresentam congestionamentos altos nos cenários onde estes ocorrem (maiores valores dos quartis Q1 e Q3) e também apresentam valores da mediana mais altos que outros cenários próximos. Finalmente, o plano No. 26 é significativamente melhor que o plano No. 27, apesar de que seus valores de $\max \{r^q\}$ serem muito próximos. A causa desta diferença, entre os dois planos, pode-se observar na Tabela 8, pois os dois planos apresentam valores similares de $\max \{r^q\}$ mas o plano No. 26 somente apresenta congestionamento em 84 dos 178 cenários extremos factíveis, e o plano No. 27 apresenta congestionamento em 136 dos 178 cenários extremos factíveis.

5.9.3 Sistema IEEE de 24 barras (caso 2): congestionamento acumulado

Este caso é similar ao caso 1 apresentado na seção anterior. A diferença entre os dois casos é que a função objetivo associada ao congestionamento do sistema é agora o corte de carga acumulado dos cenários de geração extremos factíveis para uma configuração dada, isto é, $f_2 = \sum r^q$, $q = 1, \dots, 178$. De novo, é controlado o maior valor permitido de corte de carga acumulado ao 10 % da demanda total do sistema. Os parâmetros usados para o algoritmo NSGA-II são os mesmos do caso 1.

Neste caso, a melhor fronteira Pareto-ótima que encontra o algoritmo NSGA-II modificado é apresentada na Figura 30.

As soluções associadas a esta fronteira Pareto-ótima são apresentadas na Tabela 9.

Ao considerar o congestionamento possível acumulado ($f_2 = \sum r^q$, $q = 1, \dots, 178$), a quantidade de planos de expansão que aparecem é menor e os custos associados são significativamente mais grandes. Neste caso, aparecem somente 10 planos de expansão para um congestionamento limite maior que no caso 1, já que o maior valor permitido de corte de carga acumulado mudou de 5 % da demanda total do sistema no caso 1, para 10 % no caso 2. Para o caso 2, o plano de expansão de menor custo é agora de US\$ 1241×10^6 com corte de carga acumulado de 373,1 MW. Para o caso 1, o plano de expansão de menor custo é de US\$ 756×10^6 e o valor de $\max \{r^q\}$ de 418,99 MW. O problema de planejamento da transmissão considerando múltiplos cenários de geração e congestionamento acumulado pode não ser adequado, já que todos os congestionamentos são adicionados sem considerar a probabilidade de ocorrência de cada plano de expansão, o que significa que são considerados equiprováveis. Considerar o maior

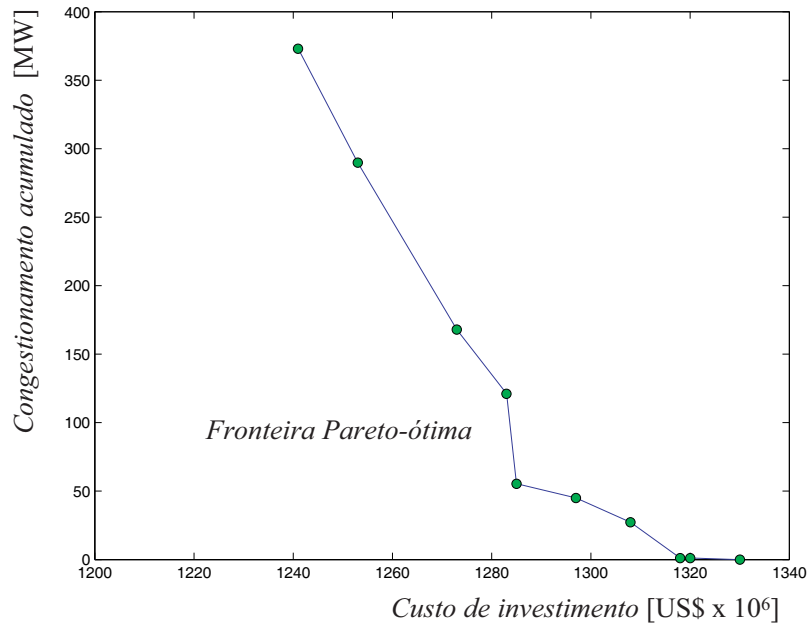


Figura 30: Fronteira Pareto-ótima para o sistema IEEE de 24 barras usando congestionamento acumulado.

Tabela 9: Informação estatística dos resultados para o sistema IEEE de 24 barras com $f_2 = \sum r^q$.

Custo [US\$ × 10 ⁶]	$\sum r^q$ (MW)
1,330.00	0,00
1,320.00	1,20
1,318.00	1,21
1,308.00	27,20
1,297.00	45,00
1,285.00	55,40
1,283.00	121,10
1,273.00	167,80
1,253.00	289,80
1,241.00	373,10

congestionamento possível (caso 1) ou o congestionamento possível médio ou o congestionamento possível médio combinado com o número de cenários onde aparece congestionamento, pode ser mais conveniente. Em consequência, o caso 2 somente se apresenta com propósitos de comparação.

5.10 Planejamento da transmissão multiobjetivo considerando incertezas e múltiplos cenários de geração

A necessidade de planejamento deriva do escopo e da complexidade do sistema elétrico, incluindo os diferentes atores responsáveis pela evolução do setor, tanto do lado da oferta quanto do lado da demanda. Os formuladores de política e as agências reguladoras são atores com grande poder sobre as variáveis do sistema. Suas decisões trazem impactos para todos os agentes e influenciam sobremaneira o futuro dos sistemas. Essas decisões, na maioria das vezes, são tomadas perante um ambiente de incertezas e necessitam de processos sistemáticos de apoio a decisão, em especial sobre as perspectivas do futuro. De fato, o futuro é incerto e não pode ser previsto com exatidão e segurança, sendo na verdade o resultado de descontinuidade, rupturas e inflexões do padrão passado, altamente influenciado por novos fatos portadores de futuro e resultado dos interesses e estratégias dos diversos atores.

As mudanças sócio-econômicas e político-institucionais que ocorrerão nas próximas décadas permitem afirmar, com razoável segurança, que a evolução futura da demanda de eletricidade, dificilmente deve seguir os padrões do passado.

Com o propósito de determinar o impacto das incertezas em demanda e geração, no custo de investimento do planejamento da expansão dos sistemas de transmissão, nesta seção propõe-se uma modelagem matemática que não considera demanda e geração determinística. Na demanda e na geração projetadas aparecem incertezas por causa da existência de diferentes elementos probabilísticos que devem ser considerados na estimação destes valores, como por exemplo: índices de crescimento da população, perdas esperadas de energia elétrica, crescimento econômico (produto interno bruto ou PIB), hidrologias, custos de combustíveis, mudança do padrão da competitividade (ex: novas tecnologias, novas fontes energéticas), penetração de energéticos substitutos (ex: gás), avanço do marco regulatório do setor de petróleo e gás, gestão ambiental restritiva, entre outros.

Como consequência do uso de variáveis probabilísticas, os valores de demanda futura e das capacidades de nova geração não são os valores determinísticos, mas a experiência mostra que os valores projetados se encontram próximos dos valores reais. Na prática, para a demanda são gerados três cenários futuros: um cenário otimista, um cenário pessimista e um cenário intermédio entre estes. A demanda futura real geralmente assume um valor entre estes três cenários.

No caso do problema de planejamento da expansão da transmissão tradicional, com frequência o método de solução adiciona durante o processo de otimização elementos (linhas ou trans-

formadores) de alto custo para atender pequenas quantidades de demanda ainda não atendidas. Estas adições podem apresentar uma alta relação custo-benefício (grandes investimentos associados a pequenos benefícios) (SILVA et al., 2006). Esta característica do planejamento tradicional é produzida por uma exigência do problema de adicionar elementos ao sistema até que **toda** a demanda seja atendida (corte de carga próximo a 0 MW). Em (SILVA et al., 2006) é mostrado que, se o modelo de planejamento da expansão não usa valores determinísticos de demanda futura, e esta se redefine como um subconjunto de valores equiprováveis em um intervalo pequeno que contem ao valor determinístico, podem-se encontrar planos de expansão do sistema de transmissão de menor custo.

O modelo de planejamento da expansão da geração elétrica, composto por usinas que usam combustíveis fósseis, usinas de energia nuclear, usinas hidroelétricas, entre outras, contem muitas incertezas também e resulta interessante determinar seu impacto no custo de investimento no problema de planejamento da expansão da transmissão. Na prática nem todas as gerações tem o mesmo nível de incerteza e se precisa de uma análise prévia das margens em que se pode encontrar a incerteza de cada usina.

Se a demanda e a geração futura, em cada barra do sistema, podem assumir qualquer valor em um intervalo de valores equiprováveis, o método de otimização identifica e promove os investimentos associados na atenção da demanda futura com probabilidade de ocorrência próxima a 1. Esta é basicamente a menor demanda do intervalo ou a demanda do cenário pessimista. A demanda futura associada a uma probabilidade de ocorrência média ou pequena, isto é, a demanda próxima ao cenário médio ou ao cenário otimista, somente será atendida se existir folga nas capacidades de transmissão dos circuitos já adicionados e que possam participar do transporte destas potências. Isto quer dizer que, demandas de valor maior que a demanda do cenário pessimista não serão atendidas, portanto, se requerem reforços adicionais. Se o crescimento futuro da demanda tende ao cenário otimista, e este não foi considerado no planejamento ao longo prazo considerando incertezas, o planejamento de curto prazo deve realizar os ajustes necessários. Desta forma, são evitados investimentos desnecessários no longo prazo.

A mesma idéia é aplicada no caso da geração futura. O método de otimização somente promove investimentos associados a geração futura com alta probabilidade de ocorrência, e a geração com pequena probabilidade de ocorrência será colocada na rede de transmissão somente se existir folga nas capacidades de transmissão já adicionadas e que possam participar do transporte destas potências. Novamente o planejamento de curto prazo deve fazer os ajustes necessários aos desvios do planejamento de longo prazo.

5.10.1 Modelagem do Problema de Planejamento de Sistemas de Transmissão considerando incertezas

Resolver o problema de planejamento da expansão de longo prazo considerando incertezas, através de técnicas de confiabilidade que usam o método de Monte Carlo, produz problemas de eficiência computacional, dada a complexidade matemática associada a considerar múltiplos cenários de geração e otimização multiobjetivo. Neste trabalho é considerada uma modelagem matemática na qual, a demanda e a geração futura podem assumir qualquer valor em um intervalo de valores equiprováveis que contem o valor determinístico de demanda e geração usado no planejamento tradicional. Desta forma são modeladas as incertezas. Nesta análise é considerada que a demanda futura na barra de carga d_i pode assumir qualquer valor no intervalo: $d_{io} - \Delta d_{io} \leq d_i \leq d_{io} + \Delta d_{io}$, onde d_{io} é o valor da demanda projetada da barra i , projetada deterministicamente. A capacidade de geração futura em cada barra de geração, também pode assumir qualquer valor no intervalo: $g_{ioma} \leq g_{imax} \leq g_{ioma} + \Delta g_{ioma}$, onde g_{ioma} é o valor da geração limite projetada na barra i .

A modelagem matemática proposta para o problema de planejamento de sistemas de transmissão considerando incerteza na demanda e na geração e considerando múltiplos cenários de geração é similar á apresentada na seção 4.2.4. As principais diferenças são:

- A função objetivo inclui os desvios entre a demanda que assume cada cenário nas barras de carga Γ , dentro do intervalo permitido, e o valor da demanda determinística definida nestas barras. A idéia é aproximar a modelagem matemática ao modelo determinístico da carga com fins de comparação.
- A função objetivo inclui os desvios entre a capacidade de geração que assume cada cenário nas barras de geração Ψ , dentro do intervalo permitido, e o valor da capacidade de geração determinística definida nestas barras. De novo, a idéia é aproximar a modelagem matemática ao modelo determinístico de geração com fins de comparação.
- A demanda em cada barra pode assumir um valor diferente no intervalo para cada cenário q . Esta consideração permite encontrar um limite inferior para os planos de expansão considerando múltiplos cenários.
- A capacidade de geração em cada barra pode assumir um valor diferente no intervalo para cada cenário q . De novo a idéia é encontrar um limite inferior para os planos de expansão considerando múltiplos cenários.

- A geração fictícia na barra i , para o cenário q , r_i^q , considera o novo limite de demanda possível nas barras.

A modelagem matemática proposta para o problema de planejamento de sistemas de transmissão considerando incerteza na demanda e na geração e considerando múltiplos cenários de geração assume então a seguinte forma:

$$\begin{aligned} \text{Min } v = & \sum_{(i,j) \in \Omega_0} c_{ij} n_{ij} + \sum_{q=1}^p \sum_{i \in \Gamma} \alpha_i r_i^q + \sum_{q=1}^p \sum_{i \in \Gamma} |d_i^q - d_{io}| \\ & + \sum_{q=1}^p \sum_{i \in \Psi} |g_{imax}^q - g_{ioma}| \end{aligned}$$

s.a.

$$Sf^q + g^q + r^q - d^q = 0$$

$$f_{ij}^q - \gamma_{ij}(n_{ij}^o + n_{ij})(\theta_i^q - \theta_j^q) = 0$$

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

$$\underline{g}_k^q \leq g_k^q \leq \bar{g}_k^q + \Delta \bar{g}_k \quad (5.16)$$

$$\bar{g}_i^q \leq g_i^q \leq \bar{g}_i^q + \Delta \bar{g}_i \quad \forall i \in \Omega_1^q \quad (5.17)$$

$$g_j^q = \underline{g}_j \quad \forall j \in \Omega_2^q \quad (5.18)$$

$$d_{io} - \Delta d_{io} \leq d_i^q \leq d_{io} + \Delta d_{io} \quad (5.19)$$

$$0 \leq r_i^q \leq d_{io} + \Delta d_{io}$$

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

$$n_{ij} \text{ inteiro; } \theta_j \text{ ilimitado}$$

$$(i, j) \in \Omega_0$$

5.10.2 Testes e resultados em planejamento da transmissão multiobjetivo considerando incertezas e múltiplos cenários de geração

Como foi apresentado na seção 4.4.2 o sistema IEEE de 24 barras possui 5.120 cenários extremos factíveis candidatos, e destes possíveis cenários, somente 178 são cenários extremos e factíveis. No apêndice B mostram-se estes 178 cenários. O algoritmo NSGA-II modificado é usado para resolver o problema de planejamento da transmissão multiobjetivo considerando múltiplos cenários de geração e considerando incerteza na demanda e na capacidade de geração. Neste teste é usado um tamanho de população N_p de 100 indivíduos, $N_q = 10$ e $N_r = 2$, seleção por torneio com $k = 3$ indivíduos participantes por torneio, taxa de mutação de 2%, mutação

controlada por corte de carga, recombinação de um ponto com $\rho_c = 100\%$, função objetivo associada na possibilidade de congestionamento considerada como o máximo corte de carga que aparece em um dos 178 cenários de geração extremos factíveis ($f_2 = \max \{r^k\}$, $k = 1, \dots, 178$), parâmetro *congmax* igual ao 5 % da demanda total do sistema, um Δd_{io} de $5\%d_{io}$, e um Δg_{iomax} de $5\%g_{iomax}$.

Para o sistema teste IEEE de 24 barras, a melhor solução encontrada sem congestionamento (sem corte de carga), usando otimização multiobjetivo apresenta um custo de 1,004 milhões de dólares, cuja configuração é apresentada a seguir:

$n_{01-02} = 1$, $n_{01-05} = 1$, $n_{03-09} = 1$, $n_{03-24} = 1$, $n_{04-09} = 1$, $n_{05-10} = 1$, $n_{06-10} = 2$,
 $n_{07-08} = 3$, $n_{08-09} = 2$, $n_{08-10} = 1$, $n_{09-11} = 1$, $n_{09-12} = 1$, $n_{10-11} = 1$, $n_{10-12} = 1$,
 $n_{11-14} = 2$, $n_{12-13} = 1$, $n_{14-16} = 1$, $n_{15-24} = 1$, $n_{16-17} = 1$, $n_{16-19} = 1$, $n_{01-08} = 1$,
 $n_{14-23} = 1$.

A solução encontrada com o algoritmo NSGA-II modificado é um ponto extremo da fronteira de Pareto, cujos valores mais representativos são apresentados na Figura 31. Nesta figura é apresentada também a fronteira de Pareto obtida sem considerar as incertezas na demanda e na geração, para fins de comparação.




Figura 31: Fronteira de Pareto para o sistema IEEE24 considerando MEG e incerteza na demanda e na geração.

A Tabela 10 mostra os valores característicos dos pontos da fronteira de Pareto apresentada na Figura 31. As configurações associadas são apresentadas na seção C.3 do Apêndice C.

Tabela 10: Características da fronteira de Pareto para o sistema IEEE24 considerando MEG e incertezas.

No.	Custo [US\$ $\times 10^6$]	$\max\{r^q\}$ (MW)	r_{prom} (MW)	Desv. Pad.	$NE_{r \neq 0}$
1	1004	0	0,00	0,00	0
2	973	2,243840877	0,02	0,23	2
3	971	2,720762089	0,03	0,26	2
4	956	19,789710750	0,16	1,60	2
5	945	34,117439470	0,27	2,78	2
6	921	35,007429140	0,25	2,70	2
7	903	44,232048020	1,03	4,74	18
8	882	47,655017660	0,60	5,09	4
9	864	54,420081700	2,66	8,92	18
10	846	60,399465400	3,34	11,63	18
11	830	67,824651390	3,83	12,22	26
12	824	98,877395660	4,15	15,06	19
13	810	108,991947600	6,30	19,46	26
14	797	118,225613200	14,50	33,76	41
15	781	124,339806200	15,24	34,90	41
16	773	149,810272500	19,99	40,96	47
17	767	183,472764800	24,37	44,87	74
18	757	205,494282900	27,94	51,68	77
19	738	215,770603600	61,61	82,68	70
20	735	245,086750000	79,31	86,08	103
21	722	248,266221300	71,68	84,15	92
22	708	257,093333400	52,41	74,67	99
23	685	259,950130800	75,79	93,98	90
24	662	264,721155500	80,78	99,23	90
25	634	303,516991700	68,21	84,43	109
26	633	314,746035000	81,76	96,38	120
27	614	315,286320200	82,11	96,83	119
28	607	350,224942500	120,36	142,90	105
29	596	360,532964800	95,76	104,87	127
30	571	368,131785900	103,58	114,09	129
31	561	410,449763700	129,50	150,62	106
32	558	410,539125800	129,38	150,63	106
33	541	424,200586800	136,99	152,19	117
34	538	424,223261300	136,89	152,22	118

Ao comparar as fronteiras de Pareto obtidas para o sistema IEEE de 24 barras com múltiplos cenários de geração, com ou sem incertezas na demanda e na geração, pode-se observar que o custo de investimento é menor quando são consideradas incertezas. Neste teste foi considerado somente o critério do maior corte de carga que aparece nos cenários de geração como métrica para medir o grau de congestionamento. Outros testes podem ser realizados usando outras

métricas que não são consideradas nesta tese.

Na Figura 32 mostra-se o diagrama *boxplot* que permite observar o comportamento estatístico das soluções da fronteira de Pareto obtida. Pode-se observar que para todos os planos de expansão encontrados, o menor corte de carga (congestionamento possível) é zero, que o valor médio dos cortes de carga são em geral pequenos (linha nas caixas), que para os cenários 1 a 19 a mediana é zero, o que se interpreta como que um alto número de cenários em que estas configurações apresentam corte de carga zero. Finalmente, pode-se observar que o valor do maior corte de carga não necessariamente é uma medida do grau do congestionamento global para cada configuração. Outras pesquisas podem indagar sobre este aspecto.




Figura 32: Diagrama box-plot com distribuição dos cortes de carga para os planos de expansão da fronteira Pareto-ótima do sistema IEEE de 24 barras com $f_2 = r_{max}$ e incertezas.

Finalmente, para fins de comparação, inclui-se o resultado de planejar o sistema de transmissão considerando contingências simples (n-1), para determinar o custo associado a obter um ade-

quado nível de confiabilidade no sistema. Como se mostra em (GALLEGO, 2005), para o sistema teste IEEE de 24 barras, a solução ótima do problema de planejamento da expansão da transmissão, considerando contingências, é de 441 milhões de dólares, e devem-se adicionar as seguintes linhas:

$$n_{01-05} = 1, n_{03-24} = 1, n_{04-09} = 1, n_{06-10} = 2, n_{07-08} = 2, n_{10-11} = 1, n_{11-13} = 1, n_{14-16} = 1, n_{15-24} = 1, n_{16-17} = 1.$$

Todas estas linhas estão contidas, por exemplo, na solução ótima alternativa 1, apresentada para o problema de planejamento considerando múltiplos cenários de geração (seção 4.4.2). Isto quer dizer que, a solução do problema de planejamento livre de congestão inclui a solução de planejamento considerando contingências. Pode-se dizer então que, dos 1.330 milhões de dólares que são requeridos para obter um sistema livre de congestionamento, 441 milhões de dólares são necessários para cumprir a condição de contingências simples, obrigatórias para os sistemas elétricos. Pode-se dizer também que, realmente o valor associado a eliminar o congestionamento do sistema corresponde a parcela: (1.330-441) milhões de dólares, ou seja, 889 milhões de dólares.

Considerando a melhor solução, obtida ao incluir incertezas na demanda e na geração, o plano de expansão muda de 1.330 milhões de dólares para 1.004 milhões de dólares. Apresenta-se uma redução do custo de expansão como resultado de considerar as incertezas na demanda e na geração, mostrando a potencialidade de considerar estas incertezas no planejamento. A Figura 33 mostra os resultados comparativos.

Na Figura 33, PT representa o valor do planejamento tradicional, o qual é tomado como referência. PS representa o valor do planejamento considerando segurança ou contingências simples. PC mostra o valor do planejamento considerando o sistema futuro livre de congestionamento usando otimização mono-objetivo. PCI mostra o valor do planejamento sem congestionamento e incluindo as incertezas na demanda e na geração. PCMO mostra o valor do planejamento com algum grau de congestionamento (5% da demanda total) e sem incertezas, encontrado usando otimização multiobjetivo. Finalmente, PCIMO mostra o valor do planejamento com algum grau de congestionamento (5% da demanda total) e considerando incertezas, encontrado usando otimização multiobjetivo. Pode-se ver que o caso PCIMO é similar em custo ao caso PS, que representa o valor de planejamento considerando contingências simples.

Finalmente, a solução do problema de planejamento da expansão da transmissão livre de congestionamento, permite determinar o nível de exigência que os cenários de geração produzem sobre o conjunto de configurações alternativas obtidas através da otimização multiobjetivo.

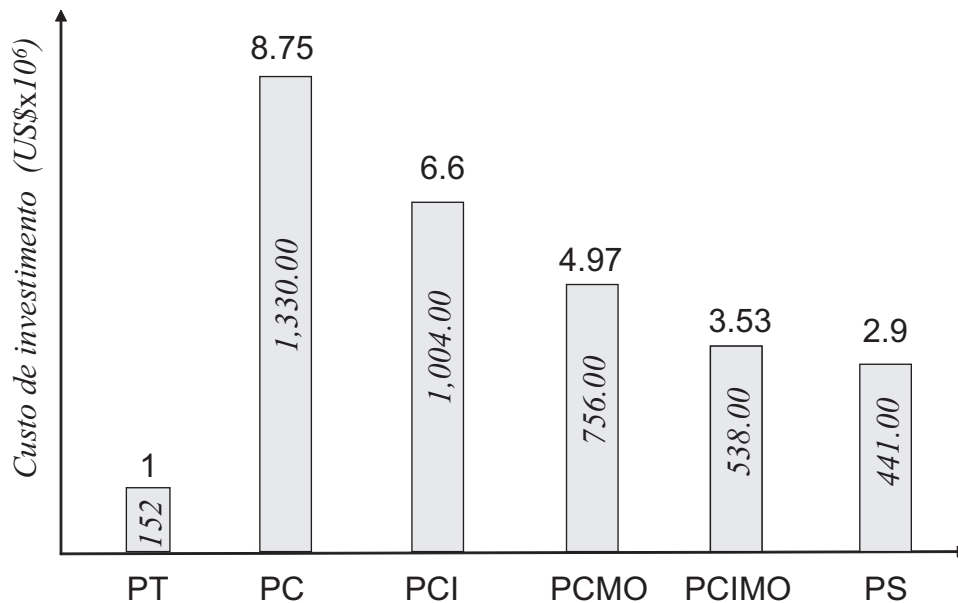


Figura 33: Resultados comparativos dos diferentes tipos de planejamento.

Na Figura 34 mostra-se de forma geral o corte de carga ou demanda não-atendida por problemas de congestionamento, que cada cenário extremo e factível de geração produz em cada uma das 37 configurações da Fronteira Pareto-ótimo apresentadas na seção C.1 do Apêndice C. Pode-se observar que os cortes de carga nas primeiras 6 configurações, produzidos por problemas de congestionamento, são pequenos em praticamente todos os cenários de geração extremos e factíveis. Pode-se ver também que alguns cenários de geração extremos são mais exigentes que outros, o que permite valorar a importância das adições de acordo com a probabilidade de ocorrência dos cenários críticos de geração. Por exemplo, o cenário de geração No. 40 mostra ser o cenário mais exigente para os diferentes planos de expansão da transmissão, já que apresenta corte de carga em 36 das 37 alternativas de solução. Somente não apresenta corte de carga por congestionamento o caso da solução ótima de 1.330 milhões de dólares. A Tabela 11 mostra este cenário.

Tabela 11: Cenário de geração extremo crítico (cenário 40).

Barra	Geração (MW)	Barra	Geração (MW)
1	0	16	465
2	0	18	1.200
7	387	21	1.200
13	1.773	22	900
15	645	23	1.980

De outro lado, o cenário de geração No. 28 somente apresenta corte de carga por limitações

de transmissão em 2 das 37 configurações do frente Pareto-ótimo (as configurações No. 34 e No. 35 da Tabela 8). A Tabela 12 mostra este cenário. Na Figura 35 apresenta-se um gráfico ampliado onde pode-se ver com mais detalhe os cortes de carga para os cenários 28 e 40.

Tabela 12: Cenário de geração extremo pouco crítico (cenário 28).

Barra	Geração (MW)	Barra	Geração (MW)
1	0	16	465
2	576	18	1.200
7	711	21	1.200
13	1.773	22	0
15	645	23	1.980

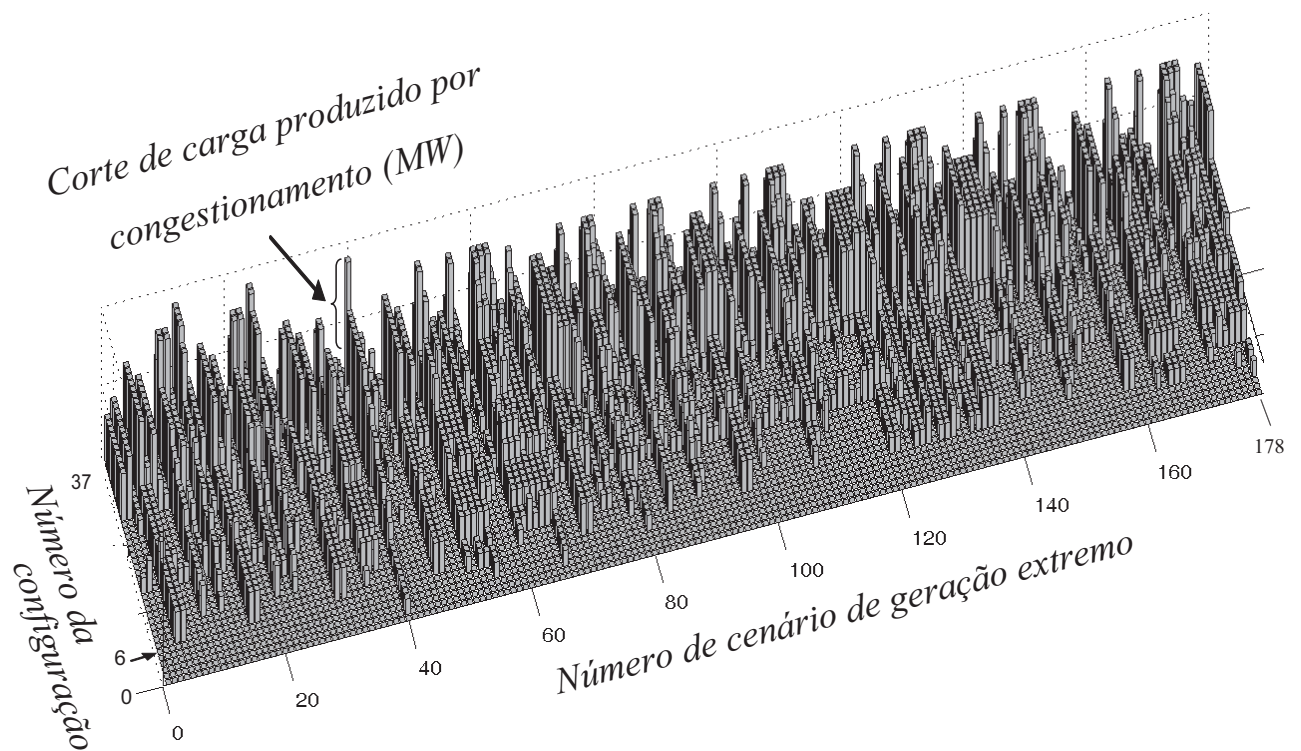


Figura 34: Distribuição dos cortes de carga para os planos de expansão da fronteira Pareto-ótima do sistema IEEE de 24 barras com $f_2 = r_{max}$.

Similarmente, a Figura 34 mostram-se outros cenários de geração críticos os quais podem ser analisados para determinar as características similares entre eles. Por exemplo, os cenários de geração 4, 5, 16, 17, 30, 31, e 40 entre outros, são críticos já que apresentam corte de carga por congestionamento em 31 das 37 configurações da fronteira Pareto-ótima. Nos sistemas reais, a cada cenário extremo e factível pode ser associada uma probabilidade de ocorrência para

reduzir ou não o impacto destes cenários críticos no custo do plano de expansão final. A seguir são apresentados os cenários extremos e factíveis de geração e o número de configurações onde estes apresentam corte de carga por congestionamento. Os cenários referenciados aparecem no Apêndice B.

$c_{001} = 11, c_{002} = 11, c_{003} = 13, c_{004} = 31, c_{005} = 31, c_{006} = 12, c_{007} = 11, c_{008} = 11,$
 $c_{009} = 28, c_{010} = 21, c_{011} = 21, c_{012} = 28, c_{013} = 11, c_{014} = 11, c_{015} = 12, c_{016} = 31,$
 $c_{017} = 31, c_{018} = 12, c_{019} = 11, c_{020} = 11, c_{021} = 28, c_{022} = 20, c_{023} = 23, c_{024} = 28,$
 $c_{025} = 12, c_{026} = 12, c_{027} = 03, c_{028} = 02, c_{029} = 13, c_{030} = 31, c_{031} = 31, c_{032} = 12,$
 $c_{033} = 12, c_{034} = 12, c_{035} = 29, c_{036} = 28, c_{037} = 28, c_{038} = 10, c_{039} = 06, c_{040} = 36,$
 $c_{041} = 11, c_{042} = 11, c_{043} = 07, c_{044} = 02, c_{045} = 06, c_{046} = 31, c_{047} = 31, c_{048} = 12,$
 $c_{049} = 11, c_{050} = 07, c_{051} = 31, c_{052} = 28, c_{053} = 31, c_{054} = 29, c_{055} = 33, c_{056} = 16,$
 $c_{057} = 14, c_{058} = 07, c_{059} = 14, c_{060} = 30, c_{061} = 28, c_{062} = 28, c_{063} = 28, c_{064} = 28,$
 $c_{065} = 28, c_{066} = 35, c_{067} = 12, c_{068} = 16, c_{069} = 11, c_{070} = 31, c_{071} = 31, c_{072} = 12,$
 $c_{073} = 20, c_{074} = 27, c_{075} = 28, c_{076} = 13, c_{077} = 11, c_{078} = 30, c_{079} = 28, c_{080} = 31,$
 $c_{081} = 12, c_{082} = 14, c_{083} = 11, c_{084} = 31, c_{085} = 12, c_{086} = 16, c_{087} = 12, c_{088} = 11,$
 $c_{089} = 30, c_{090} = 28, c_{091} = 12, c_{092} = 12, c_{093} = 16, c_{094} = 11, c_{095} = 16, c_{096} = 31,$
 $c_{097} = 31, c_{098} = 12, c_{099} = 13, c_{100} = 27, c_{101} = 12, c_{102} = 11, c_{103} = 12, c_{104} = 16,$
 $c_{105} = 14, c_{106} = 15, c_{107} = 21, c_{108} = 30, c_{109} = 27, c_{110} = 13, c_{111} = 22, c_{112} = 16,$
 $c_{113} = 12, c_{114} = 12, c_{115} = 12, c_{116} = 16, c_{117} = 11, c_{118} = 12, c_{119} = 12, c_{120} = 31,$
 $c_{121} = 31, c_{122} = 16, c_{123} = 28, c_{124} = 31, c_{125} = 31, c_{126} = 31, c_{127} = 18, c_{128} = 31,$
 $c_{129} = 31, c_{130} = 31, c_{131} = 30, c_{132} = 27, c_{133} = 31, c_{134} = 31, c_{135} = 31, c_{136} = 31,$
 $c_{137} = 31, c_{138} = 13, c_{139} = 12, c_{140} = 12, c_{141} = 12, c_{142} = 24, c_{143} = 28, c_{144} = 13,$
 $c_{145} = 11, c_{146} = 13, c_{147} = 11, c_{148} = 11, c_{149} = 30, c_{150} = 28, c_{151} = 12, c_{152} = 22,$
 $c_{153} = 11, c_{154} = 12, c_{155} = 07, c_{156} = 02, c_{157} = 06, c_{158} = 31, c_{159} = 31, c_{160} = 12,$
 $c_{161} = 07, c_{162} = 07, c_{163} = 31, c_{164} = 28, c_{165} = 31, c_{166} = 31, c_{167} = 32, c_{168} = 16,$
 $c_{169} = 11, c_{170} = 07, c_{171} = 07, c_{172} = 30, c_{173} = 28, c_{174} = 28, c_{175} = 28, c_{176} = 29,$
 $c_{177} = 28, c_{178} = 31,$

Outra observação que pode ser feita em relação a Figura 34, é que para todos os planos de expansão da fronteira Pareto-ótima existem cenários de geração alternativos que não produzem corte de carga, ou seja, que sempre é possível eliminar o congestionamento produzido por um cenário de geração através de um redespacho.

Ao analisar as primeiras quinze configurações da fronteira Pareto-ótima, os cenários de geração mais críticos, do ponto de vista da magnitude do corte de carga que apresentam e do ponto de vista do número de configurações em que estes cenários apresentam corte de carga,

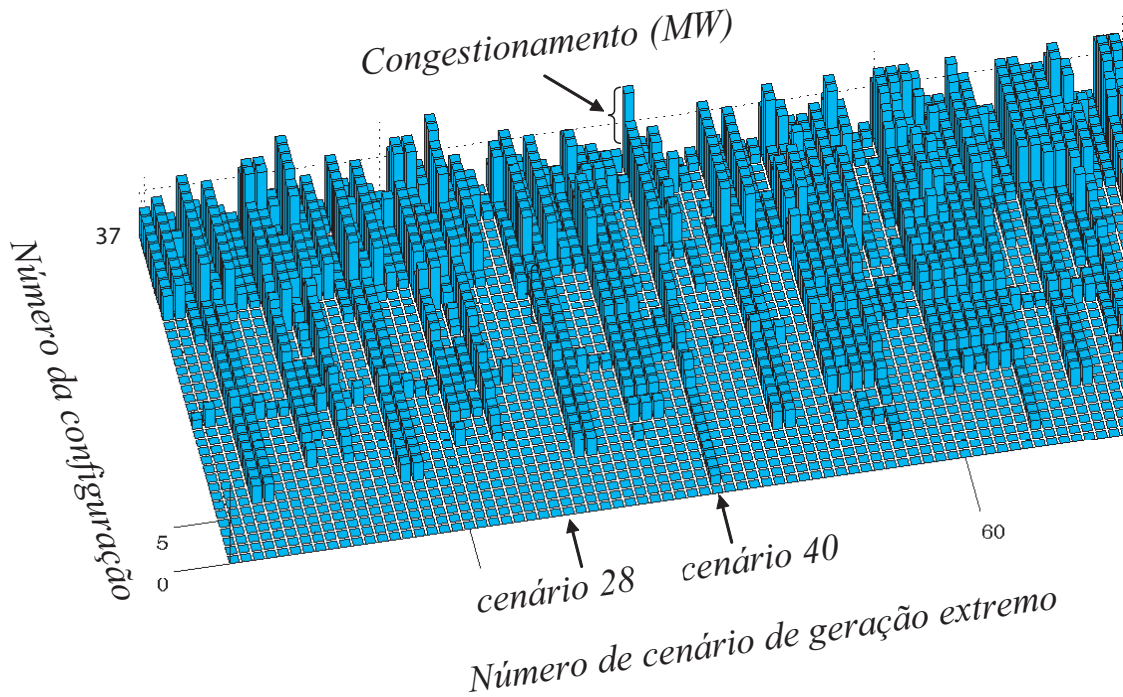


Figura 35: Distribuição dos cortes de carga para os cenários 28 e 40 com $f_2 = r_{max}$.

são as apresentadas na Tabela 13. Nesta tabela, é usada a seguinte nomenclatura:

- **a: ajustável**: Indica que o gerador é programado num valor entre seu limite inferior e seu limite superior de tal forma que permita obter o balanço de potência ativa entre a geração total e demanda total do sistema (gerador livre).
- **i: inferior**: Indica que o gerador se encontra programado em sua potência mínima (limite inferior).
- **s: superior**: Indica que o gerador se encontra programado em sua potência máxima (limite superior).

Pode-se observar que os cenários críticos estão relacionados, em geral, com uma pequena potência programada nos geradores G_{01} , G_{02} , G_{07} e G_{16} , associada a uma grande potência programada nos geradores G_{13} , G_{15} , G_{18} , G_{21} , G_{22} e G_{23} .

Testes adicionais mostram que, se um plano de expansão apresenta corte de carga, por causa do congestionamento no sistema de transmissão, num número determinado de planos

Tabela 13: Cenários de geração mais críticos para as primeiras 15 configurações.

No. Cenário	Barra de Geração									
	01	02	07	13	15	16	18	21	22	23
12	a	i	i	s	s	s	s	s	s	s
24	i	a	i	s	s	s	s	s	s	s
40	i	i	a	s	s	s	s	s	s	s
55	s	s	s	a	s	i	s	s	s	s
66	s	s	s	a	s	s	s	s	s	s
80	i	i	s	s	a	s	s	s	s	s
89	s	i	i	s	s	a	s	s	s	s
167	s	s	s	s	s	i	s	s	s	a
178	s	s	s	s	s	s	s	s	s	a

de expansão extremos e factíveis, a percentagem de planos extremos com congestionamento sempre é maior que a percentagem de planos não-extremos factíveis para os quais aparece congestionamento. Por exemplo, o plano de expansão no. 6, da Tabela 8, apresenta congestionamento em 13 dos 178 cenários extremos e factíveis de geração: 7,3% dos casos. Quando é gerado um número grande e aleatório de planos de geração não-extremos e factíveis (120.000), com distribuição de probabilidade uniforme. Este plano de expansão apresenta congestionamento somente o 1,1% dos casos. Outra característica interessante é que o valor do maior corte de carga para os cenários extremos, corresponde a 33,97 MW, enquanto que o maior corte de carga, para os cenários não extremos gerados aleatoriamente e com distribuição uniforme, é de 10,26 MW. Isto quer dizer que, os planos de expansão do sistema de transmissão apresentam menor corte de carga e menor número de casos com congestionamento quando são considerados cenários não-extremos que quando são considerados os cenários extremos.

A Tabela 14 mostra a percentagem de casos em que aparece congestionamento, tanto para cenários extremos e factíveis, como para cenários não-extremos e factíveis. Também é mostrado o maior corte de carga que aparece por congestionamento da rede de transmissão, nos dois casos. Somente são apresentados os casos dos primeiros 9 planos de expansão da fronteira Pareto-ótima obtida considerando a função objetivo $f_2 = r_{max}$.

5.11 Conclusões parciais

- Do ponto de vista prático, pode ser mais interessante ter uma solução que apresente algum grau de congestionamento, sempre que o custo de investimento possa ser recuperado. Neste contexto, a otimização multiobjetivo resulta interessante, pois permite obter

Tabela 14: Congestionamento para cenários extremos e não extremos com $f_2 = r_{max}$.

No.	Custo [10 ⁶ U\$]	% cenários extremos com congestionamento	$\max \{r^q\}$ (MW)	% cenários não extremos com congestionamento	$\max \{r^q\}$ (MW)
1	1,330.00	0,00	0,00	0,00	0,00
2	1,318.00	0,56	1,49	0,00	0,00
3	1,308.00	1,12	21,75	0,48	7,05
4	1,301.00	2,24	23,11	1,14	9,63
5	1,285.00	2,24	30,82	0,83	8,21
6	1,273.00	7,30	36,51	1,10	10,26
7	1,265.00	16,85	68,37	3,66	19,51
8	1,237.00	23,59	68,39	4,05	18,50
9	1,218.00	18,53	73,37	4,24	19,31

um conjunto de planos de expansão com diferentes níveis de congestionamento, e um **tomador de decisões** (*decision maker*) pode selecionar o plano mais conveniente a partir deste e outros critérios.

- Usar o maior congestionamento: $f_2 = r_{max}$ como uma das funções objetivo do problema de expansão multiobjetivo considerando múltiplos cenários de geração, pode ser adequado para obter uma medida do congestionamento futuro possível associado a um plano de expansão. Outras formas de medir este congestionamento futuro é usando o valor médio de congestionamento, o número de cenários onde aparece congestionamento, o valor do desvio padrão ou combinações destas, podem também ser interessantes e consideradas em futuras pesquisas. O valor do congestionamento acumulado: $f_2 = \sum r^q$, $q = 1, \dots, p$, não resulta conveniente, e foi usado somente com propósitos de comparação.
- Ao planejar redes de transmissão livres de congestionamento, podem-se identificar cenários críticos de geração, adições que aparecem em todos os cenários críticos de geração, circuitos que resultam mais exigidos pelos cenários de geração, entre outros aspectos. Neste trabalho foi mostrado que ao considerar somente os quinze primeiros planos de expansão da fronteira Pareto-ótima obtida considerando até 5% de congestionamento e $f_2 = r_{max}$, para o sistema teste IEEE de 24 barras, nos cenários críticos podem ser identificados e analisadas algumas características semelhantes entre eles, relacionadas com a programação do despacho dos geradores.
- Os cenários de geração extremos factíveis são mais restritos que os cenários de geração não-extremos e factíveis. Testes feitos com as configurações da fronteira Pareto-ótima

mostram que, para um plano de expansão que apresenta congestionamento, existe mais porcentagem de cenários extremos factíveis com congestionamento (tomando os 178 cenários extremos como 100%) que a porcentagem de cenários não-extremos factíveis com congestionamento (tomando 120.000 casos gerados aleatoriamente como 100%). Também, o valor do maior corte de carga, para os cenários extremos, resulta ser superior ao maior corte de carga dos cenários não-extremos gerados aleatoriamente e com distribuição uniforme. Isto quer dizer que, os planos de expansão do sistema de transmissão apresentam menor corte de carga e menor número de casos com congestionamento quando são considerados cenários não-extremos que quando são considerados os cenários extremos.

- Em o sistema IEEE de 24 barras, usado neste trabalho para realizar planejamento da expansão da rede transmissão livre de congestionamento, a desplanificação retira relativamente poucos circuitos, como foi mostrado no capítulo 3. Considerar desplanificação não resulta interessante neste caso. Para sistemas reais com redes de transmissão planejadas no passado em condições onde não foi considerado mercado de eletricidade, ou em condições não-ótimas, a redução do custo de investimento pode ser maior e pode resultar interessante considerar a desplanificação quando é realizado planejamento da expansão da rede de transmissão livre de congestionamento.

6 *Conclusões*

- Na primeira parte deste trabalho foi proposta uma etapa de identificação dos circuitos da rede atual que podem produzir um impacto negativo no custo de investimento do planejamento da expansão da transmissão. Como foi mostrado, a retirada de operação de alguns circuitos da rede atual, no futuro, pode reduzir o custo da expansão da rede de transmissão. Para o sistema elétrico colombiano de 93 barras, o custo de investimento usando planejamento tradicional é de 560 milhões de dólares e considerando a desplanificação o custo do plano de expansão básico diminui a 528,5 milhões de dólares, isto significa 94,3% do custo do planejamento tradicional. Este resultado mostra esta opção como atrativa dentro de um problema mais geral onde se devem considerar outras adições, por exemplo, para resolver o problema de planejamento considerando contingências ou considerando múltiplos cenários de geração. Nestes casos, a redução de custos pode ser maior.
- O problema de planejamento da expansão da transmissão considerando a retirada de circuitos da rede atual não se mostra interessante para casos em que o problema termina com a decisão da desplanificação, pois alguns aspectos não terminam resolvidos, por exemplo: como recuperar os custos de investimento dos circuitos retirados? Estes elementos podem ser definitivamente retirados do sistema ou simplesmente devem permanecer inativos durante a operação normal? Antes de definir a retirada destes circuitos deve-se fazer uma análise de segurança do sistema? Na verdade, se a desplanificação é uma etapa inicial de outro estudo, por exemplo planejamento com múltiplos cenários de geração, alguns destes circuitos retirados podem ser novamente incorporados ao sistema, o que significa que não devem ser retirados finalmente. A decisão sobre os circuitos que realmente devem ser retirados de operação (e que devem permanecer disponíveis na rede) tem de ser tomada do ponto de vista econômico, isto quer dizer que, se os custos de recuperação dos investimentos dos circuitos retirados é menor que a diferença entre o planejamento sem desplanificação e o planejamento com desplanificação, esta opção pode ser considerada atraente.
- Os testes experimentais realizados durante o desenvolvimento desta tese, mostram que é

possível encontrar uma rede de transmissão livre de congestionamento e de custo mínimo. Do ponto de vista matemático, os infinitos cenários factíveis que podem aparecer durante a operação, em um sistema de transmissão, podem ser adequadamente representados por um subconjunto de cenários, chamados de cenários extremos factíveis, os quais permitem a implementação prática deste problema de planejamento. Em consequência, o conceito de cenário extremo factível permite avançar na solução do problema de congestionamento das redes de transmissão futuras. Para o sistema teste IEEE de 24 barras foi mostrado que 178 cenários de geração podem representar adequadamente os infinitos cenários factíveis de geração que podem ser programados no sistema. Testes posteriores realizados usando um número suficiente de cenários não-extremos factíveis, gerados aleatoriamente e com distribuição uniforme, não apresentam congestionamento para a rede livre de congestionamento obtida usando os 178 cenários. Também foi mostrado que os cenários extremos factíveis são mais restritos que os cenários não-extremos factíveis, e que os valores esperados de congestionamento para cenários extremos resultam ser maiores que os valores esperados de congestionamento para cenários não-extremos.

- O custo associado para eliminar completamente o congestionamento na rede de transmissão, pode resultar economicamente inadequado. No caso do sistema IEEE de 24 barras o custo do planejamento tradicional é de 152 milhões de dólares e o custo do planejamento sem congestionamento é de 1.330 milhões de dólares. A idéia deste trabalho é mostrar quanto pode ser o custo associado para eliminar completamente o congestionamento em um sistema elétrico. Se a diferença entre estes custos pode ser recuperada através da eliminação de custos de congestionamento futuro, o plano de expansão será economicamente possível, caso contrário, simplesmente este estudo permite obter uma medida de adequação em que o sistema se encontra, do ponto de vista do livre acesso. Deve-se ter em conta que realmente, parte dos 1.330 milhões de dólares correspondem ao custo obrigatório associado às contingências simples. Neste caso, resulta mais adequado considerar como o valor para eliminar completamente o congestionamento o custo das linhas que aparecem no planejamento considerando congestionamento e que não aparecem no planejamento considerando contingências.
- Ao planejar redes de transmissão livres de congestionamento, podem-se identificar cenários críticos de geração, adições que aparecem em todos os cenários críticos de geração, circuitos que resultam mais exigidos pelos cenários de geração, entre outros aspectos. Neste trabalho foi mostrado que ao considerar somente os quinze primeiros planos de expansão da fronteira Pareto-ótima obtida considerando até um 5% de congestionamento e $f_2 = r_{max}$, para o sistema teste IEEE de 24 barras, os cenários críticos podem ser

identificados e analisadas algumas características similares entre eles, relacionadas com a programação do despacho dos geradores.

- Do ponto de vista prático pode ser mais interessante ter uma solução que apresente algum grau de congestionamento, sempre que o custo de investimento possa ser recuperado. Neste contexto, a otimização multiobjetivo resulta interessante, pois permite obter um conjunto de planos de expansão com diferentes níveis de congestionamento, e um **toma-dor de decisões** (*decision maker*) pode selecionar o plano mais conveniente a partir deste e outros critérios.
- Considerar as incertezas na demanda e na geração também resulta interessante do ponto de vista da redução dos custos de investimento associados a obter um sistema livre de congestionamento. O uso de otimização multiobjetivo considerando incertezas e sistema livre de congestionamento, permite obter um conjunto de alternativas com diferentes graus de congestionamento e valores de investimento mais facilmente recuperáveis no futuro. O algoritmo multiobjetivo se mostra como uma ferramenta interessante para aproximar os sistemas reais às condições ideais de livre congestionamento, pois pode resultar economicamente inviável eliminar completamente o congestionamento no sistema futuro.
- Do ponto de vista das metodologias usadas para resolver os problemas matemáticos resultantes, pode se dizer que o algoritmo genético de Chu-Bealey combinado com uma técnica de programação linear, resulta ser eficiente na solução de problemas de planejamento da expansão dos sistemas de transmissão mono-objetivos. Isto é especialmente importante em problemas onde é importante ter soluções de alta qualidade em tempos computacionais pequenos, como o caso do problema multiobjetivo considerando múltiplos cenários de geração, onde a metodologia deve resolver um número muito elevado de casos cada vez. A separação do problema em um subproblema de investimento e um subproblema de operação (PL) resulta ser uma alternativa interessante para resolver problemas de grande porte e que fazem parte dos chamados problemas NP-completos.
- Para o problema de planejamento multiobjetivo, o algoritmo NSGA-II modificado resulta ser eficiente na busca das soluções da fronteira de Pareto, quando são considerados múltiplos cenários de geração. Teste iniciais mostram pobre desempenho quando se usa o algoritmo NSGA-II básico, e um alto desempenho ao introduzir as modificações apresentadas na seção 5.8. Um aspecto importante é introduzir algumas particularidades dos sistemas elétricos como a relação entre o corte de carga associado a uma configuração e a quantidade de circuitos que devem ser adicionados ou retirados. Também é importante o módulo de melhoria local, no qual são usados algoritmos heurísticos construtivos para

transformar soluções infactíveis em factíveis ou reduzir o corte de carga associado a estas configurações.

- A diferença entre o planeamento tradicional e o planeamento livre de congestionamento indica que se deve fazer um grande esforço de investimento para ter um sistema eficiente do ponto de vista do mercado. No caso do sistema IEEE de 24 barras, pode-se afirmar que o sistema obtido com planeamento tradicional não apresenta uma boa adequação para condições de mercado.

Referências

ALGUACIL, N.; MOTTO, A. L.; CONEJO, A. J. Transmission expansion planning: a mixed-integer LP approach. *IEEE Transactions on Power Systems*, v. 18, n. 3, 2003.

ARROYO, J. *Heurísticas e metaheurísticas para otimização combinatória multiobjetivo*. Tese (Doutorado)- FEEC, Universidade Estadual de Campinas, 2002.

BAHIENSE, L.; OLIVEIRA, G.; PEREIRA, M.; GRANVILLE, S. A mixed integer disjunctive model for transmission network expansion. *IEEE PAS*, v. 16, n. 3, 2001.

BALDICK, R.; KAHN, E. Transmission planning issues in a competitive economic environment. *IEEE Transactions on Power Systems*, v. 8, n. 4, 1993.

BALDWIN, C.; De SALVO, C.; HOFFMAN, C.; KU, W. A model for transmission planning by logic. *AIEE Transactions PAS*, v. 79, p. 1638-1645, 1960.

BEASLEY, J.; CHU, P. C. A genetic algorithm for the generalized assignment problem. *Computers Operations Research*, 1997.

BILLINTON, R.; ALLAN, R. N. *Reliability evaluation of power systems*. New York: Plenum, 1996.

BINATO, S.; OLIVEIRA, G.; ARAUJO, J. A greedy randomized adaptive search procedure for transmission expansion planning. *IEEE Transactions on Power Systems*, v. 16, n. 2, p. 247-253, 2001.

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*, v. 16, n. 2, p. 235-240, 2001.

BJORKVOLL, T.; FLETEN, S.; NOWAK, M.; TOMASGARD, A.; WALLACE, S.; Power generation planning and risk management in a liberalized market. *IEEE PPT*, Portugal, 2001.

BOTTERUD, A.; ILIC, M.; WANGENSTEEN, I. Optimal investments in power generation under centralized and decentralized decision making. *IEEE Transactions on Power Systems*, v. 20, n. 1, 2005.

- BRAGA, A.; SARAIVA, J. T. A multiyear dynamic approach for transmission expansion planning and long-term marginal cost computation. *IEEE Transactions on Power Systems*, v. 20, n. 3, p. 1631-1639, 2005.
- CARREÑO, E. *Distribución de costos considerando cargos por uso en el proceso de la expansión de sistemas de transmisión aplicando teoría de juegos*. Dissertação (Mestrado) - Universidad Tecnológica de Pereira, 2003.
- CARRIJO, I. *Extração de regras operacionais ótimas de sistemas de distribuição de água, através de algoritmo genético multiobjetivo e aprendizagem máquina*. Tese (Doutorado) - USP São Carlos, 2004.
- CHEUNG, P. B. *Análise da reabilitação de redes de distribuição de água para abastecimento via algoritmos genéticos multiobjetivo*. Tese (Doutorado)- USP, São Carlos, 2004.
- CHOI, J.; MOUNT, T. D.; THOMAS, R. J. Probabilistic reliability criterion for planning transmission system expansions. *IEE Proceeding Generation Transmission and Distribution*, v. 153, n. 6, 2006.
- CHOI, J.; MOUNT, T. D.; THOMAS, R. J. A transmission expansion planning using contingency criteria. *IEEE Transactions on Power Systems*, v. 22, n. 4, 2007.
- CLEOBURY, E. G. Transmission planning in today's environment. *IEE Colloquium on Alternatives to More Overhead Lines*, v. 1, p. 1-10, 1993.
- COELLO, C. A. *An empirical study of evolutionary techniques for multiobjective optimization in engineering design*. Tese (Doutorado)-Tulane University, News Orleans, Louisiana, 1996.
- COELLO, C. A. Use of a self-adaptive penalty approach for engineering optimization problems. *Computers in Industry*, v. 43, 2000.
- COELLO, C. A. Theoretical and numerical constraint-handling techniques used with evolutionary algorithms: a survey of the state of the art. *Computer Methods in Applied Mechanics and Engineering*, v. 191, 2002.
- CONTRERAS, J.; WU, F. Coalition formation in transmission expansion planning. *IEEE Transactions on Power Systems*, v. 14, n. 3, p. 1144-1152, 1999.
- DAVID, A. K.; WEN, F. S. Transmission planning and investment under competitive electricity market environment. *Proceeding Of IEEE Power Engineering Society Summer Meeting*, v. 3, 2001.
- DEB, K. *Multi-objective optimization using evolutionary algorithms*. USA: John Wiley and

sons, 2001.

DEB, K.; AGRAWAL, S.; PRATAP, A.; MEYARIVAN, T. A fast and elitist multiobjective genetic algorithm. *Technical report, Indian Institute of Technology, Kanpur: Kanpur Genetic Algorithms Laboratory (KanGAL)*, 2000.

DEB, K.; AGRAWAL, S.; PRATAP, A.; MEYARIVAN, T. A fast elitist non-dominated sorting genetic algorithm for multiobjective optimization. In: *Proceedings of the Parallel Problem Solving from Nature VI*. Paris: Springer, 2000.

DECHAMPS, C.; JAMOULLE, A. Interactive computer program for planning the expansion of meshed transmission networks. *International Journal of Electrical Power and Energy Systems*, v. 2, n. 2, p. 103-108, 1980.

De OLIVEIRA, S. A. *Metaheurísticas aplicadas ao planejamento da expansão da transmissão de energia elétrica em ambiente de processamento distribuído*. Tese (Doutorado) - Universidade Estadual de Campinas, 2004.

DIOS, R. de; SOTO, F.; CONEJO, A. J. Planning to expand. *IEEE Power and Energy magazine*, v. 5, n. 6, p. 108-108, 2007.

DUSONCHET, Y. P.; EL-ABIAD, A. H. Transmission planning using discrete dynamic optimization. *IEEE Transactions On Power Apparatus and Systems*, PAS-92, n. 4, p. 1358-1371, 1973.

EHRGOTT, M. Approximation algorithms for combinatorial multicriteria optimization problems. *International Transactions in Operational Research*, v. 7, p. 1-26, 2000.

ESCOBAR, A.; GALLEGO, R. A.; ROMERO, R. Multistage and coordinated planning of the expansion of transmission systems. *IEEE Transactions on Power Systems*, v. 19, n. 2, p. 735-744, 2004.

ESCOBAR, A. H. *Planeamiento dinámico de la expansión de sistemas de transmisión usando algoritmos combinatoriales*. Dissertação (Mestrado) - Universidad Tecnológica de Pereira, 2002.

ESCOBAR, A. H.; BOLAÑOS, R. A.; CORREA, C. A. Planeamiento de la transmisión utilizando punto interior no lineal y algoritmo genético de Chu-Beasley. *Scientia et Technica, UTP-Pereira*, v. 38, 2008.

FANG, R.; HILL, D. A new strategy for transmission expansion in competitive electricity markets. *IEEE Transactions on Power Systems*, v. 18, n. 1, p. 374-380, 2003.

- FANG, R. S.; DAVID, A. K. Transmission congestion management in an electricity market. *IEEE Transactions on Power Systems*, v. 14, n. 3, p. 877-883, 1999.
- FISHER, E. B.; O'NEILL, R. P.; FERRIS, M. C. Optimal transmission switching. *IEEE Transactions on Power Systems*, v. 23, n. 3, 2008.
- FREITAS, A. *Data mining and knowledge discovery with evolutionary algorithms*. Berlin: Springer-Verlag, 2002.
- GALIANA, D.; MCGILLIS, D. T.; MARIN, M. A. Expert systems in transmission planning. *Proceeding IEEE*, v. 80, n. 5, p. 712-726, 1992.
- GALLEGO, L. A. *Planeamiento de la expansión de redes de transmisión de energía eléctrica considerando contingencias*. Dissertação (Mestrado) - Universidad Tecnológica de Pereira, 2005.
- GALLEGO, R.; MONTICELLI, A.; ROMERO, R. Tabu search algorithm for network synthesis. *IEEE Transactions on Power Systems*, v. 15, n. 2, p. 490-495, 2000.
- GALLEGO, R. A. *Planejamento a longo prazo de sistemas de transmissão usando técnicas de otimização combinatorial*. Tese (Doutorado)-FEEC DSEE Unicamp, Brasil, 1997.
- GALLEGO, R. A.; ROMERO, R.; ESCOBAR, A. Static planning of the colombian transmission system using genetic algorithms. In: *Proceeding 16th International Conference CAD/CAM*. Trinidad Tobago: U, 2000.
- GARVER, L. L. Transmission network estimation using linear programming. *IEEE Transactions on Power Apparatus and Systems*, PAS-89, n. 7, p. 1688-1697, 1970.
- GIL, H.; SILVA, E. da; GALIANA, F. Modeling competition in transmission expansion. *IEEE Transactions on Power Systems*, v. 17, n. 4, p. 1043-1049, 2002.
- GLASS, C.; POTTS, C.; SHADE, P. *Genetic algorithms and neighborhood search for scheduling unrelated parallel machines*. UK: Preprint series No.OR47, University of Southampton, 1992.
- GOLDBERG, D. E. *Genetic algorithms in search, optimization, and machine learning*. USA: AddisonWesley Longman, Inc, 1989.
- GRANELLI, G.; MONTAGNA, M.; ZANELLINI, F.; BRESESTI, P.; VAILATI, R.; INNORTA, M. Optimal network reconfiguration for congestion management by deterministic and genetic algorithms. *Electric Power System Research*, v. 76, n. 6, p. 549-556, 2006.
- GRANVILLE, S.; PEREIRA, M. *Analysis of the linearized power flow model in Benders de-*

composition. USA: EPRI-Report RP 2473-6, 1985.

HAFFNER, S. *O planejamento da expansão dos sistemas elétricos no contexto de um ambiente competitivo*. Tese (Doutorado)-Universidade Estadual de Campinas, 2000.

HAFFNER, S.; MONTICELLI, A.; GARCIA, A.; MANTOVANI, J.; ROMERO, R. Branch and bound algorithm for transmission system expansion planning using a transportation model. *Proceedings of the IEE - Generation, Transmission and Distribution*, v. 147, n. 3, p. 149-156, 2000.

HAIMES, Y.; LASDON, L.; WISMER, D. On a bicriterion formulation of the problems of integrated system identification and system optimization. *IEEE Transactions on Systems, Man, and Cybernetics*, v. 1, n. 3, p. 296-297, 1971.

HENNEY, A. A global perspective on the impact of competition on transmission. *Proceeding IEEE Colloquium on Network Pricing, Investment and Access*, v. 1, p. 1-6, 1995.

HOGAN, W. *Electricity restructuring public purposes, markets, and institutional design*. Harvard University, 2005.

HOLLAND, J. *Adaptation in natural and artificial systems*. Michigan: Ann Harbor, The University of Michigan Press, 1975.

ISHIBUCHI, H.; NAKASHIMA, T. Multi-objective pattern and feature selection by a genetic algorithm. *Proceeding GECCO*, 2000.

JONES, D. F.; MIRRAZAVI, S.; TAMIZ, M. Multi-objective metaheuristics: An overview of the current state-of-art. *European Journal of Operational Research*, v. 137, n. 1, p. 1-9, 2002.

JONG, K. A. D. *An analysis of the behavior of a class of genetic adaptive system*. Tese (Doutorado)- University of Michigan, ANN Arbor, MI, 1975.

JUNIOR, I. de J. S. *Planejamento da expansão de sistemas de transmissão considerando segurança e planos de programação da geração*. Tese (Doutorado)- Universidade Estadual de Campinas, 2005.

KALTENBATCH, J. C.; PERSON, J.; GEHRIG, E. H. A mathematical optimization technique for the expansion of electrical power transmission systems. *IEEE Transactions on Power Apparatus and Systems*, PAS 89, p. 113-119, 1970.

LATORRE, G.; CRUZ, R.; AREIZA, J.; VILLEGAS, A. Classification of publications and models on transmission expansion planning. *IEEE Transactions on Power Systems*, v. 18, n. 2, 2003.

- LU, M.; DONG, Z.; SAHA, T. A framework for transmission planning in a competitive electricity market. *IEEE/PES Transmission and Distribution Conference and exhibition: Asia and Pacific, Dalian, China*, 2005.
- LU, M.; DONG, Z.; SAHA, T. A hybrid probabilistic criterion for market-based transmission expansion planning. *IEEE Transactions on Power Systems*, v. 22, n. 4, p. 1-7, 2006.
- LU, M.; DONG, Z.; SAHA, T. A novel approach to evaluate congestion for composite power system planning in a competitive electricity market. *Power Engineering Society General Meeting*, p. 1-8, 2006.
- MEDINA, A. C. R. *Planeamiento de la expansión de sistemas de transmisión con incertidumbre en la demanda e incorporando pérdidas usando búsqueda tabú*. Dissertação (Mestrado)-Universidad Tecnológica de Pereira, 2008.
- METTE, B.; KURT, J. Benefits from coordinating congestion management - the nordic power market. *Energy Policy*, v. 35, n. 3, p. 1978-1991, 2007.
- MICHALEWICZ, Z. *Genetic algorithms + data structures: Evolution programs*. New York: Springer, 1996.
- MONTICELLI, A. *Expansão de sistemas elétricos de potencia: um algoritmo para o planejamento do sistema de transmissão*. Tese (Doutorado) - Universidade Estadual de Campinas, 1975.
- MONTICELLI, A. *Fluxo de carga em redes de energia elétrica*. Sao Paulo: Editora Edgar Bucher Ltda, 1983.
- MONTICELLI, A.; SANTOS, A.; PEREIRA, M.; CUNHA, S.; PARKER, B.; PRACA, J. Interactive transmission network planning using a least-effort criterion. *IEEE Transactions on Power Apparatus and Systems*, PAS-101, n. 10, p. 3919- 3925, 1982.
- OLIVEIRA, E. J. de; CHAVES, I.; REZENDE, J.; CARNEIRO, S. Transmission system expansion planning using a sigmoid function to handle integer investment variables. *IEEE Transactions on Power Systems*, v. 20, n. 3, p. 1616-1621, 2005.
- OSYCZKA, A. *Multicriterion optimization in engineering with FORTRAN programs*. Chichester: Ellis Horwood, 1984.
- PAPALEXOPOULOS, A. Congestion management in a competitive environment. *PICA Conference*, OH, 1997.
- PEREIRA, M. *Aplicação de análise de sensibilidade no planejamento da expansão de sistemas*

de geração/transmissão. Tese (Doutorado)-COPPE-UFRJ, 1985.

PEREIRA, M.; PINTO, L. M. Application of sensitivity analysis of load supplying capacity to interactive transmission expansion planning. *IEEE Transactions on Power Apparatus and Systems*, PAS 104, 1985.

RIDER, M.; GARCIA, A.; ROMERO, R. Power system transmission network expansion planning using ac model. *IET Generation, Transmission and Distribution*, v. 1, n. 5, p. 731-742, 2007.

RIDER, M.; GARCIA, A. V.; ROMERO, R. A. Short term transmission network expansion planning using an interior point method. *IX SEPOPE, Rio de Janeiro*, 2004.

RIDER, M. J. *Planejamento da expansão de sistemas de transmissão usando os modelos CC CA e técnicas de programação não linear*. Tese (Doutorado) - Universidade Estadual de Campinas, 2006.

ROMERO, R.; GALLEGO, R.; MONTICELLI, A. Transmission system expansion planning by simulated annealing. *IEEE Transactions on Power Systems*, v. 11, n. 1, p. 364-369, 1996.

ROMERO, R.; GALLEGO, R.; MONTICELLI, A. Transmission system expansion planning by extended genetic algorithms. *IEE Proceedings Generation, Transmission and Distribution*, v. 145, n. 3, p. 329-335, 1998.

ROMERO, R.; MONTICELLI, A. A hierarchical decomposition approach for transmission network expansion planning. *IEEE Transactions on Power Systems*, v. 9, n. 1, p. 373-380, 1994.

ROMERO, R.; MONTICELLI, A.; GARCIA, A.; HAFFNER, S. Test systems and mathematical models for transmission network expansion planning. *IEE Proceedings Generation, Transmission and Distribution*, v. 149, n. 1, p. 27-36, 2002.

ROMERO, R. A. *Planejamento da expansão de sistemas de transmissão por decomposição de Benders hierarquizada*. Dissertação (Mestrado)- Universidade Estadual de Campinas, 1989.

ROMERO, R. A. *Um método de decomposição para o planejamento a longo prazo de sistemas de transmissão*. Tese (Doutorado)-Universidade Estadual de Campinas, 1993.

ROMERO, S. P. *Decomposição lagrangeana aplicada ao problema de planejamento da expansão de sistemas de transmissão de energia elétrica considerando cenários de incertezas*. Tese (Doutorado)- Universidade Federal do Rio de Janeiro, 2007.

RUDNICK, H.; ZOLEZZI, J. Expansión de los sistemas de transmisión en mercados competi-

tivos de generación. *Actas I Reunión Internacional GT CIER 99, Optimización de los Procesos de Generación y Transmisión en Ambientes Competitivos*, Bogotá, Colombia, 1999.

SANCHEZ, I. G.; ROMERO, R.; MANTOVANI, J.; RIDER, M. Transmission expansion planning using the dc model and nonlinear programming technique. *IEE Proceeding in Generation Transmission and Distribution*, v. 152, n. 6, p. 763-769, 2005.

SAUMA, E. E.; OREN, S. S. Economic criteria for planning transmission investment in restructured electricity markets. *IEEE Transactions on Power Systems*, v. 22, n. 4, p. 1394-1405, 2007.

SCHNYDER, G.; GLAVITSCH, H. Security enhancement using an optimal switching power flow. *IEEE Transactions on Power Systems*, v. 5, n. 2, p. 674-681, 1990.

SCOTT, H.; HOGAN, S.; POPE, S. *Transmission capacity reservations and transmission congestion contracts*. Harvard University Cambridge, 1997.

SHAFFER, J. D. *Multiple Objective Optimization with Vector Evaluated Genetic Algorithms*. Tese (Doutorado)- Vanderbilt University, 1984.

SHAO, W.; VITTAL, V. Corrective switching algorithm for relieving overloads and voltage violations. *IEEE Transactions on Power Systems*, v. 20, n. 4, p. 1877-1885, 2005.

SHRESTHA, G.; FONSEKA, P. Flexible transmission and network reinforcements planning congestion alleviation. *IEE Proceeding Generation Transmission and Distribution*, v. 153, n. 5, p. 591-598, 2006.

SHRESTHA, G. B.; FONSEKA, P. A. J. Congestion-driven transmission expansion in competitive power markets. *IEEE Transactions on Power Systems*, v. 19, n. 3, p. 1658-1665, 2004.

SILVA, E. L. da; GIL, H. A.; AREIZA, J. M. Transmission network expansion planning under an improved genetic algorithm. *IEEE Transactions on Power Systems*, v. 15, n. 4, p. 1168-1175, 2000.

SILVA, I.; RIDER, M.; ROMERO, R.; GARCIA, A.; MURARI, C. Transmission network expansion planning with security constraints. *IEE Proceedings Generation, Transmission and Distribution*, v. 152, n. 6, p. 828-836, 2005.

SILVA, I.; RIDER, M.; ROMERO, R.; GARCIA, A.; MURARI, C. Transmission network expansion planning considering uncertainty in demand. *IEEE Transactions on Power Systems*, v. 21, n. 4, 2006.

STYCZYNSKI, Z. A. Power network planning using game theory. in: *Proceeding 13th Power Systems Computation Conference*, Trondheim, 1999.

SUN, E.; LIU, E. Generation asset valuation under market uncertainties. *Proceeding Power Engineering Society General Meeting*, 2007.

SUN, H.; YU, D. C. A multiple-objective optimization model of transmission enhancement planning for independent transmission company (itc). *Proceeding IEEE Power Engineering Society Summer Meeting*, v. 4, 2000.

TELLES, T.; BARBOSA, H. Inicialização da população em algoritmos genéticos com codificação real. V *Seminário sobre Elementos Finitos e Métodos Numéricos em Engenharia da UFJF, Juiz de Fora*, 1998.

TOR, O. B.; GUVEN, A. N.; SHAHIDEHPOUR, M. Congestion-driven transmission planning considering the impact of generator planning. *IEEE Transactions on Power Systems*, v. 23, n. 2, p. 781-789, 2008.

TORRE, S. de la; CONEJO, A. J.; CONTRERAS, J. Transmission expansion planning in electricity markets. *IEEE Transactions on Power Systems*, v. 23, n. 1, p. 238-248, 2008.

VILLASANA, R.; GARVER, L. L.; SALON, S. J. Transmission network planning using linear programming. *IEEE Transactions on Power Apparatus and Systems*, PAS-104, n. 2, 1985.

WHITLEY; DARREL, L. *Foundations of Genetic Algorithms*. San Francisco, USA: Morgan Kaufmann Publishers, 1993.

WIERZBICK, A. On the completeness and constructiveness of parametric characterization to vector optimization problems. *OR Spektrum*, v. 8, 1986.

WILSON, R. Architecture of power markets. Stanford University, 2001. XU, Z.; DONG, Z. Y.; WONG, K. P. Transmission planning in a deregulated environment. *IEE Proceedings Generation, Transmission and Distribution*, v. 153, n. 3, 2003.

YINGVIVATANAPONG, C.; LEE, W. J.; LIU, E. Multi-area power generation dispatch in competitive markets. *IEEE Transactions on Power Systems*, v. 23, n. 1, p. 196-203, 2008.

ZOLEZZI, J. M.; RUDNICK, H. Transmission cost allocation by cooperative games and coalition formation. *IEEE Transactions on Power Systems*, v. 17, n. 4, p. 1008-1015, 2002.

APÊNDICE A - Dados dos Sistemas Testes Utilizados

A.1 Sistema Garver de 6 barras

A.1.1 Sistema sem redespacho

Tabela 15: **Dados de barras: Garver sem redespacho.**

Barra	Geração (MW)	Carga (MW)
1	50	80
2	0	240
3	165	40
4	0	160
5	0	240
6	545	0

Tabela 16: Dados de ramos: sistema Garver.

Barra de	Barra para	n_{ij}^0	r_{ij} pu	x_{ij} pu	f_{ij}^{max} MW	c_{ij}	n_{ij}^{max}
1	2	1	0,040	0,40	100	40	5
1	3	0	0,038	0,38	100	38	5
1	4	1	0,060	0,60	80	60	5
1	5	1	0,020	0,20	100	20	5
1	6	0	0,068	0,68	70	68	5
2	3	1	0,020	0,20	100	20	5
2	4	1	0,040	0,40	100	40	5
2	5	0	0,031	0,31	100	31	5
2	6	0	0,030	0,30	100	30	5
3	4	0	0,059	0,59	82	59	5
3	5	1	0,020	0,20	100	20	5
3	6	0	0,048	0,48	100	48	5
4	5	0	0,063	0,63	75	63	5
4	6	0	0,030	0,30	100	30	5
5	6	0	0,061	0,61	78	61	5

A.1.2 Sistema com redespacho

Tabela 17: Dados de barras: Garver com redespacho.

Barra	Geração (MW)	Carga (MW)
1	150	80
2	0	240
3	360	40
4	0	160
5	0	240
6	600	0

A.2 Sistema IEEE de 24 barras

Tabela 18: Dados de barras: IEEE 24.

Barra	Geração (MW)	Carga (MW)
1	576	324
2	576	291
3	0	540
4	0	212
5	0	213
6	0	408
7	900	375
8	0	523
9	0	525
10	0	585
11	0	0
12	0	0
13	1773	795
14	0	582
15	645	951
16	465	300
17	0	0
18	1200	999
19	0	543
20	0	384
21	1200	0
22	900	0
23	1980	0
24	0	0

Tabela 19: Dados de ramos: IEEE 24.

Barra de	Barra para	n_{ij}^0	x_{ij} pu	f_{ij}^{max} MW	c_{ij} US\$	n_{ij}^{max}
1	2	1	0,0139	175	3	5
1	3	1	0,2112	175	55	5
1	5	1	0,0845	175	22	5
2	4	1	0,1267	175	33	5
2	6	1	0,192	175	50	5
3	9	1	0,119	175	31	5
3	24	1	0,0839	400	50	5
4	9	1	0,1037	175	27	5
5	10	1	0,0883	175	23	5
6	10	1	0,0605	175	16	5
7	8	1	0,0614	175	16	5
8	9	1	0,1651	175	43	5
8	10	1	0,1651	175	43	5
9	11	1	0,0839	400	50	5
9	12	1	0,0839	400	50	5
10	11	1	0,0839	400	50	5
10	12	1	0,0839	400	50	5
11	13	1	0,0476	500	66	5
11	14	1	0,0418	500	58	5
12	13	1	0,0476	500	66	5
12	23	1	0,0966	500	134	5
13	23	1	0,0865	500	120	5
14	16	1	0,0389	500	54	5
15	16	1	0,0173	500	24	5
15	21	2	0,049	500	68	5
15	24	1	0,0519	500	72	5
16	17	1	0,0259	500	36	5
16	19	1	0,0231	500	32	5
17	18	1	0,0144	500	20	5
17	22	1	0,1053	500	146	5
18	21	2	0,0259	500	36	5
19	20	2	0,0396	500	55	5
20	23	2	0,0216	500	30	5
21	22	1	0,0678	500	94	5
1	8	0	0,1344	500	35	5
2	8	0	0,1267	500	33	5
6	7	0	0,192	500	50	5
13	14	0	0,0447	500	62	5
14	23	0	0,062	500	86	5
16	23	0	0,0822	500	114	5
19	23	0	0,0606	500	84	5

A.3 Sistema colombiano de 93 barras

Tabela 20: Dados de barras: Colombia 2012.

Barra	Geração (MW)	Carga (MW)
1	240	0,00
2	165	486,66
3	0	587,08
4	0	0,00
5	40	351,42
6	34	0,00
7	136	448,03
8	230	505,87
9	0	519,69
10	0	88,84
11	108	220,15
12	47	0,00
13	0	260,08
14	0	0,00
15	0	562,84
16	0	351,90
17	35	203,00
18	540	54,10
19	1340	29,28
20	45	302,27
21	0	277,44
22	200	79,17
23	0	302,27
24	150	0,00
25	86	0,00
26	70	0,00
27	0	396,71
28	14	486,39
29	618	505,96
30	0	199,55
31	189	391,88
32	0	188,33
33	0	247,24
34	0	115,81
35	200	256,86
36	44	167,29
37	138	176,30
38	15	129,72
39	15	268,19
40	305	0,00
41	100	81,85

Tabela 20: **Dados de barras: Colombia 2012 (cont.).**

Barra	Geração (MW)	Carga (MW)
42	0	152,39
43	0	52,90
44	23	384,64
45	1208	0,00
46	150	181,62
47	0	61,60
48	885	896,26
49	0	193,27
50	240	632,75
51	0	190,45
52	0	55,6
53	320	0,00
54	0	114,19
55	40	333,59
56	0	0,00
57	130	336,94
58	190	0,00
59	160	0,00
60	1216	0,00
61	155	0,00
62	0	0,00
63	1090	52,77
64	280	132,35
65	0	197,58
66	300	0,00
67	474	397,98
68	0	0,00
69	0	106,61
70	180	0,00
71	424	471,21
72	0	0,00
73	0	0,00

Tabela 20: **Dados de barras: Colombia 2012 (cont.).**

Barra	Geração (MW)	Carga (MW)
74	0	0,00
75	0	0,00
76	40	0,00
77	0	82,85
78	0	54,07
79	300	146,87
80	0	88,34
81	0	0
82	0	0
83	0	0
84	500	0
85	0	0
86	850	0
87	0	0
88	300	0
89	0	0
90	0	0
91	0	0
92	0	0
93	0	0

Tabela 21: Dados de ramos: Colombia 2012.

Barra de	Barra para	n_{ij}^0	x_{ij} pu	f_{ij}^{max} MW	c_{ij} US\$	n_{ij}^{max}
52	88	0	0,098	300	34,190	5
43	88	0	0,1816	250	39,560	5
57	81	0	0,0219	550	58,890	5
73	82	0	0,0374	550	97,960	5
27	89	0	0,0267	450	13,270	5
74	89	0	0,0034	550	14,570	5
73	89	0	0,0246	550	66,650	5
79	83	0	0,0457	350	15,400	5
8	67	0	0,224	250	29,200	5
39	86	0	0,0545	350	9,880	5
25	28	1	0,0565	320	9,767	5
25	29	1	0,057	320	9,882	5
13	14	2	0,0009	350	3,902	5
13	20	1	0,0178	350	5,742	5
13	23	1	0,0277	350	7,007	5
14	31	2	0,1307	250	18,622	5
14	18	2	0,1494	250	20,232	5
14	60	2	0,1067	300	15,977	5
2	4	2	0,0271	350	6,662	5
2	9	1	0,0122	350	5,282	5
2	83	1	0,02	570	5,972	5
9	83	1	0,02	400	5,972	5
15	18	1	0,0365	450	7,927	5
15	17	1	0,0483	320	9,422	5
15	20	1	0,0513	320	9,652	5
15	76	1	0,0414	320	9,882	5
15	24	1	0,0145	350	5,282	5
37	61	1	0,0139	350	4,937	5
19	61	2	0,1105	250	16,092	5
61	68	1	0,0789	250	12,412	5
37	68	1	0,0544	320	9,652	5
40	68	1	0,132	320	18,162	5
12	75	1	0,0641	320	11,492	5
24	75	1	0,0161	350	5,512	5
35	36	1	0,2074	250	27,362	5
27	35	1	0,1498	250	22,072	5
35	44	2	0,1358	250	20,347	5
38	68	1	0,0389	350	7,927	5
38	39	1	0,03	350	6,317	5
27	80	1	0,0242	350	7,007	5
44	80	1	0,1014	250	17,587	5

Tabela 21: **Dados de ramos: Colombia 2012.**

Barra de	Barra para	n_{ij}^0	x_{ij} pu	f_{ij}^{max} MW	c_{ij} US\$	n_{ij}^{max}
56	81	1	0,0114	550	32,858	5
45	54	1	0,0946	320	13,562	5
45	50	2	0,007	350	4,362	5
10	78	1	0,0102	350	4,937	5
7	78	1	0,0043	350	4,132	5
30	64	1	0,1533	250	20,577	5
30	65	1	0,091	250	13,677	5
30	72	2	0,0173	350	5,512	5
55	57	1	0,0174	600	46,808	5
57	84	1	0,0087	600	26,658	5
55	84	1	0,0087	600	26,658	5
56	57	2	0,024	600	62,618	5
9	77	1	0,019	350	5,857	5
77	79	1	0,0097	350	5,167	5
1	59	2	0,0232	350	6,202	5
59	67	2	0,118	250	16,667	5
8	59	2	0,1056	250	15,402	5
1	3	1	0,104	250	15,862	5
3	71	1	0,0136	450	5,167	5
3	6	1	0,0497	350	9,422	5
55	62	1	0,0281	550	70,988	5
47	52	1	0,0644	350	10,572	5
51	52	1	0,0859	250	12,872	5
29	31	2	0,1042	250	32,981	5
41	42	1	0,0094	350	4,707	5
40	42	1	0,0153	350	5,167	5
46	53	2	0,1041	250	14,597	5
46	51	1	0,1141	250	16,322	5
69	70	2	0,0228	350	6,202	5
66	69	2	0,1217	250	17,127	5

Tabela 21: **Dados de ramos: Colombia 2012.**

Barra de	Barra para	n_{ij}^0	x_{ij} pu	f_{ij}^{max} MW	c_{ij} US\$	n_{ij}^{max}
9	69	2	0,1098	350	15,747	5
60	69	2	0,0906	350	13,677	5
31	32	1	0,0259	350	6,547	5
32	34	1	0,054	350	9,767	5
16	18	1	0,0625	350	10,917	5
16	23	1	0,0238	350	6,892	5
16	21	1	0,0282	350	6,892	5
31	34	1	0,0792	250	12,412	5
31	33	2	0,0248	350	6,432	5
31	60	2	0,1944	250	25,982	5
31	72	2	0,0244	350	6,317	5
47	54	2	0,1003	250	14,252	5
47	49	2	0,0942	250	13,562	5
18	58	2	0,0212	350	5,742	5
18	20	1	0,0504	350	9,537	5
18	66	2	0,0664	350	11,377	5
18	21	1	0,0348	350	7,467	5
18	22	1	0,0209	350	6,432	5
19	22	1	0,0691	350	11,722	5
4	5	3	0,0049	350	4,247	5
5	6	2	0,0074	350	4,477	5
17	23	1	0,0913	250	12,987	5
17	76	1	0,002	350	3,902	5
12	17	1	0,0086	350	4,707	5
1	71	2	0,0841	250	14,367	5
1	8	1	0,081	250	13,217	5
1	11	1	0,0799	250	12,527	5
4	36	2	0,085	250	13,562	5
19	58	1	0,0826	320	11,722	5
27	64	1	0,028	350	6,777	5
27	28	1	0,0238	350	6,202	5

Tabela 21: **Dados de ramos: Colombia 2012.**

Barra de	Barra para	n_{ij}^0	x_{ij} pu	f_{ij}^{max} MW	c_{ij} US\$	n_{ij}^{max}
27	44	1	0,0893	250	16,322	5
26	27	1	0,0657	350	10,917	5
27	29	1	0,0166	350	5,052	5
19	66	1	0,0516	350	9,307	5
73	74	1	0,0214	600	58,278	5
64	65	1	0,0741	350	11,837	5
29	64	1	0,0063	350	4,362	5
4	34	2	0,1016	270	14,942	5
34	70	2	0,0415	350	8,272	5
33	34	1	0,1139	320	16,322	5
8	71	1	0,0075	400	4,477	5
54	63	3	0,0495	320	9,077	5
48	63	1	0,0238	350	6,317	5
67	68	2	0,166	250	22,072	5
39	68	1	0,0145	350	5,282	5
8	9	1	0,0168	350	5,972	5
79	87	1	0,0071	350	4,477	5
8	87	1	0,0132	350	5,167	5
39	43	1	0,1163	250	16,552	5
41	43	1	0,1142	250	16,322	5
23	24	1	0,0255	350	6,317	5
21	22	1	0,0549	350	9,882	5
26	28	1	0,0512	350	9,307	5
28	29	1	0,0281	350	6,777	5
6	10	1	0,0337	350	7,582	5
33	72	1	0,0228	350	6,202	5
39	40	2	0,102	250	16,207	5
12	76	1	0,0081	350	4,707	5
48	54	3	0,0396	350	8,042	5
50	54	2	0,0876	250	12,872	5
62	73	1	0,0272	750	73,158	5

Tabela 21: **Dados de ramos: Colombia 2012.**

Barra de	Barra para	n_{ij}^0	x_{ij} pu	f_{ij}^{max} MW	c_{ij} US\$	n_{ij}^{max}
49	53	2	0,1008	250	14,252	5
40	41	1	0,0186	350	5,742	5
45	81	1	0,0267	450	13,270	5
64	74	1	0,0267	500	13,270	5
54	56	3	0,0267	450	13,270	5
60	62	3	0,0257	450	13,270	5
72	73	2	0,0267	500	13,270	5
19	82	1	0,0267	450	13,270	5
55	82	1	0,029	550	77,498	5
62	82	1	0,0101	600	30,998	5
83	85	2	0,0267	450	13,270	5
82	85	1	0,0341	700	89,898	5
19	86	1	0,1513	300	20,922	5
68	86	1	0,0404	350	8,272	5
7	90	2	0,005	350	4,247	5
3	90	1	0,0074	350	4,592	5
90	91	1	0,0267	550	13,270	5
85	91	1	0,0139	600	40,298	5
11	92	1	0,0267	450	13,270	5
1	93	1	0,0267	450	13,270	5
92	93	1	0,0097	600	30,068	5
91	92	1	0,0088	600	27,588	5

APÊNDICE B - Cenários de Geração

Na Tabela 22 são mostrados os cenários extremos factíveis resultantes para o sistema teste IEEE de 24 Barras. A nomenclatura utilizada é a seguinte:

- a: ajustável** , Indica que o gerador é programado num valor entre seu limite inferior e seu limite superior de tal forma que permita obter o balanço de potencia ativa entre a geração total e demanda total do sistema (gerador livre).
- i: inferior** , Indica que o gerador se encontra programado em sua potencia mínima (limite inferior).
- s: superior** , Indica que o gerador se encontra programado em sua potencia máxima (limite superior).

Tabela 22: cenários extremos e factíveis para o sistema IEEE de 24 barras.

No. Cenário	Barra de Geração									
	01	02	07	13	15	16	18	21	22	23
1	a	s	s	s	s	i	s	s	i	s
2	a	s	s	s	i	s	s	s	i	s
3	a	i	s	s	s	s	s	s	i	s
4	a	s	s	s	s	i	s	i	s	s
5	a	s	s	s	s	s	s	i	s	s
6	a	s	s	s	s	i	i	s	s	s
7	a	s	s	s	s	s	i	s	s	s
8	a	s	s	s	i	i	s	s	s	s
9	a	s	i	s	s	i	s	s	s	s
10	a	s	i	s	i	s	s	s	s	s
11	a	i	s	s	i	s	s	s	s	s
12	a	i	i	s	s	s	s	s	s	s
13	s	a	s	s	s	i	s	s	i	s
14	s	a	s	s	i	s	s	s	i	s
15	i	a	s	s	s	s	s	s	i	s
16	s	a	s	s	s	i	s	i	s	s
17	s	a	s	s	s	s	s	i	s	s
18	s	a	s	s	s	i	i	s	s	s
19	s	a	s	s	s	s	i	s	s	s
20	s	a	s	s	i	i	s	s	s	s
21	s	a	i	s	s	i	s	s	s	s
22	s	a	i	s	i	s	s	s	s	s
23	i	a	s	s	i	s	s	s	s	s
24	i	a	i	s	s	s	s	s	s	s
25	s	s	a	s	s	i	s	s	i	s
26	s	s	a	s	i	s	s	s	i	s
27	s	i	a	s	s	s	s	s	i	s
28	i	s	a	s	s	s	s	s	i	s
29	s	s	a	s	s	s	s	s	i	s
30	s	s	a	s	s	i	s	i	s	s
31	s	s	a	s	s	s	s	i	s	s
32	s	s	a	s	s	i	i	s	s	s
33	s	s	a	s	s	s	i	s	s	s
34	s	s	a	s	i	i	s	s	s	s
35	i	i	a	s	s	i	s	s	s	s
36	s	i	a	s	s	i	s	s	s	s
37	i	s	a	s	s	i	s	s	s	s
38	s	i	a	s	i	s	s	s	s	s
39	i	s	a	s	i	s	s	s	s	s
40	i	i	a	s	s	s	s	s	s	s

Tabela 22: Cenários extremos e factíveis para o sistema IEEE de 24 barras.

No. Cenário	Barra de Geração									
	01	02	07	13	15	16	18	21	22	23
41	s	s	s	a	s	i	s	s	i	s
42	s	s	s	a	i	s	s	s	i	s
43	s	i	s	a	s	s	s	s	i	s
44	i	s	s	a	s	s	s	s	i	s
45	s	s	s	a	s	s	s	s	i	s
46	s	s	s	a	s	i	s	i	s	s
47	s	s	s	a	s	s	s	i	s	s
48	s	s	s	a	s	i	i	s	s	s
49	s	s	s	a	s	s	i	s	s	s
50	s	s	s	a	i	i	s	s	s	s
51	s	s	i	a	s	i	s	s	s	s
52	i	i	s	a	s	i	s	s	s	s
53	s	i	s	a	s	i	s	s	s	s
54	i	s	s	a	s	i	s	s	s	s
55	s	s	s	a	s	i	s	s	s	s
56	s	s	i	a	i	s	s	s	s	s
57	s	i	s	a	i	s	s	s	s	s
58	i	s	s	a	i	s	s	s	s	s
59	s	s	s	a	i	s	s	s	s	s
60	s	i	i	a	s	s	s	s	s	s
61	i	s	i	a	s	s	s	s	s	s
62	s	s	i	a	s	s	s	s	s	s
63	i	i	s	a	s	s	s	s	s	s
64	s	i	s	a	s	s	s	s	s	s
65	i	s	s	a	s	s	s	s	s	s
66	s	s	s	a	s	s	s	s	s	s
67	s	s	s	s	a	i	s	s	i	s
68	s	i	s	s	a	s	s	s	i	s
69	i	s	s	s	a	s	s	s	i	s
70	s	s	s	s	a	i	s	i	s	s

Tabela 22: Cenários extremos e factíveis para o sistema IEEE de 24 barras.

No. Cenário	Barra de Geração									
	01	02	07	13	15	16	18	21	22	23
71	s	s	s	s	a	s	s	i	s	s
72	s	s	s	s	a	i	i	s	s	s
73	s	s	s	s	a	s	i	s	s	s
74	s	s	i	s	a	i	s	s	s	s
75	i	i	s	s	a	i	s	s	s	s
76	s	i	s	s	a	i	s	s	s	s
77	i	s	s	s	a	i	s	s	s	s
78	s	i	i	s	a	s	s	s	s	s
79	i	s	i	s	a	s	s	s	s	s
80	i	i	s	s	a	s	s	s	s	s
81	s	s	s	s	i	a	s	s	i	s
82	s	i	s	s	s	a	s	s	i	s
83	i	s	s	s	s	a	s	s	i	s
84	s	s	s	s	s	a	s	i	s	s
85	s	s	s	s	s	a	i	s	s	s
86	s	s	i	s	i	a	s	s	s	s
87	s	i	s	s	i	a	s	s	s	s
88	i	s	s	s	i	a	s	s	s	s
89	s	i	i	s	s	a	s	s	s	s
90	i	s	i	s	s	a	s	s	s	s
91	s	s	s	s	s	i	a	s	i	s
92	s	s	s	s	i	s	a	s	i	s
93	s	i	s	s	s	s	a	s	i	s
94	i	s	s	s	s	s	a	s	i	s
95	s	s	s	s	s	s	a	s	i	s
96	s	s	s	s	s	i	a	i	s	s
97	s	s	s	s	s	s	a	i	s	s
98	s	s	s	s	i	i	a	s	s	s
99	s	s	i	s	s	i	a	s	s	s
100	i	i	s	s	s	i	a	s	s	s

Tabela 22: Cenários extremos e factíveis para o sistema IEEE de 24 barras.

No. Cenário	Barra de Geração									
	01	02	07	13	15	16	18	21	22	23
101	s	i	s	s	s	i	a	s	s	s
102	i	s	s	s	s	i	a	s	s	s
103	s	s	s	s	s	i	a	s	s	s
104	s	s	i	s	i	s	a	s	s	s
105	s	i	s	s	i	s	a	s	s	s
106	i	s	s	s	i	s	a	s	s	s
107	s	s	s	s	i	s	a	s	s	s
108	s	i	i	s	s	s	a	s	s	s
109	i	s	i	s	s	s	a	s	s	s
110	s	s	i	s	s	s	a	s	s	s
111	i	i	s	s	s	s	a	s	s	s
112	s	i	s	s	s	s	a	s	s	s
113	i	s	s	s	s	s	a	s	s	s
114	s	s	s	s	s	i	s	a	i	s
115	s	s	s	s	i	s	s	a	i	s
116	s	i	s	s	s	s	s	a	i	s
117	i	s	s	s	s	s	s	a	i	s
118	s	s	s	s	s	s	s	a	i	s
119	s	s	s	s	s	i	i	a	s	s
120	s	s	s	s	s	s	i	a	s	s
121	s	s	s	s	i	i	s	a	s	s
122	s	s	i	s	s	i	s	a	s	s
123	i	i	s	s	s	i	s	a	s	s
124	s	i	s	s	s	i	s	a	s	s
125	i	s	s	s	s	i	s	a	s	s
126	s	s	s	s	s	i	s	a	s	s
127	s	s	i	s	i	s	s	a	s	s
128	s	i	s	s	i	s	s	a	s	s
129	i	s	s	s	i	s	s	a	s	s
130	s	s	s	s	i	s	s	a	s	s

Tabela 22: Cenários extremos e factíveis para o sistema IEEE de 24 barras.

No. Cenário	Barra de Geração									
	01	02	07	13	15	16	18	21	22	23
131	s	i	i	s	s	s	s	a	s	s
132	i	s	i	s	s	s	s	a	s	s
133	s	s	i	s	s	s	s	a	s	s
134	i	i	s	s	s	s	s	a	s	s
135	s	i	s	s	s	s	s	a	s	s
136	i	s	s	s	s	s	s	a	s	s
137	s	s	s	s	s	i	s	i	a	s
138	s	s	s	s	s	s	s	i	a	s
139	s	s	s	s	s	i	i	s	a	s
140	s	s	s	s	s	s	i	s	a	s
141	s	s	s	s	i	i	s	s	a	s
142	s	s	i	s	s	i	s	s	a	s
143	i	i	s	s	s	i	s	s	a	s
144	s	i	s	s	s	i	s	s	a	s
145	i	s	s	s	s	i	s	s	a	s
146	s	s	i	s	i	s	s	s	a	s
147	s	i	s	s	i	s	s	s	a	s
148	i	s	s	s	i	s	s	s	a	s
149	s	i	i	s	s	s	s	s	a	s
150	i	s	i	s	s	s	s	s	a	s
151	s	s	i	s	s	s	s	s	a	s
152	i	i	s	s	s	s	s	s	a	s
153	s	s	s	s	s	i	s	s	i	a
154	s	s	s	s	i	s	s	s	i	a
155	s	i	s	s	s	s	s	s	i	a
156	i	s	s	s	s	s	s	s	i	a
157	s	s	s	s	s	s	s	s	i	a
158	s	s	s	s	s	i	s	i	s	a
159	s	s	s	s	s	s	s	i	s	a
160	s	s	s	s	s	i	i	s	s	a

***APÊNDICE C - Configurações da Fronteira
Pareto-ótima para o Sistema IEEE
de 24 Barras Obtidas Considerando
Otimização Multiobjetivo e
Múltiplos Cenários de Geração***

C.1 Configurações para $f_2 = \max \{r^q\}$, seção (5.9.2).

Custo US\$ $1,330.00 \times 10^6$ e $\max \{r^q\} = 0,00$ (MW):

$$\begin{aligned} n_{01-02} = 1, n_{01-05} = 1, n_{03-24} = 1, n_{04-09} = 1, n_{05-10} = 2, n_{06-10} = 2, n_{07-08} = 2, \\ n_{08-09} = 1, n_{08-10} = 2, n_{09-12} = 1, n_{10-11} = 1, n_{10-12} = 2, n_{11-14} = 1, n_{12-13} = 1, \\ n_{12-23} = 1, n_{14-16} = 2, n_{15-21} = 1, n_{15-24} = 1, n_{16-17} = 2, n_{16-19} = 1, n_{17-18} = 1, \\ n_{20-23} = 1, n_{21-22} = 1, n_{01-08} = 1. \end{aligned}$$

Custo = US\$ $1,318.00 \times 10^6$ e $\max \{r^q\} = 1,49$ (MW):

$$\begin{aligned} n_{01-02} = 1, n_{03-24} = 1, n_{04-09} = 1, n_{05-10} = 1, n_{06-10} = 2, n_{07-08} = 2, n_{08-09} = 1, \\ n_{08-10} = 2, n_{09-12} = 1, n_{10-11} = 1, n_{10-12} = 2, n_{11-14} = 1, n_{12-13} = 1, n_{12-23} = 1, \\ n_{14-16} = 2, n_{15-21} = 1, n_{15-24} = 1, n_{16-17} = 2, n_{16-19} = 1, n_{17-18} = 1, n_{20-23} = 1, \\ n_{21-22} = 1, n_{01-08} = 1, n_{02-08} = 1. \end{aligned}$$

Custo US\$ $1,308.00 \times 10^6$ e $\max \{r^q\} = 21,75$ (MW):

$$\begin{aligned} n_{01-02} = 1, n_{03-24} = 1, n_{04-09} = 1, n_{05-10} = 2, n_{06-10} = 2, n_{07-08} = 2, n_{08-09} = 1, \\ n_{08-10} = 2, n_{09-12} = 1, n_{10-11} = 1, n_{10-12} = 2, n_{11-14} = 1, n_{12-13} = 1, n_{12-23} = 1, \\ n_{14-16} = 2, n_{15-21} = 1, n_{15-24} = 1, n_{16-17} = 2, n_{16-19} = 1, n_{17-18} = 1, n_{20-23} = 1, \\ n_{21-22} = 1, n_{01-08} = 1. \end{aligned}$$

Custo US\$ 1,301.00 $\times 10^6$ e $\max \{r^q\} = 23, 19$ (MW):

$$\begin{aligned} n_{01-02} &= 1, n_{03-24} = 1, n_{04-09} = 1, n_{05-10} = 1, n_{06-10} = 3, n_{07-08} = 2, n_{08-09} = 1, \\ n_{08-10} &= 2, n_{09-12} = 1, n_{10-11} = 1, n_{10-12} = 2, n_{11-14} = 1, n_{12-13} = 1, n_{12-23} = 1, \\ n_{14-16} &= 2, n_{15-21} = 1, n_{15-24} = 1, n_{16-17} = 2, n_{16-19} = 1, n_{17-18} = 1, n_{20-23} = 1, \\ n_{21-22} &= 1, n_{01-08} = 1. \end{aligned}$$

Custo US\$ 1,285.00 $\times 10^6$ e $\max \{r^q\} = 31, 07$ (MW):

$$\begin{aligned} n_{01-02} &= 1, n_{03-24} = 1, n_{04-09} = 1, n_{05-10} = 1, n_{06-10} = 2, n_{07-08} = 2, n_{08-09} = 1, \\ n_{08-10} &= 2, n_{09-12} = 1, n_{10-11} = 1, n_{10-12} = 2, n_{11-14} = 1, n_{12-13} = 1, n_{12-23} = 1, \\ n_{14-16} &= 2, n_{15-21} = 1, n_{15-24} = 1, n_{16-17} = 2, n_{16-19} = 1, n_{17-18} = 1, n_{20-23} = 1, \\ n_{21-22} &= 1, n_{01-08} = 1. \end{aligned}$$

Custo US\$ 1,273.00 $\times 10^6$ e $\max \{r^q\} = 33, 97$ (MW):

$$\begin{aligned} n_{01-02} &= 1, n_{03-24} = 1, n_{04-09} = 1, n_{05-10} = 1, n_{06-10} = 2, n_{07-08} = 2, n_{08-09} = 1, \\ n_{08-10} &= 2, n_{09-12} = 1, n_{10-11} = 1, n_{10-12} = 2, n_{11-14} = 1, n_{12-13} = 1, n_{12-23} = 1, \\ n_{14-16} &= 2, n_{15-16} = 1, n_{15-21} = 1, n_{15-24} = 1, n_{16-17} = 1, n_{16-19} = 1, n_{17-18} = 1, \\ n_{20-23} &= 1, n_{21-22} = 1, n_{01-08} = 1. \end{aligned}$$

Custo US\$ 1,265.00 $\times 10^6$ e $\max \{r^q\} = 68, 38$ (MW):

$$\begin{aligned} n_{01-02} &= 2, n_{03-24} = 1, n_{04-09} = 1, n_{05-10} = 2, n_{06-10} = 2, n_{07-08} = 2, n_{08-09} = 1, \\ n_{08-10} &= 2, n_{09-12} = 1, n_{10-11} = 1, n_{10-12} = 2, n_{11-14} = 1, n_{12-13} = 1, n_{12-23} = 1, \\ n_{14-16} &= 2, n_{15-16} = 2, n_{15-21} = 1, n_{15-24} = 1, n_{16-17} = 2, n_{16-19} = 1, n_{17-18} = 1, \\ n_{20-23} &= 1, n_{01-08} = 1. \end{aligned}$$

Custo US\$ 1,237.00 $\times 10^6$ e $\max \{r^q\} = 68, 39$ (MW):

$$\begin{aligned} n_{01-02} &= 1, n_{03-24} = 1, n_{04-09} = 1, n_{05-10} = 1, n_{06-10} = 2, n_{07-08} = 2, n_{08-09} = 1, \\ n_{08-10} &= 2, n_{09-12} = 1, n_{10-11} = 1, n_{10-12} = 2, n_{11-14} = 1, n_{12-13} = 1, n_{12-23} = 1, \\ n_{14-16} &= 2, n_{15-16} = 2, n_{15-21} = 1, n_{15-24} = 1, n_{16-17} = 2, n_{16-19} = 1, n_{17-18} = 1, \\ n_{20-23} &= 1, n_{02-08} = 1. \end{aligned}$$

Custo US\$ 1,218.00 $\times 10^6$ e $\max \{r^q\} = 73, 37$ (MW):

$$n_{01-02} = 2, n_{03-24} = 1, n_{04-09} = 1, n_{05-10} = 1, n_{06-10} = 2, n_{07-08} = 2, n_{08-09} = 1,$$

$$n_{08-10} = 2, n_{09-12} = 1, n_{10-11} = 1, n_{10-12} = 2, n_{11-14} = 1, n_{12-13} = 1, n_{12-23} = 1, \\ n_{14-16} = 2, n_{15-16} = 1, n_{15-21} = 1, n_{15-24} = 1, n_{16-17} = 2, n_{16-19} = 1, n_{17-18} = 1, \\ n_{20-23} = 1, n_{01-08} = 1.$$

Custo US\$ 1,181.00 $\times 10^6$ e $\max \{r^q\} = 83, 01$ (MW):

$$n_{01-02} = 1, n_{03-24} = 1, n_{04-09} = 1, n_{05-10} = 1, n_{06-10} = 2, n_{07-08} = 2, n_{08-09} = 1, \\ n_{08-10} = 2, n_{09-12} = 1, n_{10-11} = 1, n_{10-12} = 2, n_{11-14} = 1, n_{12-13} = 1, n_{12-23} = 1, \\ n_{14-16} = 2, n_{15-16} = 2, n_{15-21} = 1, n_{15-24} = 1, n_{16-17} = 1, n_{16-19} = 1, n_{20-23} = 1, \\ n_{02-08} = 1.$$

Custo US\$ 1,169.00 $\times 10^6$ e $\max \{r^q\} = 90, 92$ (MW):

$$n_{01-02} = 1, n_{03-24} = 1, n_{04-09} = 1, n_{05-10} = 1, n_{06-10} = 2, n_{07-08} = 2, n_{08-09} = 1, \\ n_{08-10} = 1, n_{09-11} = 1, n_{10-11} = 1, n_{10-12} = 2, n_{11-13} = 1, n_{11-14} = 1, n_{12-23} = 1, \\ n_{14-16} = 2, n_{15-16} = 1, n_{15-21} = 1, n_{15-24} = 1, n_{16-17} = 1, n_{16-19} = 1, n_{17-18} = 1, \\ n_{20-23} = 1, n_{01-08} = 1, n_{02-08} = 1.$$

Custo US\$ 1,149.00 $\times 10^6$ e $\max \{r^q\} = 116, 72$ (MW):

$$n_{01-02} = 1, n_{03-24} = 1, n_{04-09} = 1, n_{05-10} = 1, n_{06-10} = 2, n_{07-08} = 2, n_{08-09} = 1, \\ n_{08-10} = 1, n_{09-11} = 1, n_{10-11} = 1, n_{10-12} = 2, n_{11-13} = 1, n_{11-14} = 1, n_{12-23} = 1, \\ n_{14-16} = 2, n_{15-16} = 1, n_{15-21} = 1, n_{15-24} = 1, n_{16-17} = 1, n_{16-19} = 1, n_{20-23} = 1, \\ n_{01-08} = 1, n_{02-08} = 1.$$

Custo US\$ 1,136.00 $\times 10^6$ e $\max \{r^q\} = 116, 81$ (MW):

$$n_{01-02} = 1, n_{01-05} = 1, n_{03-24} = 1, n_{04-09} = 1, n_{05-10} = 1, n_{06-10} = 2, n_{07-08} = 2, \\ n_{08-09} = 1, n_{08-10} = 1, n_{09-11} = 1, n_{10-11} = 1, n_{10-12} = 2, n_{11-13} = 1, n_{11-14} = 1, \\ n_{12-23} = 1, n_{14-16} = 2, n_{15-16} = 1, n_{15-21} = 1, n_{15-24} = 1, n_{16-17} = 1, n_{16-19} = 1, \\ n_{20-23} = 1, n_{02-08} = 1.$$

Custo US\$ 1,116.00 $\times 10^6$ e $\max \{r^q\} = 124, 89$ (MW):

$$n_{01-02} = 1, n_{03-24} = 1, n_{04-09} = 1, n_{05-10} = 1, n_{06-10} = 2, n_{07-08} = 2, n_{08-09} = 1, \\ n_{08-10} = 1, n_{09-11} = 1, n_{10-11} = 1, n_{10-12} = 2, n_{11-13} = 1, n_{11-14} = 1, n_{12-23} = 1, \\ n_{14-16} = 2, n_{15-16} = 1, n_{15-21} = 1, n_{15-24} = 1, n_{16-17} = 1, n_{16-19} = 1, n_{20-23} = 1,$$

$$n_{01-08} = 1.$$

Custo US\$ 1,114.00 $\times 10^6$ e $\max \{r^q\} = 126, 16$ (MW):

$$\begin{aligned} n_{01-02} = 1, n_{03-24} = 1, n_{04-09} = 1, n_{05-10} = 1, n_{06-10} = 2, n_{07-08} = 2, n_{08-09} = 1, \\ n_{08-10} = 1, n_{09-11} = 1, n_{10-11} = 1, n_{10-12} = 2, n_{11-13} = 1, n_{11-14} = 1, n_{12-23} = 1, \\ n_{14-16} = 2, n_{15-16} = 1, n_{15-21} = 1, n_{15-24} = 1, n_{16-17} = 1, n_{16-19} = 1, n_{20-23} = 1, \\ n_{02-08} = 1. \end{aligned}$$

Custo US\$ 1,100.00 $\times 10^6$ e $\max \{r^q\} = 156, 46$ (MW):

$$\begin{aligned} n_{01-02} = 1, n_{01-05} = 1, n_{03-24} = 1, n_{05-10} = 2, n_{06-10} = 2, n_{07-08} = 3, n_{08-10} = 2, \\ n_{10-11} = 1, n_{10-12} = 2, n_{11-14} = 1, n_{12-13} = 1, n_{12-23} = 1, n_{14-16} = 2, n_{15-16} = 1, \\ n_{15-21} = 1, n_{15-24} = 1, n_{16-17} = 1, n_{16-19} = 1, n_{20-23} = 1, n_{01-08} = 1. \end{aligned}$$

Custo US\$ 1,085.00 $\times 10^6$ e $\max \{r^q\} = 162, 84$ (MW):

$$\begin{aligned} n_{01-02} = 1, n_{03-09} = 1, n_{03-24} = 1, n_{04-09} = 1, n_{05-10} = 1, n_{06-10} = 2, n_{07-08} = 2, \\ n_{08-09} = 1, n_{08-10} = 1, n_{09-12} = 1, n_{10-11} = 1, n_{10-12} = 2, n_{12-13} = 1, n_{12-23} = 1, \\ n_{14-16} = 2, n_{15-21} = 1, n_{15-24} = 1, n_{16-17} = 1, n_{16-19} = 1, n_{17-18} = 1, n_{20-23} = 1, \\ n_{01-08} = 1. \end{aligned}$$

Custo US\$ 1,076.00 $\times 10^6$ e $\max \{r^q\} = 167, 92$ (MW):

$$\begin{aligned} n_{01-02} = 1, n_{01-05} = 1, n_{03-24} = 1, n_{04-09} = 1, n_{05-10} = 1, n_{06-10} = 2, n_{07-08} = 2, \\ n_{08-09} = 1, n_{08-10} = 1, n_{09-12} = 1, n_{10-11} = 1, n_{10-12} = 2, n_{12-13} = 1, n_{12-23} = 1, \\ n_{14-16} = 2, n_{15-21} = 1, n_{15-24} = 1, n_{16-17} = 1, n_{16-19} = 1, n_{17-18} = 1, n_{20-23} = 1, \\ n_{01-08} = 1. \end{aligned}$$

Custo US\$ 1,054.00 $\times 10^6$ e $\max \{r^q\} = 173, 98$ (MW):

$$\begin{aligned} n_{01-02} = 1, n_{03-24} = 1, n_{04-09} = 1, n_{05-10} = 1, n_{06-10} = 2, n_{07-08} = 2, n_{08-09} = 1, \\ n_{08-10} = 1, n_{09-12} = 1, n_{10-11} = 1, n_{10-12} = 2, n_{12-13} = 1, n_{12-23} = 1, n_{14-16} = 2, \\ n_{15-21} = 1, n_{15-24} = 1, n_{16-17} = 1, n_{16-19} = 1, n_{17-18} = 1, n_{20-23} = 1, n_{01-08} = 1. \end{aligned}$$

Custo US\$ 1,032.00 $\times 10^6$ e $\max \{r^q\} = 187, 31$ (MW):

$$\begin{aligned} n_{01-02} = 1, n_{03-24} = 1, n_{04-09} = 1, n_{05-10} = 1, n_{06-10} = 2, n_{07-08} = 2, n_{08-09} = 1, \\ n_{08-10} = 1, n_{09-12} = 1, n_{10-11} = 1, n_{10-12} = 2, n_{11-13} = 1, n_{12-23} = 1, n_{14-16} = 2, \\ n_{15-21} = 1, n_{15-24} = 1, n_{16-17} = 1, n_{16-19} = 1, n_{20-23} = 1, n_{02-08} = 1. \end{aligned}$$

Custo US\$ 1,000.00 $\times 10^6$ e $\max \{r^q\} = 189, 43$ (MW):

$$\begin{aligned} n_{01-02} = 1, n_{01-05} = 1, n_{03-24} = 1, n_{04-09} = 1, n_{05-10} = 1, n_{06-10} = 2, n_{07-08} = 2, \\ n_{08-09} = 1, n_{08-10} = 1, n_{09-12} = 1, n_{10-11} = 1, n_{10-12} = 2, n_{12-13} = 1, n_{12-23} = 1, \\ n_{14-16} = 1, n_{15-21} = 1, n_{15-24} = 1, n_{16-17} = 1, n_{16-19} = 1, n_{20-23} = 1, n_{02-08} = 1. \end{aligned}$$

Custo US\$ 981.00 $\times 10^6$ e $\max \{r^q\} = 202, 09$ (MW):

$$\begin{aligned} n_{01-02} = 1, n_{01-05} = 1, n_{03-24} = 1, n_{05-10} = 2, n_{06-10} = 2, n_{07-08} = 2, n_{08-10} = 2, \\ n_{10-11} = 1, n_{10-12} = 2, n_{11-13} = 1, n_{12-23} = 1, n_{14-16} = 1, n_{15-21} = 1, n_{15-24} = 1, \\ n_{16-17} = 1, n_{16-19} = 1, n_{20-23} = 1, n_{01-08} = 1, n_{02-08} = 1. \end{aligned}$$

Custo US\$ 948.00 $\times 10^6$ e $\max \{r^q\} = 203, 65$ (MW):

$$\begin{aligned} n_{01-02} = 1, n_{01-05} = 1, n_{03-24} = 1, n_{05-10} = 2, n_{06-10} = 2, n_{07-08} = 2, n_{08-10} = 2, \\ n_{10-11} = 1, n_{10-12} = 2, n_{11-13} = 1, n_{12-23} = 1, n_{14-16} = 1, n_{15-21} = 1, n_{15-24} = 1, \\ n_{16-17} = 1, n_{16-19} = 1, n_{20-23} = 1, n_{01-08} = 1. \end{aligned}$$

Custo US\$ 946.00 $\times 10^6$ e $\max \{r^q\} = 203, 70$ (MW):

$$\begin{aligned} n_{01-02} = 1, n_{01-05} = 1, n_{03-24} = 1, n_{05-10} = 2, n_{06-10} = 2, n_{07-08} = 2, n_{08-10} = 2, \\ n_{10-11} = 1, n_{10-12} = 2, n_{11-13} = 1, n_{12-23} = 1, n_{14-16} = 1, n_{15-21} = 1, n_{15-24} = 1, \\ n_{16-17} = 1, n_{16-19} = 1, n_{20-23} = 1, n_{02-08} = 1. \end{aligned}$$

Custo US\$ 913.00 $\times 10^6$ e $\max \{r^q\} = 209, 52$ (MW):

$$\begin{aligned} n_{01-02} = 1, n_{01-05} = 1, n_{03-24} = 1, n_{05-10} = 2, n_{06-10} = 2, n_{07-08} = 2, n_{08-10} = 2, \\ n_{10-11} = 1, n_{10-12} = 2, n_{11-13} = 1, n_{12-23} = 1, n_{14-16} = 1, n_{15-21} = 1, n_{15-24} = 1, \\ n_{16-17} = 1, n_{16-19} = 1, n_{20-23} = 1. \end{aligned}$$

Custo US\$ 901.00 $\times 10^6$ e $\max \{r^q\} = 248,43$ (MW):

$$\begin{aligned} n_{01-02} &= 1, n_{03-24} = 1, n_{05-10} = 1, n_{06-10} = 2, n_{07-08} = 2, n_{08-10} = 2, n_{10-11} = 1, \\ n_{10-12} &= 2, n_{11-13} = 1, n_{12-23} = 1, n_{14-16} = 1, n_{15-21} = 1, n_{15-24} = 1, n_{16-17} = 1, \\ n_{16-19} &= 1, n_{20-23} = 1, n_{02-08} = 1. \end{aligned}$$

Custo US\$ 868.00 $\times 10^6$ e $\max \{r^q\} = 269,03$ (MW):

$$\begin{aligned} n_{01-02} &= 1, n_{03-24} = 1, n_{05-10} = 1, n_{06-10} = 2, n_{07-08} = 2, n_{08-10} = 2, n_{10-11} = 1, \\ n_{10-12} &= 2, n_{11-13} = 1, n_{12-23} = 1, n_{14-16} = 1, n_{15-21} = 1, n_{15-24} = 1, n_{16-17} = 1, \\ n_{16-19} &= 1, n_{20-23} = 1. \end{aligned}$$

Custo US\$ 861.00 $\times 10^6$ e $\max \{r^q\} = 292,46$ (MW):

$$\begin{aligned} n_{01-02} &= 2, n_{03-24} = 1, n_{05-10} = 1, n_{06-10} = 2, n_{07-08} = 2, n_{08-10} = 2, n_{10-11} = 1, \\ n_{10-12} &= 2, n_{11-13} = 1, n_{12-23} = 1, n_{14-16} = 1, n_{15-21} = 1, n_{15-24} = 1, n_{16-17} = 1, \\ n_{16-19} &= 1, n_{17-18} = 1. \end{aligned}$$

Custo US\$ 838.00 $\times 10^6$ e $\max \{r^q\} = 292,65$ (MW):

$$\begin{aligned} n_{01-02} &= 1, n_{03-24} = 1, n_{05-10} = 1, n_{06-10} = 2, n_{07-08} = 2, n_{08-10} = 2, n_{10-11} = 1, \\ n_{10-12} &= 2, n_{11-13} = 1, n_{12-23} = 1, n_{14-16} = 1, n_{15-21} = 1, n_{15-24} = 1, n_{16-17} = 1, \\ n_{16-19} &= 1. \end{aligned}$$

Custo US\$ 828.00 $\times 10^6$ e $\max \{r^q\} = 305,82$ (MW):

$$\begin{aligned} n_{01-02} &= 1, n_{01-05} = 1, n_{03-24} = 1, n_{05-10} = 1, n_{06-10} = 2, n_{07-08} = 2, n_{08-10} = 2, \\ n_{10-11} &= 1, n_{10-12} = 2, n_{11-13} = 1, n_{12-23} = 1, n_{14-16} = 1, n_{15-21} = 1, n_{15-24} = 1, \\ n_{16-17} &= 1. \end{aligned}$$

Custo US\$ 806.00 $\times 10^6$ e $\max \{r^q\} = 333,85$ (MW):

$$\begin{aligned} n_{01-02} &= 1, n_{03-24} = 1, n_{05-10} = 1, n_{06-10} = 2, n_{07-08} = 2, n_{08-10} = 2, n_{10-11} = 1, \\ n_{10-12} &= 2, n_{11-13} = 1, n_{12-23} = 1, n_{14-16} = 1, n_{15-21} = 1, n_{15-24} = 1, n_{16-17} = 1. \end{aligned}$$

Custo US\$ 804.00 $\times 10^6$ e $\max \{r^q\} = 362,47$ (MW):

$$n_{01-02} = 3, n_{03-24} = 1, n_{05-10} = 1, n_{06-10} = 2, n_{07-08} = 2, n_{08-10} = 1, n_{10-11} = 1, \\ n_{10-12} = 2, n_{11-13} = 1, n_{12-23} = 1, n_{14-16} = 1, n_{15-21} = 1, n_{15-24} = 1, n_{16-17} = 1, \\ n_{01-08} = 1.$$

Custo US\$ 796.00 $\times 10^6$ e $\max \{r^q\} = 369,98$ (MW):

$$n_{01-02} = 1, n_{03-24} = 1, n_{05-10} = 1, n_{06-10} = 2, n_{07-08} = 2, n_{08-10} = 1, n_{10-11} = 1, \\ n_{10-12} = 2, n_{11-13} = 1, n_{12-23} = 1, n_{14-16} = 1, n_{15-21} = 1, n_{15-24} = 1, n_{16-17} = 1, \\ n_{02-08} = 1.$$

Custo US\$ 795.00 $\times 10^6$ e $\max \{r^q\} = 400,76$ (MW):

$$n_{03-24} = 1, n_{05-10} = 1, n_{06-10} = 2, n_{07-08} = 2, n_{08-10} = 1, n_{10-11} = 1, n_{10-12} = 2, \\ n_{11-13} = 1, n_{12-23} = 1, n_{14-16} = 1, n_{15-21} = 1, n_{15-24} = 1, n_{16-17} = 1, n_{01-08} = 1.$$

Custo US\$ 785.00 $\times 10^6$ e $\max \{r^q\} = 401,21$ (MW):

$$n_{01-02} = 1, n_{01-05} = 1, n_{03-24} = 1, n_{05-10} = 1, n_{06-10} = 2, n_{07-08} = 2, n_{08-10} = 1, \\ n_{10-11} = 1, n_{10-12} = 2, n_{11-13} = 1, n_{12-23} = 1, n_{14-16} = 1, n_{15-21} = 1, n_{15-24} = 1, \\ n_{16-17} = 1.$$

Custo US\$ 763.00 $\times 10^6$ e $\max \{r^q\} = 409,41$ (MW):

$$n_{01-02} = 1, n_{03-24} = 1, n_{05-10} = 1, n_{06-10} = 2, n_{07-08} = 2, n_{08-10} = 1, n_{10-11} = 1, \\ n_{10-12} = 2, n_{11-13} = 1, n_{12-23} = 1, n_{14-16} = 1, n_{15-21} = 1, n_{15-24} = 1, n_{16-17} = 1.$$

Custo US\$ 756.00 $\times 10^6$ e $\max \{r^q\} = 418,99$ (MW):

$$n_{01-02} = 1, n_{03-24} = 1, n_{05-10} = 1, n_{06-10} = 2, n_{07-08} = 2, n_{08-09} = 1, n_{08-10} = 1, \\ n_{10-11} = 1, n_{10-12} = 1, n_{11-13} = 1, n_{12-23} = 1, n_{14-16} = 1, n_{15-21} = 1, n_{15-24} = 1, \\ n_{16-17} = 1.$$

C.2 Configurações para $\sum_{q=1}^p \sum_{i \in \Gamma} r_i^q$, seção (5.9.3).

Custo US\$ 1,330.00 $\times 10^6$ e $\sum_{q=1}^p \sum_{i \in \Gamma} r_i^q = 0,00$ (MW):

$$\begin{aligned} n_{01-02} &= 1, n_{01-05} = 1, n_{03-24} = 1, n_{04-09} = 1, n_{05-10} = 2, n_{06-10} = 2, n_{07-08} = 2, \\ n_{08-09} &= 1, n_{08-10} = 2, n_{09-11} = 1, n_{10-11} = 1, n_{10-12} = 2, n_{11-13} = 1, n_{11-14} = 1, \\ n_{12-23} &= 1, n_{14-16} = 2, n_{15-21} = 1, n_{15-24} = 1, n_{16-17} = 2, n_{16-19} = 1, n_{17-18} = 1, \\ n_{20-23} &= 1, n_{21-22} = 1, n_{01-08} = 1. \end{aligned}$$

Custo US\$ 1,320.00 $\times 10^6$ e $\sum_{q=1}^p \sum_{i \in \Gamma} r_i^q = 1,20$ (MW):

$$\begin{aligned} n_{01-02} &= 1, n_{03-24} = 1, n_{04-09} = 1, n_{05-10} = 1, n_{06-10} = 2, n_{07-08} = 2, n_{08-09} = 1, \\ n_{08-10} &= 2, n_{09-12} = 1, n_{10-11} = 1, n_{10-12} = 2, n_{11-14} = 1, n_{12-13} = 1, n_{12-23} = 1, \\ n_{14-16} &= 2, n_{15-21} = 1, n_{15-24} = 1, n_{16-17} = 2, n_{16-19} = 1, n_{17-18} = 1, n_{20-23} = 1, \\ n_{21-22} &= 1, n_{01-08} = 2. \end{aligned}$$

Custo US\$ 1,318.00 $\times 10^6$ e $\sum_{q=1}^p \sum_{i \in \Gamma} r_i^q = 1,21$ (MW):

$$\begin{aligned} n_{01-02} &= 1, n_{03-24} = 1, n_{04-09} = 1, n_{05-10} = 1, n_{06-10} = 2, n_{07-08} = 2, n_{08-09} = 1, \\ n_{08-10} &= 2, n_{09-12} = 1, n_{10-11} = 1, n_{10-12} = 2, n_{11-14} = 1, n_{12-13} = 1, n_{12-23} = 1, \\ n_{14-16} &= 2, n_{15-21} = 1, n_{15-24} = 1, n_{16-17} = 2, n_{16-19} = 1, n_{17-18} = 1, n_{20-23} = 1, \\ n_{21-22} &= 1, n_{01-08} = 1, n_{02-08} = 1. \end{aligned}$$

Custo US\$ 1,308.00 $\times 10^6$ e $\sum_{q=1}^p \sum_{i \in \Gamma} r_i^q = 27,25$ (MW):

$$\begin{aligned} n_{01-02} &= 1, n_{03-24} = 1, n_{04-09} = 1, n_{05-10} = 2, n_{06-10} = 2, n_{07-08} = 2, n_{08-09} = 1, \\ n_{08-10} &= 2, n_{09-11} = 1, n_{10-11} = 1, n_{10-12} = 2, n_{11-13} = 1, n_{11-14} = 1, n_{12-23} = 1, \\ n_{14-16} &= 2, n_{15-21} = 1, n_{15-24} = 1, n_{16-17} = 2, n_{16-19} = 1, n_{17-18} = 1, n_{20-23} = 1, \\ n_{21-22} &= 1, n_{01-08} = 1. \end{aligned}$$

Custo US\$ 1,297.00 $\times 10^6$ e $\sum_{q=1}^p \sum_{i \in \Gamma} r_i^q = 44,97$ (MW):

$$\begin{aligned} n_{01-02} &= 1, n_{03-24} = 1, n_{04-09} = 1, n_{05-10} = 1, n_{06-10} = 2, n_{07-08} = 2, n_{08-09} = 1, \\ n_{08-10} &= 2, n_{09-11} = 1, n_{10-11} = 1, n_{10-12} = 2, n_{11-13} = 1, n_{11-14} = 1, n_{12-23} = 1, \\ n_{14-16} &= 2, n_{15-16} = 2, n_{15-21} = 1, n_{15-24} = 1, n_{16-17} = 1, n_{16-19} = 1, n_{17-18} = 1, \end{aligned}$$

$$n_{20-23} = 1, n_{21-22} = 1, n_{01-08} = 1.$$

Custo US\$ 1,285.00 $\times 10^6$ e $\sum_{q=1}^p \sum_{i \in \Gamma} r_i^q = 55, 44$ (MW):

$$\begin{aligned} n_{01-02} &= 1, n_{03-24} = 1, n_{04-09} = 1, n_{05-10} = 1, n_{06-10} = 2, n_{07-08} = 2, n_{08-09} = 1, \\ n_{08-10} &= 2, n_{09-12} = 1, n_{10-11} = 1, n_{10-12} = 2, n_{11-14} = 1, n_{12-13} = 1, n_{12-23} = 1, \\ n_{14-16} &= 2, n_{15-21} = 1, n_{15-24} = 1, n_{16-17} = 2, n_{16-19} = 1, n_{17-18} = 1, n_{20-23} = 1, \\ n_{21-22} &= 1, n_{01-08} = 1. \end{aligned}$$

Custo US\$ 1,283.00 $\times 10^6$ e $\sum_{q=1}^p \sum_{i \in \Gamma} r_i^q = 121, 07$ (MW):

$$\begin{aligned} n_{01-02} &= 1, n_{03-24} = 1, n_{04-09} = 1, n_{05-10} = 1, n_{06-10} = 2, n_{07-08} = 2, n_{08-09} = 1, \\ n_{08-10} &= 2, n_{09-12} = 1, n_{10-11} = 1, n_{10-12} = 2, n_{11-14} = 1, n_{12-13} = 1, n_{12-23} = 1, \\ n_{14-16} &= 2, n_{15-21} = 1, n_{15-24} = 1, n_{16-17} = 2, n_{16-19} = 1, n_{17-18} = 1, n_{20-23} = 1, \\ n_{21-22} &= 1, n_{02-08} = 1. \end{aligned}$$

Custo US\$ 1,273.00 $\times 10^6$ e $\sum_{q=1}^p \sum_{i \in \Gamma} r_i^q = 167, 84$ (MW):

$$\begin{aligned} n_{01-02} &= 1, n_{03-24} = 1, n_{04-09} = 1, n_{05-10} = 1, n_{06-10} = 2, n_{07-08} = 2, n_{08-09} = 1, \\ n_{08-10} &= 2, n_{09-11} = 1, n_{10-11} = 1, n_{10-12} = 2, n_{11-13} = 1, n_{11-14} = 1, n_{12-23} = 1, \\ n_{14-16} &= 2, n_{15-16} = 1, n_{15-21} = 1, n_{15-24} = 1, n_{16-17} = 1, n_{16-19} = 1, n_{17-18} = 1, \\ n_{20-23} &= 1, n_{21-22} = 1, n_{01-08} = 1. \end{aligned}$$

Custo US\$ 1,253.00 $\times 10^6$ e $\sum_{q=1}^p \sum_{i \in \Gamma} r_i^q = 289, 82$ (MW):

$$\begin{aligned} n_{01-02} &= 1, n_{03-24} = 1, n_{04-09} = 1, n_{05-10} = 1, n_{06-10} = 2, n_{07-08} = 2, n_{08-09} = 1, \\ n_{08-10} &= 2, n_{09-11} = 1, n_{10-11} = 1, n_{10-12} = 2, n_{11-13} = 1, n_{11-14} = 1, n_{12-23} = 1, \\ n_{14-16} &= 2, n_{15-21} = 1, n_{15-24} = 1, n_{16-17} = 2, n_{17-18} = 1, n_{20-23} = 1, n_{21-22} = 1, \\ n_{01-08} &= 1. \end{aligned}$$

Custo US\$ 1,241.00 $\times 10^6$ e $\sum_{q=1}^p \sum_{i \in \Gamma} r_i^q = 373, 07$ (MW):

$$\begin{aligned} n_{01-02} &= 1, n_{03-24} = 1, n_{04-09} = 1, n_{05-10} = 1, n_{06-10} = 2, n_{07-08} = 2, n_{08-09} = 1, \\ n_{08-10} &= 2, n_{09-11} = 1, n_{10-11} = 1, n_{10-12} = 2, n_{11-13} = 1, n_{11-14} = 1, n_{12-23} = 1, \\ n_{14-16} &= 2, n_{15-16} = 1, n_{15-21} = 1, n_{15-24} = 1, n_{16-17} = 1, n_{17-18} = 1, n_{20-23} = 1, \\ n_{21-22} &= 1, n_{01-08} = 1. \end{aligned}$$

C.3 Configurações considerando incertezas na demanda e nos limites de geração, e MEG.

Custo US\$ 973.00 $\times 10^6$ e $\max \{r^q\} = 2, 24$ (MW):

$$\begin{aligned} n_{01-02} = 1, n_{01-05} = 1, n_{03-24} = 1, n_{04-09} = 1, n_{05-10} = 1, n_{06-10} = 2, n_{07-08} = 3, \\ n_{08-09} = 2, n_{08-10} = 1, n_{09-11} = 1, n_{09-12} = 1, n_{10-11} = 1, n_{10-12} = 1, n_{11-14} = 1, \\ n_{12-13} = 1, n_{14-16} = 1, n_{15-24} = 1, n_{16-17} = 1, n_{16-19} = 1, n_{01-08} = 1, n_{14-23} = 1. \end{aligned}$$

Custo US\$ 971.00 $\times 10^6$ e $\max \{r^q\} = 2, 72$ (MW):

$$\begin{aligned} n_{01-02} = 1, n_{01-05} = 1, n_{03-24} = 1, n_{04-09} = 1, n_{05-10} = 1, n_{06-10} = 2, n_{07-08} = 3, \\ n_{08-09} = 2, n_{08-10} = 1, n_{09-11} = 1, n_{09-12} = 1, n_{10-11} = 1, n_{10-12} = 1, n_{11-14} = 1, \\ n_{12-13} = 1, n_{14-16} = 1, n_{15-24} = 1, n_{16-17} = 1, n_{16-19} = 1, n_{02-08} = 1, n_{14-23} = 1. \end{aligned}$$

Custo US\$ 956.00 $\times 10^6$ e $\max \{r^q\} = 19, 79$ (MW):

$$\begin{aligned} n_{01-02} = 1, n_{01-05} = 1, n_{03-24} = 1, n_{04-09} = 1, n_{05-10} = 1, n_{06-10} = 2, n_{07-08} = 3, \\ n_{08-09} = 2, n_{08-10} = 1, n_{09-12} = 1, n_{10-11} = 1, n_{10-12} = 1, n_{11-14} = 1, n_{12-13} = 1, \\ n_{14-16} = 1, n_{15-24} = 1, n_{16-17} = 1, n_{16-19} = 1, n_{01-08} = 1, n_{02-08} = 1, n_{14-23} = 1. \end{aligned}$$

Custo US\$ 945.00 $\times 10^6$ e $\max \{r^q\} = 34, 12$ (MW):

$$\begin{aligned} n_{01-02} = 1, n_{01-05} = 1, n_{03-24} = 1, n_{04-09} = 1, n_{05-10} = 1, n_{06-10} = 2, n_{07-08} = 3, \\ n_{08-09} = 2, n_{08-10} = 1, n_{09-12} = 1, n_{10-11} = 1, n_{10-12} = 1, n_{11-14} = 1, n_{12-13} = 1, \\ n_{14-16} = 1, n_{15-16} = 1, n_{15-24} = 1, n_{16-17} = 1, n_{16-19} = 1, n_{02-08} = 1, n_{14-23} = 1. \end{aligned}$$

Custo US\$ 921.00 $\times 10^6$ e $\max \{r^q\} = 35, 01$ (MW):

$$\begin{aligned} n_{01-02} = 1, n_{01-05} = 1, n_{03-24} = 1, n_{04-09} = 1, n_{05-10} = 1, n_{06-10} = 2, n_{07-08} = 3, \\ n_{08-09} = 2, n_{08-10} = 1, n_{09-12} = 1, n_{10-11} = 1, n_{10-12} = 1, n_{11-14} = 1, n_{12-13} = 1, \\ n_{14-16} = 1, n_{15-24} = 1, n_{16-17} = 1, n_{16-19} = 1, n_{02-08} = 1, n_{14-23} = 1. \end{aligned}$$

Custo US\$ 903.00 $\times 10^6$ e $\max \{r^q\} = 44, 23$ (MW):

$$\begin{aligned} n_{01-02} = 1, n_{01-05} = 1, n_{03-24} = 1, n_{04-09} = 1, n_{05-10} = 2, n_{06-10} = 2, n_{07-08} = 3, \\ n_{08-09} = 2, n_{09-12} = 1, n_{10-11} = 1, n_{10-12} = 1, n_{11-14} = 1, n_{12-13} = 1, n_{14-16} = 1, \\ n_{15-24} = 1, n_{16-17} = 1, n_{16-19} = 1, n_{01-08} = 1, n_{14-23} = 1. \end{aligned}$$

Custo US\$ 882.00 $\times 10^6$ e $\max \{r^q\} = 47, 66$ (MW):

$$\begin{aligned} n_{01-02} = 1, n_{01-05} = 1, n_{03-24} = 1, n_{04-09} = 1, n_{05-10} = 1, n_{06-10} = 2, n_{07-08} = 2, \\ n_{08-09} = 2, n_{09-12} = 1, n_{10-11} = 1, n_{10-12} = 1, n_{11-14} = 1, n_{12-13} = 1, n_{14-16} = 1, \\ n_{15-24} = 1, n_{16-17} = 1, n_{01-08} = 1, n_{06-07} = 1, n_{14-23} = 1. \end{aligned}$$

Custo US\$ 864.00 $\times 10^6$ e $\max \{r^q\} = 54, 42$ (MW):

$$\begin{aligned} n_{01-02} = 1, n_{01-05} = 1, n_{03-24} = 1, n_{04-09} = 1, n_{05-10} = 1, n_{06-10} = 3, n_{07-08} = 3, \\ n_{08-09} = 2, n_{09-12} = 1, n_{10-11} = 1, n_{10-12} = 1, n_{11-14} = 1, n_{12-13} = 1, n_{14-16} = 1, \\ n_{15-24} = 1, n_{16-17} = 1, n_{01-08} = 1, n_{14-23} = 1. \end{aligned}$$

Custo US\$ 846.00 $\times 10^6$ e $\max \{r^q\} = 60, 40$ (MW):

$$\begin{aligned} n_{01-02} = 1, n_{01-05} = 1, n_{03-24} = 1, n_{04-09} = 1, n_{05-10} = 1, n_{06-10} = 2, n_{07-08} = 3, \\ n_{08-09} = 2, n_{09-12} = 1, n_{10-11} = 1, n_{10-12} = 1, n_{11-14} = 1, n_{12-13} = 1, n_{14-16} = 1, \\ n_{15-24} = 1, n_{16-17} = 1, n_{02-08} = 1, n_{14-23} = 1. \end{aligned}$$

Custo US\$ 830.00 $\times 10^6$ e $\max \{r^q\} = 67, 82$ (MW):

$$\begin{aligned} n_{01-02} = 1, n_{01-05} = 1, n_{03-24} = 1, n_{04-09} = 1, n_{05-10} = 1, n_{06-10} = 2, n_{07-08} = 2, \\ n_{08-09} = 2, n_{09-12} = 1, n_{10-11} = 1, n_{10-12} = 1, n_{11-14} = 1, n_{12-13} = 1, n_{14-16} = 1, \\ n_{15-24} = 1, n_{16-17} = 1, n_{02-08} = 1, n_{14-23} = 1. \end{aligned}$$

Custo US\$ 824.00 $\times 10^6$ e $\max \{r^q\} = 98, 88$ (MW):

$$\begin{aligned} n_{01-02} = 1, n_{03-24} = 1, n_{04-09} = 1, n_{05-10} = 1, n_{06-10} = 2, n_{07-08} = 3, n_{08-09} = 2, \\ n_{09-12} = 1, n_{10-11} = 1, n_{10-12} = 1, n_{11-14} = 1, n_{12-13} = 1, n_{14-16} = 1, n_{15-24} = 1, \\ n_{16-17} = 1, n_{02-08} = 1, n_{14-23} = 1. \end{aligned}$$

Custo US\$ 810.00 $\times 10^6$ e $\max \{r^q\} = 108,99$ (MW):

$$n_{01-02} = 1, n_{03-24} = 1, n_{04-09} = 1, n_{05-10} = 1, n_{06-10} = 2, n_{07-08} = 2, n_{08-09} = 1, \\ n_{08-10} = 1, n_{09-12} = 1, n_{10-11} = 1, n_{10-12} = 1, n_{11-14} = 1, n_{12-13} = 1, n_{14-16} = 1, \\ n_{15-24} = 1, n_{16-17} = 1, n_{01-08} = 1, n_{14-23} = 1.$$

Custo US\$ 797.00 $\times 10^6$ e $\max \{r^q\} = 118,23$ (MW):

$$n_{01-02} = 1, n_{03-24} = 1, n_{05-10} = 1, n_{06-10} = 3, n_{07-08} = 2, n_{08-09} = 2, n_{09-12} = 1, \\ n_{10-11} = 1, n_{10-12} = 1, n_{11-14} = 1, n_{12-13} = 1, n_{14-16} = 1, n_{15-24} = 1, n_{16-17} = 1, \\ n_{02-08} = 1, n_{14-23} = 1.$$

Custo US\$ 781.00 $\times 10^6$ e $\max \{r^q\} = 124,34$ (MW):

$$n_{01-02} = 1, n_{03-24} = 1, n_{05-10} = 1, n_{06-10} = 2, n_{07-08} = 2, n_{08-09} = 2, n_{09-12} = 1, \\ n_{10-11} = 1, n_{10-12} = 1, n_{11-14} = 1, n_{12-13} = 1, n_{14-16} = 1, n_{15-24} = 1, n_{16-17} = 1, \\ n_{02-08} = 1, n_{14-23} = 1.$$

Custo US\$ 773.00 $\times 10^6$ e $\max \{r^q\} = 149,81$ (MW):

$$n_{01-02} = 1, n_{03-24} = 1, n_{05-10} = 1, n_{06-10} = 2, n_{07-08} = 2, n_{08-09} = 2, n_{09-12} = 1, \\ n_{10-12} = 2, n_{12-13} = 1, n_{12-23} = 1, n_{14-16} = 1, n_{15-24} = 1, n_{16-17} = 1, n_{01-08} = 1.$$

Custo US\$ 767.00 $\times 10^6$ e $\max \{r^q\} = 183,47$ (MW):

$$n_{01-02} = 1, n_{03-24} = 1, n_{05-10} = 1, n_{06-10} = 2, n_{07-08} = 1, n_{08-09} = 2, n_{09-12} = 1, \\ n_{10-11} = 1, n_{10-12} = 1, n_{11-14} = 1, n_{12-13} = 1, n_{14-16} = 1, n_{15-24} = 1, n_{16-17} = 1, \\ n_{01-08} = 1, n_{14-23} = 1.$$

Custo US\$ 757.00 $\times 10^6$ e $\max \{r^q\} = 205,49$ (MW):

$$n_{01-02} = 1, n_{03-24} = 1, n_{05-10} = 1, n_{06-10} = 2, n_{07-08} = 1, n_{08-09} = 2, n_{09-12} = 1, \\ n_{10-12} = 2, n_{12-13} = 1, n_{12-23} = 1, n_{14-16} = 1, n_{15-24} = 1, n_{16-17} = 1, n_{01-08} = 1.$$

Custo US\$ 738.00 $\times 10^6$ e $\max \{r^q\} = 215,77$ (MW):

$$n_{01-02} = 1, n_{03-24} = 1, n_{05-10} = 1, n_{06-10} = 2, n_{07-08} = 2, n_{08-09} = 2, n_{09-12} = 1, \\ n_{10-12} = 2, n_{12-13} = 1, n_{12-23} = 1, n_{14-16} = 1, n_{15-24} = 1, n_{16-17} = 1.$$

Custo US\$ 735.00 $\times 10^6$ e $\max \{r^q\} = 245,09$ (MW):

$$n_{03-24} = 1, n_{05-10} = 1, n_{06-10} = 2, n_{07-08} = 2, n_{08-09} = 2, n_{09-12} = 1, n_{10-12} = 2, \\ n_{12-13} = 1, n_{12-23} = 1, n_{14-16} = 1, n_{15-24} = 1, n_{16-17} = 1.$$

Custo US\$ 722.00 $\times 10^6$ e $\max \{r^q\} = 248,27$ (MW):

$$n_{01-02} = 1, n_{03-24} = 1, n_{05-10} = 1, n_{06-10} = 2, n_{07-08} = 1, n_{08-09} = 2, n_{09-12} = 1, \\ n_{10-12} = 2, n_{12-13} = 1, n_{12-23} = 1, n_{14-16} = 1, n_{15-24} = 1, n_{16-17} = 1.$$

Custo US\$ 708.00 $\times 10^6$ e $\max \{r^q\} = 257,09$ (MW):

$$n_{01-02} = 1, n_{01-05} = 1, n_{03-24} = 1, n_{04-09} = 1, n_{05-10} = 1, n_{06-10} = 1, n_{07-08} = 3, \\ n_{08-09} = 2, n_{09-12} = 1, n_{10-11} = 1, n_{10-12} = 1, n_{12-13} = 1, n_{14-16} = 1, n_{15-24} = 1, \\ n_{16-17} = 1, n_{17-18} = 1, n_{01-08} = 1.$$

Custo US\$ 685.00 $\times 10^6$ e $\max \{r^q\} = 259,95$ (MW):

$$n_{01-02} = 1, n_{01-05} = 1, n_{03-24} = 1, n_{05-10} = 2, n_{06-10} = 2, n_{07-08} = 3, n_{08-09} = 2, \\ n_{09-12} = 1, n_{10-11} = 1, n_{10-12} = 1, n_{12-13} = 1, n_{14-16} = 1, n_{15-24} = 1, n_{16-17} = 1, \\ n_{17-18} = 1.$$

Custo US\$ 662.00 $\times 10^6$ e $\max \{r^q\} = 264,72$ (MW):

$$n_{01-02} = 1, n_{01-05} = 1, n_{03-24} = 1, n_{05-10} = 1, n_{06-10} = 2, n_{07-08} = 3, n_{08-09} = 2, \\ n_{09-12} = 1, n_{10-11} = 1, n_{10-12} = 1, n_{12-13} = 1, n_{14-16} = 1, n_{15-24} = 1, n_{16-17} = 1, \\ n_{17-18} = 1.$$

Custo US\$ 634.00 $\times 10^6$ e $\max \{r^q\} = 303,52$ (MW):

$$n_{01-02} = 1, n_{03-24} = 1, n_{04-09} = 1, n_{06-10} = 2, n_{07-08} = 3, n_{08-09} = 1, n_{09-12} = 1, \\ n_{10-11} = 1, n_{10-12} = 1, n_{12-13} = 1, n_{14-16} = 1, n_{15-24} = 1, n_{16-17} = 1, n_{17-18} = 1, \\ n_{02-08} = 1.$$

Custo US\$ 633.00 $\times 10^6$ e $\max \{r^q\} = 314,75$ (MW):

$$n_{01-02} = 2, n_{03-24} = 1, n_{04-09} = 1, n_{06-10} = 2, n_{07-08} = 4, n_{08-09} = 1, n_{09-12} = 1, \\ n_{10-11} = 1, n_{10-12} = 1, n_{12-13} = 1, n_{14-16} = 1, n_{15-24} = 1, n_{16-17} = 1, n_{02-08} = 1.$$

Custo US\$ 614.00 $\times 10^6$ e $\max \{r^q\} = 315,29$ (MW):

$$n_{01-02} = 1, n_{03-24} = 1, n_{04-09} = 1, n_{06-10} = 2, n_{07-08} = 3, n_{08-09} = 1, n_{09-12} = 1, \\ n_{10-11} = 1, n_{10-12} = 1, n_{12-13} = 1, n_{14-16} = 1, n_{15-24} = 1, n_{16-17} = 1, n_{02-08} = 1.$$

Custo US\$ 607.00 $\times 10^6$ e $\max \{r^q\} = 350,22$ (MW):

$$n_{01-02} = 1, n_{01-05} = 1, n_{03-24} = 1, n_{04-09} = 1, n_{06-10} = 2, n_{07-08} = 2, n_{08-09} = 1, \\ n_{09-12} = 1, n_{10-11} = 1, n_{10-12} = 1, n_{12-13} = 1, n_{14-16} = 1, n_{15-24} = 1, n_{16-17} = 1, \\ n_{17-18} = 1.$$

Custo US\$ 596.00 $\times 10^6$ e $\max \{r^q\} = 360,53$ (MW):

$$n_{01-02} = 1, n_{03-24} = 1, n_{05-10} = 1, n_{06-10} = 2, n_{07-08} = 2, n_{08-09} = 1, n_{09-12} = 1, \\ n_{10-11} = 1, n_{10-12} = 1, n_{12-13} = 1, n_{14-16} = 1, n_{15-24} = 1, n_{16-17} = 1, n_{01-08} = 1.$$

Custo US\$ 571.00 $\times 10^6$ e $\max \{r^q\} = 368,13$ (MW):

$$n_{01-02} = 1, n_{03-24} = 1, n_{06-10} = 2, n_{07-08} = 2, n_{08-09} = 1, n_{09-12} = 1, n_{10-11} = 1, \\ n_{10-12} = 1, n_{12-13} = 1, n_{14-16} = 1, n_{15-24} = 1, n_{16-17} = 1, n_{02-08} = 1.$$

Custo US\$ 561.00 $\times 10^6$ e $\max \{r^q\} = 410,45$ (MW):

$$n_{01-02} = 2, n_{03-24} = 1, n_{06-10} = 2, n_{07-08} = 2, n_{08-09} = 1, n_{09-12} = 1, n_{10-12} = 2, \\ n_{12-13} = 1, n_{14-16} = 1, n_{15-24} = 1, n_{16-17} = 1, n_{17-18} = 1.$$

Custo US\$ 541.00 $\times 10^6$ e $\max \{r^q\} = 424,20$ (MW):

$$n_{01-02} = 2, n_{03-24} = 1, n_{06-10} = 2, n_{07-08} = 2, n_{08-09} = 1, n_{09-12} = 1, n_{10-12} = 2, \\ n_{12-13} = 1, n_{14-16} = 1, n_{15-24} = 1, n_{16-17} = 1.$$

Custo US\$ 538.00 $\times 10^6$ e $\max \{r^q\} = 424, 22$ (MW):

$$n_{01-02} = 1, n_{03-24} = 1, n_{06-10} = 2, n_{07-08} = 2, n_{08-09} = 1, n_{09-12} = 1, n_{10-12} = 2, \\ n_{12-13} = 1, n_{14-16} = 1, n_{15-24} = 1, n_{16-17} = 1.$$

APÊNDICE D - Desempenho do Algoritmo CBGA

D.1 Melhor desempenho do algoritmo CBGA para o sistema IEEE de 24 barras considerando MEG

Tabela 23: Desempenho do algoritmo CBGA para a melhor solução do sistema IEEE de 24 barras considerando MCG.

Número da geração no CBGA	Investimento US\$ $\times 10^6$	Número de PLs
16	1837,16	24386
24	1544,94	30616
43	1514,32	44678
89	1498,00	81168
203	1467,00	175508
281	1461,00	242614
360	1438,00	306338
374	1424,00	317730
376	1415,00	319154
382	1396,00	324494
459	1385,00	387862
491	1353,00	412070
664	1330,00	556962

Parâmetros: 20 indivíduos da população inicial gerados usando AHC. 70 indivíduos da população inicial gerados aleatoriamente, taxa de mutação de 2%, seleção por torneio com 4 pais por torneio, mutação controlada, diversidade de 2 bits.

Valor médio de 839 problemas de PL por iteração (ciclo do CBGA).

D.2 Desempenho do algoritmo CBGA para o sistema IEEE de 24 barras considerando MEG




Figura 36: Melhor desempenho do algoritmo CBGA para o sistema IEEE de 24 barras considerando múltiplos cenários de geração.




Figura 37: Curvas de desempenho do algoritmo CBGA para o sistema IEEE de 24 barras considerando mutação variável.

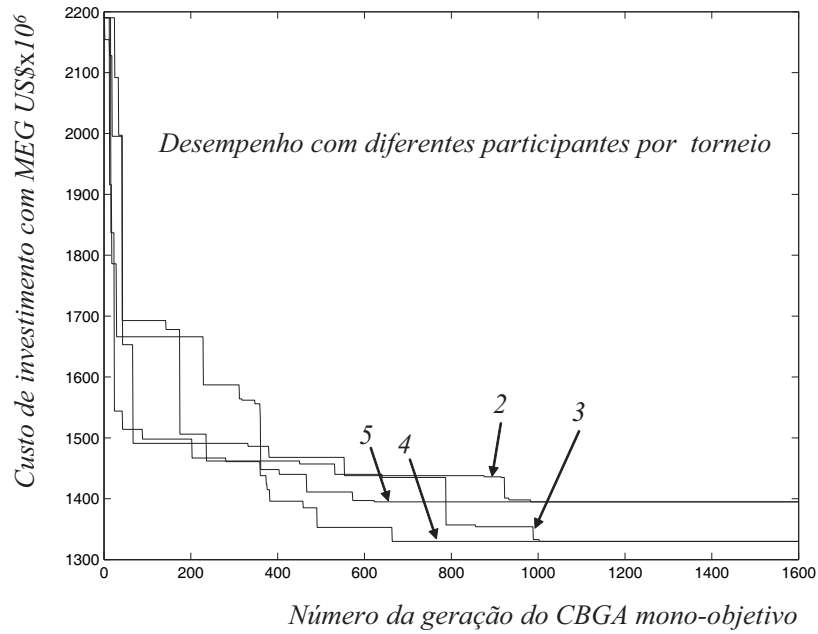


Figura 38: Curvas de desempenho do algoritmo CBGA para o sistema IEEE de 24 barras considerando seleção variável.

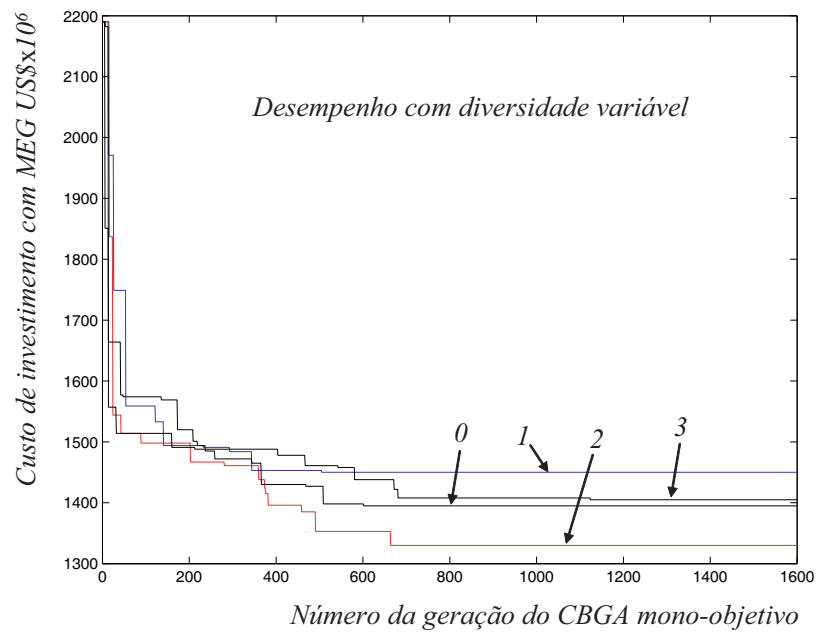


Figura 39: Curvas de desempenho do algoritmo CBGA para o sistema IEEE de 24 barras considerando diversidade variável.

D.3 Desempenho do algoritmo CBGA usando população inicial aleatória

Tabela 24: Desempenho do algoritmo CBGA usando população inicial aleatória o sistema IEEE de 24 barras considerando MCG

Número da geração no CBGA	Investimento US\$ $\times 10^6$	Número de PLs
315	2453,00	256854
427	2353,00	347278
455	2203,00	367214
523	2183,00	419368
589	2164,00	473302
626	2001,00	502850
722	1971,00	577076
892	1950,00	704524
930	1920,00	733716
961	1919,00	760060
982	1885,00	775546
1023	1755,00	806340
1141	1739,00	897654
1260	1705,00	989680
1287	1673,00	1011040
1395	1655,00	1100040
1500	1623,00	1188560
2616	1595,60	2033116

APÊNDICE E - Trabalhos Mais Relevantes

Desenvolvidos Durante a Execução da Presente Pesquisa

- *Transmission Network Expansion Planning Considering Multiple Generation Scenarios*, IEEE/PES 2008 Transmission and Distribution Latin America Conference, Bogotá Colombia, 2008.
- *Transmission Network Expansion Planning Considering Uncertainty in Generation and Demand*, IEEE/PES 2008 Transmission and Distribution Latin America Conference, Bogotá Colombia, 2008.
- *Algoritmo Genético Especializado Aplicado al Problema de Planeamiento de la Transmisión con Incertidumbre en Generación y Demanda*, XIV Latin Ibero-American Congress on Operations Research (CLAIO), Cartagena Colombia, 2008.
- *Métodos Inteligentes para Inicializar Algoritmos Branch and Bound en Planeamiento de Sistemas Eléctricos de Transmisión*, XIV Latin Ibero-American Congress on Operations Research (CLAIO), Cartagena Colombia, 2008.
- *Efficiency Oriented Transmission System Expansion Planning*, enviado a consideração para publicação na revista IEEE transactions on Power Systems, 2008.
- *Using traditional heuristic algorithms on initial population of genetic algorithms applied to the transmission expansion planning problem*, enviado a consideração para publicação na revista IET Generation, Transmission and Distribution, 2008.
- *Planeamiento de la Transmisión Utilizando Punto Interior No Lineal y Algoritmo Genético de Chu-Beasley*, Revista Scientia et Technica, año XIII, No. 38, Colombia, Junio 2008.
- *Planeamiento de la Expansión de la Transmisión Considerando Contingencias Mediante el Algoritmo Multiobjetivo NSGA-II*, Revista Scientia et Technica, año XIII, No. 36, 2007.