

**UNIVERSIDADE FEDERAL DE ITAJUBÁ
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA**

MURIELL DE RODRIGUES E FREIRE

**ALGORITMO EVOLUTIVO ADAPTATIVO
VIA MULTIOPERADORES APLICADO AO
PLANEJAMENTO DA EXPANSÃO DE
SISTEMAS DE TRANSMISSÃO**

Tese submetida ao Programa de Pós-Graduação em Engenharia Elétrica como parte dos requisitos para obtenção do Título de Doutor em Ciências em Engenharia Elétrica.

Área de Concentração: Automação e Sistemas Elétricos Industriais

Orientador: Prof. Armando Martins Leite da Silva

Coorientador: Prof. Leonardo de Mello Honório

Julho de 2016
Itajubá – MG



Ministério da Educação
UNIVERSIDADE FEDERAL DE ITAJUBÁ
Criada pela Lei nº 10.435, de 24 de abril de 2002

A N E X O I

FOLHA DE JULGAMENTO DA BANCA EXAMINADORA

Título da Tese: **“Algoritmo Evolutivo Adaptativo Via Multioperadores Aplicado ao Planejamento da Expansão de Sistemas de Transmissão”**

Autor: **Muriell de Rodrigues e Freire**

JULGAMENTO

Examinadores	Conceito A = Aprovado - R = Reprovado	Rubrica
1º	A	
2º	A	
3º	A	
4º	A	
5º	A	
6º	A	

Resultado Final: Conceito final: A, ou seja, Aprovado

Observações: _____

Observações:

- (1) O Trabalho será considerado Aprovado (A) se todos os Examinadores atribuírem conceito A.
- (2) O Trabalho será considerado Reprovado (R) se forem atribuídos pelos menos 2 conceitos R.
- (3) O Trabalho será considerado no Conceito final como Insuficiente (I) se for atribuído um conceito R. Neste caso o candidato deverá apresentar novo trabalho. A banca deve definir como avaliar a nova versão da Tese.

Este documento terá a validade de 90 (noventa) dias a contar da data da defesa da Tese.

Itajubá, 01 de julho de 2016

Prof. Dr. Luiz Antônio da Fonseca Manso
1º Examinador - UFSJ

Prof. Dr. Edimar José de Oliveira
2º Examinador - UFJF

Prof. Dr. Zulmar Soares Machado Júnior
3º Examinador - UNIFEI

Prof. Dr. Carlos Henrique Valério de Moraes
4º Examinador - UNIFEI

Prof. Dr. Leonardo de Mello Honório
5º Examinador (Co-orientador) - UFJF

Prof. Dr. Armando Martins Leite da Silva
6º Examinador (Orientador) - UNIFEI/PUC-Rio

Dedico esta Tese à minha família,
em especial aos meus pais: Gilberto e Luci.

AGRADECIMENTOS

A Deus, pela oportunidade de vivenciar esta conquista, além da coragem e saúde para ultrapassar todas as barreiras impostas para que este sonho pudesse se tornar realidade.

Ao professor Armando Martins Leite da Silva, pelos ensinamentos transmitidos durante o processo de orientação, pela oportunidade, paciência, e amizade, além de todos os incentivos para que eu pudesse concluir este trabalho.

Ao professor Leonardo de Mello Honório, pela coorientação, amizade, incentivos e confiança depositada.

Aos meus pais, Gilberto Freire e Luci Mairy Rodrigues, pelo carinho, amor, apoio, incentivo e ensinamentos que levarei para o resto de minha vida.

À Carla de Souza, por estar ao meu lado em diversos momentos difíceis da minha vida, pela sua paciência, pelo seu carinho e, principalmente, pelo seu amor.

Aos colegas do grupo de pesquisa GESIS, pelo companheirismo e ajuda nos momentos difíceis. Em especial aos colegas Fernando Assis e Lucas Ramalho, por toda a ajuda e amizade.

À Universidade Federal de Itajubá e todos os seus professores, pelos conhecimentos, auxílios, suporte e incentivos recebidos.

A todos aqueles que direta ou indiretamente contribuíram para a realização deste trabalho.

RESUMO

A solução do problema de Planejamento da Expansão da Transmissão (PET) visa determinar os investimentos em reforços à rede elétrica que devem ser realizados para se atender o crescimento do consumo de energia elétrica. A utilização de métodos de otimização exatos se torna inviável em muitos dos problemas PET para sistemas reais, pois a explosão combinatorial torna o custo computacional proibitivo. Nesse sentido, técnicas meta-heurísticas têm demonstrado ser uma excelente opção, apresentando resultados satisfatórios tanto do ponto de vista da qualidade das soluções quanto em relação ao desempenho computacional.

Esta tese de doutorado tem como objetivo propor uma nova meta-heurística para resolução de problemas PET estático e de longo prazo. Baseada nos conceitos dos tradicionais algoritmos evolutivos, o algoritmo proposto utiliza multi-operadores de busca e um mecanismo dinâmico para adaptação das probabilidades de seleção e aplicação destes operadores. Dois conjuntos de operadores estocásticos são propostos: evolutivos e especialistas. A formulação matemática adotada para o PET inclui a definição de um problema de programação linear, baseado no modelo de fluxo de potência DC com perdas, e um algoritmo para avaliação do critério de segurança “N-1”, utilizado para garantir um nível adequado de confiabilidade ao sistema. Como forma de reduzir o custo dos investimentos sem comprometer a confiabilidade, uma nova metodologia é proposta para avaliação do critério “N-1”, a qual relaxa os limites operacionais dos equipamentos permitindo um determinado nível de sobrecarga em caso de contingências simples.

A ideia principal do algoritmo proposto é, a partir de um conjunto de operadores de busca com diferentes heurísticas, descobrir quais operadores são mais eficientes na resolução de um determinado problema PET, e em qual momento do processo de busca cada operador deve ser utilizado. O desempenho deste algoritmo é avaliado através de sua aplicação na resolução de problemas PET para duas redes bastante conhecidas na literatura da área: Sistema IEEE RTS-79 e Sistema Sul Brasileiro. Os resultados são amplamente discutidos.

ABSTRACT

The solution of the Transmission Expansion Planning (TEP) problem aims to define the investments in reinforcements for the electrical network that must be carried out to meet the growth of energy demand. The use of traditional optimization methods becomes unfeasible in many of TEP problems for real systems, because the combinatorial explosion makes the computational cost prohibitive. In this context, metaheuristics techniques have proven to be an excellent option, with acceptable results bearing in mind the quality of solutions and computational performance.

This doctoral thesis aims to propose a new metaheuristic for solving static and long-term TEP problems. Based on the concepts of the traditional evolutionary algorithms, the proposed algorithm uses multi-operators of search and a dynamic mechanism for adaptation of the selection probabilities of these operators. Two sets of stochastic operators are proposed: evolutionary and specialist. The mathematical formulation adopted for TEP includes the definition of a linear programming problem, based on the DC power flow model with losses, and an algorithm to evaluate the "N-1" security criterion, used to ensure an adequate reliability level for the system. In order to reduce the investment cost without compromising reliability levels, a new methodology is proposed to evaluate the "N-1" criterion, which relaxes the operating limits of equipment allowing restricted levels of overload in case of single contingencies.

The main idea of the proposed algorithm is, from a set of search operators based on different heuristics, find out those operators that are more efficient in solving a given TEP problem, and at what instant of the search process each operator should be used. The proposed algorithm performance is evaluated through its application in solving TEP problems for two well known networks in the power system area: IEEE RTS-79 and Southern Brazilian systems. The results are deeply discussed.

SUMÁRIO

LISTA DE FIGURAS	iii
LISTA DE TABELAS	v
LISTA DE ABREVIATURAS	viii
CAPÍTULO 1: INTRODUÇÃO.....	1
1.1 CONSIDERAÇÕES GERAIS.....	1
1.2 REVISÃO BIBLIOGRÁFICA	4
1.2.1 Modelagem Matemática do PET.....	5
1.2.2 Linhas de Abordagem.....	8
1.2.3 Técnicas para Resolução do Problema PET	13
1.2.4 Meta-heurísticas Aplicadas ao Problema PET.....	17
1.3 MOTIVAÇÃO E OBJETIVO DA TESE.....	32
1.4 ESTRUTURA DA TESE.....	36
CAPÍTULO 2 : ALGORITMO EVOLUTIVO ADAPTATIVO	38
2.1 INTRODUÇÃO À COMPUTAÇÃO EVOLUCIONÁRIA	38
2.2 ADAPTAÇÃO DE PARÂMETROS.....	45
2.2.1 Ajuste de Parâmetros em Algoritmos Evolutivos	45
2.2.2 Algoritmos Evolutivos com Múltiplos Operadores de Reprodução	47
2.2.3 Adaptação das Probabilidades de Seleção dos Operadores.....	49
2.2.4 Avaliação do Desempenho dos Operadores	51
2.2.5 Avaliação da Qualidade dos Operadores	55
2.2.6 Estratégias para Seleção Adaptativa de Operadores	57
2.3 OPERADORES EVOLUTIVOS.....	64
2.4 CONSIDERAÇÕES FINAIS.....	69
CAPÍTULO 3: PLANEJAMENTO DA EXPANSÃO DA TRANSMISSÃO	70
3.1 INTRODUÇÃO.....	70
3.2 FORMULAÇÃO MATEMÁTICA DO PROBLEMA PET	70
3.2.1 Perdas Ôhmicas na Transmissão	74
3.2.2 Critério de Segurança “N-1”	75
3.2.3 Representação e Avaliação das Soluções.....	78
3.2.4 Método de Manipulação de Restrições ϵ -constrained	80

3.3	ALGORITMO PROPOSTO	83
3.3.1	Inicialização Inteligente da População	89
3.3.2	Operadores Especialistas	92
3.4	CONSIDERAÇÕES FINAIS	94
CAPÍTULO 4: RESULTADOS E DISCUSSÕES		96
4.1	INTRODUÇÃO	96
4.2	ÍNDICES E CRITÉRIOS PARA AVALIAÇÃO DO DESEMPENHO	97
4.3	SISTEMA IEEE RTS-79.....	103
4.3.1	Caso 1: IEEE24 “N-0”	104
4.3.2	Caso 2: IEEE24 “N-1” 0%	109
4.3.3	Caso 3: IEEE24 “N-1” 10%	114
4.3.4	Caso 4: IEEE24 “N-1” 20%	119
4.4	SISTEMA SUL BRASILEIRO.....	123
4.4.1	Caso 5: SBR “N-0”	124
4.4.2	Caso 6: SBR “N-1” 0%	130
4.4.3	Caso 7: SBR “N-1” 10%	135
4.4.4	Caso 8: SBR “N-1” 20%	140
4.5	CONSIDERAÇÕES FINAIS	145
CAPÍTULO 5: ASPECTOS COMPLEMENTARES		149
5.1	INTRODUÇÃO	149
5.2	ESTUDO DE CONFIABILIDADE	152
5.2.1	Avaliação da Confiabilidade para o Sistema IEEE RTS-79	155
5.2.2	Avaliação da Confiabilidade para o Sistema Sul Brasileiro	158
5.3	ESTUDO DE COMPENSAÇÃO REATIVA	161
5.3.1	Alocação de Banco de Capacitores para o Sistema IEEE RTS-79	165
5.3.2	Alocação de Banco de Capacitores para o Sistema Sul Brasileiro.....	168
5.4	ANÁLISE DOS CUSTOS	170
5.5	CONSIDERAÇÕES FINAIS	176
CAPÍTULO 6: CONCLUSÕES E TRABALHOS FUTUROS		178
REFERÊNCIAS BIBLIOGRÁFICAS		186
APÊNDICE A: DADOS PARA OS SISTEMAS TESTES.....		194

LISTA DE FIGURAS

Figura 2.1: Fluxograma do ciclo evolutivo básico de um EA [ES03]	41
Figura 2.2: Taxonomia global do ajuste de parâmetros em EAs [EMSS07].....	47
Figura 3.1: Pseudocódigo do algoritmo AES-TEP	87
Figura 3.2: Pseudocódigo da função <i>AplicarOperador</i>	88
Figura 3.3: Pseudocódigo da função <i>AdaptarProbabilidades</i>	88
Figura 4.1: Diagrama unifilar para o sistema IEEE24 - topologia original	103
Figura 4.2: Gráfico de convergência comparando o grupo dos operadores evolutivos (Evol) com o grupo dos operadores especialistas (Exp) - Caso IEEE24 “N-0”	106
Figura 4.3: Gráfico de convergência comparando as inicializações 100% aleatória (“100%”), mista (“50%”) e 100% inteligente (“0%”) - Caso IEEE24 “N-0”	108
Figura 4.4: Gráfico de convergência comparando versões AES-TEP com multioperadores e com um único operador (estática) - Caso IEEE24 “N-0”	109
Figura 4.5: Gráfico de convergência comparando o grupo dos operadores evolutivos (Evol) com o grupo dos operadores especialistas (Exp) - Caso IEEE24 “N-1” 0%	111
Figura 4.6: Gráfico de convergência comparando as inicializações 100% aleatória (“100%”), mista (“50%”) e 100% inteligente (“0%”) - Caso IEEE24 “N-1” 0%	112
Figura 4.7: Gráfico de convergência comparando versões AES-TEP com multioperadores e com um único operador (estática) - Caso IEEE24 “N-1” 0%	113
Figura 4.8: Gráfico de convergência comparando o grupo dos operadores evolutivos (Evol) com o grupo dos operadores especialistas (Exp) - Caso IEEE24 “N-1” 10% ..	116
Figura 4.9: Gráfico de convergência comparando as inicializações 100% aleatória (“100%”), mista (“50%”) e 100% inteligente (“0%”) - Caso IEEE24 “N-1” 10%	117
Figura 4.10: Gráfico de convergência comparando versões AES-TEP com multioperadores e com um único operador (estática) - Caso IEEE24 “N-1” 10%	118
Figura 4.11: Gráfico de convergência comparando o grupo dos operadores evolutivos (Evol) com o grupo dos operadores especialistas (Exp) - Caso IEEE24 “N-1” 20% ..	121
Figura 4.12: Gráfico de convergência comparando as inicializações 100% aleatória (“100%”), mista (“50%”) e 100% inteligente (“0%”) - Caso IEEE24 “N-1” 20%	122
Figura 4.13: Gráfico de convergência comparando versões AES-TEP com multioperadores e com um único operador (estática) - Caso IEEE24 “N-1” 20%	123
Figura 4.14: Diagrama unifilar para o sistema SBR - topologia original	124

Figura 4.15: Gráfico de convergência comparando o grupo dos operadores evolutivos (Evol) com o grupo dos operadores especialistas (Exp) - Caso SBR “N-0”	127
Figura 4.16: Gráfico de convergência comparando as inicializações 100% aleatória (“100%”), mista (“50%”) e 100% inteligente (“0%”) - Caso SBR “N-0”	128
Figura 4.17: Gráfico de convergência comparando versões AES-TEP com multioperadores e com um único operador (estática) - Caso SBR “N-0”	130
Figura 4.18: Gráfico de convergência comparando o grupo dos operadores evolutivos (Evol) com o grupo dos operadores especialistas (Exp) - Caso SBR “N-1” 0%	132
Figura 4.19: Gráfico de convergência comparando as inicializações 100% aleatória (“100%”), mista (“50%”) e 100% inteligente (“0%”) - Caso SBR “N-1” 0%	134
Figura 4.20: Gráfico de convergência comparando versões AES-TEP com multioperadores e com um único operador (estática) - Caso SBR “N-1” 0%	135
Figura 4.21: Gráfico de convergência comparando o grupo dos operadores evolutivos (Evol) com o grupo dos operadores especialistas (Exp) - Caso SBR “N-1” 10%	137
Figura 4.22: Gráfico de convergência comparando as inicializações 100% aleatória (“100%”), mista (“50%”) e 100% inteligente (“0%”) - Caso SBR “N-1” 10%	139
Figura 4.23: Gráfico de convergência comparando versões AES-TEP com multioperadores e com um único operador (estática) - Caso SBR “N-1” 10%	140
Figura 4.24: Gráfico de convergência comparando o grupo dos operadores evolutivos (Evol) com o grupo dos operadores especialistas (Exp) - Caso SBR “N-1” 20%	142
Figura 4.25: Gráfico de convergência comparando as inicializações 100% aleatória (“100%”), mista (“50%”) e 100% inteligente (“0%”) - Caso SBR “N-1” 20%	144
Figura 4.26: Gráfico de convergência comparando versões AES-TEP com multioperadores e com um único operador (estática) - Caso SBR “N-1” 20%	145
Figura 5.1: Fluxograma simplificado para o algoritmo de avaliação da confiabilidade	154

LISTA DE TABELAS

Tabela 4.1: Os 10 melhores planos conhecidos para o caso IEEE24 “N-0”	104
Tabela 4.2: Comparação do AES-TEP com e sem adaptação de probabilidades – Grupo dos operadores evolutivos – Caso IEEE24 “N-0”	105
Tabela 4.3: Comparação do AES-TEP com e sem adaptação de probabilidades – Grupo dos operadores especialistas – Caso IEEE24 “N-0”	105
Tabela 4.4: Comparação entre as inicializações 100% aleatória (“100%”), mista (“50%”) e 100% inteligente (“0%”) – Caso IEEE24 “N-0”	107
Tabela 4.5: Comparação entre versões AES-TEP com multioperadores e com um único operador reprodutivo (estática) – Caso IEEE24 “N-0”	108
Tabela 4.6: Os 10 melhores planos conhecidos para o caso IEEE24 “N-1” 0%	110
Tabela 4.7: Comparação entre versões AES-TEP utilizando operadores evolutivos (Evol) ou operadores especialistas (Exp) – Caso IEEE24 “N-1” 0%	110
Tabela 4.8: Comparação entre as inicializações 100% aleatória (“100%”), mista (“50%”) e 100% inteligente (“0%”) – Caso IEEE24 “N-1” 0%	112
Tabela 4.9: Comparação entre versões AES-TEP com multioperadores e com um único operador reprodutivo (estática) – Caso IEEE24 “N-1” 0%	113
Tabela 4.10: Os 10 melhores planos conhecidos para o caso IEEE24 “N-1” 10%	114
Tabela 4.11: Comparação entre versões AES-TEP utilizando operadores evolutivos (Evol) ou operadores especialistas (Exp) – Caso IEEE24 “N-1” 10%	115
Tabela 4.12: Comparação entre as inicializações 100% aleatória (“100%”), mista (“50%”) e 100% inteligente (“0%”) – Caso IEEE24 “N-1” 10%	116
Tabela 4.13: Comparação entre versões AES-TEP com multioperadores e com um único operador reprodutivo (estática) – Caso IEEE24 “N-1” 10%	118
Tabela 4.14: Os 10 melhores planos conhecidos para o caso IEEE24 “N-1” 20%	119
Tabela 4.15: Comparação entre versões AES-TEP utilizando operadores evolutivos (Evol) ou operadores especialistas (Exp) – Caso IEEE24 “N-1” 20%	120
Tabela 4.16: Comparação entre as inicializações 100% aleatória (“100%”), mista (“50%”) e 100% inteligente (“0%”) – Caso IEEE24 “N-1” 20%	121
Tabela 4.17: Comparação entre versões AES-TEP com multioperadores e com um único operador reprodutivo (estática) – Caso IEEE24 “N-1” 20%	122
Tabela 4.18: Os 10 melhores planos conhecidos para o caso SBR “N-0”	125

Tabela 4.19: Comparação do AES-TEP com e sem adaptação de probabilidades – Grupo dos operadores evolutivos – Caso SBR “N-0”	126
Tabela 4.20: Comparação do AES-TEP com e sem adaptação de probabilidades – Grupo dos operadores especialistas – Caso SBR “N-0”	126
Tabela 4.21: Comparação entre as inicializações 100% aleatória (“100%”), mista (“50%”) e 100% inteligente (“0%”) – Caso SBR “N-0”	128
Tabela 4.22: Comparação entre versões AES-TEP com multioperadores e com um úni-co operador reprodutivo (estática) – Caso SBR “N-0”	129
Tabela 4.23: Os 10 melhores planos conhecidos para o caso SBR “N-1” 0%	131
Tabela 4.24: Comparação entre versões AES-TEP utilizando operadores evolutivos (Evol) ou operadores especialistas (Exp) – Caso SBR “N-1” 0%	131
Tabela 4.25: Comparação entre as inicializações 100% aleatória (“100%”), mista (“50%”) e 100% inteligente (“0%”) – Caso SBR “N-1” 0%	133
Tabela 4.26: Comparação entre versões AES-TEP com multioperadores e com um úni-co operador reprodutivo (estática) – Caso SBR “N-1” 0%	134
Tabela 4.27: Os 10 melhores planos conhecidos para o caso SBR “N-1” 10%	136
Tabela 4.28: Comparação entre versões AES-TEP utilizando operadores evolutivos (Evol) ou operadores especialistas (Exp) – Caso SBR “N-1” 10%	136
Tabela 4.29: Comparação entre as inicializações 100% aleatória (“100%”), mista (“50%”) e 100% inteligente (“0%”) – Caso SBR “N-1” 10%	138
Tabela 4.30: Comparação entre versões AES-TEP com multioperadores e com um úni-co operador reprodutivo (estática) – Caso SBR “N-1” 10%	139
Tabela 4.31: Os 10 melhores planos conhecidos para o caso SBR “N-1” 20%	141
Tabela 4.32: Comparação entre versões AES-TEP utilizando operadores evolutivos (Evol) ou operadores especialistas (Exp) – Caso SBR “N-1” 20%	141
Tabela 4.33: Comparação entre as inicializações 100% aleatória (“100%”), mista (“50%”) e 100% inteligente (“0%”) – Caso SBR “N-1” 20%	143
Tabela 4.34: Comparação entre versões AES-TEP com multioperadores e com um úni-co operador reprodutivo (estática) – Caso SBR “N-1” 20%	144
Tabela 5.1: Classificação do Nível do Risco pela Severidade (SEV)	153
Tabela 5.2: Índices de confiabilidade para o caso IEEE24 “N-1” 0% (Caso 2)	155
Tabela 5.3: Índices de confiabilidade para o caso IEEE24 “N-1” 10% (Caso 3)	156
Tabela 5.4: Índices de confiabilidade para o caso IEEE24 “N-1” 20% (Caso 4)	157

Tabela 5.5: Índices de confiabilidade para o caso SBR “N-1” 0% (Caso 6)	158
Tabela 5.6: Índices de confiabilidade para o caso SBR “N-1” 10% (Caso 7)	159
Tabela 5.7: Índices de confiabilidade para o caso SBR “N-1” 20% (Caso 8)	160
Tabela 5.8: Planos de alocação de reativos para o caso IEEEE24 “N-1” 0% (Caso 2)	166
Tabela 5.9: Planos de alocação de reativos para o caso IEEEE24 “N-1” 10% (Caso 3)	167
Tabela 5.10: Planos de alocação de reativos para o caso IEEEE24 “N-1” 20% (Caso 4)	167
Tabela 5.11: Planos de alocação de reativos para o caso SBR “N-1” 0% (Caso 6)	168
Tabela 5.12: Planos de alocação de reativos para o caso SBR “N-1” 10% (Caso 7)	169
Tabela 5.13: Planos de alocação de reativos para o caso SBR “N-1” 20% (Caso 8)	170
Tabela 5.14: Análise de custos para o Sistema IEEE RTS-79	173
Tabela 5.15: Análise de custos para o Sistema Sul Brasileiro	174
Tabela A.1: Dados de barra para o sistema IEEEE24	195
Tabela A.2: Dados de linhas e transformadores para o sistema IEEEE24	196
Tabela A.3: Dados de barra para o sistema SBR	197
Tabela A.4: Dados de linhas e transformadores para o sistema SBR	198

LISTA DE ABREVIATURAS

ACO	-	Otimização por Colônia de Formigas (Ant Colony Optimization)
AEA	-	Algoritmo Evolutivo Adaptativo (Adaptive Evolutionary Algorithm)
All	-	Algoritmo de Inicialização Inteligente
AIS	-	Sistema Imunológico Artificial (Artificial Immune System)
AP	-	Estratégia Adaptativa Adaptive Pursuit
CHA	-	Algoritmos Heurísticos Construtivos (Constructive Heuristic Algorithm)
DE	-	Evolução Diferencial (Differential Evolution)
EA	-	Algoritmo Evolutivo (Evolutionary Algorithm)
EC	-	Computação Evolucionária ou Evolutiva (Evolutionary Computation)
EENS	-	Valor Esperado da Energia Não Suprida (Expected Energy Not Supplied)
EP	-	Programação Evolucionária (Evolutionary Programming)
EPNS	-	Valor Esperado da Potência Não Suprida (Expected Power Not Supplied)
ES	-	Estratégia Evolutiva (Evolution Strategy)
EvE	-	Exploration versus Exploitation
FPO	-	Fluxo de Potencia Ótimo
GA	-	Algoritmo Genético (Genetic Algorithm)
GP	-	Programação Genética (Genetic Programming)
GRASP	-	Procedimento de Busca Adaptativa Aleatória Gulosa (Greedy Randomized Adaptive Search Procedure)
LCS	-	Sistemas Classificadores com Aprendizagem (Learning Classifier Systems)
LOLC	-	Custo de Perda de Carga (Loss of Load Cost)
LOLD	-	Duração Média de Perda de Carga (Loss of Load Duration)
LOLE	-	Expectativa de Perda de Carga (Loss of Load Expectation)
LOLF	-	Frequência de Perda de Carga (Loss of Load Frequency)
LOLP	-	Probabilidade de Perda de Carga (Loss of Load Probability)
MAB	-	Estratégia Adaptativa Multi-Armed Bandit

MCS	- Simulação Monte Carlo Não Sequencial (Non-Sequential Monte Carlo Simulation)
OO	- Otimização Ordinal (Ordinal Optimization)
PET	- Planejamento da Expansão de Sistemas Elétricos de Transmissão
PL	- Programação Linear (Linear Programming)
PLIM	- Programação Linear Inteiro Misto
PM	- Estratégia Adaptativa Probability Matching
PNL	- Programação Não Linear
PNLIM	- Programação Não Linear Inteiro Misto
POAR	- Planejamento Ótimo de Alocação de Reativos
PPS	- Probabilidade de Problemas no Sistema
PSO	- Otimização por Enxame de Partículas (Particle Swarm Optimization)
QL	- Estratégia Adaptativa Q-learning
SA	- Recozimento Simulado (Simulated Annealing)
SEP	- Sistemas Elétricos de Potência
SEV	- Índice de Severidade (Severity Index)
SPAR	- Subproblema de Alocação de Reativos
SPI	- Subproblema de Investimento
SPO	- Subproblema de Operação
TS	- Busca Tabu (Tabu Search)

CAPÍTULO 1

INTRODUÇÃO

1.1 CONSIDERAÇÕES GERAIS

Dentre os diversos problemas de otimização vinculados à área de Sistemas Elétricos de Potência (SEP), o problema de Planejamento da Expansão da Transmissão (PET) tem como objetivo principal a definição de um plano de expansão para o sistema de transmissão que garanta a manutenção do fornecimento de energia e a operação do sistema de forma adequada [LRM11]. Assim, dado o horizonte de planejamento e um determinado cenário futuro de demanda e geração de energia elétrica, a solução ótima para um problema PET deve especificar as linhas de transmissão a serem construídas e os transformadores a serem instalados na rede elétrica. Além de satisfazer as necessidades do mercado de energia e possuir o menor custo de investimento possível, a solução encontrada para o problema PET deve também atender certas especificações de qualidade e segurança nos serviços [LCAV03].

Os primeiros trabalhos voltados para a resolução de problemas PET foram realizados de forma manual e bastante intuitiva, baseados na experiência dos planejadores que dispunham apenas de programas de fluxo de potência, curto-circuito e estabilidade transitória [R11]. Contudo, nestes trabalhos, a expansão dos sistemas de transmissão era relativamente simples, visto que as alternativas para expansão eram poucas, as incertezas eram mínimas, e o planejamento era limitado a poucos cenários de demanda, hidrologia e parâmetros econômicos. Com o crescimento dos sistemas de transmissão e aumento significativo da dificuldade e complexidade do planejamento da expansão, surgiram metodologias e algoritmos computacionais baseados em técnicas de busca e otimização, com uma forte tendência para o planejamento automático.

Na grande maioria das abordagens matemáticas encontradas na literatura [LCAV03, HHK13], o PET é definido como um problema de Programação Não Linear Inteiro Misto (PNLIM) de grande complexidade. Dentre os fatores que dificultam a resolução de problemas PET para os atuais sistemas de transmissão pode-se citar: a grande dimensão dos sistemas; a natureza discreta das decisões de investimentos (reforços); o comportamento aleatório (i.e., indisponibilidades) dos equipamentos de geração e transmissão; as incertezas associadas ao crescimento da carga e geração, e também na localização de novas fontes de geração [R11]. Assim, o PET se torna um problema de otimização combinatorial classificado como NP-completo, o que significa que ainda não foi descoberto qualquer método computacional que o resolva em um tempo polinomial, uma vez que existem inúmeras soluções de ótimos locais (problema multimodal), as quais aumentam exponencialmente à medida que a dimensão do sistema elétrico analisado cresce [EGR04].

De acordo com [LCAV03], devido à elevação do nível de incertezas com a nova regulamentação do setor elétrico e ao grande nível de competitividade observada no atual mercado de energia, muitos trabalhos técnicos têm sido publicados objetivando expandir o conhecimento na área de planejamento de sistemas elétricos e aprimorar os modelos e métodos de resolução do problema PET. Além disso, os avanços na área da ciência da computação e a maior disponibilidade de recursos computacionais estimularam fortemente as pesquisas de técnicas para resolução dos problemas PET a partir da aplicação de algoritmos computacionais de otimização [HHK13].

Os problemas PET em um horizonte de planejamento de longo prazo podem ser classificados entre diferentes linhas de abordagem [R11]: Interativa ou Automática; Determinística ou Não-Determinística; e ainda Estática ou Dinâmica. Além da escolha do modelo matemático a ser adotado, o processo de resolução de um problema PET envolve a seleção e aplicação de um método computacional de otimização, onde o objetivo principal é a minimização da função custo definida pelo modelo: custo de construção/instalação de novas linhas/transformadores, custo de operação e manutenção da rede, custo das

perdas de energia, custo de interrupção, custos socioambientais, multas, entre outros. De maneira geral, os métodos que têm sido utilizados para resolução dos problemas PET podem ser divididos em duas categorias principais [HHK13]: métodos de otimização matemáticos e métodos de otimização meta-heurísticos. Os métodos matemáticos ainda podem ser subdivididos em métodos exatos e métodos aproximados.

Independentemente da abordagem adotada ou do método de resolução, a partir da obtenção de um conjunto de boas alternativas para expansão do sistema, o planejador deve realizar uma rigorosa análise técnica visando escolher o plano de expansão que apresenta a melhor relação custo/benefício para a sociedade. Algumas das ferramentas computacionais que podem ser utilizadas nesta tarefa [R11]: programas de fluxo de potência não-linear (fluxo AC), análise de curto-circuito, análise do nível de confiabilidade, estudo de estabilidade transitória, entre outros. Se for considerado apenas a construção e/ou instalação de novos equipamentos no sistema, um plano de expansão que proporciona o menor custo de investimento pode não apresentar a melhor relação custo/benefício quando avaliado por algum índice de confiabilidade, nível de perdas ôhmicas, critérios de segurança, ou até mesmo políticas de investimento público. Além disso, a opção por um plano com o menor custo pode, futuramente, demandar gastos adicionais em equipamentos, tornando-o inviável ou até mesmo economicamente desinteressante [LRM11]: por exemplo, a necessidade de suporte de potência reativa (compensação de reativos) e a regulação de tensão podem aumentar muito o custo do investimento.

Dentro do grupo dos algoritmos de otimização chamados de “meta-heurísticas” (métodos estocásticos ou probabilísticos), têm-se os algoritmos baseados na Computação Evolutiva, que adaptam alguns conceitos do funcionamento da natureza para algoritmos computacionais de busca e otimização. Com base na teoria da seleção natural de Darwin [ES03], os mecanismos naturais que provocam a evolução dos seres vivos podem ser considerados processos inteligentes. Além disso, outras linhas de pesquisa estudam o comportamento inteligente de seres vivos em coletividade buscando se auto-organizar para atingir

um dado objetivo. Desta forma, podem ser incluídos no funcionamento dos algoritmos de otimização mecanismos de auto-organização, adaptação, evolução, competição, cooperação, dentre outros [W07].

Na área da Computação Evolutiva, a família dos Algoritmos Evolutivos (*Evolutionary Algorithms* - EAs) têm se mostrado altamente efetivos na resolução de vários dos diferentes problemas de otimização do mundo real [ES03]. Contudo, a utilização dos EAs exige que o usuário tenha conhecimento prévio de como ajustar os parâmetros iniciais do algoritmo. Normalmente, este ajuste é feito de maneira empírica através de métodos de “tentativa e erro” [EMSS07]. De fato, um bom conjunto de parâmetros iniciais aumenta a eficiência do algoritmo, e uma má escolha pode levar ao fracasso do método. Além disso, a qualidade do ajuste de parâmetros depende do problema que está sendo abordado e do estágio do processo de busca [FCSS08, GFC10]: parâmetros que são bons para o estágio inicial do processo de busca podem não ser eficientes para estágios posteriores.

Em um Algoritmo Evolutivo Adaptativo (AEA), um mecanismo de adaptação deve controlar dinamicamente os parâmetros que regulam o processo de busca (processo evolutivo), como forma de otimizar o desempenho do algoritmo na resolução de um problema. Este mecanismo deve receber informações do processo de busca através de alguma estratégia de realimentação [T05, W07]. Tendo em vista a complexidade computacional dos atuais problemas PET e a dificuldade dos planejadores em utilizar ferramentas de otimização mais eficientes com os EAs, espera-se que uma metodologia baseada em um AEA possa ser muito vantajosa para a área de pesquisa em planejamento de SEP.

1.2 REVISÃO BIBLIOGRÁFICA

A presente seção tem como objetivo revisar e discutir o atual estado da arte do problema de Planejamento da Expansão do Sistema de Transmissão de Energia Elétrica (PET), apresentando as principais estratégias para a sua modelagem e resolução. Assim, serão apresentados os trabalhos mais relevantes des-

ta área de pesquisa, abordando os modelos matemáticos para os sistemas de potência e as técnicas de otimização que têm sido utilizadas para resolução de problemas PET.

1.2.1 Modelagem Matemática do PET

A utilização de técnicas computacionais para modelagem e resolução dos problemas PET inicia-se na década de 70, com a formulação do primeiro modelo linear por Garver [G70]. Desde então, a grande maioria dos trabalhos desenvolvidos para a resolução de problemas PET tem utilizado modelos lineares para a representação e avaliação dos planos de expansão [HHK13]. Como apresentado em [RMGH02], estes modelos matemáticos lineares consideram apenas o fluxo de potência ativa (fluxo DC) e podem ser divididos em quatro modelos básicos: Modelo de Transportes, Modelo DC, Modelo Híbrido e Modelo Disjuntivo.

O primeiro modelo linear desenvolvido para o PET, chamado de modelo de transportes [G70], pode ser entendido como uma versão simplificada do modelo DC, onde apenas as restrições lineares são consideradas: leva-se em conta a primeira lei de Kirchhoff e a capacidade de transmissão das linhas, desprezando-se, portanto, a segunda lei de Kirchhoff. Este modelo obteve muito sucesso em suas aplicações, pois o fato de não possuir as restrições não lineares do modelo DC reduz consideravelmente a complexidade do problema PET, tornando-o um problema de programação linear inteiro misto (PLIM). Contudo, deve-se ter em mente que um plano de expansão obtido por este modelo pode apresentar carga não suprida para a rede intacta (i.e., solução não factível) quando se realiza uma análise utilizando um modelo mais completo.

A formulação do modelo DC para o problema PET é uma generalização do modelo de fluxo de carga DC [M83], sendo considerada como ideal para o PET por possuir a melhor relação entre complexidade computacional e qualidade das soluções obtidas. Além disso, pode-se incluir neste modelo a estimação de perdas ôhmicas nas linhas de transmissão e transformadores do sistema: em-

bora as perdas sejam calculadas de forma aproximada, os planos de expansão obtidos com este modelo são, geralmente, mais robustos numa análise AC do que aqueles provenientes de um estudo incluindo o modelo DC sem a consideração das perdas [R11]. As perdas de potência ativa são estimadas e adicionadas como cargas fictícias nas extremidades dos respectivos ramos do sistema.

Apesar do modelo DC não levar em consideração os valores de tensão nas barras e o fluxo de potência reativa, este modelo tem sido amplamente utilizado para formulação do problema PET [HHK13]. Assim, numa primeira fase do processo de planejamento, utiliza-se o modelo DC para se obter o melhor conjunto de soluções candidatas para expansão do sistema e posteriormente faz-se uma análise destas soluções com a inclusão de outras restrições operacionais, critérios de segurança e com o modelo de fluxo AC.

Nos modelos híbridos para os problemas PET pode-se observar uma combinação entre as características do modelo de transporte e do modelo DC, visando melhorar a qualidade da solução final sem aumentar muito a complexidade do problema. O modelo híbrido mais comum considera as restrições não lineares do modelo DC (segunda lei de Kirchhoff) apenas para a topologia original do sistema (antes da expansão); as restrições lineares de balanço de fluxo nas barras (primeira lei de Kirchhoff) e capacidade de transmissão nas linhas são consideradas para todos os ramos do sistema [RMGH02].

Visando transformar o problema não linear em um problema linear equivalente, o modelo disjuntivo incorpora na formulação do PET um parâmetro M de valor suficientemente elevado, considerando os reforços a serem adicionados como valores binários. Contudo, a determinação do parâmetro M e o aumento significativo do número de variáveis são as principais desvantagens deste modelo [R11, MSA15]. Este modelo é o menos utilizado entre todos os modelos formulados para o PET.

Geralmente, o problema PET para sistemas reais pode apresentar duas características que dificultam a utilização de um modelo de fluxo de potência AC:

rede não conexa e linhas sobrecarregadas. Contudo, algumas simplificações podem ser feitas na modelagem do sistema de potência, como por exemplo, a utilização de um modelo linear. Existem alguns trabalhos onde na resolução do problema PET utiliza-se o modelo AC [Y01, DLLW06, RGR07, GRRG09]. Apesar do modelo AC ser mais completo e preciso, para muitos sistemas reais de médio ou grande porte, o problema da explosão combinatorial aliada à maior complexidade do modelo matemático (presença de muitas restrições não lineares) torna o uso deste modelo inviável (custo computacional elevado).

A utilização de um modelo AC numa primeira fase do problema PET (i.e., no processo de busca pelo conjunto de planos candidatos à expansão), ainda é incipiente, sendo poucos trabalhos a considerar o assunto [R11]. Dentre suas vantagens, podem ser citadas: consideração da potência reativa e eficiente alocação de reforços, cálculo preciso das perdas de energia, incorporação da operação de equipamentos não-lineares, etc. Além do aumento da complexidade computacional, o uso do modelo AC tem como desvantagem a dificuldade em ser adequado a uma eficiente técnica de otimização, de forma que alguns métodos (e.g., Newton) podem não apresentar convergência para uma dada configuração. Já o modelo de fluxo DC não apresenta este tipo de problema, pois sempre irá convergir para um dado ponto de operação do sistema, mesmo que este ponto esteja fora da realidade [M83].

No presente trabalho, escolheu-se o modelo DC com perdas para realizar a formulação matemática do problema PET. Como desvantagens deste modelo, podem ser citadas: não consideração da potência reativa; necessidade de se reforçar o plano ótimo quando o mesmo é analisado por um modelo AC; dificuldades para se incluir perdas de energia [HHK13]. Contudo, estas desvantagens podem ser amenizadas com a estimação e incorporação das perdas de potência ativa no modelo DC. É interessante notar que, para sistemas reais de médio e grande porte, as perdas ativas nos elementos do sistema de transmissão podem ser significativas, tanto do ponto de vista financeiro como do operacional.

1.2.2 Linhas de Abordagem

As linhas de abordagem utilizadas para o PET podem ser classificadas como: Interativa ou Automática; Estática ou Multiestágio; Determinística ou Não-Determinística. Independentemente da modelagem matemática utilizada, na abordagem interativa o planejador deve interagir com um algoritmo computacional, interferindo no processo de planejamento da expansão e tomando decisões baseadas em estudos complementares e também na sua própria experiência sobre o sistema. Por outro lado, na abordagem automática as decisões em relação à expansão da rede são definidas a partir de um algoritmo de busca, sem que haja qualquer interferência do planejador [R11].

No planejamento utilizando uma abordagem estática, para um dado horizonte de planejamento (normalmente de médio ou longo prazo), considera-se apenas um único período de tempo para que todos os reforços definidos pelo plano de expansão sejam adicionados ao sistema [R11]. Em outras palavras, a solução do problema PET estático consiste em definir a localização e o número de reforços necessários à expansão da rede elétrica, sem se preocupar com o aspecto temporal da adição dos mesmos (i.e., todos os reforços serão adicionados simultaneamente). Nota-se que a grande maioria dos trabalhos encontrados na literatura se destina a esta linha de abordagem [HHK13], principalmente por apresentar um nível de complexidade menor em relação à abordagem multiestágio.

Num PET do tipo Multiestágio ou Dinâmico [EGR04, LRHM11, POHS15], além da determinação dos ramos que devem ser reforçados e do número de reforços necessários para se atender a demanda futura, deve-se definir também o momento mais apropriado para se construir/instalar os elementos necessários para a expansão do sistema, tendo como objetivo a minimização dos custos dos investimentos em valor presente. Assim, a partir de uma segmentação do horizonte de planejamento em vários estágios, esta abordagem considera também a evolução temporal dos reforços que serão adicionados à rede.

Comparada com a abordagem estática, o planejamento multiestágio apresenta um maior nível de complexidade, pois a segmentação do horizonte de planejamento aumenta consideravelmente o número de variáveis de decisão e de restrições a serem analisadas, exigindo assim um maior esforço computacional para se encontrar o conjunto dos melhores planos de expansão. Apesar de a abordagem multiestágio ser a mais indicada para problemas reais de planejamento, observa-se que uma pequena parcela dos trabalhos encontrados na literatura se dedica a esta linha de abordagem [HHK13]. Além disso, poucos trabalhos incluem incertezas à abordagem multiestágio, visto que a consideração de incertezas, sejam elas externas ou internas, também aumenta significativamente a complexidade do problema PET.

Geralmente, os estudos do PET são delimitados em função do horizonte de tempo [R11]: 1) Longo Prazo, no qual são definidas as principais interconexões de transmissão entre as maiores áreas do sistema, considerando às alternativas de expansão do parque gerador; 2) Médio Prazo, no qual são determinados maiores detalhes das interconexões previamente estipuladas, e também as alternativas de expansão para os sistemas regionais; 3) Curto Prazo, no qual são efetuados os ajustes finais nas alternativas previamente selecionadas, ajustes como a compensação reativa, comportamento dinâmico, níveis de curto circuito, confiabilidade, etc. No caso do planejamento estático, para um horizonte de planejamento de longo prazo pode-se considerar um período de tempo de 15, 20, ou até mesmo 30 anos. Já no caso do planejamento multiestágio, o período temporal entre um estágio e outro pode ser de 2, 3 ou até 5 anos.

Modelos matemáticos adotando uma abordagem determinística para o PET não levam em consideração qualquer tipo de incerteza em relação aos dados utilizados durante o processo de planejamento. Assim, este tipo de abordagem pode tanto negligenciar aspectos relacionados às incertezas externas e internas ao sistema, como também simplificá-los o tanto quanto possível [LRM11]: por exemplo, a demanda de potência futura pode ser representada por cenários mais ou menos otimistas, e ponderações podem ser feitas em relação às taxas de juros. Sistemáticamente, a utilização de modelos determinísticos visa

encontrar soluções para o problema PET que representem o melhor conjunto de opções de investimento (menor custo de investimento possível), e que sejam capazes de minimizar o corte de carga para a condição da rede intacta e também mediante critérios de segurança determinísticos como o “N-1” ou “N-2” (contingências simples ou duplas). Contudo, observa-se que os modelos determinísticos podem ser muito importantes numa etapa inicial do processo de planejamento, de forma a reduzir o espaço de busca ou o número de alternativas a serem avaliadas por modelos mais completos.

Nos modelos com abordagem não determinística, o processo de planejamento leva em consideração algumas incertezas e indefinições vinculadas ao sistema: projeções de mercado (demanda e geração de energia futura), regras de comercialização de energia, taxas de desconto e de câmbio, aflúncias hidrológicas, custos de produção (operação e manutenção, e gastos com combustível) e de interrupção de energia, restrições ambientais, disponibilidades dos equipamentos do sistema, entre outras [R11]. Desta forma, é necessário que os planos de expansão encontrados para o problema PET sejam robustos e flexíveis a ponto de suportar os diferentes cenários futuros, atendendo à demanda futura por energia com a melhor relação entre o custo e o benefício.

De acordo com [LRM11], utilizando-se uma abordagem estática para o problema PET pode-se realizar estudos considerando vários tipos de incertezas e desenvolver novos modelos que visem não somente a minimização dos custos de investimentos, mas também a minimização dos custos relacionados às incertezas do problema (caracterizando como um problema de otimização multicritério ou multiobjetivo).

A grande maioria dos trabalhos realizados nas últimas décadas utiliza a abordagem determinística para o problema PET [HHK13]. Entre estes trabalhos, a maior parte se dedica à abordagem determinística considerando somente o cenário de rede intacta para a geração das propostas de planos de expansão. Observa-se que poucos trabalhos levam em consideração o critério de segurança “N-1” em sua modelagem [MSPCPP82, SSL89, RPCS96, SRRGM05,

YHJX05, TGS08, LRM11, KPR13]. A dificuldade para se incluir o critério de segurança nos modelos se deve ao elevado esforço computacional necessário para se avaliar os planos de expansão candidatos. Como exemplo, a inclusão do “N-1” implica que para cada plano candidato deve-se simular a retirada de um dos equipamentos do sistema por vez, e verificar se o sistema é capaz de absorver essa contingência e operar sem corte de carga ou sobrecargas.

Uma forma de contornar ou reduzir a elevada complexidade gerada pela inclusão de um critério de segurança no modelo determinístico é, após a primeira fase de buscas utilizando apenas o critério da rede intacta (sem contingências), aplicar o critério “N-1” ou “N-2” somente ao conjunto dos melhores planos de expansão encontrados para o problema [MSPCPP82, SSL89, YHJX05]. Contudo, essa estratégia não garante que os planos finais, depois de verificados e elencados por algum critério de segurança, representam as melhores alternativas de expansão para o sistema.

Alguns trabalhos [RPCS96, SRRGM05, TGS08] utilizam a estratégia de incluir o critério de segurança “N-1” em todos os estágios do processo de planejamento da transmissão, incluindo o critério “N-1” como uma restrição de segurança na modelagem do problema. Contudo, esse tipo de modelagem implica num grande aumento da complexidade computacional do problema (devido ao elevado número de execuções da rotina de programação linear) e, para sistemas reais de grande porte, torna-se inviável a utilização desta metodologia quando não se possui uma ferramenta de otimização eficiente.

De acordo com [LRM11], a utilização de uma lista de contingências (listagem de equipamentos que serão testados pelo critério de segurança) considerando todos os equipamentos do sistema pode ser computacionalmente inviável para sistemas reais de grande porte. Neste caso, visando encontrar planos de expansão mais robustos sem comprometer a eficiência do algoritmo de busca e sem despendar muito recurso computacional, a utilização de uma lista de contingências reduzida parece ser uma boa alternativa para se incluir um critério de segurança na modelagem do problema PET: por exemplo, pode-se incluir

na lista apenas os equipamentos mais críticos para o sistema. Além disso, como os planos obtidos podem não conter o plano ótimo, dado que a lista de contingências reduzida pode sofrer alterações na consideração de diferentes planos de expansão, pode-se definir uma área de interesse onde o critério “N-1” deva ser respeitado, resultando em um menor número de contingências a ser considerado para cada plano de expansão candidato [R11].

Em uma abordagem não-determinística para o problema PET considerando incertezas internas, o objetivo é encontrar planos que minimizem os custos de investimento na expansão e de produção requeridos para o fornecimento de energia, atendendo a determinado nível de confiabilidade estabelecido por índices como o LOLE (*Loss of Load Expectation* – Corte de Carga Esperado) [LRM11]. Contudo, observa-se que geralmente os trabalhos considerando incertezas internas fazem uso de funções de avaliação com um alto custo computacional, o que dificulta ainda mais a resolução do problema PET para sistemas de médio e grande porte. Por outro lado, uma abordagem não-determinística, que inclui as incertezas externas ao sistema, deve levar em consideração aspectos como projeção de carga de longo prazo, indefinição da localização de novos produtores de energia (geração distribuída) e configuração futura e novos equipamentos do sistema elétrico. Assim, um dos principais desafios para o planejador é a identificação das incertezas mais relevantes ao estudo e também como fazer a modelagem e inclusão destas incertezas no problema PET [R11].

Vários são os fatores externos que podem influenciar na modelagem do problema PET: nova regulamentação do setor de geração de energia elétrica e alterações na regulação econômica; competitividade do mercado de energia e também o livre acesso aos sistemas de transmissão e distribuição; crescente preocupação com os impactos ambientais da produção e uso da eletricidade; e aumento da oposição pública à construção de linhas de transmissão [LRM11]. Além disso, outras incertezas podem ser incluídas: futuro crescimento da carga; disponibilidade e preços dos combustíveis; e custos e tempos de construção de diferentes reforços. Em geral, os trabalhos divulgados analisam um nú-

mero muito reduzido de cenários [HHK13], especialmente para o caso da transmissão, o qual apresenta requisitos computacionais mais elevados.

1.2.3 Técnicas para Resolução do Problema PET

A princípio, o problema PET de longo prazo utilizando um modelo de fluxo DC pode ser formulado como um problema PNLIM, cuja solução ótima minimiza o custo de investimento na expansão da rede elétrica e faz com que o sistema opere de forma adequada para um dado cenário futuro de carga e geração. Assim, dado a topologia original da rede elétrica em estudo e os valores de geração e carga para o horizonte de planejamento, determina-se a solução de custo mínimo para a expansão, a qual deve atender completamente a demanda futura por energia sem haver cortes de cargas. As técnicas de otimização utilizadas para a resolução deste problema podem ser divididas em duas categorias principais [HHK13]: Métodos Matemáticos e Métodos Meta-heurísticos.

A abordagem mais comum na resolução do problema PET de longo prazo consiste na divisão do problema PNLIM em dois subproblemas [SRRGM05, LRHM11]: 1) Subproblema de Investimento – dado o espaço de busca para o problema (conjunto de todas as possíveis soluções candidatas), deve-se escolher um plano de expansão candidato e avaliar o custo de investimento para realizar tal expansão, buscando assim encontrar planos viáveis com o menor custo possível; 2) Subproblema de operação – o plano de expansão candidato deve ser avaliado de forma a verificar se o sistema apresenta ou não carga não suprida (adicionalmente, pode-se verificar se o plano atende a um determinado nível de segurança ou confiabilidade). Assim, a otimização global é atingida através de uma solução iterativa das resoluções separadas dos subproblemas de operação e investimento. No caso do subproblema de operação, verifica-se que a técnica mais comumente utilizada é a programação linear (PL), representada por algoritmos como o Simplex e Pontos Interiores [R11].

Os métodos de otimização classificados como matemáticos podem ser divididos em três grupos: métodos analíticos, métodos clássicos e algoritmos heurísticos. O primeiro grupo está representado por diversos algoritmos de otimiza-

ção bastante conhecidos da área de pesquisa operacional: algoritmos de programação linear [G70, VGS85], não linear [YH89], dinâmica [DE73], inteiro mista [SSL89], entre outros. Os métodos clássicos estão representados por métodos de decomposição matemática (Decomposição de Benders) [BPG01, MSA15] e algoritmos enumerativos (*Branch and Bound*) [HMGR01, DR14]. Já os métodos heurísticos são representados pelos Algoritmos Heurísticos Construtivos (*Constructive Heuristic Algorithm – CHA*) [G70, MALRS14]. Normalmente, os métodos classificados como matemáticos são determinísticos, ou seja, sempre geram a mesma solução para o problema quando inserida a mesma entrada de dados.

Um dos primeiros algoritmos computacionais propostos para a resolução do problema PET foi o Algoritmo Heurístico Construtivo de Garver [G70]: a partir da utilização de um modelo linear, em cada passo do algoritmo resolve-se um problema PL considerando as variáveis de expansão (reforços adicionados ao sistema) como variáveis reais (valores contínuos) e transformando assim o PNLIM em um simples PL. Vale lembrar que os reforços adicionados ao sistema devem sempre ser representados por valores inteiros. Contudo, alguns trabalhos desconsideram a integralidade das variáveis como forma de determinar os ramos mais atrativos para receber reforços [HHK13].

A estratégia básica da grande maioria dos métodos heurísticos CHA consiste em um processo iterativo onde, dado um critério de desempenho ou índice de atratividade (regras heurísticas), a cada passo do algoritmo escolhe-se adicionar ou remover reforços ao plano de expansão. Estas adições e remoções de reforços guiam o processo em direção a soluções de boa qualidade, mas não garante que a solução ótima global para o problema seja encontrada. As regras heurísticas podem estar relacionadas aos índices de sobrecarga nos ramos [G70], de corte de carga [PP85], do critério do mínimo esforço (distribuição dos fluxos nos ramos) [MSPCPP82] ou ainda ao índice de carga não suprida [BOA01]. A referência [MALRS14] apresenta um CHA baseado em uma árvore de busca, e utiliza dois índices de desempenho para guiar a busca, um baseado na abertura angular entre as barras e outro baseado na diferença de tensão.

A grande diferença entre os diferentes métodos heurísticos encontrados na literatura, além do modelo matemático escolhido para representar o sistema de potência, é a regra heurística utilizada para fazer a seleção dos reforços a serem adicionados ao plano de expansão. Os CHA mais conhecidos na literatura são: Garver [G70], Villasana-Garver-Salon [VGS85], Mínimo Esforço [MSPCPP82], e Mínimo Corte de Carga [PP85]. Apesar destes métodos não garantirem a otimalidade global da solução, observa-se que os planos de boa qualidade identificados por estes métodos podem ser utilizados para fazer a inicialização da população de indivíduos em técnicas de otimização mais eficientes como as meta-heurísticas.

Os métodos clássicos de otimização via algoritmo de *Branch and Bound* [HMGR01] baseiam-se numa estratégia de enumeração e construção de uma árvore de busca, onde cada nó representa um problema candidato e cada ramo representa uma nova restrição que deve ser considerada. A partir dos mecanismos de separação, relaxação e sondagem, todas as soluções inteiras da região viável do problema são enumeradas de modo implícito ou explícito, o que permite para problemas convexos que todas as soluções ótimas sejam encontradas de maneira determinística. Contudo, observa-se que estes métodos, assim como nos métodos de programação dinâmica [DE73], necessita-se de uma grande quantidade de recursos computacionais, limitando sua aplicação a sistemas de pequeno porte ou a modelagens muito simplificadas.

A técnica de decomposição matemática baseada em Benders tem sido aplicada ao problema PET, com objetivo de dividir o problema global em uma série de subproblemas menores e de fácil resolução [BPG01]. Assim, o problema PET é resolvido iterativamente com os subproblemas trocando informações. Como exemplo, os subproblemas de investimento e operação podem ser separados: primeiro, o subproblema de investimento seleciona um plano de expansão preliminar e depois o subproblema de operação analisa o plano proposto e expressa as restrições operativas em termos das variáveis de investimento através de restrições lineares chamadas “Cortes de Benders”; na sequência, estas novas restrições são adicionadas ao subproblema de investimento e uma

nova iteração de Benders é realizada até que a convergência seja alcançada. No algoritmo proposto por [TGS08], o critério de segurança “N-1” é considerado através da inclusão de um subproblema de segurança ao sistema; contudo, observa-se que para sistemas de grande porte este algoritmo é inviável, pois apresenta um alto custo computacional.

A aplicação de métodos analíticos ou clássicos aos problemas PET reais, geralmente, esbarra em obstáculos que dificultam sua utilização [R11]. A não-linearidade dos modelos matemáticos, a explosão combinatorial observada em problemas de grande porte, e a não convexidade do espaço de busca presentes nos estudos de expansão dos sistemas elétricos podem acarretar em problemas de convergência do algoritmo de otimização. Além disso, a multimodalidade da função objetivo (presenças de diversos ótimos locais) dificulta muito a utilização dos métodos determinísticos, pois os mesmos podem ficar presos em soluções subótimas (ótimos locais).

Visando explorar o espaço de busca além do ótimo local e contornar problemas como a explosão combinatorial e o elevado tempo computacional, os modelos meta-heurísticos têm se mostrado como uma excelente alternativa em relação aos demais modelos propostos para o PET [LRHM11]. Estes novos algoritmos, normalmente, são aplicados a problemas de médio e grande porte, são de fácil implementação, e utilizam técnicas inteligentes de busca, como forma de evitar o aprisionamento em regiões subótimas e assim obter soluções de boa qualidade (próximas ao ótimo global) a um custo computacional aceitável.

De acordo com [HHK13], dentro da área de pesquisa do PET diversos algoritmos baseados em métodos meta-heurísticos já foram propostos, como: Recozimento Simulado (SA), Algoritmos Genéticos (GA), Busca Tabu (TS), Programação Evolucionária (EP), Procedimento de Busca Adaptativa Aleatória Gulosa (GRASP), Otimização por Enxame de Partículas (PSO), Estratégia Evolutiva (ES), Otimização por Colônia de Formigas (ACO), Evolução Diferencial (DE), Sistemas Imunológicos Artificiais (AIS), entre outros. Estes algoritmos são de alguma forma não determinísticos, pois a presença de variáveis estocásticas no processo de otimização permite que o algoritmo produza soluções diferen-

tes para uma mesma entrada de dados. Ademais, dos trabalhos que já foram publicados, alguns algoritmos são classificados como sendo de propósito geral (chamados de problemas independentes) e outros como especializados. Os algoritmos especializados empregam informação específica do problema PET e, portanto, sua aplicação fica limitada a este tipo de problema.

Os modelos heurísticos representam uma melhor alternativa aos modelos analíticos ou clássicos, pois, utilizando informações específicas do problema PET (índices de sensibilidades ou atratividade) para definir os reforços, apresentam um baixo esforço computacional mesmo quando aplicados a sistemas de grande porte. Contudo, visto que os índices utilizados consistem de informações de soluções locais para o problema, os algoritmos heurísticos não são capazes de encontrar as melhores soluções para o problema, pois não realizam busca global (fornecem soluções aproximadas para o problema) [R11].

Para sistemas de grande porte, devido a características como o elevado nível combinatório, não convexidade do espaço de busca factível e função objetivo multimodal (múltiplas soluções ótimas, onde algumas podem ser melhores soluções globais e outras melhores soluções locais), algoritmos baseados em meta-heurísticas são mais indicados para a resolução do problema PET, pois apresentam um esforço computacional reduzido em relação os métodos clássicos e analíticos, e ainda são capazes de encontrar soluções de melhor qualidade quando comparados com os modelos heurísticos [LRHM11, R11].

1.2.4 Meta-heurísticas Aplicadas ao Problema PET

Meta-heurísticas baseadas nos GA, ES, DE e AIS fazem parte da família dos Algoritmos Evolutivos (EA), pois utilizam algum método probabilístico para simular o processo de evolução natural das espécies [ES03]. Visto que o algoritmo de otimização proposto pelo presente trabalho de tese (Algoritmo Evolutivo Adaptativo via Multioperadores) para resolução do problema PET está baseado em conceitos relativos aos EAs, a presente seção tem como objetivo abordar exclusivamente os trabalhos utilizando meta-heurísticas para solução do problema PET.

- **Recozimento Simulado (*Simulated Annealing* - SA)**

Os algoritmos classificados como SA baseiam-se em conceitos definidos pela mecânica estatística para resolver problemas de busca e otimização, simulando o processo físico onde um material é esquentado a uma temperatura elevada e então resfriado lentamente de modo a se obter ao final do processo uma estrutura cristalina perfeita (estado de menor energia). O primeiro trabalho a aplicar a meta-heurística SA ao problema PET foi proposto por [RGM96]. Contudo, nos trabalhos apresentados por [GMR98b, MS01, MI07], observa-se um desempenho inferior do SA (soluções de qualidade inferior e maior esforço computacional) quando comparado às meta-heurísticas GA e TS. Observa-se, portanto, que a meta-heurística SA não tem sido muito aplicada como técnica de resolução do problema PET, dado o seu fraco desempenho computacional para se resolver este tipo de problema.

O trabalho apresentado em [BS03] propõe uma aplicação da meta-heurística SA para resolução de problemas PET multiestágio (abordagem dinâmica). O modelo matemático escolhido foi o fluxo de potência DC com perdas. Na avaliação dos planos de expansão candidatos, realiza-se um processo iterativo para cálculos das perdas ativas, representadas como cargas fictícias para o sistema: a perda de potência ativa em um determinado ramo do sistema é calculada e dividida entre as duas barras ligadas pelo ramo. O algoritmo procura minimizar os custos de investimento na expansão e de operação do sistema: para cada plano de expansão, calculam-se os preços marginais nodais de longo prazo e a remuneração marginal correspondente, de modo a obter ao final do processo os valores das tarifas de uso da rede de transmissão.

No trabalho [BS05] tem-se a continuidade do trabalho realizado em [BS03], o qual propõe a inclusão de um índice de confiabilidade na função objetivo. Assim, o problema PET configura-se com um problema multicritérios de difícil resolução, visto que a inclusão de índices de confiabilidade nas restrições dificulta ainda a resolução do problema. O índice de confiabilidade Energia Esperada Não Suprida (*Expected Energy Not Supplied* - EENS) é calculado através de uma simulação Monte Carlo pseudo-cronológica [LMMB00]. Através de intera-

ções entre o algoritmo e o planejador (metodologia interativa), definem-se níveis aceitáveis para o custo de investimento e índice EENS, os quais podem ser alterados impondo uma melhoria ou degradação de um em relação ao outro, até que o planejador esteja satisfeito com a solução encontrada. A incorporação da análise de confiabilidade e o modelo de simulação Monte Carlo pseudo-cronológica resulta num algoritmo que demanda um elevado esforço computacional para realizar o processo de otimização.

- **Algoritmos Genéticos (*Genetic Algorithms – GA*)**

Nos anos 60, o pesquisador John Holland estudou o projeto de sistemas artificiais baseados nos mecanismos dos sistemas naturais e evolução natural das espécies, formulando então os conceitos da meta-heurística GA [ES03]. Seu objetivo inicial foi a formalização matemática e a explicação rigorosa dos processos de evolução e adaptação em sistemas naturais. Estes algoritmos têm demonstrado uma grande eficiência para tratar problemas complexos de otimização inteiro mista, não convexos e não lineares, tais como o problema PET.

A referência [Y01] apresenta uma proposta de um GA para resolver problemas PET considerando tanto uma abordagem estática como multiestágio. A modelagem do problema utiliza um modelo de fluxo AC, minimizando os custos de investimento, operação, manutenção e perdas de energia. A possibilidade de redespacho dos geradores facilita a resolução do problema e permite que as restrições operacionais e de segurança do sistema sejam atendidas. Contudo, o trabalho não demonstra a viabilidade da aplicação deste algoritmo em sistemas reais de grande porte, aplicando-o apenas a um sistema pequeno de seis barras (Sistema Garver) e para um horizonte de planejamento dividido em apenas três estágios. Observa-se neste algoritmo que é permitido que circuitos existentes na topologia base (antes da expansão) sejam removidos, o que consiste em uma operação incomum para sistemas reais de potência.

Um método eficiente baseado em GA é foi proposto em [EGR04], aplicado à resolução do problema PET multiestágio e utilizando um modelo de fluxo DC. Para inicialização da população inicial do GA, utiliza-se um algoritmo heurístico

construtivo [G70] baseado em índices de sensibilidade [MSPCPP82, PP85] e modelo de fluxo DC. Verificou-se que gerar populações iniciais de melhor qualidade proporciona ao algoritmo um maior desempenho no processo de busca, como também já havia sido apresentado por [GMR98a, GMR98b].

O trabalho [RRS07] propõe um novo GA para resolução do problema PET multiestágio com algumas modificações em relação àquele ao algoritmo proposto por [EGR04]. Visando melhorar o processo de busca, na inicialização da população e na criação de novos indivíduos se considera apenas as soluções factíveis, utilizando um CHA para fazer o melhoramento das soluções infactíveis. Esta heurística de “factibilização” do indivíduo pode ser vista como uma busca local. O algoritmo também busca fazer um controle de diversidade mantendo uma população totalmente distinta durante o processo evolutivo, diminuindo assim as chances do algoritmo ficar preso em uma região de ótimo local e melhorando a qualidade dos planos de expansão obtidos. Observa-se que algoritmo proposto apresenta uma boa eficiência, convergindo com um número relativamente reduzido de execuções de PL.

Na referência [SRRGM05], tem-se a aplicação da meta-heurística GA na resolução do problema PET estático usando o modelo de fluxo DC e considerando restrições de segurança pelo critério determinístico “N-1”. Diferentemente dos trabalhos [MSPCPP82, SSL89], que primeiro realizam o processo de busca pelo conjunto das melhores soluções para depois fazer análise de segurança, neste algoritmo, o critério de segurança é considerado como parte da modelagem matemática do problema (as soluções devem atender simultaneamente ao critério de rede intacta e ao critério “N-1”). Este modelo leva a um aumento do custo computacional, mas proporciona soluções robustas e, conseqüentemente, com custo de investimento mais elevado. Nota-se que para sistemas de médio e grande porte o número de execuções da rotina PL aumenta consideravelmente, tornado sua aplicação proibitiva para alguns sistemas reais. A utilização de uma lista de contingência considerando somente os equipamentos de interesse seria uma forma de contornar esse problema. Por outro lado, a construção desta lista de contingência é tarefa difícil, visto que, à medida que se

reforça a rede, os pontos críticos são alterados e fazendo-se necessária a atualização da lista.

Observa-se que a nova regulamentação do setor de energia elétrica estimulou a criação de novos modelos para o problema PET, cujo objetivo não é somente minimizar os custos de investimentos em expansão do sistema, mas também minimizar riscos e o impacto aos consumidores, melhorando a qualidade nos serviços e buscando maximizar o lucro e o benefício social dos projetos de expansão. Neste sentido, o trabalho [XDW06] apresenta um novo modelo para resolução do problema PET estático (utilizando o GA), visando maximizar o benefício da expansão, o qual é definido pelo lucro esperado dos investimentos feitos na rede de transmissão e o custo de perdas de carga, sujeito às restrições financeiras e técnicas. Contudo, esta nova abordagem para planejamento do sistema de transmissão, considerando uma maior dinâmica quanto à inserção de novas unidades geradoras, ainda precisa ser aperfeiçoada antes de ser aceito como uma ferramenta usual, uma vez que proporciona uma maior dificuldade para o planejamento da transmissão.

Por fim, o trabalho [SA15] apresenta um interessante modelo para resolução de problemas PET de longo prazo com múltiplos cenários de geração. O algoritmo proposto está baseado num GA adaptado para resolver problemas multi-objetivo e numa modelagem estática para o PET de longo prazo. Apesar dos bons resultados apresentados, este trabalho não considera qualquer critério de segurança ou confiabilidade para o sistema.

- **Busca Tabu (Tabu Search – TS)**

A meta-heurística TS incorpora o conceito de memória adaptativa (lista Tabu) para explorar o espaço de busca além do ótimo local. Ao contrário da busca local que sempre se move ao redor de um ponto e finaliza em um ótimo local quando não existe uma configuração vizinha melhor, o processo de busca TS seleciona de modo agressivo o melhor dos movimentos possíveis em cada passo do algoritmo, podendo até vir a piorar o valor da função objetivo [H15].

O trabalho [GMR98b] apresenta uma comparação das meta-heurísticas SA, GA e TS aplicadas ao problema PET estático e modelo de fluxo DC. A partir da identificação das principais qualidades individuais de cada algoritmo, é proposto um novo algoritmo híbrido baseado em TS e incorporando algumas características das outras duas técnicas (SA e GA). Os resultados demonstram que o algoritmo híbrido se mostrou superior as outras meta-heurísticas, encontrando soluções de melhor qualidade e com um custo computacional menor. Observa-se que o sucesso do modelo híbrido se deve ao mecanismo de redução eficiente de vizinhança das soluções e a um algoritmo eficiente para geração das soluções iniciais.

Uma nova meta-heurística baseada em um TS paralelo é apresentada na referência [MS01]. Com objetivo de reduzir o custo computacional e acelerar o processo de busca, a estratégia utilizada pelo algoritmo faz a decomposição da vizinhança da solução atual em várias subvizinhanças e também utiliza listas Tabu de diversos comprimentos (listas múltiplas), o que permite que a busca seja feita em diversas direções. A busca em uma região mais ampla do espaço de busca resulta em uma melhoria da qualidade das soluções. O desempenho deste novo algoritmo é comparado com as meta-heurísticas SA, GA e TS aplicadas ao problema PET estático de longo prazo. Observa-se que os resultados indicam uma relativa superioridade da nova metodologia, tanto em relação ao custo computacional quanto à qualidade dos planos encontrados. Contudo, a codificação binária das soluções é uma desvantagem, pois para sistemas de grande porte leva a um aumento da complexidade computacional do algoritmo e também a uma grande demanda por memória.

Em continuidade ao trabalho proposto em [MS01], a referência [MI07] apresenta um algoritmo híbrido entre as meta-heurísticas TS e OO (Otimização Ordinal) para resolução de problemas PET com abordagem estática. A utilização da estratégia OO visa reduzir o número de soluções candidatas a serem analisadas na vizinhança, reduzindo o custo computacional do algoritmo. Esta seleção é feita de forma probabilística ao calcular um subespaço de soluções factíveis na vizinhança. Os resultados apresentados mostram uma redução do custo

computacional, mas a qualidade dos planos encontrados é inferior os apresentados pelas meta-heurísticas TS sequencial e paralela. Contudo, justifica-se a utilização deste novo algoritmo para sistemas de grande porte, onde o custo computacional de meta-heurísticas tradicionais é relativamente maior.

Na referência [LMRR08], a meta-heurística TS proposta é aplicada na resolução de problemas PET multiestágio. A estratégia multiestágio utilizada faz a resolução de vários subproblemas estáticos separadamente e considera na função objetivo os custos relativos às perdas ôhmicas e ao atendimento de índices de confiabilidade. Uma função gulosa GRASP é utilizada para definir os planos iniciais de boa qualidade para serem utilizados como ponto inicial do algoritmo TS, melhorando os resultados obtidos e reduzindo o custo computacional (redução da vizinhança). Nota-se nos resultados obtidos que a inclusão dos custos das perdas na função objetivo e a consideração de um bom nível de confiabilidade possibilitam uma melhor continuidade do estudo da expansão após o horizonte de planejamento.

No trabalho [H15], a resolução do problema PET é realizada por meio de uma meta-heurística híbrida formada pelas técnicas GA e TS, considerando o critério de segurança determinístico “N-1”. Diferentemente das propostas anteriores, neste trabalho a meta-heurística TS é utilizada durante o processo de evolução dos indivíduos do GA, como um mecanismo de busca local (melhoria das soluções): a cada geração, os indivíduos gerados pelos mecanismos de seleção, recombinação e de mutação são aprimorados utilizando o TS.

- **Programação Evolucionária (*Evolutionary Programming* – EP)**

A meta-heurística EP foi proposta por Lawrence J. Fogel em 1966 e faz parte do grupo de algoritmos classificados como Algoritmos Evolutivos (AE) [ES03], pois está baseado em conceitos evolutivos como o processo de evolução das espécies encontrado na natureza. Diferentemente da meta-heurística GA, a estratégia utilizada na EP realiza a evolução dos indivíduos aplicando apenas operadores de mutação e seleção, descartando o uso dos operadores evolutivos de recombinação. O processo de substituição é probabilístico, ou seja, feito

através de torneios estocásticos. Já o processo de seleção dos pais é determinístico: todos os indivíduos da população geram descendentes a cada iteração. Contudo, cada solução pai, através da mutação, gera apenas um filho.

O primeiro trabalho utilizando a meta-heurística EP para resolver o problema PET estático foi proposto por [CN99]. Utilizando um modelo de fluxo DC, o algoritmo tem como objetivo minimizar o custo de investimentos em expansão e o corte de carga do sistema. Aplicado a um sistema com seis barras e um sistema real mexicano, os resultados apresentados comprovaram a eficiência deste algoritmo quando comparado com os resultados apresentados em [GMR98b] (meta-heurísticas SA, GA e um algoritmo híbrido baseado em TS): o algoritmo proposto apresentou um custo computacional inferior, ou seja, necessitou de um número menor de execuções da rotina de PL. Observa-se que o esforço computacional ainda pode ser reduzido se a população inicial for gerada de forma não aleatória, isto é, utilizando alguma regra heurística.

- **Procedimento de Busca Adaptativa Aleatória Gulosa (*Greedy Randomized Adaptive Search Procedure - GRASP*)**

O algoritmo GRASP utiliza duas fases de busca para encontrar a solução do problema: a fase construtiva, que é generalização de um algoritmo heurístico construtivo, e uma fase de melhoria local, usando um algoritmo de busca através de vizinhança de solução. Esta meta-heurística pode ser considerada como uma evolução dos algoritmos heurísticos construtivos “gulosos”, onde em cada iteração do algoritmo, realiza-se uma busca local de forma a evoluir a solução para a melhor solução presente em sua vizinhança [R11].

Na referencia [BOA01], a meta-heurística GRASP proposta é aplicada aos sistemas Sul e Sul-Sudeste Brasileiros utilizando uma abordagem estática do problema PET. Neste algoritmo, a primeira fase construtiva tem como objetivo a obtenção de soluções factíveis para o problema: os planos de expansão são obtidos a partir da avaliação de uma função gulosa (*greedy function*), criando uma lista dos melhores ramos a serem reforçados. Na segunda fase construti-

va é realizada uma busca local na vizinhança do plano, visando melhorar a solução obtida na fase de construção (diminuir o custo do plano).

Em [FBRF05], uma nova versão do GRASP é proposta para o problema PET, onde se utilizou a estratégia *Path Relinking* como objetivo de explorar diferentes trajetórias entre dois planos conhecidos de alta qualidade. Para tanto, identifica-se diferentes pontos que receberam reforços entre os dois planos previamente escolhidos, para então realizar uma busca local na vizinhança dos mesmos, retirando-se e adicionando-se reforços com base na função gulosa. O algoritmo proposto é aplicado aos sistemas Sul e Sul-Sudeste Brasileiros e, comparando os resultados com [BOA01], observa-se uma melhora do plano ótimo encontrado para o sistema Sul-Sudeste.

- **Otimização por Enxame de Partículas (*Particle Swarm Optimization - PSO*)**

A meta-heurística PSO foi inicialmente proposta por Kennedy e Eberhart em 1995 para simular o comportamento de um bando de pássaros ou um cardume de peixes. É considerado um algoritmo de inteligência coletiva (*Swarm Intelligence Algorithm*), pois tenta imitar o comportamento dos organismos sociais. No caso dos pássaros, o bando escolhe um líder para guiar a busca por comida, de forma que todos os outros indivíduos serão atraídos pelo líder e irão segui-lo em sua busca. O líder do bando deve ser o indivíduo com melhor valor de aptidão: critério este que garante que a busca seja global. Contudo, cada indivíduo do bando irá manter uma busca pessoal (busca local) por comida e, caso encontre alguma coisa, tentará informar aos outros indivíduos. Naturalmente, quando existir um indivíduo com melhores atributos (melhor aptidão) que o atual líder, este se tornará o novo líder do bando e atrairá os outros indivíduos para próximo de si [R11].

O primeiro trabalho a propor um algoritmo baseado em PSO para resolver o problema PET [SRC02] utiliza um modelo de avaliação com fluxo AC e uma abordagem de planejamento estático. Nesta proposta, o modelo tem como objetivo a minimização dos custos de investimento da expansão, minimização de

perdas ativas nas linhas e equipamentos e maximização da receita bruta do uso da rede. Como o algoritmo foi aplicado em um sistema de pequeno porte, cabe ainda verificar sua viabilidade e eficiência na resolução de problemas de médio e grande porte.

A referência [YHJX05] apresenta uma proposta do PSO para resolução de problemas PET multiestágio considerando o critério de segurança “N-1”. O modelo matemático usado é o de fluxo DC, onde a função objetivo minimiza os custos de investimentos na expansão e inclui uma penalização para soluções que não atendem as restrições de segurança. O algoritmo permite que parte das partículas sofra mutações após um determinado número de iterações e, uma vez finalizado o processo de busca, uma mutação é aplicada ao melhor plano encontrado na tentativa de melhorar ainda mais o resultado. Visando reduzir o esforço computacional, o critério de segurança “N-1” é aplicado somente para o melhor plano obtido em cada iteração. Os resultados mostram que a taxa de sucesso de obtenção do ótimo global é de apenas 20% para o PSO tradicional e 32% para a metodologia proposta.

Em [JCYZ07], um algoritmo PSO é proposto para resolver problemas PET estático com modelos de fluxo DC, minimizando os custos de investimentos e perdas ativas, e penalizando planos que gerem violação de fluxos e conectividade da rede. Resultados comparando as meta-heurísticas PSO, GA e ACO são apresentados, mostrando que o PSO e o GA utilizados obtiveram um melhor desempenho na busca pelo plano ótimo dos sistemas estudados. Contudo, o ACO apresentou uma velocidade de convergência maior (menor número de execuções de PL), com um pequeno comprometimento do desempenho na busca pelo ótimo global.

Uma proposta para resolução de problemas PET multiestágio é apresentada em [YGD08], onde é considerado o efeito do crescimento de carga durante cada estágio do horizonte e o aumento do custo de construção de reforços no futuro. A modelagem matemática utiliza o modelo de fluxo DC para avaliação dos planos candidatos. Um algoritmo de otimização *Chaos* é utilizado para ge-

rar a população inicial do PSO. A metodologia proposta é deficiente ao não considerar um modelo que também vise minimizar as perdas ativas e atender aos critérios de segurança ou índices de confiabilidade.

- **Estratégias de Evolução (*Evolution Strategies* – ES)**

Esta meta-heurística foi inicialmente desenvolvida pelo pesquisador Rechenberg, em 1965, sendo a primeira técnica a explorar a teoria da evolução das espécies na solução de problemas [ES03]. O principal operador desta meta-heurística é o operador de mutação; o operador de recombinação pode existir, mas desempenha um papel secundário. Na estratégia $(\mu+1)$ -ES de Rechenberg, μ pais geram um único filho, que irá substituir o pior indivíduo da população. Schwefel propôs depois duas novas estratégias, onde μ pais geram λ filhos: na estratégia $(\mu+\lambda)$ -ES, o processo de seleção leva em conta tanto os filhos quanto os pais; já na estratégia (μ, λ) -ES, o processo de seleção utiliza apenas os filhos. O processo de substituição é determinístico, de modo que somente os melhores indivíduos são mantidos para a próxima geração. Já o processo de seleção dos pais é aleatório: algum critério de seleção é usado (Roleta, Ranking, Torneio Estocástico, etc.).

A primeira proposta de aplicação da ES ao problema PET multiestágio foi feita por [LSRMSR06], utilizando somente operadores de mutação e seleção para realizar a busca. Visando melhorar a qualidade da população inicial e aumentar a eficiência do algoritmo, a função heurística gulosa proposta por [BOA01] é usada para inicializar a população. Além de minimizar os custos de investimento a metodologia também realiza uma análise de confiabilidade, buscando minimizar o custo de interrupção de energia (*Loss of Load Cost* – LOLC) [LMMB00, ML04].

O trabalho proposto por [MSLRSR07], em continuidade ao trabalho anterior, apresenta um novo algoritmo baseado na ES onde se considera na função objetivo do problema PET o custo das perdas ativas do sistema. Observa-se que a consideração de perdas durante o processo de otimização gera um aumento no custo do plano ótimo encontrado, dado que os planos possuem número

maior de reforços adicionados e conseqüentemente são mais robustos que os planos obtidos por [LSRMSR06]. Desta forma, concluí-se que, ao se considerar as perdas e o custo de interrupção de energia, é possível obter uma melhor continuidade do plano de expansão após o horizonte de planejamento.

No trabalho [M14], uma nova metodologia baseada na técnica ES é utilizada para solução do problema de planejamento da expansão da subtransmissão de energia elétrica. Neste trabalho, na busca pelas melhores alternativas de expansão, considera-se a minimização do custo de investimento mais o custo das perdas ôhmicas da rede de subtransmissão. A busca é realizada através de um conjunto reduzido de ramos candidatos, selecionados dentre a lista completa de candidatos: uma estrutura de árvore de decisão utiliza índices de desempenho específicos aos sistemas elétricos como heurística para reduzir o espaço de busca do problema.

- **Otimização por Colônia de Formigas (*Ant Colony Optimization* – ACO)**

Os algoritmos baseados na meta-heurística ACO são sistemas multiagentes nos quais o comportamento de cada agente se baseia na simulação do mecanismo natural de procura por comida das formigas. Cada formiga será uma solução para um determinado problema. A ACO também faz parte do grupo de inteligência coletiva (*Swarm Intelligence Algorithm*), uma vez que as formigas se comunicam através de rastros de feromônio depositados no solo, na tentativa de encontrar o menor caminho entre seu ninho e uma fonte de alimentos [R06, R11].

A referência [RLMSR06] apresenta a proposta do primeiro algoritmo baseado na meta-heurística ACO aplicado na resolução de problemas PET estático. A estratégia utilizada baseia-se no Sistema de Colônia de Formigas (*Ant Colony System* – ACS), que é um dos algoritmos mais eficientes e utilizados dentro do grupo de algoritmos ACO. A avaliação da qualidade dos planos candidatos utiliza um modelo de fluxo DC minimizando apenas o custo de investimento na expansão. Como forma de melhorar o desempenho do algoritmo, utiliza-se a função heurística apresentada em [BOA01] para guiar a busca das formigas na

direção das melhores regiões do espaço de busca (adição dos reforços mais interessantes).

Em continuidade ao trabalho anterior, os trabalhos [R06, RLM08] apresentam um estudo detalhado de ajustes de parâmetros para a meta-heurística ACO aplicada ao problema PET. Conclui-se que, uma vez feito o ajustado adequado, os mesmos não precisam ser alterados quando se aplica o algoritmo em diferentes sistemas, comprovando a robustez do algoritmo proposto. Os resultados apresentados para problemas de planejamento estático e multiestágio comprovam a importância da inclusão do custo das perdas ativas na função objetivo. Em [RLM08], uma análise de confiabilidade é realizada para os melhores planos selecionados pelo processo de otimização. Já o trabalho [R06] apresenta o estado da arte de inúmeros algoritmos que já foram desenvolvidos baseados em ACO.

Um estudo comparativo detalhado do desempenho das meta-heurísticas ES, TS e ACO é apresentado pelo trabalho [LSMRRS08], considerando a resolução de problemas PET multiestágio e modelo de fluxo DC com perdas ativas. Ao fim do processo de busca pela solução de menor custo, um estudo de confiabilidade é realizado para auxiliar o planejador no processo de tomada de decisão: o melhor plano de expansão deve minimizar os custos de investimento, perdas ativas e interrupção de energia medida pelo índice LOLC. A função gulosa proposta por [BOA01] é utilizada para criação dos planos iniciais nas meta-heurísticas ES e TS e como função heurística no ACO. Os resultados apresentados indicam um melhor desempenho do ACO e ES quanto à qualidade das soluções, enquanto que o custo computacional é menor para o ACO.

- **Evolução Diferencial (*Differential Evolution* – DE)**

Desenvolvido por Storn e Price em 1995 [ES03], a meta-heurística DE é um algoritmo evolutivo baseado em populações que pode ser classificado com um tipo de ES. A ideia principal do DE é usar diferenças de vetores (daí o nome diferencial) para gerar perturbações nos indivíduos da população, evoluindo-os para a região do ótimo global do problema. Este método requer o ajuste de

poucos parâmetros de controle, é de rápida convergência, de fácil implementação, trabalha bem com problemas multimodais, e é robusto quando bem implementado. Possui um mecanismo simples de mutação e um operador de cruzamento (operador diferencial), que realiza uma combinação linear de um certo número de indivíduos (normalmente três). Cada indivíduo gera apenas um filho por iteração; se o filho for melhor que o pai então assume o seu lugar na população (seleção determinística).

No trabalho [DLLW06], tem-se uma aplicação da meta-heurística DE para resolução do problema PET considerando uma abordagem estática e um modelo de fluxo AC. A modelagem utilizada tem como objetivo a minimização do custo de investimento, do índice de confiabilidade EENS e das perdas econômicas de consumidores, além da flexibilidade na expansão para se readaptar de acordo com diferentes cenários de carga. Observa-se que, apesar do algoritmo proposto considerar diversos critérios de otimização (multiobjetivo), não se faz um estudo completo em relação às dificuldades encontradas para resolver este tipo de problema, principalmente quanto à avaliação de índices de confiabilidade. O trabalho também apresenta um estudo comparando as meta-heurísticas GA, ES e DE, além das diferentes versões do DE com modificação no mecanismo de cruzamento e mutação.

Outra aplicação da meta-heurística DE é realizada pela referência [STIS07], considerando o problema PET multiestágio e minimizando apenas o custo do investimento na expansão. A modelagem matemática baseia-se no modelo de fluxo DC e não permite o redespacho de potência entre os geradores. O trabalho apresenta uma comparação de desempenho feita entre o DE proposto e um GA convencional, apresentado melhores resultados para a metodologia proposta. Apesar de não considerar o custo das perdas ativas e também aspectos relacionados à segurança do sistema, observa-se que a proposta apresentou bons resultados e é uma aplicação interessante.

- **Sistema Imunológico Artificial (*Artificial Immune System - AIS*)**

Inspirado no sistema imunológico natural (SIN), o AIS é uma metodologia de busca e otimização composta por estratégias inteligentes para resolução de problemas do mundo real [RLH09]. Quando o corpo é exposto a elementos estranhos, o SIN identifica o anticorpo com mais alta afinidade e inicia o processo de proliferação, gerando clones. Alguns destes clones passam pelo processo de mutação em relação à célula original, gerando um novo nível de afinidade para o antígeno. Os novos anticorpos com mais alta afinidade passam por um processo de maturação e podem tornar-se células Plasma (responsáveis pela produção de anticorpos e ataque aos antígenos) ou células de Memória (possuem a habilidade de manter configurações das células com maior adaptabilidade, permitindo dirigir repostas imunológicas mais rápidas a antígenos em específico).

Os algoritmos baseados no AIS se utilizam de heurística para explorar eficientemente áreas de interesse no espaço de solução, possuindo ferramentas para executar pesquisa local e global simultaneamente. Estas ferramentas são baseadas em dois conceitos: hipermutação e edição de receptores. Enquanto a hipermutação executa pequenos passos com objetivo de o anticorpo ter uma afinidade mais alta, determinando ótimos locais, a edição de receptores permite que o anticorpo execute grandes passos, caindo em posições onde a procura por anticorpos de mais alta afinidade possa ser mais promissora [R11].

A referência [RLH09] apresenta uma aplicação de um algoritmo baseado em AIS para resolução de problemas PET multiestágio considerando o modelo de fluxo DC com perdas ativas. A função objetivo visa minimizar custos de investimento, perdas ativas e custos de interrupção de energia medidos pelo índice LOLC. A proposta foi aplicada a um sistema de pequeno porte e um sistema real de médio porte. Os resultados mostram que a metodologia proposta foi mais eficiente que a meta-heurística TS, principalmente quando a inicialização é feita de forma inteligente (utiliza-se uma função heurística para gerar a população inicial).

1.3 MOTIVAÇÃO E OBJETIVO DA TESE

Observa-se que muitos dos problemas reais de planejamento e tomada de decisão envolvem a otimização combinatorial de parâmetros, podendo chegar a centenas, milhares ou até milhões de variáveis de decisão. Especificamente no caso do PET, devido ao problema da explosão combinatorial para sistemas elétricos de médio e grande porte, esses problemas podem apresentar uma complexidade computacional muito alta e não podem ser solucionados em tempo viável por técnicas de busca exaustiva (“força bruta”). Além disso, a utilização de métodos de otimização matemáticos (métodos exatos) pode acarretar em um tempo computacional proibitivo quando aplicados a muitos dos problemas reais de planejamento. Por outro lado, os métodos heurísticos apresentam um baixo custo computacional e geram soluções aproximadas (ótimos locais ou subótimos), não garantindo a obtenção da solução ótima global do problema.

Em uma abordagem dinâmica, a solução de problemas reais de planejamento da transmissão deve responder a três questões básicas: quais reforços são necessários ao sistema para atender o crescimento da demanda por energia elétrica, e ainda, onde e quando estas linhas de transmissão e transformadores devem ser alocados na rede elétrica. Considerando-se apenas incertezas internas, o objetivo do problema se restringe a encontrar o plano de expansão que melhor atende a demanda futura de energia com o menor custo de investimento e máxima confiabilidade. Contudo, para se obter um modelo matemático mais completo e, conseqüentemente, soluções mais adequadas aos problemas PET reais, se faz necessário a consideração de incertezas externas. Assim, conclui-se que a obtenção de planos de expansão mais flexíveis ou robustos, capazes de suportar os diferentes cenários futuros, representa a melhor estratégia para os problemas reais de planejamento.

Muitas das publicações encontradas na literatura são dedicadas à aplicação de abordagens determinísticas ao problema PET, sendo empregada uma grande diversidade de técnicas de otimização e de modelos matemáticos para o problema. Normalmente, a modelagem utilizada para avaliar o plano de expansão

é baseada em modelos lineares simplificados, como o modelo de transporte ou fluxo de potência DC. Em geral, somente os custos de investimento são considerados na função objetivo e as incertezas (internas e externas) são ignoradas ou modeladas de forma simplificada. Além disso, poucos trabalhos consideram as perdas ôhmicas dos equipamentos ou critérios de segurança na modelagem do PET [LRM11, HHK13].

A grande maioria das empresas do setor elétrico brasileiro tem aplicado técnicas de planejamento interativas para fazer o planejamento de suas redes de transmissão, atendendo principalmente ao critério determinístico “N-1” e fazendo uso basicamente de programas de fluxo AC. Além disso, como forma de realizar avaliações mais criteriosas das alternativas de reforços, outras ferramentas computacionais de auxílio ao planejamento também podem ser utilizadas: programas de avaliação de curto-circuito, índices de confiabilidade e de estabilidade transitória. Contudo, o interesse das empresas do setor elétrico brasileiro por ferramentas que utilizem técnicas de otimização mais avançadas e também modelos matemáticos mais completos tem ajudado a fomentar a pesquisa e o desenvolvimento de novas ferramentas de otimização na área de planejamento da expansão do sistema elétrico [R11].

Na literatura científica da área, a abordagem mais comum para se resolver problemas PET em sistemas de médio ou grande porte é a utilização de técnicas computacionais probabilísticas (meta-heurísticas), com a obtenção de resultados aproximados (não há garantia da obtenção da solução ótima global). Estes métodos de otimização são estruturados a partir de parâmetros estocásticos (i.e., variáveis aleatórias) e, por não utilizarem a derivada da função objetivo, são considerados métodos de ordem zero. A função objetivo é usada apenas para avaliar as soluções candidatas e a busca por soluções ótimas é guiada por algumas heurísticas, que nada mais são que regras de como explorar o espaço de busca de maneira inteligente. Dentre essas técnicas destacam-se os algoritmos pertencentes à família dos EAs, que podem ser aplicados sem o uso de qualquer tipo de informação específica do problema (comportando-se como uma técnica de otimização genérica) ou incorporando heurísticas específicas

do problema (algoritmo de aplicabilidade mais restrita, porém com maior desempenho computacional).

Os trabalhos [LRHM11, R11] apresentam uma importante contribuição para a área: um estudo minucioso comparando o desempenho computacional de diversas meta-heurísticas aplicadas ao problema PET multiestágio (dinâmico); nestes trabalhos, pode-se observar que para os problemas PET estudados a meta-heurística ES apresenta o melhor desempenho.

O teorema “*No Free Lunch*” (NFL), apresentado pela referência [WM97], faz uma observação interessante quanto ao uso dos EAs: na média, todos os algoritmos evolutivos possuem desempenho equivalente, quando aplicados aos infinitos problemas de otimização. Desta forma, não existe algoritmo para a resolução de todos os problemas de otimização que seja genericamente (em média) superior a outro algoritmo competidor. Segundo o NFL, quando se compara o desempenho de dois algoritmos somente é possível afirmar que um algoritmo evolutivo comporta-se melhor que outro com respeito à resolução de uma classe ou um grupo específico de problemas, e como consequência, comporta-se inadequadamente para outros problemas.

De forma geral, pode-se afirmar que se um dado algoritmo A é melhor que um algoritmo B em uma série de k problemas, então deve haver outra série de k problemas em que o algoritmo B tem um desempenho superior ao algoritmo A [WM97]. Portanto, surge a ideia de incorporar diversos operadores de busca (multioperadores: conjunto de operadores estocásticos para busca e otimização), cada um especializado em um determinado tipo/classe de problema, em um único EA; desta forma, pode-se esperar que o algoritmo fique capacitado a resolver vários problemas diferentes, bastando para isso que o melhor operador para resolver aquele problema esteja entre os operadores implementados. Assim, para cada estágio do processo de busca, este EA multioperadores deve ser capaz de detectar com eficiência qual dos seus operadores maximiza o desempenho computacional do algoritmo como um todo, utilizando o operador ótimo com a maior frequência possível.

A partir do levantamento bibliográfico apresentado no presente capítulo e das considerações realizadas a respeito do teorema NFL, o principal objetivo deste trabalho de tese é propor um Algoritmo Evolutivo Adaptativo (AEA) utilizando múltiplos operadores de busca (multioperadores), e com poucos parâmetros de controle a serem ajustados pelo usuário. Para tanto, a partir de um conjunto diversificado de operadores de busca, um mecanismo dinâmico e automático de adaptação será proposto como forma de ajustar as probabilidades de seleção e aplicação dos operadores, buscando assim melhorar a eficiência do processo de busca por boas soluções para o PET e expandir os conhecimentos nas áreas de pesquisa em SEP e EAs. Além de possuir um conjunto adequado de operadores, um importante requisito para este algoritmo é ter um bom critério de avaliação da produtividade/utilidade de seus operadores, podendo assim ajustar de maneira adequada as probabilidades de seleção dos mesmos. Ademais, para a resolução dos problemas PET, dois conjuntos de operadores estocásticos serão propostos: evolutivos e especialistas. Nos operadores especialistas busca-se a utilização de heurísticas específicas dos sistemas elétricos de potência, como forma de guiar estes operadores estocásticos na busca pelas melhores soluções do problema.

Pretende-se também com este trabalho, realizar a aplicação e avaliação do AEA proposto em dois sistemas de transmissão de pequeno porte bastante conhecidos na literatura da área: sistema IEEE RTS-79 e sistema Sul Brasileiro (configuração da década de 80). Para tanto, será realizado um estudo estatístico minucioso dos resultados obtidos na resolução de problemas PET de longo prazo. Considerando a abordagem estática e determinística, a modelagem matemática adotada para o PET inclui a definição de um problema de programação linear (PL), baseado no modelo de fluxo DC com perdas na transmissão, e um algoritmo para avaliação do critério de segurança determinístico “N-1”, utilizado para garantir certo nível de confiabilidade ao sistema. Neste estudo, deve ser destacado o desempenho computacional do algoritmo proposto, o esforço computacional para realizar a busca, a taxa de sucesso para obtenção das melhores soluções conhecidas, e a qualidade dos planos de expansão encontrados.

1.4 ESTRUTURA DA TESE

Esta Tese de Doutorado é composta por seis capítulos. O presente capítulo teve como objetivo fazer um levantamento do estado da arte do problema PET, apresentando as principais metodologias que já foram utilizadas para resolver o problema, e fornecendo as razões pelas quais se justifica a aplicação de técnicas de otimização baseadas em meta-heurísticas. Apresenta-se também a motivação e a justificativa para a realização do trabalho: desenvolvimento de um Algoritmo Evolutivo Adaptativo Via Multioperadores, como forma de melhorar o desempenho da meta-heurística no processo de busca pelos melhores plano de expansão para o PET, além de reduzir os parâmetros a serem ajustados pelo usuário (planejador).

O Capítulo 2 faz uma introdução aos EAs, apresentando os principais paradigmas da computação evolutiva e a conceituação teórica de algumas das técnicas utilizadas para ajuste de parâmetros. Também realiza uma introdução aos conceitos básicos sobre os AEA, apresentando algumas das técnicas e critérios encontrados na literatura atual. Ademais, são apresentados os operadores de busca genéricos (não fazem uso de qualquer heurística específica do PET), chamados de evolutivos.

No Capítulo 3, apresenta-se a formulação matemática do problema PET de longo prazo, considerando uma abordagem determinística e estática, juntamente com o método utilizado para a manipulação das restrições e com algoritmo de “Inicialização Inteligente” da população. Esta modelagem considera um fluxo de potência DC com perdas e uma versão relaxada para o critério de segurança “N-1”. Além disso, apresenta-se em detalhes o AEA multioperadores proposto para resolução de problemas PET, juntamente com o conjunto dos operadores especialistas (operadores estocásticos utilizando heurísticas específicas de sistemas de potência).

No Capítulo 4, os resultados obtidos com a aplicação do algoritmo proposto para o problema PET são minuciosamente apresentados e discutidos, avalian-

do o desempenho computacional do algoritmo em diversos estudos de casos e também para diversas combinações de parâmetros, operadores e estratégias de inicialização da população.

O Capítulo 5 aborda uma discussão sobre a importância da metodologia de resolução do PET fornecer ao planejador do sistema um conjunto de boas soluções (as 10 melhores soluções), ao invés de uma única boa solução. Estudos de confiabilidade e compensação de reativos são utilizados para exemplificar esta ideia. Além disso, uma análise de custos é realizada para exemplificar um processo decisório de escolha do melhor plano de expansão (plano com a melhor relação entre o custo do investimento e nível de confiabilidade).

Finalmente, no Capítulo 6, são apresentadas as conclusões e as principais contribuições desta Tese de Doutorado. Além disso, são feitas algumas propostas para trabalhos futuros e possível continuação deste trabalho.

CAPÍTULO 2

ALGORITMO EVOLUTIVO ADAPTATIVO

2.1 INTRODUÇÃO À COMPUTAÇÃO EVOLUCIONÁRIA

A Computação Evolucionária (*Evolutionary Computation* - EC) é um ramo dentro da ciência da computação que engloba técnicas que simulam processos da natureza para gerar algoritmos computacionais inteligentes de busca e otimização. Abstraindo conceitos da Evolução Natural das Espécies (teoria da evolução de Darwin - 1859), a EC apresenta abordagens alternativas para resolver, de forma simples e aproximada, problemas complexos [ES03]. Assim, dado um problema a ser resolvido, a ideia básica da EC é manter uma população de “estruturas de conhecimento”, que vai evoluindo durante um processo de seleção, competição e variação controlada. Cada uma destas “estruturas” representa uma solução candidata para o problema e se movimenta sobre um dado espaço de busca (domínio do problema) [F07].

Os primeiros passos dados na área da EC foram de biólogos e geneticistas, a partir da simulação de processos vitais de um ser humano em um computador. Na década de 60, um grupo de cientistas, em que o nome de John H. Holland se destaca, iniciaram um estudo em que era implementada uma população de indivíduos onde cada um possuía seu genótipo e estava sujeito a operações de seleção, recombinação e mutação. Mais tarde, estes estudos foram modelados e formalizados, passando a ser conhecido como Algoritmos Genéticos (GA) [ES03].

De acordo com Fialho [F07], várias abordagens para sistemas baseados na evolução foram propostas, tendo como principais diferenças os operadores utilizados e o tipo de codificação dos indivíduos. Dentre elas, pode-se citar: Estratégias de Evolução (ES) - Rechenberg (1965); Programação Evolucionária (EP)

- Fogel, Owens e Walsh (1966); Algoritmos Genéticos (GA) - Holland (1975); Sistemas Classificadores com Aprendizagem (LCS) - Holland (1975); Programação Genética (GP) - Koza (1992); e Evolução Diferencial (DE) - Storn e Price (1995). Apesar de se tratar de técnicas criadas por autores diferentes, em momentos diferentes e com focos diferentes, todas têm uma estrutura básica em comum: realizam reprodução, impõem variações aleatórias, promovem competição e executam seleção de indivíduos de uma dada população. Para Von Zuben [VZ00], sempre que estes quatro processos estiverem presentes, seja na natureza ou em simulação computacional, a evolução é o produto resultante.

Com o avanço das pesquisas relacionadas à EC, outras técnicas surgiram e ganharam importância no meio científico. Como exemplo, novas propostas baseadas na chamada Computação Natural (técnicas que utilizam a natureza como fonte de inspiração) também podem ter uma forte motivação física ou biológica tais como bandos de pássaros, cardumes, enxames, termodinâmica ou também resposta imunológica dos animais. Dentro da Computação Natural, além das técnicas vinculadas a EC, novas meta-heurísticas foram propostas, por exemplo: Recozimento Simulado (SA), Otimização por Colônia de Formigas (ACO), Otimização por Enxame de Partículas (PSO) e Sistemas Imunológicos Artificiais (AIS), entre outras.

A expressão genérica Algoritmo Evolutivo (*Evolutionary Algorithm* - EA) é usada para classificar um amplo conjunto de técnicas heurísticas de resolução de problemas complexos, as quais baseiam seu funcionamento em um mecanismo semelhante ao do processo de evolução natural das espécies (teoria evolutiva de Darwin) [ES03]. Trabalhando com um conjunto de possíveis soluções para um determinado problema (indivíduos), a metodologia utilizada por estas técnicas se fundamenta no uso de mecanismos de seleção das melhores soluções e na geração de novas soluções candidatas através da recombinação de características das soluções selecionadas [VZ00]. Os indivíduos são avaliados de acordo com uma função de avaliação especificamente formulada para o problema em questão.

Para um bom entendimento dos algoritmos propostos com a filosofia dos EAs, alguns conceitos básicos devem ser definidos [F07]:

- **Indivíduo:** candidato à solução do problema, cuja codificação depende da técnica evolutiva escolhida e do problema a ser resolvido;
- **Genes:** cada atributo do indivíduo. Por exemplo, quando o indivíduo é codificado na forma de um vetor de valores inteiros, cada posição do vetor é um gene;
- **População:** coleção de indivíduos (candidatos à solução) que competem entre si pela sobrevivência;
- **Aptidão do Indivíduo (*fitness*):** totalmente dependente do problema, define o quanto este candidato à solução está apto para solucionar o problema. Pode ser feita uma analogia com o papel do meio-ambiente na teoria da evolução das espécies: “só os indivíduos mais aptos/fortes sobrevivem”;
- **Função de Avaliação:** terá o trabalho de julgar a aptidão de cada indivíduo da população. Deve quantificar a qualidade ou utilidade da solução que está sendo apresentada por um dado indivíduo candidato.

É comum em problemas de otimização, utilizar como função de avaliação (também chamada de função de aptidão) para um indivíduo a função objetivo do problema. Posteriormente, na Seção 3.2 do próximo capítulo, será apresentada a formulação matemática adotada para a modelagem do problema PET, onde os termos “indivíduos”, “genes” e “função de avaliação” serão adequadamente contextualizados ao problema tratado.

Conforme mostra a Figura 2.1, a operação de um EA começa com a fase de inicialização dos indivíduos, que pode ser feita de forma completamente aleatória (seguindo uma distribuição uniforme de probabilidades) ou guiada por alguma heurística construtiva (quando se tem algum conhecimento inicial do problema). O objetivo desta fase é “espalhar” os indivíduos sobre o espaço de busca para que os mesmos evoluam e encontrem a região/ponto de ótimo global do problema [ES03]. Para alguns EAs, garantir a diversidade da população

inicial é um ponto importante para que seus mecanismos de busca funcionem eficientemente, especialmente no caso da otimização combinatória [HW03].

A evolução dos indivíduos (processo de busca pelas melhores soluções do problema) ocorre em um processo cíclico, onde a cada nova iteração, novos indivíduos são gerados através da aplicação dos operadores de reprodução (também chamados de operadores de busca, variação, evolutivos ou estocásticos). De acordo com a Figura 2.1, o ciclo evolutivo básico (processo iterativo) de um EA genérico pode ser dividido em quatro etapas:

1. **Avaliação:** Etapa que consiste em atribuir um valor de aptidão (*fitness*) para cada indivíduo da população. Este valor avalia o quão bem cada indivíduo resolve o problema em questão e é utilizado para guiar o processo evolutivo;
2. **Seleção:** Processo que determina quais são os indivíduos mais adequados para se aplicar os operadores de reprodução, com o objetivo de gerar os novos indivíduos que irão compor a nova população. De forma geral, escolhem-se os indivíduos com as melhores aptidões;
3. **Reprodução:** Etapa que gera um conjunto de descendentes (novos indivíduos: filhos) a partir da aplicação dos operadores de reprodução sobre os indivíduos selecionados na etapa anterior;
4. **Substituição:** Nesta etapa, um mecanismo que realiza o intercâmbio geracional será responsável por substituir os indivíduos da geração anterior (pais) pelos novos indivíduos (filhos): uma nova população será gerada. Normalmente, a substituição se dá quando um indivíduo filho é melhor (maior aptidão) que seu(s) pai(s).

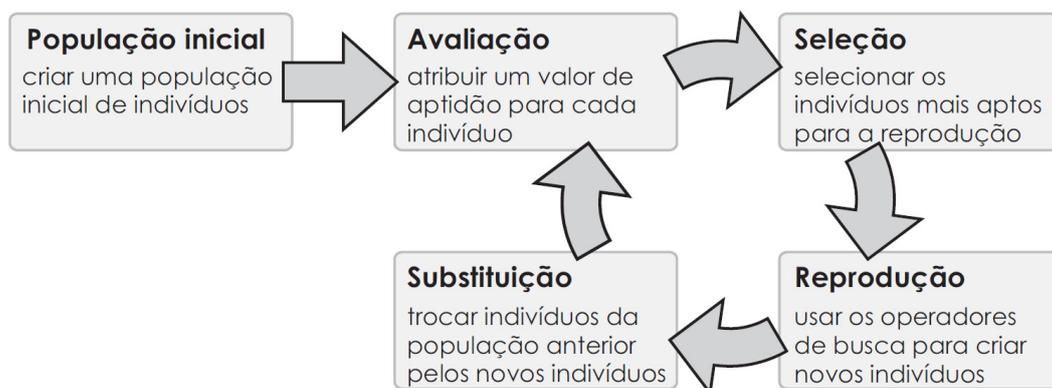


Figura 2.1: Fluxograma do ciclo evolutivo básico de um EA [ES03].

Atualmente, existem diversas estratégias para seleção e substituição de indivíduos, o que permite alterar as características de operação dos EAs [W07]. Por exemplo, aplicando-se estratégias adequadas pode-se: privilegiar os indivíduos mais adaptados em cada geração (estratégia chamada de elitista); aumentar a pressão seletiva sobre os indivíduos melhor adaptados; gerar um número reduzido de descendentes em cada geração; aumentar a diversidade da população, e outras muitas variantes. Em [W07] tem-se uma listagem bastante completa sobre as estratégias evolutivas para seleção e substituição.

A forma com a qual um EA vai explorar o espaço de busca do problema é definida pelos operadores de busca (reprodução) [W07]. Depois de mais de 50 anos de pesquisas na área da EC, existe uma grande diversidade de operadores de busca propostos na literatura [ES03, W07]. Os diferentes tipos de operadores existentes, com suas particularidades, dão características peculiares às diferentes variantes dos EAs. Os chamados operadores de recombinação (ou cruzamento) permitem combinar/misturar características de dois ou mais indivíduos, gerando, eventualmente, indivíduos descendentes melhores adaptados que seus progenitores. Já os operadores de mutação introduzem diversidade genética mediante a variações aleatórias. Estas são as duas classes de operadores de busca mais difundidas dentro da EC.

Como todo processo iterativo, um EA necessita de um critério de parada. Normalmente, o critério de parada leva em consideração a quantidade de gerações processadas, interrompendo o processo evolutivo após um determinado número de gerações [ES03]. Outras alternativas usam como critério de parada a variação dos valores de aptidão dos indivíduos para identificar a convergência do algoritmo, interrompendo o processo evolutivo quando: a) nenhuma melhora considerável for observada durante um determinado número de gerações; ou b) a estimativa do erro atinge um valor mínimo em relação a um valor ideal para o problema. Uma boa alternativa para o critério de parada é realizar um número máximo de avaliações do problema (cálculo da função objetivo e restrições).

Dentre as vantagens de se usar um EA, se destacam a sua facilidade de implementação e a sua eficiência em diversos problemas complexos de otimização. Apesar de ser um método estocástico (i.e., devido à presença de variáveis aleatórias, existe uma certa probabilidade de se encontrar a solução ótima global), os EAs são bastante robustos e, se bem implementados, podem gerar respostas satisfatórias (próximas ao ótimo global) com um custo computacional aceitável. Em comparação com outros métodos de otimização, uma grande vantagem dos EAs é a sua facilidade de trabalhar com sistemas do tipo “caixa preta”, fazendo apenas algumas hipóteses sobre as funções objetivo e encontrando boas soluções para o problema [W07]. Portanto, observa-se que os EAs conseguem apresentar um bom desempenho em diversas categorias de problemas de busca e otimização.

Atualmente, os EAs possuem uma grande aplicação em problemas reais, complexos e de grande porte, onde a utilização de métodos exatos seria impossível ou computacionalmente inviável. Como foi apresentado no Capítulo 1 desta tese, a maioria dos trabalhos propostos para a resolução do problema PET utilizam meta-heurísticas (métodos aproximados), muitos deles baseados nos conceitos da EC, fato este justificado pela complexidade apresentada pelos problemas de planejamento de sistemas elétricos de grande porte (e.g., exploração combinatória, não linearidade, não convexidade, etc.) [HHK13].

De acordo com Fialho [F07], o desempenho e a eficiência de um EA estão fortemente relacionados à definição de alguns parâmetros a serem utilizados, cujos valores devem ser estudados de acordo com as necessidades do problema e dos recursos disponíveis. Na grande maioria dos casos, esses parâmetros são definidos empiricamente, através de tentativa e erro, ou também com base na análise do problema [EMSS07]. Neste contexto, podem-se listar os seguintes parâmetros:

- **Tamanho da População:** afeta o desempenho global e a eficiência dos EAs. Se a população é pequena, conseqüentemente a cobertura do espaço de busca por geração também é pequena, o que influencia muito no desempenho do algoritmo. Se a população é grande, fornecendo uma cobertu-

ra representativa sobre o domínio do problema, a possibilidade de acontecer uma convergência prematura para uma solução de ótimo local se torna muito pequena. Entretanto, quanto maior a população, mais recursos computacionais serão demandados pelo algoritmo. Tipicamente, a população é muito menor do que o espaço de busca a ser explorado: motivo pelo qual os EAs são classificados com técnicas inteligentes de otimização;

- **Probabilidades de Aplicação dos Operadores:** um EA é formado por um repertório de K operadores de busca responsáveis por explorar o espaço de busca localmente ou globalmente. A cada iteração, o operador i tem uma probabilidade P_i de ser escolhido e aplicado sobre um ou mais indivíduos. Saber ajustar esses valores de forma correta é um passo fundamental para o desempenho e a eficiência do algoritmo. Como exemplo, em um GA básico tem-se apenas dois operadores de reprodução: operador de cruzamento, aplicado com uma determinada “taxa de cruzamento”, e operador de mutação, aplicado em função da “taxa de mutação”;
- **Taxa de Cruzamento:** Quanto maior a probabilidade de realização de cruzamentos, mais diversidade será inserida na população. Mas se essa taxa for muito alta, indivíduos com boas características para a solução do problema poderão ser perdidos; e se for muito baixa, a busca pode estagnar. Dependendo do estágio em que se encontra a busca, ou seja, dependendo da maturidade da população, tal taxa pode sofrer variações;
- **Taxa de Mutação:** Uma pequena probabilidade de realização de mutação já garante que a busca não se prenda em regiões do espaço de busca, possibilitando que qualquer ponto seja atingido. Quanto maior a taxa de mutação, maior a aleatoriedade da busca. Assim como para o cruzamento, a taxa de mutação também pode variar de acordo com a maturidade da população.

Neste trabalho, propõe-se o desenvolvimento e a aplicação de uma nova meta-heurística para resolução de problemas PET, a qual está baseada nos conceitos dos EAs adaptativos. Assim, após a conceituação teórica dos mecanismos básicos utilizados na construção dos EAs, a próxima seção deste capítulo tem como objetivo fazer uma introdução teórica das estratégias utilizadas no ajuste

dos parâmetros de controle dos EAs e dos conceitos básicos sobre os EAs adaptativos, especialmente os algoritmos com adaptação das probabilidades de seleção dos operadores de busca e variação (operadores evolutivos). Algumas das estratégias e critérios encontrados na literatura atual serão apresentadas e discutidas. Posteriormente, serão apresentados os operadores evolutivos selecionados para aplicação nos problemas PET.

2.2 ADAPTAÇÃO DE PARÂMETROS

2.2.1 Ajuste de Parâmetros em Algoritmos Evolutivos

O desenvolvimento de um EA eficiente requer certo número de atividades: definição de uma codificação apropriada para o problema; escolha da estratégia evolutiva a ser usada; desenvolvimento dos operadores de reprodução; estratégias de seleção e substituição apropriadas; definição da função de aptidão; e ajuste dos parâmetros que controlam o comportamento do algoritmo. O ajuste dos parâmetros de controle é uma importante tarefa no desenvolvimento de um EA, dado que um conjunto de parâmetros ruim pode impactar negativamente na performance do algoritmo. Por outro lado, o ajuste ótimo de parâmetros vai variar de problema para problema [W07, F10].

Em um GA, por exemplo, deve-se ajustar o tamanho da população, as probabilidades de aplicação dos operadores de mutação e cruzamento, o tamanho do torneio de seleção, o número máximo de gerações (que determina o custo total do algoritmo, visto que a avaliação da função objetivo é a parte mais cara computacionalmente), e alguns parâmetros adicionais que vão depender dos operadores adotados. Os valores destes parâmetros influenciam fortemente na busca por boas soluções. Infelizmente, o ajuste correto do valor de cada parâmetro é uma tarefa que normalmente consome muito tempo e esforço, podendo ser mais trabalhosa que a própria implementação do GA [W07, F10].

O processo de atribuir valores aos parâmetros de controle é uma das etapas mais importantes para o correto balanceamento das capacidades de “explora-

ção” e “exploração” dos EAs [F10]. Sabendo que os valores dos parâmetros possuem impacto significativo na performance dos EAs, a atribuição de valores de má qualidade pode, por exemplo, causar convergência prematura do algoritmo ou torná-lo instável. Nesse sentido, EAs adaptativos que realizem a tarefa de ajustar seus parâmetros de forma automática e dinâmica podem ser muito vantajosos em comparação aos algoritmos estáticos (sem adaptação) [W07].

De maneira geral, podem-se distinguir duas formas de atribuir valores aos parâmetros de um EA: calibração manual ou controle automático dos parâmetros. Na calibração manual, o usuário deve encontrar por tentativa e erro bons valores para os parâmetros antes da execução do algoritmo; depois de ajustados, os parâmetros permanecem fixos durante todo o processo evolutivo. Já o controle automático de parâmetros é uma alternativa na qual os parâmetros são ajustados durante a execução do problema, através de alguma estratégia de adaptação. No trabalho [EMSS07], os métodos e estratégias para controle automático dos parâmetros de um EA são classificados em uma das três categorias a seguir (ver Figura 2.2):

- **Métodos Determinísticos:** Quando os valores dos parâmetros são alterados por alguma regra determinística. Esta regra pode alterar os valores dos parâmetros de forma predeterminada, especificada pelo usuário e sem usar qualquer informação do processo de busca, ou fazer um controle dinâmico, onde os parâmetros são atualizados segundo uma função determinística definida em função do tempo/iteração.
- **Métodos Adaptativos:** Quando os valores dos parâmetros são obtidos por um mecanismo de realimentação que monitora o processo de evolução do algoritmo, recompensando ou castigando os valores dos parâmetros de acordo com seus desempenhos. O desempenho de um operador/parâmetro pode, por exemplo, ser avaliado em função da melhora ou piora na função de aptidão do problema (função *fitness*). Nesta categoria, os parâmetros são adaptados de forma global, ou seja, são adaptados em relação ao EA como um todo.
- **Métodos Auto Adaptativos:** Os parâmetros a serem adaptados são codificados dentro da representação das soluções do problema, ou seja,

cada indivíduo terá o seu próprio conjunto de parâmetros a serem adaptados durante o processo evolutivo. A ideia é que cada indivíduo da população tenha o seu próprio conjunto ótimo de parâmetros para guiar sua busca da forma mais eficiente possível. Nesta categoria, os parâmetros de um EA e a solução para o problema tratado vão “coevoluir” para um ponto de ótimo.

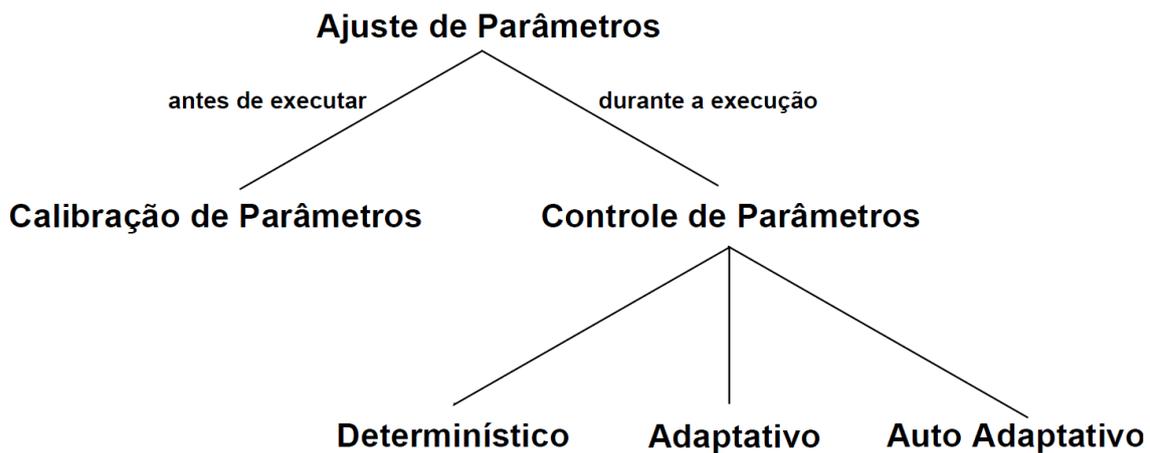


Figura 2.2: Taxonomia global do ajuste de parâmetros em EAs [EMSS07].

2.2.2 Algoritmos Evolutivos com Múltiplos Operadores de Reprodução

Os operadores de reprodução realizam a tarefa de amostrar novos pontos do espaço de busca (novos candidatos à solução), usando como base as informações obtidas de um ou mais indivíduos da população. No início das pesquisas da EC, os operadores de mutação e cruzamento eram os mais utilizados, mas atualmente existe um grande número de operadores que foram desenvolvidos para resolver diversos tipos de problemas, sendo comum se encontrar operadores genéricos (desenvolvidos para resolver uma grande gama de problemas do tipo “caixa preta”) e operadores especializados (desenvolvido para um problema específico) [ES03, W07].

A grande maioria dos operadores de reprodução é classificada como sendo do tipo estocástico. Nestes, sua execução envolve uma variável aleatória, cujo valor é gerado a partir de um sorteio guiado por alguma distribuição de probabilidades predefinida pelo usuário (Uniforme, Gaussiana, etc.). Esta característica

permite que o operador exiba uma série de comportamentos diferentes, reduzindo as chances do algoritmo ficar preso em uma região de ótimo local. Desta forma, o uso de variáveis estocásticas nos operadores evolutivos ajuda a melhorar a robustez do processo de pesquisa, visto que os operadores determinísticos sempre geram o mesmo resultado para uma mesma entrada.

De acordo com Whitacre [W07], uma opção para melhorar a robustez de um EA é a incorporação de múltiplos operadores de reprodução, cada um contendo uma determinada estratégia de busca (“linha de pesquisa”) e, consequentemente, especialista em explorar um dado tipo/classe de problema. Diversos trabalhos já foram publicados mostrando que o uso de múltiplos operadores pode ajudar a melhorar o desempenho geral de um EA [MLS94, BS00, T05, W07, FRSS10, F10, SLFG14, LFH16].

Por outro lado, a adição de múltiplos operadores só é aconselhada se não for possível determinar qual é o tipo do problema a ser resolvido e qual é a estratégia de busca mais eficaz para resolvê-lo. Como exemplo, na otimização de um problema unimodal (i.e., função objetivo com um único ponto de mínimo ou máximo) e com superfície de aptidão “suave”, a estratégia de busca obtida através de um operador de busca baseado no vetor gradiente deverá ser muito melhor do que qualquer outra estratégia de busca obtida com um operador estocástico [W07]. O levantamento de informações a respeito do problema tratado é muito importante para a correta configuração dos parâmetros, como por exemplo, saber se o problema é linear ou não, unimodal ou multimodal, possui espaço de busca convexo ou não, etc. Contudo, estas informações raramente estão disponíveis ao usuário, principalmente quando se está tratando de problemas reais tipo “caixa preta”.

Na resolução de problemas de otimização complexos e com restrições, é de se esperar que um EA usando uma única estratégia de busca não seja eficiente em toda a superfície de aptidão (“*fitness landscape*”). Normalmente, as aplicações de EAs são feitas em problemas complexos, visto que para os problemas mais simples os algoritmos tradicionais de programação matemática já os re-

solvem de forma eficiente e com menor custo computacional. Desta forma, pode-se esperar que um EA portando múltiplos operadores poderá apresentar um processo de busca mais robusto e, conseqüentemente, ser eficiente em uma maior quantidade de problemas [W07].

2.2.3 Adaptação das Probabilidades de Seleção dos Operadores

No desenvolvimento de um EA, além da seleção de um conjunto de operadores adequado e eficaz, deve-se também fazer o ajuste das taxas com que estes operadores serão aplicados. Desta forma, as probabilidades ou taxas de aplicação dos operadores vão impactar no desempenho do algoritmo como um todo. Por exemplo, a utilização exclusiva de um único operador em detrimento dos outros poderá levar o processo de busca a convergir muito rápido (perdendo diversidade na população) e ficar preso em um ponto ou em uma região de ótimo local.

De acordo com Sá e Barbosa [SB98], observa-se que um bom conjunto de parâmetros iniciais aumenta a eficiência da busca de um EA. Por outro lado, uma má escolha pode levar ao fracasso do algoritmo. Visto que o processo evolutivo pode ser dividido em vários estágios de busca e que a qualidade da escolha dos parâmetros depende do problema que está sendo abordado, existe a possibilidade de que a escolha de um conjunto inicial de parâmetros não seja eficiente durante todo o processo de busca, ou seja, para cada estágio do processo poderá existir um determinado operador que seja mais adequado e gere melhores resultados. Frequentemente, utiliza-se o método da tentativa e erro para otimizar os parâmetros de controle de um EA. Contudo, nota-se que uma busca exaustiva pelo conjunto ótimo de parâmetros pode ser um problema mais complexo que o próprio problema original a ser resolvido.

Ao invés de executar o algoritmo diversas vezes, buscando encontrar um bom conjunto de probabilidades para os operadores (método da tentativa e erro), a ideia básica presente no EA proposto por este trabalho, e que será apresentado no Capítulo 3, é a utilização de um mecanismo automático de adaptação, de

forma a permitir que o algoritmo “aprenda” as taxas de seleção dos operadores durante o processo de busca pela solução do problema. A estratégia é ajustar as probabilidades de aplicação dos operadores dinamicamente, de acordo com o desempenho obtido pelos operadores em cada estágio da busca. Para tanto, utiliza-se as informações colhidas ao longo do processo evolutivo como forma de alimentar os mecanismos de atualização (adaptação) das probabilidades.

Existem muitas maneiras de adaptar os diferentes parâmetros de um EA. Uma ideia é adaptar as probabilidades dos operadores dando-lhes “crédito” de acordo com o seu “desempenho”. Este desempenho, normalmente, é avaliado em função de uma melhora na aptidão de um indivíduo da população após sofrer a aplicação de um dado operador [W07]. Nesse sentido, as técnicas propostas na literatura diferem nas particularidades de como essa ideia é implementada [SB98, W07, F10]. Os pontos principais em questão são:

- Quando e quanto dar de recompensa ao operador?
- Só o próprio operador merece a recompensa?
- Como avaliar a qualidade de um operador?
- Deve-se levar em conta o histórico de produtividade?
- Devem-se estabelecer taxas mínimas de aplicação dos operadores?

A adaptação das probabilidades de seleção dos operadores de reprodução é um dos aspectos de desenvolvimento dos EAs que tem sido mais exaustivamente estudado na área de EC, visto o difícil e tedioso trabalho de ajustar estes parâmetros, particularmente quando o algoritmo possui mais de dois operadores [W07, F10]. A decisão de quais operadores utilizar e com qual frequência é um desafio no desenvolvimento dos EAs, o que tem incentivado fortemente a pesquisa e desenvolvimento de técnicas e estratégias adaptativas para os parâmetros de controle dos EAs [EMSS07].

Normalmente, as estratégias adaptativas fazem uso direto de informações do processo evolutivo e possuem dois mecanismos básicos de funcionamento [F10]:

1. **Avaliação do Desempenho:** Critério utilizado para medir a qualidade do operador, atribuindo créditos de acordo com a produtividade apresentada e quantificando sua utilidade/eficiência para cada estágio do processo de busca;
2. **Seleção Adaptativa de Operadores:** Estratégia utilizada para realizar a adaptação das taxas de seleção dos operadores, transformando os valores estimados de qualidade em uma distribuição de probabilidades.

2.2.4 Avaliação do Desempenho dos Operadores

Um requisito importante para um EA com adaptação das probabilidades de seleção dos operadores é o critério de avaliação do desempenho, onde cada operador evolutivo, após a sua execução, deve receber uma recompensa que quantifique o seu desempenho. Assim, a recompensa R_i é o resultado da interação do operador i com o ambiente (estágio atual do processo evolutivo), que no caso do um EA significa uma medida da performance ou produtividade do operador. Posteriormente, as recompensas obtidas em cada estágio do processo evolutivo são utilizadas para atualizar (adaptar) as probabilidades dos operadores, incrementando as taxas dos operadores mais produtivos e decrementando as taxas dos operadores que não estão tendo uma boa performance.

Observa-se na literatura que a abordagem mais utilizada para avaliar a produtividade de um operador é a melhora na função de aptidão (função *fitness*) trazida pelos descendentes gerados [W07, F10, GFC10]. Outra abordagem é considerar na avaliação da produtividade uma combinação da melhora na função de aptidão e do ganho de diversidade gerados pelo operador, visto que a diversidade genética da população é fundamental para o sucesso do processo de busca [MFSS09]. Neste trabalho, considera-se que a cada aplicação do operador i , seja a um ou mais indivíduos da população, este irá gerar um único filho (novo indivíduo) e terá seu crédito r_i calculado em função da variação Δf no valor da função de aptidão. Esta variação Δf pode ser estimada com referência local (em relação aos próprios pais) ou com referência global (e.g., em relação ao melhor indivíduo ou ao valor médio do *fitness* da população corrente).

Dado um EA portando um conjunto de K operadores evolutivos, antes do processo de adaptação das probabilidades, cada operador i é executado M_i vezes (aplicação do operador em um ou mais indivíduos da população para gerar novos indivíduos), de forma que cada execução gera um crédito $r_i(j)$, onde $i = 1, \dots, K$ e $j = 1, \dots, M_i$. A cada T iterações do ciclo evolutivo, o operador i pode ter a sua probabilidade de seleção P_i atualizada em função da medida de qualidade “Recompensa Média” [T05], definida pela seguinte equação:

$$R_i(t) = \frac{1}{M_i} \sum_{j=1}^{M_i} r_i(j) \quad (2.1)$$

onde cada incremento de tempo t é relativo a um ciclo de adaptação (ciclo adaptativo), que por sua vez representa T ciclos evolutivos (gerações). Normalmente, o período adaptativo T é definido em função do número de gerações entre uma adaptação e outra. Outra abordagem interessante é definir T em função de um certo número de avaliações da função objetivo do problema, ou seja, a cada T avaliações da função objetivo, realiza-se um ciclo adaptativo das probabilidades [W07].

O trabalho [WPS06] propõe o critério da “Recompensa Extrema” para cálculo da recompensa $R_i(t)$ de um operador evolutivo i , onde, após a sua aplicação M_i vezes sobre os indivíduos da população, atribui-se como recompensa ao operador o valor do maior crédito $r_i(j)$ obtido durante o período T (i.e., valor extremo dentro de uma janela temporal), tal que:

$$R_i(t) = \text{Max}_{j=1, \dots, M_i} [r_i(j)] \quad (2.2)$$

As referências [WPS06, W07, F10] mostram que a utilização de estratégias adaptativas que gerem soluções *outliers* (“produtividade fora do padrão” ou “valores extremos”) produz melhores resultados que aquelas que geram boas soluções em média. Este critério visa maximizar o uso dos operadores que geram ganhos extremos na função *fitness*. Contudo, neste trabalho, a estratégia adotada no EA adaptativo proposto é o critério da “Recompensa Média Normalizada” [F10], que atribui ao operador i o seguinte valor:

$$R_i(t) = \left[\frac{1}{M_i} \sum_{j=1}^{M_i} r_i(j) \right] \frac{1}{R_{Max}} \quad (2.3)$$

onde o valor R_{Max} é a maior média dos créditos recebidos, considerando o conjunto dos K operadores: visto que a magnitude dos créditos recebidos muda significativamente durante o processo evolutivo, normalizam-se as recompensas médias obtidas individualmente pelos operadores, de forma que, independentemente do atual estágio do processo de busca, $0 \leq R_i(t) \leq 1$.

Nas Equações (2.1) e (2.3), a recompensa média representa múltiplas interações entre um operador evolutivo i e o problema de otimização. Essa abordagem é interessante, pois aumenta a possibilidade de utilização de um operador com baixa probabilidade, além de normalizar as recompensas para critério de comparação de desempenho. Ademais, para todas as abordagens apresentadas acima (Equações 2.1, 2.2 e 2.3), após o período adaptativo T , se um determinado operador evolutivo i não foi utilizado (i.e., $M_i = 0$), então sua recompensa R_i deve ser nula.

Whitacre [W07] apresenta algumas possibilidades para o cálculo do crédito $r_i(j)$, o que pode ser feito seguindo algum critério de interpretação da variação Δf gerada pelo operador i . Sendo $f(\text{filho})$ o valor da função de aptidão do novo indivíduo gerado, e considerando que se deseja a maximização da aptidão (evolução dos indivíduos), o crédito $r_i(j)$ gerado na j -ésima aplicação do operador i pode ser calculado das seguintes formas:

- **Critério 1:** O crédito é calculado em relação ao valor de aptidão do indivíduo pai $f(\text{pai})$ (referência local) e é fixo (independe do ganho produzido):

$$r_i(j) = \begin{cases} 1 & \text{se } f(\text{filho}) > f(\text{pai}) \\ 0 & \text{caso contrário} \end{cases} \quad (2.4)$$

- **Critério 2:** O crédito é calculado em relação ao $f(\text{pai})$ (referência local) e proporcional ao ganho ou a perda de aptidão observada:

$$r_i(j) = f(\text{filho}) - f(\text{pai}) \quad (2.5)$$

- **Critério 3:** O crédito é calculado em relação ao $f(\text{pai})$ (referência local) e proporcional ao ganho de aptidão observado (apenas se apresentar melhora):

$$r_i(j) = \text{Max}[0, f(\text{filho}) - f(\text{pai})] \quad (2.6)$$

Diferentemente do Critério 2 (Equação 2.5), este critério não penaliza o operador quando o indivíduo filho possuir uma aptidão inferior ao seu pai (i.e., se não produzir melhora, o crédito atribuído será zero).

- **Critério 4:** O crédito é calculado em relação à média dos valores de aptidão dos indivíduos da população $f(\text{média})$ (referência global) e é fixo (independe do ganho produzido):

$$r_i(j) = \begin{cases} 1 & \text{se } f(\text{filho}) > f(\text{média}) \\ 0 & \text{caso contrário} \end{cases} \quad (2.7)$$

- **Critério 5:** O crédito é calculado com referência global sendo proporcional ao ganho ou a perda relativa observada:

$$r_i(j) = \frac{f(\text{filho}) - f(\text{média})}{f(\text{média})} \quad (2.8)$$

onde $f(\text{média})$ é a média dos valores de aptidão dos indivíduos da população. Neste critério, penaliza-se o operador que não gerar um filho com aptidão melhor que o valor médio da população (crédito negativo).

- **Critério 6:** O crédito é calculado em relação à média dos valores de aptidão dos indivíduos da população $f(\text{média})$ (referência global) e é proporcional ao ganho observado (não normalizado):

$$r_i(j) = \text{Max}[0, f(\text{filho}) - f(\text{média})] \quad (2.9)$$

- **Critério 7:** O crédito é calculado em relação ao indivíduo cuja aptidão é melhor que 90% das aptidões de todos os indivíduos da população $f(90\%)$ (referência global) e é proporcional ao ganho observado:

$$r_i(j) = \text{Max}[0, f(\text{filho}) - f(90\%)] \quad (2.10)$$

- **Critério 8:** O crédito é calculado através de um processo de classificação (*ranking*) do indivíduo filho gerado em relação a todos os indivíduos da população corrente:

$$r_i(j) = \sum_{p=1}^{N_{Pop}} \phi(\text{filho}, p) \quad (2.11)$$

$$\phi(\text{filho}, p) = \begin{cases} 1 & \text{se } f(\text{filho}) > f(p) \\ 0 & \text{caso contrário} \end{cases}$$

onde N_{Pop} é o número de indivíduos da população, e $f(p)$ é o valor de aptidão do p -ésimo indivíduo da população.

Para todos os critérios listados acima, pode-se considerar ainda o custo computacional demandado pelo operador para gerar o filho, visto que alguns operadores requerem mais de uma avaliação da função de aptidão (normalmente, o cálculo da função de aptidão é o processamento mais caro de um EA). Portanto, independentemente do critério escolhido para o cálculo da produtividade, dividir o crédito pelo custo da produção do novo indivíduo parece ser uma boa ideia [SB98].

As referências [SB98, BS00] apresentam o conceito de Ancestralidade: para cada crédito $r_i(j)$ obtido pelo operador i , pode-se distribuí-lo pelos operadores que geraram os pais do indivíduo filho, e possivelmente também os avós e bisavós, considerando que a capacidade de gerar pais que geram bons filhos também merece ganho de produtividade. Contudo, deve-se ter em mente que este recurso demanda uma estrutura de dados adicional para armazenar a ancestralidade (árvore com os operadores) além da inserção de dois novos parâmetros: *levels*, o número de ancestrais que será levado em conta, e *decay*, que corresponde à porcentagem de crédito que será atribuída a cada nível de ancestralidade.

2.2.5 Avaliação da Qualidade dos Operadores

Em um algoritmo para seleção adaptativa de operadores, a cada instante, um mecanismo iterativo deve escolher um de seus operadores para ser aplicado a

um ambiente externo, resultando numa recompensa atribuída ao operador selecionado. Este mecanismo deve então usar a recompensa obtida, juntamente com o seu estado interno (histórico de recompensas), para adaptar as taxas com que os operadores são selecionados. Deve-se notar que o ambiente externo considerado (i.e., o problema de otimização com os seus diversos estágios de busca) é não estacionário, o que significa que a distribuição de probabilidades deverá mudar durante o processo de busca/otimização (depende do estágio da busca ou região do espaço de busca) [T05].

Dado um EA adaptativo portando um conjunto de K operadores evolutivos, cada operador i possui uma probabilidade $P_i(t)$ de ser selecionado e aplicado à população corrente [T05], tal que:

$$\forall t : 0 \leq P_i(t) \leq 1 \quad (2.12)$$

$$\sum_{i=1}^K P_i(t) = 1 \quad (2.13)$$

onde t é o passo de tempo discreto entre um período adaptativo e outro. O período adaptativo do EA proposto neste trabalho é definido por T gerações, de forma que a cada T gerações, a variável t é incrementada.

Como discutido na seção anterior, quando um operador i é executado no tempo t , um crédito $r_i(t)$ é gerado e utilizado para o cálculo da recompensa média $R_i(t)$ (Equação 2.3). Desta forma, cada um dos K operadores terá uma recompensa associada, e que provavelmente será uma variável aleatória não estacionária. Todos os créditos recebidos por um determinado operador, e dentro da janela temporal t , são armazenados em uma lista de créditos para posterior cálculo da recompensa média; após o cálculo da recompensa esta lista é descartada.

Cada operador i do EA adaptativo, além dos valores $P_i(t)$ e $R_i(t)$, possui também um valor $Q_i(t)$ que especifica uma estimativa da qualidade/utilizada dos operadores em função das atuais recompensas e do histórico de recompensas recebidas durante o processo evolutivo [T05]. Desta forma, a estimativa de qualidade deverá indicar o quão bom ele tem sido para o estágio atual da busca. Entre um período adaptativo e outro, a estimativa de qualidade $Q_i(t)$ é atualizada através da seguinte expressão:

$$Q_i(t + T) = Q_i(t) + \alpha [R_i(t + T) - Q_i(t)] \quad (2.14)$$

onde α é a taxa de atualização da estimativa de qualidade, tal que: $0 \leq \alpha \leq 1$. O valor inicial para a qualidade de um operador é $Q_i(0) = 0$, e sempre estará dentro da faixa: $0 \leq Q_i(t) \leq 1$. O parâmetro α faz o controle da memória do algoritmo de alocação de operadores: para $\alpha = 1$ resulta num sistema sem memória e com máxima atualização; para $\alpha = 0$ resulta num sistema com máxima memória e sem nenhuma atualização. O objetivo da inserção de memória no algoritmo adaptativo é minimizar o efeito de variações bruscas oriundas de um bom desempenho local de um operador evolutivo.

Idealmente, dado um determinado estágio do processo evolutivo, maximizar o valor da estimativa de qualidade para um operador implica em resolver o problema de busca da melhor forma possível, ou seja, aplicando os operadores evolutivos da forma mais eficiente possível [T05].

Adicionalmente, nas referências [FCSS08, F10] utiliza-se uma abordagem interessante para estimativa da qualidade de um operador: dado uma janela temporal de tamanho l , armazenam-se em uma lista todos os créditos recebidos pelo operador, de forma que ao valor de qualidade será atribuído o maior valor dentre os créditos armazenados. Esta abordagem está baseada nos resultados apresentados por [WPS06, W07], onde a utilização de operadores que produzam créditos/recompensas *outliers* (valores extremos ou fora do padrão) gera melhores resultados ao processo de busca. Contudo, após diversos testes empíricos com o PET, adotou-se neste trabalho o critério da "Recompensa Média Normalizada" (Equação 2.3) para atribuir recompensa aos operadores, atualizando a estimativa de qualidade através da Equação (2.14).

2.2.6 Estratégias para Seleção Adaptativa de Operadores

Esta seção tem como objetivo apresentar as principais técnicas encontradas na literatura para transformar os valores de qualidade em uma distribuição de probabilidades para seleção de operadores evolutivos. Existem na literatura da EC

diversos trabalhos abordando estratégias para seleção adaptativa dos operadores evolutivos (EAs adaptativos) [D89, J95, SB98, BS00, T05, WPS06, FCSS08, FRSS10, GFC10, LFK11, SLFG14, LFH16], onde a principal justificativa para a realização da adaptação das probabilidades é que, para o conjunto de operadores adotado, o operador ótimo para resolver o problema vai depender das características do problema e do estágio em que se encontra o processo evolutivo. Em todos estes trabalhos, os EAs adaptativos propostos apresentam bons resultados em comparação às versões estáticas (sem adaptação).

- **Estratégia *Probability Matching* (PM)**

Nos primeiros trabalhos abordando EAs adaptativos [D89, J95, SB98], o mecanismo de seleção dos operadores é similar ao método “Casamento de Probabilidades” (*Probability Matching* - PM), no qual a probabilidade de seleção de um determinado operador é proporcional às recompensas recebidas por ele. Assim, em um EA adaptativo utilizando a estratégia PM, dado um conjunto de K operadores evolutivos, a probabilidade de seleção $P_i(t)$ para o i -ésimo operador será proporcional a sua qualidade $Q_i(t)$, tal que:

$$P_i(t) = \frac{Q_i(t)}{\sum_{j=1}^K Q_j(t)} \quad (2.15)$$

Contudo, a utilização da estratégia PM na forma da equação acima (eq. 2.15) leva o algoritmo a perder alguns operadores durante o processo evolutivo, visto que, se um operador i chegar a obter uma probabilidade nula ($P_i(t) = 0$), este operador não será mais utilizado e, conseqüentemente, não receberá recompensas, o que fará a sua qualidade permanecer nula até o final do processo. Esta condição é indesejável para um EA adaptativo e dinâmico, pois operadores ruins para um determinado estágio da busca podem vir a se tornarem bons em estágios futuros do processo evolutivo. Portanto, é necessário que todos os operadores estejam ativos durante todo o processo, de forma que suas estimativas de qualidade $Q_i(t)$ estejam sempre sendo atualizadas [BS00, T05].

Uma forma de garantir que todos os operadores permaneçam ativos durante todo o processo de busca é definir um valor mínimo P_{min} para as probabilidades $P_i(t)$ (taxa que garante uma utilização mínima de cada um dos operadores evolutivos) [T05], tal que: $P_{min} \leq P_i(t) \leq P_{max}$. Como resultado, o valor máximo P_{max} que qualquer probabilidade $P_i(t)$ pode assumir é dado por: $P_{max} = 1 - (K - 1)P_{min}$, onde K é o número de operadores utilizados. Assim, a Equação (2.15) pode ser reescrita da seguinte forma:

$$P_i(t) = P_{min} + (1 - KP_{min}) \frac{Q_i(t)}{\sum_{j=1}^K Q_j(t)} \quad (2.16)$$

Pode-se concluir das Equações (2.3), (2.14) e (2.16) que, quando um operador i não receber créditos por um determinado número de períodos adaptativos, a recompensa $R_i(t)$ e a qualidade $Q_i(t)$ vão convergir para zero, e a probabilidade $P_i(t)$ vai convergir para P_{min} ; por outro lado, quando apenas um dos operadores evolutivos receber créditos, após um determinado número de períodos adaptativos, sua probabilidade $P_i(t)$ vai convergir para P_{max} .

A estratégia PM definida pela Eq. (2.16) é considerada uma boa estratégia para adaptar as probabilidades do algoritmo de alocação de operadores, contudo, perde muito em termos da maximização do valor esperado para o total de recompensas recebidas pelo operador ótimo [T05]. Supondo que um determinado EA adaptativo com apenas dois operadores evolutivos, Op_1 e Op_2 , quando aplicado a um determinado problema, receba valores constantes de recompensas R_1 e R_2 . Para este caso, da Eq. (2.16) pode-se chegar à seguinte relação:

$$\frac{P_1(t) - P_{min}}{P_2(t) - P_{min}} = \frac{R_1}{R_2} \quad (2.17)$$

Em uma estratégia adaptativa ideal, quando R_1 é maior que R_2 o algoritmo deve maximizar o uso do operador Op_1 como forma de obter o melhor desempenho possível (maximizar o uso do operador ótimo). Contudo, a Eq. (2.17) mostra que, quanto mais próximos forem os valores de R_1 e R_2 , pior será o desempenho do algoritmo. Como exemplo, quando $R_1 = 10$, $R_2 = 9$ e $P_{min} = 0,1$, têm-se $P_1 = 0,52$ e $P_2 = 0,48$, o que está longe do desejável, pois os valores para maximização do uso do operador ótimo deveriam ser: $P_1 = 0,9$ e $P_2 = 0,1$.

- **Estratégia *Adaptive Pursuit* (AP)**

Propostos inicialmente por Thathachar e Sastry [T05], os algoritmos *Pursuit* são uma classe de algoritmos de rápida convergência desenvolvidos para serem utilizados no aprendizado de autômatos. Já na estratégia AP, quando aplicada a um EA adaptativo, tem-se como objetivo realizar a atualização da distribuição de probabilidades dos operadores evolutivos visando à maximização do uso do operador de maior qualidade (i.e., operador com o maior valor Q_i).

Semelhantemente ao EA adaptativo utilizando a estratégia PM, um EA baseado na estratégia AP seleciona e aplica um operador i de acordo com a distribuição de probabilidades para seu conjunto de K operadores, atualizando a qualidade $Q_i(t)$ em função da recompensa $R_i(t)$ recebida durante o processo evolutivo. O que difere as duas estratégias é como as probabilidades são atualizadas. Na estratégia AP, após a atualização das estimativas de qualidade, o operador i^* com maior valor de qualidade $Q_i(t)$ é considerado como sendo o melhor operador para o atual estágio do processo de busca, e tem a sua probabilidade $P_i(t)$ incrementada de acordo com a seguinte equação:

$$P_{i^*}(t + T) = (1 - \beta)P_{i^*}(t) + \beta \quad (2.18)$$

onde i^* é o índice do operador de maior qualidade, tal que: $i^* = \operatorname{argmax}_i [Q_i(t)]$; T é o período do ciclo adaptativo (e.g., número de gerações); e o parâmetro β é a taxa de adaptação das probabilidades, tal que: $0 \leq \beta \leq 1$. Para todos os outros operadores i do conjunto (não ótimos), os valores de probabilidades serão decrementados da seguinte forma:

$$\forall i \neq i^* : P_i(t + T) = (1 - \beta)P_i(t) \quad (2.19)$$

Das Equações (2.18) e (2.19) pode-se concluir que se um determinado operador permanecer como o melhor durante um determinado período de tempo sua probabilidade de seleção vai convergir para 1, enquanto os outros valores de probabilidades serão anulados (os operadores deixarão de ser selecionados). Como visto anteriormente, essa é uma característica indesejável para um EA adaptativo quando aplicado a um ambiente não estacionário.

Como forma de adaptar a estratégia AP para ambientes não estacionários, altera-se a regra de atualização das probabilidades adicionando-se um valor de probabilidade mínima permitida P_{min} , forçando então os valores de probabilidade $P_i(t)$ a ficar dentro do intervalo $[P_{min}, P_{max}]$, tal que: $P_{min} \leq P_i(t) \leq P_{max}$. Assim, identificado o melhor operador para o atual estágio da busca, i^* , realiza-se a adaptação da distribuição de probabilidades da seguinte forma [T05]:

$$\begin{cases} P_{i^*}(t+T) = P_{i^*}(t) + \beta[P_{max} - P_{i^*}(t)] & \text{se } i^* = \operatorname{argmax}_i [Q_i(t+T)] \\ P_i(t+T) = P_i(t) + \beta[P_{min} - P_i(t)] & \forall i \neq i^* \end{cases} \quad (2.20)$$

onde T , P_{min} e β são parâmetros definidos pelo usuário, e a probabilidade máxima é dada por: $P_{max} = 1 - (K-1)P_{min}$.

Nota-se que para a relação $P_{max} > P_{min}$ ser verdadeira (desejável para que haja adaptação) tem-se que respeitar a seguinte restrição: $P_{min} < K^{-1}$. Um valor interessante para a probabilidade mínima é $P_{min} = (2K)^{-1}$ [T05], o que resulta no seguinte valor para a probabilidade máxima: $P_{max} = 0,5 + P_{min}$. Uma forma de se entender a operação da estratégia AP com esses valores é pensar que o algoritmo deve escolher o melhor operador em metade do tempo, enquanto na outra metade todos os operadores têm igual probabilidade de serem escolhidos.

Considerando novamente o caso do EA adaptativo com dois operadores, Op_1 e Op_2 , sendo aplicado a um ambiente estacionário que retorna sempre as mesmas recompensas, $R_1 = 10$ e $R_2 = 9$, dado que $P_{min} = 0,1$ pode-se concluir que após algumas iterações (o que vai depender do parâmetro β) o algoritmo AP vai convergir para $P_1 = 0,9$ e $P_2 = 0,1$, ou seja, tem-se o melhor operador sendo executado em quase 90% do tempo. Também se observa que o operador mais fraco (com pior qualidade) é utilizado com um taxa mínima, resultado que é bastante interessante para ambientes não estacionários: os valores de qualidade continuam a ser atualizados de acordo com a Equação (2.14), o que habilita o algoritmo evolutivo a reagir e modificar sua distribuição de probabilidades para outro cenário, caso haja alguma mudança na distribuição de recompensas aos operadores.

- **Estratégia *Multi-Armed Bandit* (MAB)**

Esta é uma estratégia relativamente nova na literatura e tem sido bastante utilizada para o desenvolvimento de EAs adaptativos. Baseada na Teoria dos Jogos, a MAB visa encontrar o melhor balanço entre “exploração” e “exploração” (*Exploration versus Exploitation - EvE*) na utilização dos operadores evolutivos: o operador mais promissor (com maior qualidade) precisa ser utilizado (“exploração”) o tanto quando possível, visando à maximização do desempenho global do EA; ao mesmo tempo, não se pode deixar de utilizar os outros operadores com menor qualidade (“exploração”), visto que um determinado operador de baixa qualidade pode vir a se tornar o operador ótimo em um estágio futuro do processo de busca. Em termos de robustez e eficiência, as referências [FRSS10, F10] demonstram que a estratégia MAB gera melhores resultados quando comparada às estratégias PM e AP.

Diferentemente das estratégias probabilísticas PM e AP, na MAB o processo de seleção do operador a ser utilizado é realizado de forma determinística, onde, dado um conjunto de K operadores, seleciona-se o operador i que possui o maior valor para a seguinte métrica [F10]:

$$Q_i(t) + C \times \sqrt{\frac{2 \log \sum_{j=1}^K n_j(t)}{n_i(t)}} \quad (2.21)$$

onde $n_i(t)$ é número de vezes que o operador i foi executado até o instante de tempo t ; $Q_i(t)$ é a estimativa de qualidade do operador i ; e C é o parâmetro de controle para o balanço EvE da estratégia. Nesta métrica, o termo da esquerda favorece o operador com melhor qualidade (“exploração”), já o termo da direita favorece a utilização do operador menos utilizado (“exploração”) até o instante t . A cada execução do operador i , deve-se atualizar o valor $n_i(t)$, de forma que: $n_i(t+1) = n_i(t) + 1$.

Nas estratégias PM e AP, a seleção do operador que será aplicado em um determinado instante de tempo é realizada através de um sorteio probabilístico com base na atual distribuição de probabilidades, onde o operador ótimo deve-

rá ter maiores chances de ser selecionado. Já a estratégia MAB, não há atualização da distribuição de probabilidades, pois a seleção é feita de forma determinística através da escolha do operador que maximiza sua métrica (Expressão 2.21). Desta forma, pode-se observar que o mecanismo de seleção baseada na MAB, em relação a PM e AP, demanda um maior custo computacional, pois, para cada seleção de operador, deve-se primeiro calcular a Expressão (2.21) para todos os operadores e depois escolher qual operador aplicar.

Em ambientes não estacionários, para os quais necessita-se de alocação dinâmica dos operadores, a estratégia MAB deve ser adaptada de forma a habilitá-la a identificar a transição entre um cenário e outro, reinicializando seus parâmetros de modo a permitir que operadores ruins em determinados estágios da busca possam se tornar bons em estágios posteriores. Nesse sentido, os algoritmos DMAB, SMAB e RMAB propostos por Fialho [F10] representam uma boa alternativa para o problema.

- **Estratégia Q-learning (QL)**

Na estratégia QL o problema da seleção adaptativa dos operadores evolutivos é modelado como um problema de aprendizagem por reforço, onde um agente (EA adaptativo) precisa aprender um comportamento através de interações do tipo “tentativas e erros” com um ambiente dinâmico (problema de otimização). O agente pode interagir com o ambiente de duas formas: percepção e ação. Ao interagir com o ambiente, o agente recebe informação sobre o estado atual, escolhendo então uma ação a ser executada. Esta ação causa uma alteração no ambiente, o qual retorna ao agente um sinal de reforço que pode ser uma recompensa ou uma penalidade [SLFG14].

A referência [SLFG14] apresenta uma interessante proposta de aplicação da estratégia QL para realizar a seleção adaptativa dos operadores de variação de um algoritmo DE. Nesta abordagem, o DE pode ser visto como um agente que “aprende” através de interações com o ambiente, no caso a população de indivíduos. O DE interage com os indivíduos através dos operadores de variação e

o sinal de reforço é calculado através da avaliação dos indivíduos gerados (ganho na função *fitness* e ganho de diversidade). Assim, o DE pode aprender a melhor política de utilização dos operadores pela experimentação das consequências de suas ações.

A despeito dos bons resultados apresentados pelas estratégias MAB [F10] e QL [SLFG14], neste trabalho, adotou-se a estratégia AP para realizar a seleção adaptativa dos operadores evolutivos (Eq. 2.20), pois é de fácil implementação, apresenta melhores resultados que a estratégia PM [T05], e ainda possui um custo computacional inferior às estratégias MAB e QL. Adicionalmente, adotou-se a Equação (2.3) para o cálculo das recompensas e a Equação (2.14) para a avaliação da qualidade dos operadores.

2.3 – OPERADORES EVOLUTIVOS

Esta seção tem como objetivo fazer a descrição dos operadores evolutivos (ou operadores de reprodução) selecionados para serem utilizados pelo EA adaptativo proposto no Capítulo 3. Visto que o PET é um problema de otimização combinatória, optou-se pela utilização de operadores genéticos de recombinação e mutação, em codificação decimal (números inteiros), de fácil implementação e com baixo custo computacional. Nesse sentido, os operadores foram escolhidos após diversos testes empíricos com os mais diversos encontrados na literatura [ES03, W07], visando também formar um conjunto com estratégias as mais distintas possíveis.

No contexto dos EAs, os operadores evolutivos podem ser classificados em dois grupos distintos: operadores de recombinação, que geram novos indivíduos através da combinação de características genéticas de dois ou mais indivíduos pais, e operadores de mutação, que criam um novo indivíduo a partir de um único pai. Sabe-se que estes operadores podem possuir comportamento de busca local ou global, dependendo da estratégia utilizada, e também, podem ser combinados de forma a se obter uma estratégia de busca mais eficiente [F10].

A partir de testes empíricos, verificou-se que a utilização de operadores de recombinação associados aos operadores de mutação gera melhores resultados que a utilização individual de cada operador. Desta forma, neste trabalho considera-se que cada operador evolutivo é formado pela combinação de um operador de recombinação com um operador de mutação, utilizados um após o outro e nesta ordem: dado os indivíduos pais, primeiro aplica-se o de recombinação para depois aplicar o de mutação.

Seguindo a classificação apresentada, sete operadores genéticos em codificação decimal foram adotados, sendo quatro de recombinação (UNX, SPX, IRX, e LRX) e três de mutação (SWM, UNM e BDM) [ES03] – estes operadores serão definidos a seguir. Assim, o conjunto dos K operadores evolutivos utilizados pelo algoritmo proposto é formado pelas 12 possíveis combinações destes operadores genéticos: UNX-SWM, UNX-UNM, UNX-BDM, SPX-SWM, SPX-UNM, SPX-BDM, IRX-SWM, etc. A utilização da estratégia adaptativa AP fará com que a combinação com melhor produtividade/qualidade seja utilizada com maior frequência e no estágio mais adequado ao processo de busca.

Os operadores de recombinação foram modificados de tal forma que, a partir de dois indivíduos pais, geram um único indivíduo filho. Considerando a formulação matemática para o PET apresentada pela Seção 3.2 do próximo capítulo, nos operadores genéticos apresentados a seguir, cada operador pode receber um ou dois indivíduos pais (\vec{n}_p para mutação, ou \vec{n}_{p1} e \vec{n}_{p2} para cruzamento) e gerar apenas um único indivíduo filho (\vec{n}_f). Números aleatórios sorteados sobre uma distribuição uniforme de probabilidades e dentro de um intervalo fechado $[x^{min}, x^{max}]$ são simbolizados como $U_I(x^{min}, x^{max})$ quando forem do tipo inteiro e $U_R(x^{min}, x^{max})$ quando forem do tipo real.

- **UNX - Uniform Crossover**

Este operador gera um novo indivíduo filho \vec{n}_f a partir de uma mistura uniforme do material genético de dois indivíduos pais \vec{n}_{p1} e \vec{n}_{p2} , tal que, para cada gene i de \vec{n}_f :

$$n_{F,i} = \begin{cases} n_{P1,i} & \text{se } r_i \leq 0,5 \\ n_{P2,i} & \text{caso contrário} \end{cases} \quad (2.22)$$

onde para cada valor r_i sorteia-se um número real aleatório tal que: $r_i = U_R(0,1)$. A estratégia deste operador é posicionar o novo indivíduo em um dos vértices do “hipercubo” que pode ser formado por todas as possíveis combinações de genes dos indivíduos pais.

- **SPX - Single-point Crossover**

Neste operador, o novo indivíduo \vec{n}_F é gerado a partir da mistura de material genético dos indivíduos pais \vec{n}_{P1} e \vec{n}_{P2} em relação a um único ponto de cruzamento k , tal que, para cada gene i de \vec{n}_F :

$$n_{F,i} = \begin{cases} n_{P1,i} & \text{se } i \leq k \\ n_{P2,i} & \text{caso contrário} \end{cases} \quad (2.23)$$

onde k é um valor inteiro sorteado uma única vez e dado por: $k = U_I(0, n_L)$; n_L é a dimensão do vetor \vec{n}_F (número de ramos candidatos à expansão). Semelhantemente ao operador UNX (eq. 2.22), este operador também posiciona o novo indivíduo em um dos vértices do “hipercubo” formado pelas possíveis combinações de genes dos indivíduos pais. Contudo, este operador tende a manter determinados agrupamentos de genes. Já o operador UNX tende a desfazer agrupamentos, misturando o material genético dos dois pais de forma uniforme.

- **IRX - Intermediate Recombination**

Dado o “hipercubo” formado por todas as possíveis combinações de genes dos indivíduos pais \vec{n}_{P1} e \vec{n}_{P2} , este operador visa misturar o material genético dos pais e posicionar o novo indivíduo filho \vec{n}_F no interior do “hipercubo”, tal que, para cada gene i de \vec{n}_F :

$$n_{F,i} = \begin{cases} n_{P1,i} + U_I(0, n_{P2,i} - n_{P1,i}) & \text{se } n_{P2,i} > n_{P1,i} \\ n_{P2,i} + U_I(0, n_{P1,i} - n_{P2,i}) & \text{caso contrário} \end{cases} \quad (2.24)$$

- **LRX - Line Recombination**

Dado dois indivíduos pais \vec{n}_{P1} e \vec{n}_{P2} , este operador utiliza a estratégia de posicionar o novo indivíduo \vec{n}_F sobre o segmento de reta que liga os pontos \vec{n}_{P1} e \vec{n}_{P2} , tal que, para cada gene i de \vec{n}_F :

$$n_{F,i} = n_{P1,i} + \text{Round}[w(n_{P2,i} - n_{P1,i})] \quad (2.25)$$

onde w é um valor real sorteado uma única vez e dado por: $w = U_R(0,1)$; a função “Round” retorna o valor inteiro mais próximo do valor real recebido como parâmetro (faz o arredondamento de real para inteiro).

- **SWM - Swap Gene Mutation**

Dado um indivíduo pai \vec{n}_P , este operador gera um novo indivíduo filho \vec{n}_F a partir da troca do material genético entre os genes $k1$ e $k2$, tal que, para cada gene i de \vec{n}_F :

$$n_{F,i} = \begin{cases} n_{P,k2} & \text{se } i = k1 \\ n_{P,k1} & \text{se } i = k2 \\ n_{P,i} & \text{caso contrário} \end{cases} \quad (2.26)$$

onde $k1$ e $k2$ são dois números inteiros distintos, sorteados uma única vez e dados por: $k1 = U_I(0, n_L)$ e $k2 = U_I(0, n_L)$; n_L é a dimensão do vetor \vec{n}_F (número de ramos candidatos à expansão).

- **UNM - Uniform Mutation**

Este operador gera um novo indivíduo filho \vec{n}_F incrementando ou decrescendo o valor de um determinado gene k do indivíduo pai \vec{n}_P , tal que, para cada gene i de \vec{n}_F :

$$n_{F,i} = \begin{cases} n_{P,k} + 1 & \text{se } i = k \text{ e } r \leq 0,5 \\ n_{P,k} - 1 & \text{se } i = k \text{ e } r > 0,5 \\ n_{P,i} & \text{caso contrário} \end{cases} \quad (2.27)$$

onde k é um valor inteiro sorteado uma única vez e dado por: $k = U(0, n_L)$; n_L é a dimensão do vetor \vec{n}_F (número de ramos candidatos à expansão); r é um valor real sorteado uma única vez e dado por: $r = U_R(0,1)$.

- **BDM - Boundary Mutation**

Desenvolvido para otimizar problemas onde a solução ótima está próxima das bordas do espaço de busca, este operador gera um novo indivíduo filho \vec{n}_F igualando o valor de um determinado gene k do indivíduo pai \vec{n}_P ao limite inferior n_k^{min} ou superior n_k^{max} tal que, para cada gene i de \vec{n}_F :

$$n_{F,i} = \begin{cases} n_k^{min} & \text{se } i = k \text{ e } r \leq 0,5 \\ n_k^{max} & \text{se } i = k \text{ e } r > 0,5 \\ n_{P,i} & \text{caso contrário} \end{cases} \quad (2.28)$$

onde k é um valor inteiro sorteado uma única vez e dado por: $k = U(0, n_L)$; n_L é a dimensão do vetor \vec{n}_F (número de ramos candidatos à expansão); e r é um valor real sorteado uma única vez e dado por: $r = U_R(0,1)$.

- **CUT - Operador de Reparação**

Este último operador é chamado de operador de reparação, pois é utilizado para reposicionar os indivíduos dentro do espaço de busca do problema, caso estejam fora, garantindo as restrições de limite inferior e superior para as variáveis de decisão do problema. Contudo, este operador não é nem um operador de recombinação nem de mutação, apenas uma ferramenta auxiliar utilizada sempre ao final da execução de qualquer um dos operadores evolutivos (combinação de cruzamento com mutação). Assim, para cada gene i de \vec{n}_F , tem-se que:

$$n_{F,i} = \begin{cases} n_i^{min} & \text{se } n_{P,i} < n_i^{min} \\ n_i^{max} & \text{se } n_{P,i} > n_i^{max} \\ n_{P,i} & \text{caso contrário} \end{cases} \quad (2.29)$$

onde n_i^{min} e n_i^{max} são os valores de limite inferior e superior para a variável i .

2.4 CONSIDERAÇÕES FINAIS

No presente capítulo foi realizada uma introdução teórica a respeito dos algoritmos evolutivos (EAs), discutindo-se as principais estratégias para ajuste de parâmetros, a influência destes parâmetros no desempenho do algoritmo e a possibilidade de utilização de múltiplos operadores de reprodução. Além disso, foi realizada uma revisão bibliográfica sobre as principais abordagens para adaptação de parâmetros em EAs, tendo como objetivo principal a discussão das principais estratégias para seleção adaptativa de operadores de reprodução. Ademais, foi definido o conjunto de operadores evolutivos adotados para serem utilizados no EA proposto pelo próximo capítulo.

Observa-se que muitos problemas reais de planejamento e tomada de decisão envolvem a otimização de parâmetros discretos e/ou contínuos, podendo apresentar tantas combinações que a busca exaustiva pela solução ótima se torna completamente inviável. Especificamente no caso da solução de problemas PET, devido ao problema da explosão combinatória encontrado para sistemas elétricos de grande porte, a elevada complexidade computacional não permite que estes problemas sejam solucionados, em tempo aceitável, por técnicas de força bruta (busca exaustiva). Também, a utilização de algoritmos de otimização exatos (técnicas determinísticas) pode apresentar tempo computacional proibitivo quando aplicado a problemas reais de planejamento do sistema elétrico. Nesse sentido, a aplicação de algoritmos inteligentes de otimização, como os algoritmos evolutivos, se torna bastante vantajosa.

A utilização de múltiplos operadores de reprodução e de uma estratégia de seleção adaptativa e dinâmica dos operadores é uma abordagem muito interessante para o desenvolvimento de EAs, pois, de acordo com Zuben [VZ00], quando se considera todas as classes/tipos de problemas existentes, não há nenhum operador que claramente apresente um desempenho superior aos demais: cada operador é particularmente eficiente para uma determinada classe de problemas e extremamente ineficiente para outras [WM97]. Estes conceitos serão incorporados ao EA proposto pelo próximo capítulo.

CAPÍTULO 3

PLANEJAMENTO DA EXPANSÃO DA TRANSMISSÃO

3.1 INTRODUÇÃO

Este capítulo tem como objeto apresentar a metodologia proposta pela presente tese para a resolução de problemas de Planejamento da Expansão da Transmissão (PET). Primeiramente, a formulação matemática adotada para o problema PET é apresentada, incluindo a definição do algoritmo de programação linear (PL), baseado em um modelo de fluxo DC com perdas, e o critério de segurança “N-1”, utilizado para garantir a confiabilidade das soluções encontradas. Na sequência, o Algoritmo Evolutivo Adaptativo (AEA) proposto será detalhadamente descrito, juntamente com as metodologias adotadas para permitir sua aplicação na resolução de problemas PET. Além disso, a metodologia heurística selecionada para fazer a inicialização da população será apresentada. Por fim, um grupo de operadores de reprodução especialistas será proposto para solução de problemas PET.

3.2 FORMULAÇÃO MATEMÁTICA DO PROBLEMA PET

Neste trabalho, a abordagem adotada para o problema PET está baseada em uma modelagem estática e determinística, onde, dado um horizonte de planejamento com um único estágio (previsão para um cenário futuro de carga e geração), determinam-se quais ramos do sistema de transmissão devem ser reforçados e quantos reforços devem ser adicionados. Estes reforços (i.e., investimentos em equipamentos de transmissão - linhas ou transformadores) devem, idealmente, ser feitos no início do horizonte de planejamento, como forma de garantir o completo atendimento da demanda futura.

Para representação do fluxo de potência utiliza-se o modelo DC, através de uma generalização do modelo de fluxo de carga linearizado apresentado por Monticelli [M83]. Normalmente, a formulação do problema PET estático e sem critério de segurança (planejamento da rede intacta apenas), considerando um modelo de fluxo DC, é definido como um problema de Programação Não Linear Inteiro Misto (PNLIM) [SRRGM05], tal que:

$$\text{Min } v(n) = \sum_{(i-j) \in \Omega} (c_{ij} n_{ij}) + \sum_{k \in \Gamma} (cg_k g_k + cr_k r_k) \quad (3.1)$$

sujeito a:

$$\begin{cases} \mathbf{g} + \mathbf{r} + \mathbf{B}\theta = \mathbf{d} \\ |f_{ij}| \leq (n_{ij}^0 + n_{ij}) f_{ij}^{max} \\ \mathbf{g}^{min} \leq \mathbf{g} \leq \mathbf{g}^{max} \\ 0 \leq \mathbf{r} \leq \mathbf{d} \\ 0 \leq n_{ij} \leq n_{ij}^{max} \end{cases} \quad (3.2)$$

onde:

- n é o vetor plano de expansão (solução candidata) e seu elemento n_{ij} é o número de reforços adicionados ao ramo $i - j$;
- n_{ij}^{max} é o número máximo permitido para adição de reforços ao ramo $i - j$;
- n_{ij}^0 é o número de elementos do ramo $i - j$ presente no caso base (topologia original antes da adição de reforços ao sistema);
- $v(n)$ é o custo total do investimento para um determinado plano de expansão n : custo dos reforços somado ao custo operacional (geração e carga não suprida);
- c_{ij} é o custo para adição de um reforço/elemento ao ramo $i - j$;
- cg_k é o custo de geração de potência ativa na barra k (custo do gerador);
- cr_k é o custo do corte de carga (carga não suprida) para a barra k ;
- f_{ij} é o fluxo de potência ativa total através do ramo $i - j$, calculado da seguinte forma: $f_{ij} = (\theta_i - \theta_j)(x_{ij}^{-1})$;
- x_{ij} é a reatância equivalente do ramo $i - j$;
- f_{ij}^{max} é o fluxo de potência ativa máximo permitido em um único elemento do ramo $i - j$ (i.e., capacidade máxima de um elemento);
- B é a matriz de susceptância para o sistema, considerando as linhas e transformadores do caso base e dos reforços adicionados pelo plano n ;

- g é o vetor de geração, onde seu elemento g_k é o valor da geração (despacho) na barra k ;
- g^{max} e g^{min} são os valores de capacidade máxima e mínima dos geradores;
- d é o vetor de demanda, onde seu elemento d_k é a carga demandada pela barra k ;
- r é o vetor de geradores fictícios, onde seu elemento r_k representa o valor do corte de carga na barra k ;
- θ é o vetor de ângulos das tensões nodais, onde θ_k é o ângulo da barra k ;
- Ω é o conjunto de todos os ramos $i - j$ candidatos a expansão do sistema;
- Γ é o conjunto de todas as barras do sistema.

Neste modelo (Eq. 3.1 e 3.2), os vetores n , g , r e θ representam as variáveis de decisão do problema, onde n são variáveis inteiras, e g , r e θ são variáveis reais. Os valores de g , r , d , f e x estão em pu (“por unidade”), já os valores de θ estão em radianos. Visto que os reforços são equipamentos de transmissão a serem construídos/instalados no sistema elétrico, estes não podem ser fracionados, motivo pelo qual as variáveis n_{ij} devem assumir apenas valores inteiros.

A inclusão dos geradores fictícios nas barras de carga (elementos r_k) permite que, independentemente do plano de expansão considerado, o problema de programação considerado para o PET sempre tenha solução, pois, caso não seja possível o completo atendimento da carga (devido a alguma restrição elétrica), define-se o valor do corte de carga através da geração fictícia nas barras. Desta forma, pode-se concluir que, no problema definido pelas Expressões (3.1) e (3.2), todos os possíveis planos de expansão n presentes no espaço de busca (definido por: $0 \leq n_{ij} \leq n_{ij}^{max}$) são factíveis, ou seja, independentemente do plano, sempre existirá um estado operativo para o sistema.

Os parâmetros cr_k (custo do corte de carga) geralmente recebem valores muito maiores que os custos dos geradores cg_k e da adição de reforços c_{ij} , de forma a forçar a solução do problema a reduzir ao máximo as cargas não supridas: cortes de carga são economicamente inviáveis; neste trabalho adota-se $cr_k = 1000$

para todos os problemas. Contudo, mesmo com valores altos para cr_k , dependendo do sistema considerado e das possibilidades de expansão pode ocorrer de não existir solução com corte de carga nulo: neste caso a melhor solução deverá ser aquela que apresenta o menor corte de carga possível.

O problema PNLIM apresentado anteriormente (Eq. 3.1 e 3.2) poder ser desacoplado em dois subproblemas: Subproblema de Investimento (SPI) e Subproblema de Operação (SPO). O SPI é um problema de otimização combinatória que tem por objetivo a minimização do custo de investimento na expansão do sistema, restrito ao completo atendimento da demanda futura (rede intacta). Já no SPO, para um determinado plano de expansão candidato, resolve-se um problema de programação linear (PL) com o objetivo de encontrar o estado ótimo de operação do sistema (despacho dos geradores e ângulos das tensões nodais) que minimize os custos de geração e corte de carga nas barras. Assim, a partir das Expressões (3.1) e (3.2), define-se o SPI da seguinte forma:

$$\text{Min } f(n) = \sum_{(i-j) \in \Omega} (c_{ij} n_{ij}) \quad (3.3)$$

sujeito a:

$$\begin{cases} cc(n) = 0 \\ 0 \leq n_{ij} \leq n_{ij}^{max} \end{cases} \quad (3.4)$$

onde $f(n)$ é o custo total de investimento para o plano de expansão n ; $cc(n)$ é total de cortes de carga para a rede intacta, tal que: $cc(n) = \sum(r_k)$; e r_k é o corte de carga na barra k . Para um determinado plano n , os valores de corte de carga são obtidos a partir da solução do SPO (definido a seguir). Para o SPI, o plano n representa o conjunto das variáveis de decisão (valores inteiros), e definem o seu espaço de busca. Logo, para que um plano n seja factível deve possuir corte de carga nulo em todas as barras do sistema, ou seja: $cc(n) = 0$.

Das Expressões (3.1) e (3.2), defini-se o SPO como um problema de fluxo de potência ótimo DC, também chamado de despacho econômico, pois minimiza o custo total de geração. Neste, o plano candidato n é fixo, ou seja, não é uma variável de decisão e sim um dado de entrada do problema. Desta forma, pode-se definir o SPO como um problema PL, tal que:

$$\text{Min } C_{\text{op}}(n) = \sum_{k \in \Gamma} (cg_k g_k + cr_k r_k) \quad (3.5)$$

sujeito a:

$$\begin{cases} \mathbf{g} + \mathbf{r} + \mathbf{B}\theta = \mathbf{d} \\ |\mathbf{f}_{ij}| \leq (n_{ij}^0 + n_{ij}) \mathbf{f}_{ij}^{\text{max}} \\ \mathbf{g}^{\text{min}} \leq \mathbf{g} \leq \mathbf{g}^{\text{max}} \\ 0 \leq \mathbf{r} \leq \mathbf{d} \end{cases} \quad (3.6)$$

onde $C_{\text{op}}(n)$ é o valor da função objetivo do SPO, chamado de custo operacional (custo total da geração mais custo do corte de carga) para o plano n . Semelhantemente ao que ocorre no problema global do PET (problema PNLIM - Eq. 3.1 e 3.2), a adição de geradores fictícios nas barras de carga faz com que as soluções do espaço de busca do SPO sejam sempre factíveis, visto que, caso não seja possível o atendimento da carga, gera-se um valor de corte de carga. Um ponto importante deste modelo é a adição do custo de geração cg_k , pois é através dele que irá se definir uma “ordem de mérito” para o redespacho dos geradores; este assunto será tratado na seção (3.2.2).

3.2.1 Perdas Ôhmicas na Transmissão

De forma a considerar as perdas ôhmicas no processo de resolução dos problemas PET, um modelo especial de fluxo de potência DC é usado [LRM11]. Basicamente, as perdas são estimadas a partir do vetor de ângulos das tensões nodais, obtido com a solução do SPO para uma dada configuração n . Posteriormente, estas perdas são distribuídas como cargas fictícias, onde as barras i e j recebem metade das perdas ôhmicas estimadas para o circuito que as conecta. A partir destes novos valores de cargas nas barras, um novo SPO é resolvido para o mesmo plano de expansão n , e assim um novo vetor ângulos é encontrado, o qual corresponde à solução de rede intacta com perdas. Todo este processo é repetido uma segunda vez, visando uma maior precisão para os valores calculados, o que ao fim resulta na resolução de três PLs. A quantidade de perdas ΔP_{ij} associadas ao ramo $i - j$ pode ser aproximada por:

$$\Delta P_{ij} = (r_{ij} \times f_{ij}^2) \quad (3.7)$$

onde r_{ij} é a resistência total para o ramo $i - j$ (pu). Este processo iterativo de inclusão das perdas ativas no SPO visa uma modelagem mais precisa do despacho dos geradores e, conseqüentemente, uma melhor representação do fluxo de potência ativa nos ramos. Desta forma, os planos obtidos com esta modelagem apresentam maiores benefícios em aspectos operativos do sistema, como o perfil de tensão, o nível de carregamento dos circuitos e a confiabilidade.

Como será visto na Seção (3.2.3), neste trabalho de tese utiliza-se um EA como ferramenta para resolução do SPI de problemas PET. Contudo, cada plano de expansão avaliado pelo EA demanda a solução de um SPO (Expressões 3.5 e 3.6), que por sua vez necessita da solução de um problema PL, quando o problema não considera perdas, ou três PLs, quando se considera perdas. Para resolução dos PLs utiliza-se o algoritmo Simplex, implementado através do pacote matemático GLPK (GNU *Linear Programming Kit*). Este pacote permite que se utilize a funcionalidade da “reotimização”, que é o reaproveitamento do estado/base do último PL realizado, reduzindo significativamente o custo computacional para os casos do SPO com perdas.

3.2.2 Critério de Segurança “N-1”

No PET para sistemas reais, o planejador está interessado em obter um conjunto de planos de expansão que minimizem os custos de investimento e também garantam um adequado nível de qualidade de energia aos consumidores. Neste sentido, embora a consideração de critérios de segurança seja essencial para garantir um bom nível de confiabilidade nos sistemas planejados, a maioria dos trabalhos disponível na literatura resolve o problema PET somente para a rede intacta [HHK13]. Critérios de segurança determinísticos ou probabilísticos são levados em consideração somente em alguns trabalhos: como exemplos têm-se as referências [SRRGM05, TGS08, LRM11, VTSR14, LFH16].

O critério determinístico “N-1” define que o sistema deve suportar a contingência (falha ou remoção) de qualquer simples elemento de transmissão, mantendo

do o fornecimento de energia aos consumidores sem qualquer sobrecarga nos equipamentos da rede. Um ponto importante deste critério, quando aplicado aos PETs reais, é que não pode haver redespacho dos geradores quando ocorrer uma contingência: sabe-se que este critério é bastante conservador, pois gera planos caros e de altíssima confiabilidade, mas é o critério que tem sido adotado pela maioria das empresas. A estratégia adotada neste trabalho é considerar o critério “N-1” como uma restrição durante todo o processo de otimização, onde os melhores planos encontrados não têm somente que satisfazer o critério de rede intacta (SPO), mas também o critério “N-1”. Entretanto, observa-se que para sistemas de grande porte esta estratégia demanda um elevado esforço computacional [LRM11]. A consideração do critério de segurança “N-1” no problema PET leva a formulação de um novo SPI, tal que:

$$\text{Min } f(n) = \sum_{(i-j) \in \Omega} (c_{ij} n_{ij}) \quad (3.8)$$

sujeito a:

$$\begin{cases} cc(n) = 0 \\ sc(n) = 0 \\ 0 \leq n_{ij} \leq n_{ij}^{max} \end{cases} \quad (3.9)$$

onde $sc(n)$ é o nível total de sobrecarga atribuído ao plano n após sua verificação pelo critério “N-1” (descrito a seguir). Quando um plano n respeita a restrição $sc(n) = 0$ significa que este plano atende/suporta o critério “N-1”.

Para o cálculo do nível total de sobrecarga $sc(n)$ do critério “N-1”, cada ramo $i-j$ que esteja ativo na rede intacta deve ter um de seus elementos removidos, de forma que o valor de $sc(n)$ é obtido somando-se, ramo a ramo, a sobrecarga total $sc_{ij}(n)$ obtida após a contingência no ramo $i-j$. O valor $sc_{ij}(n)$ é obtido a partir da solução encontrada para o SPO da rede intacta:

- 1) Atualiza-se a matriz B para a contingência no ramo $i-j$;
- 2) Resolve-se um fluxo de potência DC (Eq. 3.10) utilizando o vetor de despachos g encontrado com solução do SPO da rede intacta;
- 3) Para cada ramo ativo do sistema, verifica-se a ocorrência de sobrecarga causada pela contingência $i-j$, acumulando-se em $sc_{ij}(n)$, ramo a ramo, a quantidade do fluxo de potência ativa que excede a capacidade máxima.

Assim, $sc(n)$ irá depender dos reforços presentes no plano n e deverá ser nulo quando o plano atender/suportar o critério “N-1”. O modelo matemático utilizado para cálculo do fluxo de potência DC é definido por um sistema de equações lineares [M83], tal que:

$$B\theta = (d - r - g) \quad (3.10)$$

onde B é matriz de susceptância, atualizada para cada contingência $i-j$; θ é o vetor de ângulos a ser encontrado (incógnitas do sistema); d é o vetor de carga; r é o vetor de cortes de carga; e g é o vetor de despacho dos geradores. Os valores de r e g são obtidos com a solução do SPO para a rede intacta. Neste trabalho, o sistema linear apresentado pela Equação (3.10) é resolvido com a aplicação do método da Eliminação de Gauss, implementado através do pacote matemático IMSL® *Fortran Numerical Math Library*.

Na prática, sabe-se que em sistemas reais, após uma contingência simples, pode-se permitir que alguns equipamentos continuem a operar sobrecarregados por um determinado tempo, desde que essas sobrecargas não ultrapassem determinados limites e não permaneçam por um longo período de tempo [LRM11, VTSR14]. Assim, visando reduzir o custo dos planos encontrados para o PET, sem deteriorar muito a confiabilidade das configurações, uma versão relaxada do critério de segurança “N-1” é proposta: no cálculo de $sc(n)$, sobrecargas que estejam abaixo de um determinado limite máximo sc_{max} são negligenciadas. Por exemplo, considerando $sc_{max} = 10\%$, após a remoção de qualquer simples elemento do sistema, apenas as sobrecargas superiores a 10% da capacidade máxima do ramo serão consideradas no cálculo de $sc(n)$. O parâmetro sc_{max} é chamado de Fator de Relaxamento do Critério “N-1”.

Em alguns casos, durante a avaliação do critério “N-1”, pode ocorrer o ilhamento de barras, gerando assim um subsistema. Neste caso, resolve-se o sistema linear apresentado pela Equação (3.10) com duas barras *swings*, a barra *swing* original da rede intacta e uma nova barra *swing* para o subsistema que foi ilhado (barra de maior geração ou, caso não tenha uma barra de geração, menor carga). Os eventuais cortes de carga gerados pela avaliação do “N-1” são adicionados em $sc(n)$.

Um ponto importante na modelagem do problema PET com critério “N-1” é a definição de uma “ordem de mérito” para o redespacho dos geradores na rede intacta. Esta ordem é obtida através da definição dos custos de geração cg_k , onde: quanto menor o custo de um gerador, maior será a sua prioridade no despacho de potência ativa. Assim, independentemente da forma com que o SPO foi implementado, da linguagem de programação, e do pacote matemático utilizado, o despacho dos geradores irá depender apenas dos dados elétricos do sistema e do plano de expansão avaliado. Além disso, com a utilização da ordem de mérito define-se certa lógica para despacho dos geradores, fazendo com que planos próximos um do outro (eletricamente semelhantes) tenham despachos semelhantes. Na verdade, a ordem de mérito é uma consequência de um ponto de operação futuro ao qual se deseja que o sistema opere (e.g., a energia de geradores hidráulicos é mais barata que a dos térmicos, logo tem prioridade de utilização).

3.2.3 Representação e Avaliação das Soluções

No contexto dos EAs, cada indivíduo da população representa uma possível solução para o problema PET, ou seja, é um plano de expansão candidato. Assim, a codificação do indivíduo é feita através de um vetor de números inteiros n , com dimensão igual ao número de ramos candidatos a expansão n_L (ramos onde se é permitido adição de reforços). Cada gene n_{ij} do indivíduo representa um ramo do sistema ligando a barra i à barra j (elemento do vetor n), podendo variar de zero até o número máximo de reforços permitidos para o ramo. Esta restrição de limite mínimo e máximo para as variáveis n_{ij} define o espaço de busca do problema PET, tal que: $0 \leq n_{ij} \leq n_{ij}^{max}$.

Um EA pode ser utilizado para resolver problemas PET com e sem critério de segurança “N-1”, onde: as Expressões (3.3) e (3.4) definem o SPI do PET sem “N-1”, e as Expressões (3.8) e (3.9) definem o SPI do PET com “N-1”. Assim, função objetivo utilizada para avaliar o *fitness* $f(n)$ (aptidão) dos indivíduos é dada pela Expressão (3.3) ou (3.8): minimização do custo total de investimento na expansão. Além disso, cada indivíduo n possui também um valor *unfitness*

$uf(n)$ que quantifica sua infactibilidade: este valor representa a soma do total de cortes de carga para a rede intacta, $cc(n)$, com nível total de sobrecarga após a avaliação do critério “N-1”, $sc(n)$. Desta forma, a avaliação de um determinado indivíduo é realizada através dos seguintes passos:

1. Verifica-se se os reforços presentes no plano n atendem a restrição de limite mínimo e máximo: se $n_{ij} < 0$, então $n_{ij} = 0$; senão se $n_{ij} > n_{ij}^{max}$ então $n_{ij} = n_{ij}^{max}$; este passo é equivalente a executar o operador CUT, descrito na Seção (2.3) do capítulo anterior.
2. Calcula-se o valor da função $f(n)$: este será o valor de *fitness* do indivíduo (custo do investimento em reforços ao sistema); neste caso, o objetivo é a minimização do valor $f(n)$;
3. Calcula-se o valor da função $cc(n)$: após a solução do SPO para a rede intacta, com ou sem a consideração das perdas, este valor é o total de cortes de carga (pu) obtido com o despacho econômico para o plano n ;
4. Calcula-se o valor da função $sc(n)$: utiliza-se a metodologia apresentada pela Seção (3.2.2) para calcular o nível total de sobrecarga (pu) após avaliação do plano n pelo critério de segurança “N-1”;
5. Por fim, calcula-se $uf(n) = cc(n) + sc(n)$: este será o valor de *unfitness* do indivíduo (sempre positivo); o indivíduo n é classificado como factível quando $uf(n) = 0$, ou como infactível quando $uf(n) > 0$;

Pode-se concluir então que para se encontrar boas soluções com o modelo do PET proposto, o EA deve resolver um SPI de forma que os planos de expansão obtidos permitam que o sistema consiga atender a toda demanda futura (suprir as cargas no final do horizonte de planejamento), respeite o critério de segurança “N-1” (relaxado ou não), e ainda tenham custo mínimo de investimento em novos equipamentos. Assim, pode-se notar que o problema a ser resolvido pelo EA é um problema de otimização restrito, pois possui restrições de igualdade (ver Eq. 3.4 ou 3.9). Portanto, o EA adaptativo proposto pelo presente capítulo deve possuir algum mecanismo que o habilite a trabalhar com planos factíveis e infactíveis, visto que para problemas que possuem região factível muito estreita ou relativamente pequena é inviável manter apenas indivíduos factíveis na população [HW03, ES03].

Normalmente, os EAs são desenvolvidos para resolver problemas de otimização irrestritos (sem restrições). Para que estes algoritmos possam ser utilizados na resolução de problemas de otimização restrita, deve-se lançar mão de algum método de manipulação de restrições. Basicamente, estes métodos podem ser divididos em quatro categorias, de acordo com a forma com que as restrições são tratadas: 1) descarte ou reparação de soluções inactíveis; 2) penalidade para restrições não satisfeitas; 3) otimização multiobjetivo; e 4) comparação lexicográfica. De acordo com a referência [HW03], na maioria dos EAs aplicados a problemas restritos, as inactibilidades são penalizadas diretamente na função objetivo. Além disso, observa-se que a grande maioria dos trabalhos que utilizam meta-heurísticas para resolver problemas PET penalizam a inactibilidade dos planos candidatos diretamente na função objetivo [HHK13]. Contudo, neste trabalho propõe-se a utilização do método de comparação lexicográfica “ ϵ -constrained” [TS10].

3.2.4 Método de Manipulação de Restrições ϵ -constrained

Os autores Takahama e Sakai [TS10] propõem uma nova metodologia, chamada de “ ϵ -constrained”, utilizando ordenação lexicográfica e relaxamento das restrições. Esta abordagem faz o relaxamento das restrições de igualdade e desigualdade no estágio inicial do processo de busca e, gradualmente, vai diminuindo o relaxamento como forma de conduzir os indivíduos inactíveis para dentro das regiões factíveis do problema. Para tanto, utiliza-se um mecanismo de comparação e ordenação dos indivíduos, onde a comparação lexicográfica substitui a tradicional comparação ordinal (baseada apenas no valor de *fitness*). Assim, tendo em vista a eficiência e robustez apresentada pelo método, neste trabalho adotou-se esta abordagem para implementação do mecanismo de manipulação de restrições.

Neste método, a função de violação de restrições $uf(n)$ (valor *unfitness*) e a função objetivo $f(n)$ são utilizadas separadamente: ambas as funções são minimizadas através de um método lexicográfico, no qual a violação de restrições precede a função objetivo. Uma vez que a factibilidade dos planos de expansão

candidatos é mais importante que a otimização da função objetivo, o EA deve primeiro posicionar os indivíduos dentro de uma região factível para então minimizar a função objetivo do problema. Especificamente para o problema PET, dado o plano de expansão n , a função $f(n)$ representa o custo de investimento (Eq. 3.3 ou 3.8) e a função $uf(n)$ é definida como: $uf(n) = cc(n)$, para os casos do SPI sem a consideração do critério “N-1” (Eq. 3.4); ou $uf(n) = cc(n) + sc(n)$, quando se considera o critério “N-1” no SPI (Eq. 3.9).

A adaptação de um EA para a utilização do método ε -constrained se faz através do uso de um novo mecanismo para comparação dos indivíduos, definido da seguinte forma [TS10]:

$$(f_1, uf_1) <_{\varepsilon} (f_2, uf_2) \Leftrightarrow \begin{cases} f_1 < f_2 & \text{se } uf_1, uf_2 \leq \varepsilon \\ f_1 < f_2 & \text{se } uf_1 = uf_2 \\ uf_1 < uf_2 & \text{caso contrário} \end{cases} \quad (3.11)$$

onde, para um determinado indivíduo i , os valores f_i e uf_i são os valores da função objetivo e da função de violação de restrição, respectivamente. O operador “ $<_{\varepsilon}$ ” é chamado de comparador “ ε -level”, onde o parâmetro ε é um valor real positivo ($\varepsilon \geq 0$) que define o nível de relaxamento das restrições. O objetivo do parâmetro ε é relaxar as restrições num estágio inicial do processo de busca e conduzir gradativamente os indivíduos na direção das regiões factíveis. Usualmente, o ε -level não precisa ser controlado, pois muitos problemas de otimização restritos podem ser resolvidos utilizando-se apenas a comparação lexicográfica dos indivíduos, o que significa manter o parâmetro ε constante e igual a zero durante todo o processo de busca. Contudo, para problemas com região factível estreita e/ou muito segmentada, o ε -level deve ser convenientemente controlado, como forma de se obter soluções de alta qualidade.

Uma forma simples e eficiente de controlar o parâmetro ε é utilizando uma função exponencial decrescente $\varepsilon(t)$, tal como na Equação (3.12) [TS10]. O valor inicial $\varepsilon(0)$ é dado pelo valor da função de violação de restrição do θ -ésimo indivíduo da população inicial: $\varepsilon(0) = uf_{\theta}$. A cada geração t do EA, o parâmetro ε é atualizado. Quando número de gerações t for igual ao parâmetro T_c , o parâmetro ε é ajustado para zero, o que finaliza o relaxamento das restrições.

$$\varepsilon(t) = \begin{cases} \varepsilon(0) \times \left(1 - \frac{t}{T_c}\right)^{cp} & \text{se } 0 < t < T_c \\ 0 & \text{caso contrário} \end{cases} \quad (3.12)$$

onde T_c é o parâmetro que controla o período de convergência de $\varepsilon(t)$; e cp é o parâmetro que controla a velocidade de redução do relaxamento.

Neste trabalho, visando eliminar os parâmetros $\varepsilon(0)$, T_c e cp (parâmetros que devem ser ajustados pelo usuário), propõe-se um novo método para controle do parâmetro ε (nível de relaxamento das restrições), definido por:

$$\varepsilon(t) = \frac{1}{N_{Pop}} \sum_{i=1}^{N_{Pop}} uf_i \quad (3.13)$$

onde a cada nova geração t do EA, atribui-se ao parâmetro ε ao valor médio da função de violação de restrição (*unfitness*) para a população corrente; N_{Pop} é o número de indivíduos presentes na população. Desta forma, no EA que será proposto pela Seção 3.3, substitui-se o parâmetro fixo ε da Eq. (3.11) pela função $\varepsilon(t)$ da Eq. (3.13), visando um controle automático e dinâmico do relaxamento das restrições de corte de carga e sobrecarga para o PET, e permitindo que no estágio inicial do processo evolutivo os indivíduos tenham certo nível de infactibilidade e encontrem com mais facilidade as regiões factíveis do problema. Testes empíricos com este método mostraram que, na medida em que a população evolui, a função $\varepsilon(t)$ converge para zero em torno de 10 a 20% do número máximo de gerações permitido.

Uma grande vantagem da utilização do método ε -constrained, em comparação aos métodos que penalizam a infactibilidade dos indivíduos na função objetivo, é a eliminação do parâmetro “custo da infactibilidade” (i.e., custo do corte de carga e da sobrecarga ao “N-1”), reduzindo assim o número de parâmetros a serem ajustados pelo usuário e tornando o algoritmo de otimização mais robusto (menos dependente do ajuste de parâmetros). Ademais, a redução de parâmetros em um EA é muito vantajosa, pois boa parte do tempo gasto na implementação das meta-heurísticas é utilizada no ajuste de parâmetros [EMSS07].

3.3 ALGORITMO PROPOSTO

Nesta seção, o AEA proposto para a resolução de problemas PET, com ou sem critério de segurança “N-1”, será detalhadamente descrito. A formulação matemática adotada para o PET baseia-se na abordagem determinística e estática, e foi convenientemente apresentada pela Seção 3.2 do presente capítulo.

O algoritmo AES-TEP (*Adaptive Evolutionary System for Transmission Expansion Planning*) proposto neste trabalho está baseado em um EA utilizando múltiplos operadores de reprodução e a estratégia AP (*Adaptive Pursuit*) para adaptar as probabilidades de seleção de seus operadores. Visando maior robustez e eficiência no processo de resolução dos problemas PET, principalmente para sistemas de médio e grande porte, o AES-TEP ajusta as taxas de seleção dos operadores de forma automática e dinâmica. Desta forma, para cada estágio do processo evolutivo, o algoritmo utiliza com maior frequência o operador que apresenta maior produtividade. O conjunto dos K operadores reprodutivos utilizados pelo algoritmo AES-TEP pode ser formado pelos os operadores evolutivos (descritos na Seção 2.3) ou pelos operadores especialistas (descritos na Seção 3.3.2); a princípio, pode-se utilizar qualquer quantidade de operadores. Visto que o PET é um problema de otimização restrito (restrições da Eq. 3.4 ou 3.9), substituem-se os comparadores ordinais pelo comparador ε -level (Eq. 3.11) para permitir que o algoritmo manipule soluções factíveis e infactíveis. O controle do nível de relaxamento do ε -level é realizado de forma automática através da estratégia proposta pela Eq. (3.13).

O Algoritmo 1 (Figura 3.1) mostra um pseudocódigo para o algoritmo AES-TEP. Objetivando-se a resolução de um problema PET para um sistema com n_B barras e n_L ramos candidatos, as etapas deste algoritmo são descritas como:

1. A função “criarPop” executa a tarefa de criar e inicializar uma população Pop com N_{Pop} indivíduos; os indivíduos podem ser inicializados de forma Inteligente (algoritmo descrito pela Seção 3.3.1) ou totalmente aleatória (distribuição uniforme de probabilidades);

2. A função “avaliarAptidão” faz a avaliação da aptidão de todos os N_{Pop} indivíduos da Pop , calculando para cada indivíduo n o valor de sua função objetivo $f(n)$ e de sua função de violação de restrições $uf(n)$ (descrito pela Seção 3.2.3);
3. Com a função “ordenarPop”, os indivíduos pertencentes a Pop são ordenados em função de suas aptidões, utilizando para isso o comparador ε -level (descrito pela Seção 3.2.4); na sequência, identifica-se o indivíduo incumbente P_{best} , o qual será sempre o melhor indivíduo da Pop ;
4. O período adaptativo T , é fixado em $T = 2$ (valor obtido após diversos testes empíricos); assim, a cada duas gerações ocorrerá uma iteração do algoritmo de adaptação de probabilidades (ver Seção 2.2.6);
5. Os vetores \vec{P} , \vec{Q} , \vec{R} e \vec{N} , de dimensão igual a K , e os parâmetros P_{min} e P_{max} são inicializados com os valores sugeridos pela referência [T05];
6. O critério de parada para o processo evolutivo considera duas possibilidades: 1) Número máximo de gerações T_{max} , de forma que o algoritmo irá realizar no máximo T_{max} iterações; ou 2) Número máximo de gerações sem melhora na incumbente Q_{max} , ou seja, o processo é finalizado após Q_{max} gerações sem que o melhor indivíduo da Pop se altere (indica estagnação do processo evolutivo - adotou-se $Q_{max} = 0,2 \times T_{max}$);
7. De acordo com a Expressão (3.13), para cada nova geração t do algoritmo, atualiza-se o parâmetro ε utilizado pelo comparador ε -level;
8. Para cada geração t , realiza-se um processo iterativo com N_{Pop} iterações, nas quais seleciona-se aleatoriamente pares de indivíduos distintos (pais: p_1 e p_2) da Pop atual, e aplica-se um dos K operadores reprodutivos para gerar um novo indivíduo (filho: p_F - ver Algoritmo 2, Figura 3.2), tal que:
 - a. A partir da distribuição de probabilidades dos operadores (\vec{P}), a função “selecionarOperador” retorna o índice op do operador selecionado: sorteio onde a probabilidade de se selecionar um operador i é P_i ; o algoritmo utilizado neste sorteio é conhecido como “Roulette Wheel”;

- b. A função “selecionarPais” retorna um par de indivíduos da Pop (p_1 e p_2), distintos e aleatoriamente selecionados;
 - c. A função “AplicarOperador” aplica o operador op ao par de indivíduos p_1 e p_2 , produzindo um novo indivíduo p_F (filho); a função “avaliarAptidão” faz a avaliação da aptidão de p_F ;
 - d. Visando preservar a diversidade genética da Pop e, consequentemente, evitar a convergência prematura, executa-se a função “selecionarPaiSub” para selecionar o indivíduo p_P da Pop que esteja mais próximo de p_F (métrica: distância Euclidiana);
 - e. Se p_F possuir valor de aptidão melhor que p_P , então se atribui ao operador op um valor de crédito r_{op} (proporcional ao ganho de aptidão) e p_F substitui p_P na Pop ; caso contrário, o indivíduo p_F é descartado e o crédito r_{op} atribuído ao operador será nulo; o crédito que será atribuído ao operador é gerado pela função “ganhoAptidão” (Eq. 3.14);
9. Ao fim de um ciclo evolutivo (nova geração), a função “ordenarPop” é executada para ordenar os atuais indivíduos da Pop ; na sequência, verifica-se se houve a melhora do incumbente P_{best} : caso haja um indivíduo na Pop melhor que o atual P_{best} , então P_{best} é atualizado e o contador q é zerando; caso contrário, o contador q é incrementado (q armazena o número de gerações sem melhoras no P_{best});
10. A cada duas gerações, a função “AdaptarProbabilidades” (Algoritmo 3 – Figura 3.3) é executada para realizar a adaptação da distribuição de probabilidades \vec{P} (ver Seções 2.2.4, 2.2.5 e 2.2.6):
- a. Os valores de “Recompensa Média Normalizada” dos operadores (elementos do vetor \vec{R}) são calculados de acordo com a Eq. (2.3);
 - b. Os valores de qualidade dos operadores (elementos do vetor \vec{Q}) são atualizados de acordo com a Eq. (2.14);
 - c. A distribuição de probabilidades \vec{P} é atualizada (adaptada) através da estratégia AP definida pela Eq. (2.20);
 - d. Os parâmetros α e β devem ser previamente ajustados pelo usuário do algoritmo.

11. Antes de se iniciar uma nova geração da *Pop*, verifica-se o critério de parada para o processo evolutivo (descrito no item 6); com a finalização do processo, o algoritmo retorna a lista ordenada *TopTen* com as 10 melhores soluções encontradas para o problema PET.

É importante observar que a estratégia adotada para o processo de substituição de indivíduos considera que o indivíduo pai (p_P) para um determinado indivíduo filho (p_F) será sempre o indivíduo da população corrente que está mais próximo de p_F (utiliza-se nesta avaliação a distância Euclidiana). Esta abordagem visa à manutenção da diversidade genética populacional, buscando evitar a convergência prematura do algoritmo para uma região de ótimo local. Além disso, a utilização desta estratégia impede que haja duplicação de uma determinada solução: característica esta que se torna vantajosa na resolução de problemas PET, pois muitos planejadores desejam encontrar um conjunto de boas soluções ao invés de uma única solução; daí o motivo pelo qual o algoritmo retorna, ao fim do processo de busca, uma lista com as 10 melhores soluções encontradas (esta lista é chamada de “TopTen”).

A função “ganhoAptidão” do Algoritmo 2 (Figura 3.2) é utilizada para calcular o crédito r_{op} que será atribuído ao operador op caso haja uma substituição do indivíduo p_P por p_F (“se o filho for melhor que o pai”). Assim, a partir do comparador ε -level (descrito na Seção 3.2.4), o critério adotado para o cálculo dos créditos é definido por:

$$r_{op} = \begin{cases} \text{Max}\left(0, \frac{f(p_P) - f(p_F)}{f(p_P)}\right) & \text{se } uf(p_P) \leq \varepsilon \text{ e } uf(p_F) \leq \varepsilon \\ \text{Max}\left(0, \frac{uf(p_P) - uf(p_F)}{uf(p_P)}\right) & \text{caso contrário} \end{cases} \quad (3.14)$$

Da Expressão (3.14), pode-se observar que: se os indivíduos p_P e p_F forem factíveis, então o crédito gerado será o ganho observado na função objetivo (referência local); caso contrário, o crédito gerado será o ganho observado na função violação de restrições (*função unfitness*). Deve-se notar também que a aplicação de um determinado operador sempre gera crédito, sendo este crédito nulo quando o operador não gera um indivíduo filho melhor que seu pai.

Algoritmo 1: AES-TEP + ε -constrained

ENTRADA: *Prob* (problema PET), *Ops* (lista com K operadores), N_{Pop} (número de indivíduos da *Pop*), T_{max} (número máximo de gerações), α e β (parâmetros de controle da estratégia AP).

DADOS: \vec{P} (probabilidades de seleção), \vec{Q} (qualidades), \vec{R} (recompensas), \vec{N} (número de utilizações de cada operador), P_{min} e P_{max} (limites mínimo e máximo para as probabilidades), *Pop* (população: lista com N_{Pop} indivíduos), Q_{max} (número máximo de gerações sem melhora da incumbente), *op* (índice do operador selecionado), *t* (contador de gerações), *q* (contador de gerações sem melhora da incumbente), P_{best} (indivíduo incumbente), T (período para adaptação das probabilidades), ε (parâmetro do comparador ε -level).

SAÍDA: *TopTen* (lista ordenada com as 10 melhores soluções encontradas para o *Prob*).

INÍCIO

```

Pop ← criarPop( $N_{Pop}$ , Prob)
avaliarResultado(Pop, Prob)
ordenarPop(Pop)
 $P_{best}$  ← Pop(0)
PARA op ← 1 até  $K$  FAÇA
     $P(op)$  ←  $K^{-1}$ 
     $Q(op)$  ← 0
     $R(op)$  ← 0
     $N(op)$  ← 0
FIM
 $P_{min}$  ←  $(2K)^{-1}$ 
 $P_{max}$  ←  $(0,5 + P_{min})$ 
t ← 0
q ← 0
T ← 2
 $Q_{max}$  ←  $(0,2 \times T_{max})$ 
ENQUANTO (t <  $T_{max}$ ) E (q <  $Q_{max}$ ) FAÇA
    t ← t + 1
     $\varepsilon$  ←  $\varepsilon(t)$ 
    PARA i ← 1 até  $N_{Pop}$  FAÇA
        op ← selecionarOperador( $\vec{P}$ )
        AplicarOperador(op, Ops, Pop, Prob)
    FIM
    ordenarPop(Pop)
    SE Pop(0) é melhor que  $P_{best}$  ENTÃO
         $P_{best}$  ← Pop(0)
        q ← 0
    SENÃO
        q ← q + 1
    FIM
    SE resto(t/T) = 0 ENTÃO
        AdaptarProbabilidades()
    FIM
FIM
Retornar TopTen

```

FIM

Figura 3.1: Pseudocódigo do algoritmo AES-TEP.

Algoritmo 2: AplicarOperador(*op*, *Ops*, *Pop*, *Prob*)

ENTRADA: *op* (índice do operador selecionado), *Ops* (lista de operadores), *Pop* (população), *Prob* (problema PET).

DADOS: *Op_s* (operador de reprodução selecionado), *p₁* e *p₂* (indivíduos da *Pop*, distintos e aleatoriamente selecionados), *p_F* (indivíduo filho gerado pelo operador *Op_s*), *p_P* (candidato a substituição: indivíduo da *Pop* mais próximo ao *p_F*), \vec{R} (recompensas), \vec{N} (número de utilizações de cada operador).

INÍCIO

```
[p1, p2] ← selecionarPais(Pop)
Ops ← Ops(op)
pF ← Ops(p1, p2)
avaliarAptidão(pF, Prob)
pP ← selecionarPaiSub(pF, Pop)
SE pF é melhor que pP ENTÃO
    R(op) ← R(op) + ganhoAptidão(pF, pP)
    Pop(pP) ← pF
```

FIM

```
N(op) ← N(op) + 1
```

FIM

Figura 3.2: Pseudocódigo da função *AplicarOperador*.

Algoritmo 3: AdaptarProbabilidades()

DADOS: \vec{P} (probabilidades), \vec{Q} (qualidades), \vec{R} (recompensas), \vec{N} (número de utilizações de cada operador), *P_{min}* e *P_{max}* (limites mínimo e máximo para as probabilidades), α e β (parâmetros de controle da estratégia AP), *R_{max}* (maior valor de recompensa média), *bst* (índice do operador de maior qualidade), *argMax* (função que retorna o índice do maior elemento do vetor).

INÍCIO

```
Rmax ← 0
PARA i ← 1 até K FAÇA
    R(i) ← R(i) / N(i)
    Rmax ← Max(Rmax, R(i))
    N(i) ← 0
FIM
PARA i ← 1 até K FAÇA
    R(i) ← R(i) / Rmax
    Q(i) ← Q(i) +  $\alpha$ [(R(i) - Q(i))]
    R(i) ← 0
FIM
```

```
bst ← argMax( $\vec{Q}$ )
PARA i ← 1 até K FAÇA
    SE i = bst ENTÃO
        P(i) ← P(i) +  $\beta$ [Pmax - P(i)]
    SENÃO
        P(i) ← P(i) +  $\beta$ [Pmin - P(i)]
FIM
```

FIM

FIM

FIM

Figura 3.3: Pseudocódigo da função *AdaptarProbabilidades*.

3.3.1 Inicialização Inteligente da População

Normalmente, a população inicial de um EA é formada por indivíduos aleatórios, uniformemente distribuídos pelo espaço de busca do problema (i.e., sorteio realizado a partir de uma distribuição de probabilidades uniforme). Contudo, quando se tem *a priori* alguma informação específica a respeito do problema a ser resolvido (heurística), pode-se gerar uma população inicial com indivíduos de melhor qualidade, distribuídos de maneira inteligente pelo espaço de busca. De acordo com as referências [GMR98a, GMR98b, CN99, BOA01, EGR04, RRS07, YGD08, R11], uma estratégia que pode ser utilizada para reduzir o custo computacional e melhorar o desempenho da meta-heurística, principalmente quando aplicada a problemas PET para sistemas de médio e grande porte, é a utilização de um processo de Inicialização Inteligente, gerando de maneira eficiente os indivíduos da população inicial.

Para o problema PET, um plano de boa qualidade possui grande parte dos reforços que fazem parte dos melhores planos de expansão que podem ser encontrados para o problema. Nesse sentido, pode-se utilizar algum algoritmo heurístico construtivo como forma de se obter soluções aproximadas para o problema, servindo então, como ponto de partida para a definição de uma estratégia de inicialização inteligente da população. Contudo, sabe-se que, para a grande maioria dos problemas de otimização, e principalmente para os problemas de otimização combinatória, a eficiência de um EA depende fortemente do nível de diversidade genética da população [HW03, ES03]. Assim, a pura e simples utilização de um algoritmo heurístico construtivo para a criação de indivíduos de boa qualidade não é interessante, pois se deve também garantir diversidade genética na população.

No SPO (subproblema de operação), definido pelas Expressões (3.5) e (3.6), um subproduto da resolução do problema PL são as variáveis duais (multiplicadores de Lagrange) associadas às restrições. Especificamente em relação às restrições de balanço de potências nas barras ($g + r + B\theta = d$), as variáveis duais a elas associadas (também chamadas de custos marginais) são de gran-

de interesse, pois podem ser utilizadas na construção de planos iniciais de boa qualidade e também para guiar o processo de busca. Sendo π_i^d a variável dual para a barra i , e θ_i o ângulo da tensão nodal na barra i , pode-se estimar o benefício da adição de reforço ao ramo $i - j$ em termos do índice de carga não suprida [BOA01], o qual é baseado em mudanças nas susceptâncias dos ramos pela adição de novos reforços e definido como:

$$\pi_{ij}^d = (\theta_i - \theta_j)(\pi_i^d - \pi_j^d) \quad (3.15)$$

onde π_{ij}^d é a variável dual associada à susceptância do ramo $i - j$. Na referência [LRM11], considera-se também o custo de investimento c_{ij} para a adição de um novo reforço ao ramo $i - j$, definindo-se uma função heurística para avaliar o benefício da adição de reforço ao ramo $i - j$, tal que:

$$\eta(i, j) = \left| \frac{\pi_{ij}^d}{c_{ij}} \right| \quad (3.16)$$

onde $\eta(i, j)$ é o valor da função heurística para o ramo $i - j$: quanto maior for este valor, melhor será a relação custo/benéfico para adição de um novo reforço ao ramo.

Especificamente para os problemas PET considerando o critério “N-1” (Eq. 3.8 e 3.9), pode acontecer de um plano atender ao critério de rede intacta (i.e., satisfazer à restrição corte de carga nulo) e não atender ao critério “N-1”, necessitando da adição de mais reforços ao plano. Neste caso, os valores π_i^d para todas as barras do sistema serão nulos e, conseqüentemente, os valores para a função heurística da Eq. (3.16) também serão nulos, perdendo assim a sua capacidade de indicar os ramos mais atrativos para adição de reforços. Logo, considera-se neste trabalho que, um plano inactível que atende ao critério de rede intacta e não atende ao critério “N-1”, terá as diferenças $\pi_i^d - \pi_j^d$ da Eq. (3.15) igualadas a um, tal que: $\pi_{ij}^d = (\theta_i - \theta_j)$.

Neste trabalho, o algoritmo construtivo heurístico proposto para realizar a inicialização inteligente da população utiliza a função heurística definida pela Eq.

(3.16) como conhecimento básico para a criação de indivíduos de boa qualidade. Os passos do Algoritmo de Inicialização Inteligente (All) são dados por:

1. Criar um novo indivíduo n sem nenhuma adição de reforços, ou seja, o vetor plano de expansão é nulo;
2. Avaliar o indivíduo n : resolver o SPI (Eq. 3.3 e 3.4 para o PET sem critério “N-1”; ou Eq. 3.8 e 3.9 para o PET com “N-1”) e, conseqüentemente, o SPO (Eq. 3.5 e 3.6, com ou sem perdas); a partir das variáveis duais obtidas com a solução do SPO (PL), calcular o valor da função heurística (Eq. 3.16) para todos os ramos candidatos a expansão;
3. Verificar se o indivíduo n é factível (i.e., plano de expansão atende ao critério de rede intacta e, quando for o caso, atende ao critério “N-1”): se sim, ir para o passo 5, caso contrário, ir para o próximo passo;
4. Utilizar as Expressões (3.17) e (3.18) para seleccionar o ramo r do plano n , o qual irá receber a adição de um único elemento; após o reforço do plano n , voltar ao passo 2.

$$r = \begin{cases} \arg \max_{(i-j) \in \Omega} [\eta(i, j)] & \text{se } q \leq 0,25 \\ r_S & \text{caso contrário} \end{cases} \quad (3.17)$$

$$p(i, j) = \begin{cases} \frac{\eta(i, j)}{\sum_{(t-u) \in \Omega} \eta(t, u)} & \text{se } (i-j) \in \Omega \\ 0 & \text{caso contrário} \end{cases} \quad (3.18)$$

onde r é o ramo que deverá ser reforçado, tal que: $r \in \Omega$; Ω é o conjunto de todos os ramos $i-j$ candidatos a expansão; q é um número real aleatório uniformemente distribuído em $[0,1]$; “arg max” é uma função que retorna o ramo com maior valor para a função heurística $\eta(i, j)$; r_S é uma variável aleatória que segue uma distribuição discreta dada pela Expressão (3.18), tal que: $r_S \in \Omega$; $p(i, j)$ é a probabilidade de se adicionar um reforço ao ramo $i-j$;

5. Adicionar o indivíduo n a população do EA; se o número de indivíduos da população atual for menor que o tamanho desejado para a população (N_{Pop}), voltar ao passo 1, senão finalizar a execução do algoritmo.

Basicamente, pode-se definir três estratégias para a inicialização da população do EA: 1) 100% Aleatória, onde todos os indivíduos são aleatoriamente distribuídos pelo espaço de busca; 2) 100% Inteligente, onde todos os indivíduos são criados pelo All; ou 3) Mista, onde 50% dos indivíduos são criados pelo All e o restante são aleatoriamente distribuídos. No Capítulo 4 será apresentado um estudo comparativo do desempenho do AES-TEP utilizando estas três estratégias para inicialização da população. É importante ressaltar que os indivíduos criados pelo All são soluções aproximadas para o PET; assim, estes indivíduos serão sempre factíveis. Já os indivíduos criados de forma aleatória poderão, eventualmente, apresentar certo nível de infactibilidade.

3.3.2 Operadores Especialistas

Como o objetivo de aumentar a eficiência do algoritmo AES-TEP na busca pelas melhores soluções do problema PET, neste trabalho, propõe-se um novo grupo de operadores reprodutivos, chamados de operadores especialistas. Estes operadores utilizam heurísticas específicas de sistemas elétricos para gerar novos indivíduos de forma inteligente. Assim, visando guiar os operadores na identificação dos ramos mais interessantes para adição ou remoção de reforços, após a solução do SPO de rede intacta (Eq. 3.5 e 3.6) para um determinado plano n , a cada ramo $i - j$ do conjunto de ramos candidatos a expansão será atribuído dois valores para os seguintes índices de desempenho:

1. **Índice de Abertura Angular (Ind_A):**

$$Ind_A(i, j) = \left| \frac{\Delta\theta_{ij}}{c_{ij}} \right| \quad (3.19)$$

onde $Ind_A(i, j)$ é o índice de abertura angular atribuído ao ramo $i - j$ do plano candidato n (sempre positivo); $\Delta\theta_{ij}$ é a abertura angular entre as tensões das barras i e j , tal que: $\Delta\theta_{ij} = \theta_i - \theta_j$; e c_{ij} é o custo unitário para adição de reforço ao ramo $i - j$.

2. **Índice de Carregamento (Ind_C):**

$$Ind_C(i, j) = \left| \frac{L_{ij}}{c_{ij}} \right| \quad (3.20)$$

onde $Ind_C(i, j)$ é o índice de carregamento atribuído ao ramo $i - j$ do plano candidato n (sempre positivo); L_{ij} é o carregamento para o ramo $i - j$, dado pela relação entre o fluxo total de potência ativa f_{ij} e a capacidade máxima f_{ij}^{max} do ramo, tal que: $L_{ij} = f_{ij} / f_{ij}^{max}$; c_{ij} é o custo unitário para a adição de reforço ao ramo $i - j$.

Partindo de uma relação custo/benefício, os índices de desempenho definidos pelas Expressões (3.19) e (3.20) podem ajudar na identificação de possíveis melhorias aos planos de expansão candidatos, possivelmente produzindo impactos mais significativos sobre os aspectos operacionais do sistema, visto que se considera informações específicas aos sistemas elétricos tratados.

No PET, observa-se que planos com corte de carga para a rede intacta ou com sobrecarga após o teste do critério “N-1” (i.e., planos infactíveis) devem sempre receber a adição de reforços, até que a disponibilidade de transmissão do sistema seja capaz de suprir completamente a demanda por energia, tanto no caso de rede intacta como no caso de contingência simples; caso contrário, busca-se a remoção de reforços desnecessários, reduzindo o custo de investimento ao menor valor possível. Nesse sentido, considera-se que os ramos com grandes valores para Ind_A e Ind_C são bons candidatos para a adição de reforços. Por outro lado, os ramos com valores pequenos para os índices são bons candidatos para a remoção de reforços. Desta forma, utilizando as informações heurísticas geradas pelos índices Ind_A e Ind_C , duas estratégias para a mutação dos indivíduos são propostas:

1. **Expert Roulette Wheel Mutation:** nesta estratégia utiliza-se o algoritmo *Roulette Wheel* (RW) [ES03] para sortear o ramo $i - j$ que deverá ter seus reforços incrementados ou decrementados em uma unidade; se o plano candidato n for infactível (i.e., possuir corte de carga para a rede intacta ou sobrecarga ao “N-1”), o ramo que receberá o reforço é sorteado com probabilidades proporcionais aos valores dos índices; caso contrário, o ramo que terá seus reforços decrementados será sorteado com probabilidades inversamente proporcionais aos índices; dois operadores de mutação podem ser derivados desta estratégia: um utilizando o índi-

ce Ind_A , identificado como RMA, e outro utilizando o índice Ind_C , identificado como RMC.

2. **Expert Swap Gene Mutation:** nesta estratégia, o operador SWM (descrito na Seção 2.3) é convenientemente modificado de forma a utilizar as informações heurísticas de um determinado índice para trocar (inverter) os reforços entre os ramos $k1$ e $k2$ do plano candidato n ; visando aumentar os reforços em um ramo e reduzir no outro, o ramo $k1$ é sorteado com probabilidades proporcionais aos valores do índice escolhido; já o ramo $k2$ é sorteado com probabilidades inversamente proporcionais ao índice; os sorteios são realizados utilizando o algoritmo RW; dois operadores de mutação podem ser derivados desta estratégia, o SMA, que utiliza o índice Ind_A , e o SMC, que utiliza o índice Ind_C .

Por fim, o grupo de operadores chamados de operadores especialistas é então definido pela combinação dos novos operadores de mutação RMA, RMC, SMA e SMC com os operadores de recombinação UNX e SPX (definidos na Seção 2.3), dando origem a oito novos operadores de reprodução: UNX-RMA, UNX-RMC, UNX-SMA, UNX-SMC, SPX-RMA, SPX-RMC, SPX-SMA e SPX-SMC. Destaca-se que, tanto o grupo dos operadores evolutivos (Seção 2.3) como o grupo dos especialistas são compostos por operadores estocásticos, visto que todos se utilizam variáveis aleatórias em seu funcionamento [ES03]. Informa-se ainda que, uma vez calculados os índices de desempenho (Eq. 3.19 e 3.20) para um determinado plano n , estes deverão ser normalizados em função dos valores de máximo e mínimo para cada índice, facilitando assim sua utilização no método de seleção probabilística RW.

3.4 CONSIDERAÇÕES FINAIS

Este capítulo teve com objetivo apresentar detalhadamente toda a metodologia que foi adotada para a modelagem e resolução dos problemas PET. A formulação matemática utilizada inclui um algoritmo de programação linear (PL), baseado em um modelo de fluxo DC com perdas, e um método determinístico para avaliação do critério de segurança “N-1”. O critério “N-1”, em sua versão origi-

nal ou relaxada, foi utilizado para garantir um bom nível de confiabilidade nas soluções encontradas para o PET. O algoritmo evolutivo adaptativo proposto, chamado de AES-TEP, foi detalhadamente descrito, juntamente com as metodologias adotadas para permitir sua aplicação nos problemas PET. Além disso, a metodologia heurística utilizada para fazer a inicialização inteligente da população foi apresentada, juntamente com a proposta de um novo grupo de operadores de reprodução, especializados em problemas PET (operadores especialistas).

O algoritmo AES-TEP proposto, já considerando o grupo de operadores especialistas, apresenta algumas contribuições inovadoras para o atual estado da arte do PET e da EC: 1) utilização de estratégia adaptativa para seleção dos seus operadores de reprodução; 2) utilização de operadores gerados pela associação de operadores de recombinação com operadores de mutação; 3) critério de substituição do indivíduo filho pelo indivíduo da população que esteja mais próximo; 4) manutenção da população com apenas indivíduos distintos; 5) utilização de heurísticas específicas ao PET diretamente nos operadores de reprodução; e 6) metodologia simples e robusta para manipulação das restrições do problema (independe do ajuste de parâmetros).

Especificamente na área de planejamento de sistemas elétricos, a principal contribuição deste trabalho é a utilização de uma meta-heurística evolutiva com múltiplos operadores de busca e seleção adaptativa destes operadores. Esta proposta é de simples implementação e fácil configuração (poucos parâmetros para ajuste), visando à maximização do uso do operador que produz melhores resultados para cada estágio do processo de busca. Desta forma, o algoritmo libera o usuário da tarefa de ajustar os valores de probabilidades de seleção dos operadores, o que dá certa robustez à ferramenta de busca proposta. Basicamente, a metodologia AES-TEP possui quatro parâmetros a serem ajustados pelo usuário (N_{Pop} , T_{max} , α e β), o que é pouco quando comparado com outras meta-heurísticas propostas para o PET. O próximo capítulo irá apresentar e discutir os resultados obtidos com a metodologia proposta.

CAPÍTULO 4

RESULTADOS E DISCUSSÕES

4.1 INTRODUÇÃO

Neste capítulo serão apresentados e discutidos os resultados obtidos com a aplicação do algoritmo evolutivo proposto pelo Capítulo 3 (AES-TEP). A fim de avaliar o desempenho do algoritmo AES-TEP na resolução de problemas PET estáticos e determinísticos, dois sistemas elétricos bastante conhecidos na literatura especializada foram utilizados: Sistema IEEE RTS-79 (IEEE24) [APM79] e Sistema Sul Brasileiro (SBR) [RMGH02]. O IEEE24 possui 24 barras e 41 ramos candidatos à expansão, podendo ser classificado como um sistema acadêmico de pequeno porte. Já o sistema SBR possui 46 barras e 79 ramos candidatos, podendo ser classificado como um sistema real de pequeno porte. A partir destes dois sistemas, utilizou-se o algoritmo AES-TEP para resolver oito problemas PET distintos (chamados nas seções seguintes de casos):

1. **IEEE24 “N-0”**: PET para o sistema IEEE24, sem perdas e sem critérios de segurança (considera apenas o critério da rede intacta);
2. **IEEE24 “N-1” 0%**: PET para o sistema IEEE24, considerando as perdas ôhmicas e o critério de segurança “N-1” sem relaxamento ($sc_{max} = 0\%$);
3. **IEEE24 “N-1” 10%**: PET para o sistema IEEE24, considerando as perdas ôhmicas e o critério de segurança “N-1” relaxado com $sc_{max} = 10\%$;
4. **IEEE24 “N-1” 20%**: PET para o sistema IEEE24, considerando as perdas ôhmicas e o critério de segurança “N-1” relaxado com $sc_{max} = 20\%$;
5. **SBR “N-0”**: PET para o sistema SBR, sem perdas e sem critérios de segurança (considera apenas o critério da rede intacta);
6. **SBR “N-1” 0%**: PET para o sistema SBR, considerando as perdas ôhmicas e o critério de segurança “N-1” sem relaxamento ($sc_{max} = 0\%$);

7. **SBR “N-1” 10%:** PET para o sistema SBR, considerando as perdas ôhmicas e o critério de segurança “N-1” relaxado com $sc_{max} = 10\%$;
8. **SBR “N-1” 20%:** PET para o sistema SBR, considerando as perdas ôhmicas e o critério de segurança “N-1” relaxado com $sc_{max} = 20\%$;

Na modelagem dos dados de entrada utilizados para as simulações, adotaram-se as condições e configurações propostas por [SRRGM05], tais como: conjunto de ramos candidatos à expansão, número máximo de reforços por ramo, carga e geração para o horizonte futuro, etc. Todos os dados utilizados nas simulações estão listados no Apêndice A. Na seção seguinte, a metodologia utilizada para avaliação do desempenho do algoritmo AES-TEP será detalhada.

4.2 ÍNDICES E CRITÉRIOS PARA AVALIAÇÃO DO DESEMPENHO

Nesta seção, apresenta-se uma descrição detalhada da metodologia experimental adotada para avaliar o desempenho do algoritmo evolutivo proposto (AES-TEP). Primeiramente, para se entender os índices e critérios utilizados na avaliação de desempenho, algumas definições se fazem necessárias:

- **Avaliação do Problema:** É a avaliação do problema PET para um determinado indivíduo n (plano de expansão candidato), envolvendo o cálculo do valor da função objetivo $f(n)$ e do valor da função violação de restrições $uf(n)$; geralmente, o custo computacional das avaliações do problema representa a maior parte do custo computacional total que o algoritmo evolutivo demanda durante o processo de busca pelas melhores soluções; no caso do problema PET, a maior parte do custo computacional se deve a solução do subproblema operacional (SPO), através da resolução de problemas PL e, quando se considera o critério de segurança “N-1”, da resolução dos sistemas lineares decorrentes dos cálculos de fluxo de potência DC; na Seção 3.2.3 do Capítulo 3 apresenta-se uma descrição detalhada destes procedimentos.
- **Solução Factível:** É uma solução que satisfaz a todas as restrições do problema; no método ε -constrained aplicado ao problema PET (vide Seção 3.3.4), uma solução n é dita factível quando $uf(n) = 0$ (i.e., corte de carga

nulo para a rede intacta e/ou sobrecarga nula para qualquer contingência simples);

- **Execução Factível:** É quando uma determinada execução do algoritmo, após o término do processo evolutivo, encontra pelo menos uma solução factível; visto que o método ε -constrained usa uma relação lexicográfica, onde a factibilidade da solução é mais importante que a otimização da função objetivo, para que uma execução seja considerada factível, pelo menos o melhor indivíduo da população final deve ser factível;
- **Solução Bem Sucedida:** É uma solução factível que é igual ou melhor que o atual ótimo global do problema (i.e., igual ou melhor que a melhor solução conhecida até o momento); em alguns casos (e.g., quando o problema de otimização é de difícil resolução), na classificação de uma solução como bem sucedida, verifica-se a sua factibilidade e a sua proximidade ao ótimo global: soluções factíveis que atendam a um determinado erro mínimo podem ser classificadas como bem sucedidas;
- **Execução Bem Sucedida:** É quando uma determinada execução do algoritmo, após o término do processo evolutivo, encontra pelo menos uma solução bem sucedida; assim, para que uma execução seja considerada bem sucedida, pelo menos o melhor indivíduo da população final deve ser uma solução bem sucedida.

Dado o problema PET a qual se deseja resolver, a avaliação de desempenho para uma determinada versão do algoritmo AES-TEP é feita após N_{Max} execuções do algoritmo (“rodadas”), onde em cada rodada inicializa-se o gerador de números pseudo-aleatórios com uma semente diferente. Neste trabalho, adotou-se $N_{Max} = 100$ em todos os casos simulados. Desta forma, os índices e critérios utilizados na avaliação do desempenho do algoritmo são:

- **I_Q - Índice de Qualidade:** valor percentual que quantifica a qualidade da melhor solução obtida pelo algoritmo após uma única execução, tal que: $I_Q = 100\% \times (f_{gb} / f_{bst})$; onde f_{gb} é o valor da função objetivo para o ótimo global (custo do melhor plano conhecido); e f_{bst} é o valor da função obje-

tivo para a melhor solução encontrada pelo algoritmo após uma única execução;

- **IQ - Índice Médio de Qualidade:** média aritmética simples para o índice I_Q , após N_{Max} execuções do algoritmo; quanto maior for este valor, melhor será o desempenho do algoritmo (i.e., mais próximas do ótimo global estarão as soluções obtidas pelo algoritmo);
- **I_{TT} - Índice de Qualidade do TopTen:** valor percentual que quantifica a qualidade das 10 melhores soluções (“TopTen”) obtidas pelo algoritmo após uma única execução, sendo calculado da seguinte forma:

$$I_{TT} = 100\% \times \frac{1}{10} \sum_{i=1}^{10} \left(\frac{f_{gb}}{f_i} \right) \quad (4.1)$$

onde f_{gb} é o valor da função objetivo para o ótimo global (ou melhor solução conhecida); f_i é o valor da função objetivo para a i -ésima solução do conjunto “TopTen” (as 10 melhores soluções obtidas após uma única execução);

- **ITT - Índice Médio de Qualidade do TopTen:** média aritmética simples para o índice I_{TT} , após N_{Max} rodadas do algoritmo; quanto maior for este valor, melhor será o desempenho do algoritmo (i.e., mais próximas do ótimo global estarão as 10 melhores soluções obtidas pelo algoritmo);
- **TS - Taxa de Sucesso:** valor percentual que mostra a relação entre o número de execuções bem sucedidas (N_{Suc}) e o número total de execuções realizadas (N_{Max}), tal que: $TS = 100\% \times (N_{Suc} / N_{Max})$; quanto maior for este valor, melhor será o desempenho do algoritmo no processo de busca (i.e., maior capacidade do algoritmo de encontrar a melhor ou as melhores soluções do problema);
- **TM_s - Tempo Médio de uma Execução Bem Sucedida:** média aritmética simples do tempo computacional demandado pelo algoritmo para obter uma solução bem sucedida, considerando as N_{Max} execuções realizadas; quanto menor for este valor, melhor será o desempenho do algoritmo (mais rápido ele chega à melhor solução conhecida);

- **TM_C - Tempo Médio para Convergência:** média aritmética simples do tempo computacional demandado pelo algoritmo para atingir um dos critérios de parada do processo evolutivo (convergência), considerando as N_{Max} execuções realizadas; quanto menor for este valor, melhor será o desempenho do algoritmo (mais rápido ele converge); contudo, deve-se tomar cuidado ao analisar este índice, pois pode ocorrer de um algoritmo ficar preso em uma determinada região sub-ótima do espaço de busca, estagnar o seu processo evolutivo, e assim convergir mais rápido.

Como foi visto nos Capítulos 1 e 3, a consideração do critério de segurança “N-1” durante todo o processo de busca pelas melhores soluções aumenta significativamente a complexidade computacional do problema PET. Assim, de forma a viabilizar a análise estatística para as diversas versões do algoritmo proposto, adotou-se neste trabalho uma versão “relaxada” da taxa de sucesso (TS), onde, nos caso do PET com “N-1”, se considera que uma execução é bem sucedida quando ela encontrar pelo menos uma das 10 melhores soluções conhecidas para o problema. Vale salientar que, esta nova versão da TS é utilizada exclusivamente nos casos do PET que consideram o critério “N-1” durante a busca; para os casos do PET sem o critério “N-1”, ou seja, para o IEEE24 “N-0” e o SBR “N-0”, uma execução será bem sucedida somente se encontrar a melhor solução conhecida para o problema (ótimo global).

Como exemplo, na resolução de um determinado problema PET com critério “N-1”, obteve-se para uma dada versão do algoritmo AES-TEP os seguintes valores: $TS = 50\%$, $TM_S = 10m$, e $TM_C = 12m$. Neste caso, pode-se dizer que: das 100 execuções realizadas, 50 foram bem sucedidas, gastando em média 10 minutos para encontrar uma das 10 melhores soluções conhecidas para o problema; além disso, nas 100 execuções realizadas, cada rodada gostou em média 12 minutos para finalizar o processo de busca (convergir). Nas tabelas apresentadas pelas seções seguintes, os valores mais significativos para cada um dos índices de desempenho considerados (IQ , ITT , etc.) estão destacados como: colorido de azul para indicar que é o melhor valor, ou colorido de vermelho para indicar que é o pior valor.

O algoritmo proposto AES-TEP foi implementado na linguagem C#.NET e utiliza as bibliotecas GLPK, para resolver os problemas PL, e IMSL Fortran, para resolver os sistemas de equações lineares. Os tempos definidos pelos índices TM_S e TM_C se referem a um processador Intel Core i7-3770 (3.40GHz); as unidades de medida utilizadas para o tempo computacional são: segundos (s) ou minutos (m). Nas simulações utilizou-se o recurso *Multithreading*, o que permitiu a simulação de até oito casos em paralelo (carga máxima para um processador com oito núcleos – quatro núcleos físicos e quatro virtuais).

A utilização do algoritmo AES-TEP demanda o ajuste prévio de quatro parâmetros de controle (vide Seção 3.3): N_{Pop} , T_{max} , α e β . A partir do ajuste destes parâmetros e da definição dos operadores reprodutivos a serem utilizados (operadores evolutivos ou especialistas), pode-se definir diversas versões para o algoritmo AES-TEP. O ajuste de N_{Pop} (número de indivíduo da população) e T_{max} (número máximo de gerações permitido) deve levar em consideração a dimensão e a complexidade do problema tratado. A configuração $\alpha = 0$ e $\beta = 0$ para o AES-TEP faz com que o sistema adaptativo (estratégia AP) fique desativado, mantendo as probabilidades iniciais de seleção dos operadores fixas durante todo o processo evolutivo: neste caso, a versão AES-TEP será chamada de versão estática (sem adaptação de probabilidades).

O grupo de operadores a ser utilizado pelo AES-TEP, a princípio, pode receber qualquer quantidade de operadores, não existindo um número máximo de operadores permitido. Contudo, neste trabalho, consideram-se três possibilidades: 1) todos os oito operadores especialistas definidos pela Seção 3.3.2; ou 2) todos os 12 operadores evolutivos definidos pela Seção 2.3; ou 3) um único operador reprodutivo, que pode ser evolutivo ou especialista. É importante notar que, nas versões AES-TEP utilizando um único operador reprodutivo (e.g., SPX-UNM, UNX-RMA, etc.), o sistema adaptativo está desativado ($\alpha = 0$ e $\beta = 0$) e a versão é chamada de estática: esta versão do AES-TEP é equivalente aos tradicionais EAs utilizando um único operador reprodutivo e com parâmetros de controle fixos. Como exemplo, pode-se dizer que a versão “SPX-UNM”

do AES-TEP é equivalente ao GA proposto por [SRRGM05]; já a versão "SPX-SWM" é equivalente ao GA proposto por [SA15].

Para comparar o desempenho de versões do AES-TEP, analisando a dinâmica do processo evolutivo, foram utilizados gráficos de convergência [TS10]. Nestes, após as N_{Max} execuções, as linhas coloridas em destaque (azul, vermelho, etc.) representam a performance média para versões distintas do algoritmo. Já as áreas coloridas sombreadas que acompanham os valores médios (regiões de azul ou vermelho; utilizadas apenas para comparar duas versões específicas do algoritmo), representam a "margem de variação" para o melhor indivíduo da população, n_{bst} . Após as N_{Max} execuções de uma versão do algoritmo, para cada geração t das T_{max} gerações, tem-se os valores de erro médio, máximo e mínimo para o n_{bst-t} . Assim, os gráficos de convergência semi-log apresentam a evolução do erro em função do número de gerações, de forma que: $y(t) = \text{Log}(\text{erro} + 1)$, onde $\text{erro} = |f_{bst-t} - f_{gb}|$; f_{gb} é o valor da função objetivo para a melhor solução conhecida do problema; e f_{bst-t} é o valor da função objetivo para o melhor indivíduo da t -ésima geração (n_{bst-t}). Desta forma, pode-se notar nos gráficos de convergência que, quanto mais próximo de zero estiver o valor do erro, mais próximo do ótimo global estará o melhor indivíduo da população: considera-se a execução como bem sucedida quando o erro se torna nulo. Além disso, pode-se notar que existe certa relação entre o índice IQ e o valor final do erro médio.

Por fim, informa-se que, para todos os casos simulados, todas as execuções do algoritmo AES-TEP realizadas foram execuções factíveis, ou seja, em todas as simulações obtiveram-se ao fim do processo evolutivo soluções factíveis (planos com corte de carga nulo e/ou sobrecarga nula para contingências simples). Desta forma, as tabelas com resultados, apresentadas pelas próximas seções, não fazem referência à factibilidade das soluções encontradas. Contudo, para problemas onde as regiões de factibilidade são muito segmentadas e/ou reduzidas, pode-se definir uma taxa de factibilidade para o algoritmo (semelhante à TS), ou até mesmo um índice de qualidade para a factibilidade das soluções.

4.3 SISTEMA IEEE RTS-79

O sistema de transmissão IEEE RTS-79 (IEEE24), o qual está representado pelo diagrama unifilar da Figura 4.1 [APM79], possui para seu horizonte futuro uma previsão de demanda total de 8.550 MW e capacidade máxima de geração de 10.215 MW. Este sistema é composto de 24 barras e 41 ramos candidatos à expansão (34 ramos existentes na topologia original e mais sete ramos novos). Independentemente dos elementos existentes na topologia original, cada um dos 41 ramos candidatos pode receber, no máximo, até três reforços. Todos os dados que foram utilizados nas simulações deste sistema estão listados no Apêndice A.1.

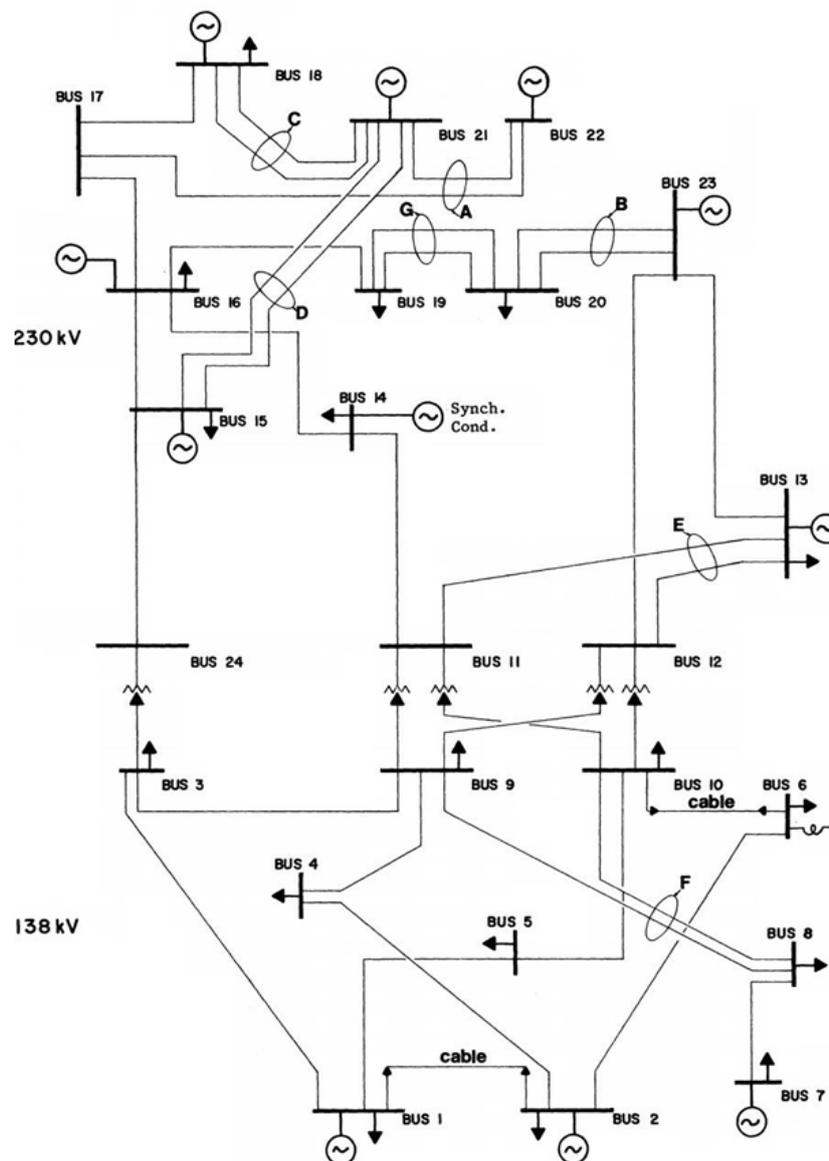


Figura 4.1: Diagrama unifilar para o sistema IEEE24 – topologia original.

4.3.1 Caso 1: IEEE24 “N-0”

Neste caso, o problema PET para o sistema IEEE24 não considera as perdas ôhmicas dos equipamentos de transmissão e também não considera qualquer critério de segurança. Assim, as soluções para o problema devem minimizar o custo de investimento, satisfazendo apenas a restrição de corte de carga nulo para a rede intacta. Para tanto, permite-se o redespacho total dos geradores: para um dado plano candidato, realiza-se o redespacho dos geradores de modo a minimizar o custo operacional do sistema (custo do corte de carga mais o custo da geração – vide Seção 3.2). Na tabela 4.1 estão listados os 10 melhores planos conhecidos para este caso, ordenados pelo custo de investimento.

Tabela 4.1: Os 10 melhores planos conhecidos para o caso IEEE24 “N-0”.

N.	Custo (10 ⁶ US\$)	Perdas (MW)	N.Refs	Planos de Expansão - Reforços Adicionados por Ramo (ID)													
				1	3	8	9	10	11	15	17	18	23	24	29	38	
1	152,0	0,0	5					1	2		1		1				
2	163,0	0,0	6	1				1	2		1						1
3	164,0	0,0	5					1	2		1	1					
4	174,0	0,0	6		1			1	2	1				1			
5	180,0	0,0	6					1	2		1					1	1
6	182,0	0,0	6		1			1	2		1						1
7	183,0	0,0	6				1	1	2		1						1
8	184,0	0,0	6					1	2		1			1			1
9	185,0	0,0	7	1	1			1	2	1							1
10	187,0	0,0	6			1		1	2		1						1

A Tabela 4.2 apresenta os resultados obtidos com a aplicação do algoritmo AES-TEP utilizando o grupo dos operadores evolutivos (todos os 12 operadores evolutivos definidos pela Seção 2.3). Nesta tabela, duas versões do algoritmo são comparadas: a) versão adaptativa, onde $\alpha = 0,4$ e $\beta = 0,9$; e b) versão estática (sem adaptação), onde $\alpha = 0$ e $\beta = 0$. A comparação se dá para três diferentes tamanhos de população (parâmetro $N_{Pop} = 50, 100$ ou 150), nas quais todos os indivíduos foram inicializados de forma completamente aleatória. O número máximo de gerações permitido foi fixado em $T_{max} = 120$.

Semelhantemente à Tabela 4.2, na Tabela 4.3 apresenta-se os resultados obtidos com a aplicação do algoritmo AES-TEP utilizando o grupo dos operadores especialistas (todos os oito operadores especialistas definidos pela Seção

3.3.2). Novamente, duas versões do algoritmo são comparadas: a) versão adaptativa, onde $\alpha = 0,4$ e $\beta = 0,9$; e b) versão estática (sem adaptação), onde $\alpha = 0$ e $\beta = 0$. Nesta comparação, defini-se três diferentes tamanhos de população (parâmetro $N_{Pop} = 40, 80$ ou 120), com todos os indivíduos inicializados de forma completamente aleatória. O número máximo de gerações permitido também foi fixado em $T_{max} = 120$.

Tabela 4.2: Comparação do AES-TEP com e sem adaptação de probabilidades – Grupo dos operadores evolutivos – Caso IEEE24 “N-0”.

α	β	N_{Pop}	IQ(%)	ITT(%)	TS(%)	$TM_S(s)$	$TM_C(s)$
0	0	50	93,71	70,15	42,0	5,978	6,789
0,4	0,9	50	96,51	71,64	58,0	5,976	6,720
0	0	100	98,06	74,90	72,0	12,24	13,45
0,4	0,9	100	98,30	75,95	72,0	11,63	13,32
0	0	150	98,33	76,38	73,0	18,18	20,23
0,4	0,9	150	99,40	77,59	87,0	17,22	20,01

Tabela 4.3: Comparação do AES-TEP com e sem adaptação de probabilidades – Grupo dos operadores especialistas – Caso IEEE24 “N-0”.

α	β	N_{Pop}	IQ(%)	ITT(%)	TS(%)	$TM_S(s)$	$TM_C(s)$
0	0	40	99,49	69,08	96,0	3,270	4,376
0,4	0,9	40	99,90	72,27	98,0	2,948	4,063
0	0	80	99,91	74,73	98,0	6,219	8,488
0,4	0,9	80	99,93	78,29	99,0	5,521	7,770
0	0	120	99,83	76,21	97,0	9,077	12,50
0,4	0,9	120	100,0	79,09	100	7,765	11,18

Nas Tabelas 4.2 e 4.3 pode-se notar que, para este caso de estudo, a utilização do mecanismo de adaptação de probabilidades com os parâmetros $\alpha = 0,4$ e $\beta = 0,9$ gerou melhoras no desempenho do algoritmo para todas as configurações testadas, reduzindo o tempo computacional e aumentando a qualidade das soluções encontradas. Como esperado, pode-se observar também que, com o aumento do tamanho da população, a qualidade das soluções tende a aumentar e, conseqüentemente, o algoritmo demanda maiores tempos computacionais. Além disso, comparando a Tabela 4.2 com a 4.3, fica evidente a superioridade do AES-TEP utilizando o grupo dos operadores especialistas: soluções de melhor qualidade a um custo computacional inferior.

O gráfico de convergência da Figura 4.2 apresenta uma comparação para duas versões do algoritmo: “Ops. Evol.”, que é o AES-TEP utilizando o grupo dos operadores evolutivos, onde $\alpha = 0,4$, $\beta = 0,9$ e $N_{Pop} = 100$; e “Ops. Exp.”, que é o AES-TEP utilizando o grupo dos operadores especialistas, onde $\alpha = 0,4$, $\beta = 0,9$ e $N_{Pop} = 80$. Neste gráfico, pode-se observar a superioridade dos operadores especialistas em relação aos operadores evolutivos, pois, mesmo com uma população menor, o algoritmo apresenta uma melhor eficiência na busca: converge com um menor número de gerações e com um erro médio menor.

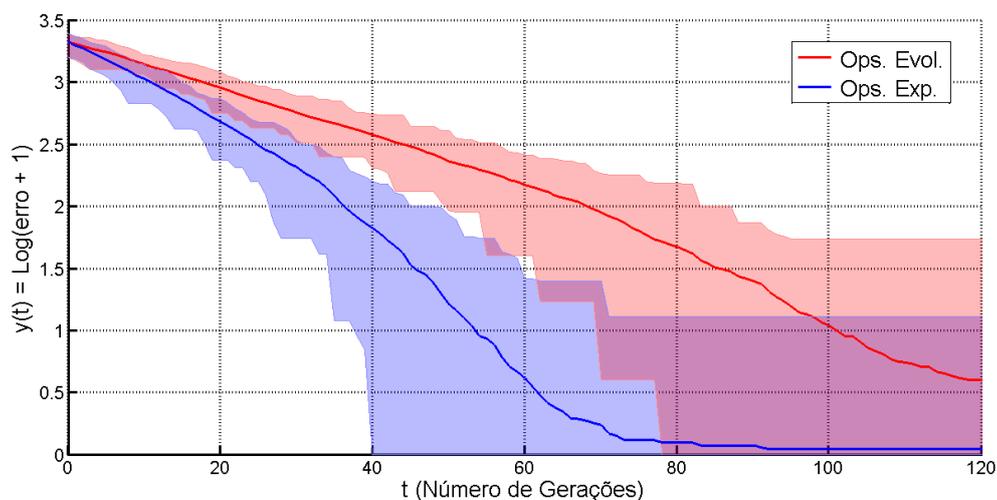


Figura 4.2: Gráfico de convergência comparando o grupo dos operadores evolutivos (Evol) com o grupo dos operadores especialistas (Exp) – Caso IEEE24 “N-0”.

A Tabela 4.4 apresenta os resultados obtidos com a aplicação de duas versões do algoritmo AES-TEP: a) “Evol”, que é a versão utilizando o grupo dos operadores evolutivos; e b) “Exp”, que é a versão utilizando o grupo dos operadores especialistas. Nestas versões, utiliza-se o seguinte conjunto de parâmetros: $\alpha = 0,4$, $\beta = 0,9$, $N_{Pop} = 80$ e $T_{max} = 120$. Na coluna “Rnd” tem-se a indicação do tipo de inicialização da população utilizado: 1) “100%” quando 100% dos indivíduos foram inicializados de forma aleatória; 2) “0%” quando 100% dos indivíduos foram inicializados pelo Algoritmo de Inicialização Inteligente (All - vide Seção 3.3.1); e 3) “50%” quando a inicialização é mista, ou seja, 50% dos indivíduos são aleatórios e 50% são gerados pelo All.

Pode-se observar na Tabela 4.4 que a utilização de indivíduos gerados pelo All (i.e., planos de expansão iniciais de melhor qualidade) proporciona ao algoritmo AES-TEP uma significativa redução do custo computacional, tanto para “E-

vol” como para “Exp”. Especificamente no caso da versão “Exp” com “Rnd = 0%”, apesar de o All reduzir a taxa de sucesso de 99 para 95%, o ganho em termos do custo computacional compensaria sua utilização: 67,5% de redução no tempo médio para uma execução de sucesso. Já no caso da versão “Evol” com “Rnd = 0%”, além da redução do tempo, o All melhora a qualidade das soluções encontradas.

Tabela 4.4: Comparação entre as inicializações 100% aleatória (“100%”), mista (“50%”) e 100% inteligente (“0%”) – Caso IEEE24 “N-0”.

Ops	Rnd	IQ(%)	ITT(%)	TS(%)	TM _s (s)	TM _c (s)
Evol	100%	98,04	73,98	78,0	9,307	10,72
Exp	100%	99,93	78,29	99,0	5,521	7,770
Evol	50%	91,42	69,98	40,0	2,761	3,877
Exp	50%	98,59	76,42	83,0	2,481	4,515
Evol	0%	98,53	77,30	83,0	2,292	4,061
Exp	0%	99,75	79,64	95,0	1,788	4,018

A Figura 4.3 apresenta um gráfico de convergência comparando as seis versões do algoritmo AES-TEP presentes na Tabela 4.4, tal que: “Ops” indica o uso dos operadores evolutivos (“Evol”) ou dos especialistas (“Exp”); e “Rnd” indica a porcentagem de indivíduos aleatórios na população inicial. Pode-se verificar neste gráfico que, apesar do All fazer com que o algoritmo gaste um menor número de gerações para obter um baixo valor para o erro médio, a qualidade das soluções finais (valor final para o erro médio) fica comprometida, principalmente para a versão “Exp”. Pode-se observar também que a utilização do All (tanto em “Rnd: 0%” com em “Rnd: 50%”) faz com que o algoritmo já inicie o processo evolutivo com um baixo erro médio.

Na Tabela 4.5 apresenta-se uma comparação entre versões AES-TEP com multioperadores e com um único operador reprodutivo: na coluna “Ops”, “Evol”, identifica a versão AES-TEP utilizando o grupo dos operadores evolutivos, onde $\alpha = 0,4$ e $\beta = 0,9$; “Exp” identifica a versão AES-TEP utilizando o grupo dos operadores especialistas, onde $\alpha = 0,4$ e $\beta = 0,9$; as outras versões do AES-TEP são versões estáticas ($\alpha = 0$ e $\beta = 0$) utilizando um único operador de reprodução (e.g., “LRX-UNM” é a versão AES-TEP utilizando apenas o operador

evolutivo LRX-UNM – vide Seção 2.3). Para todas estas versões utilizou-se: $N_{Pop} = 80$, $T_{max} = 120$, e inicialização da população com 100% dos indivíduos gerados de forma aleatória.

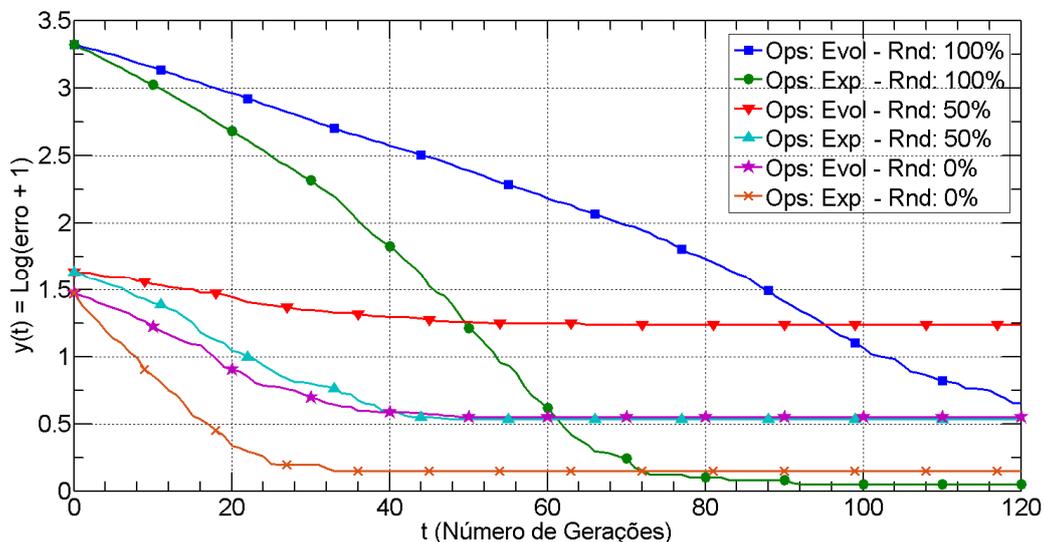


Figura 4.3: Gráfico de convergência comparando as inicializações 100% aleatória (“100%”), mista (“50%”) e 100% inteligente (“0%”) – Caso IEEE24 “N-0”.

Tabela 4.5: Comparação entre versões AES-TEP com multioperadores e com um único operador reprodutivo (estática) – Caso IEEE24 “N-0”.

Ops	α	β	IQ(%)	ITT(%)	TS(%)	TM _s (s)	TM _c (s)
Evol	0,4	0,9	98,04	73,98	78,0	9,307	10,72
Exp	0,4	0,9	99,93	78,29	99,0	5,521	7,770
LRX-UNM	0	0	34,58	28,11	0,00	-	10,11
SPX-UNM	0	0	95,25	62,29	73,0	8,951	10,27
SPX-SWM	0	0	97,06	59,98	78,0	8,312	9,530
UNX-SMC	0	0	91,85	73,85	11,0	8,523	10,48
SPX-RMA	0	0	100,0	78,69	100	4,587	6,823

Observa-se na Tabela 4.5 que a versão “LRX-UNM” foi a versão AES-TEP que apresentou o pior desempenho, obtendo taxa de sucesso nula (i.e., não encontrou a melhor solução conhecida para o problema em nenhuma das 100 execuções realizadas); já a versão estática “SPX-RMA” resultou no melhor desempenho para o algoritmo, encontrando melhores soluções a um custo computacional inferior. Comparando a versão “Exp” com a “SPX-RMA”, pode-se verificar que os desempenhos estão próximos. Estes resultados podem ser novamente verificados na Figura 4.4, onde um gráfico de convergência compara as

sete versões AES-TEP que foram apresentadas pela Tabela 4.5. Para este problema PET em questão (caso IEEE “N-0”), pode-se verificar que o operador “SPX-RMA” é o operador mais indicado para ser utilizado por um EA tradicional (algoritmo estático com um único operador de reprodução).

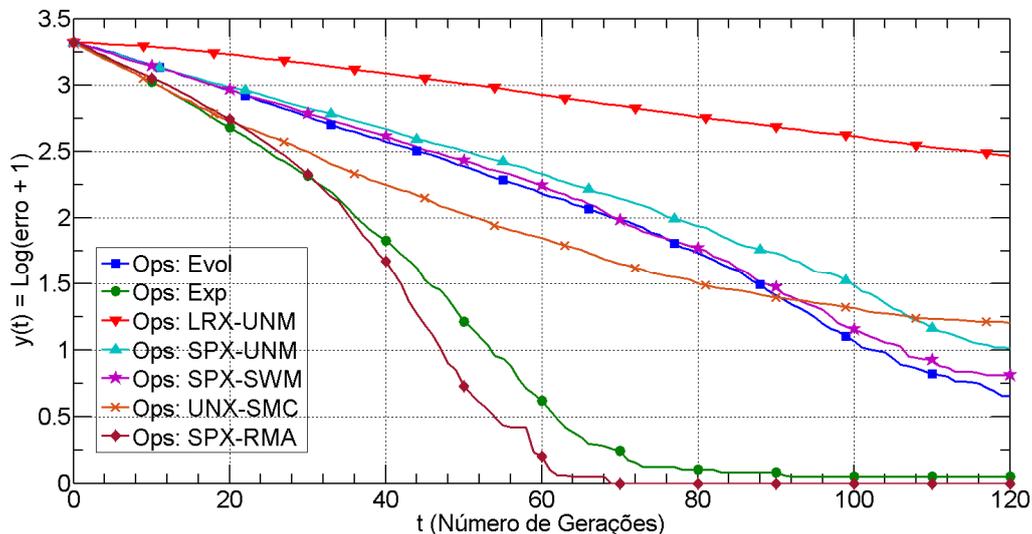


Figura 4.4: Gráfico de convergência comparando versões AES-TEP com multioperadores e com um único operador (estática) – Caso IEEE24 “N-0”.

4.3.2 Caso 2: IEEE24 “N-1” 0%

Neste caso, a modelagem do problema PET para o sistema IEEE24 considera as perdas ôhmicas dos equipamentos de transmissão e o tradicional critério de segurança “N-1” sem relaxamento ($sc_{max} = 0\%$ - vide Seção 3.2.2). As soluções para este problema devem minimizar o custo de investimento, satisfazendo simultaneamente a duas restrições: 1) corte de carga nulo para a rede intacta; e 2) sobrecarga nula para qualquer contingência simples. Para a rede intacta, permite-se o redespacho total dos geradores: para um dado plano candidato, realiza-se o redespacho dos geradores de modo a minimizar o custo operacional do sistema (despacho econômico); já no caso de contingência simples, permite-se o redespacho apenas da barra *swing*. Na tabela 4.6 estão listados os 10 melhores planos conhecidos para este caso: dado que estes planos possuem o mesmo custo de investimento, a ordenação foi feita em função do valor das perdas.

Tabela 4.6: Os 10 melhores planos conhecidos para o caso IEEE24 “N-1” 0%.

N.	Custo (10 ⁶ US\$)	Perdas (MW)	N.Refs	Planos de Expansão - Reforços Adicionados por Ramo (ID)												
				3	4	6	10	11	14	15	16	17	18	20	33	39
1	681	138,90	17	1	1	2	2	3		1		2		2	1	2
2	681	138,98	17	1	1	2	2	3		1	1	1	1	1	1	2
3	681	139,01	17	1	1	2	2	3	1			2	1	1	1	2
4	681	139,18	17	1	1	2	2	3	1		2		2		1	2
5	681	139,20	17	1	1	2	2	3	1		1	1	2		1	2
6	681	139,21	17	1	1	2	2	3		1	2		2		1	2
7	681	139,39	17	1	1	2	2	3	1		1	1	1	1	1	2
8	681	139,47	17	1	1	2	2	3		1	2		1	1	1	2
9	681	139,83	17	1	1	2	2	3		1	1	1		2	1	2
10	681	139,91	17	1	1	2	2	3	1			2		2	1	2

A Tabela 4.7 apresenta os resultados obtidos com a aplicação de quatro versões do algoritmo AES-TEP: na coluna “Ops”, “Evol” identifica versão utilizando o grupo dos operadores evolutivos, e “Exp” identifica versão utilizando o grupo dos operadores especialistas (i.e., Experts); nas colunas α e β tem-se, $\alpha = 0,25$ e $\beta = 0,5$ para versão adaptativa, ou $\alpha = 0$ e $\beta = 0$ para versão estática (sem adaptação das probabilidades). A fim de comparar o desempenho destas versões, dois diferentes tamanhos de população foram utilizados: $N_{Pop} = 100$ ou 200 , onde todos dos indivíduos foram inicializados de forma aleatória. Além disso, o número máximo de gerações permitido foi fixado em $T_{max} = 300$.

Tabela 4.7: Comparação entre versões AES-TEP utilizando operadores evolutivos (Evol) ou operadores especialistas (Exp) – Caso IEEE24 “N-1” 0%.

N_{Pop}	Ops	α	β	IQ(%)	ITT(%)	TS(%)	TM _s (s)	TM _c (s)
100	Evol	0	0	92,87	88,08	8,0	54,04	62,85
		0,25	0,5	93,35	89,21	4,0	54,91	61,22
	Exp	0	0	99,34	96,76	79	39,53	55,03
		0,25	0,5	99,80	97,99	94	30,82	49,60
200	Evol	0	0	93,67	89,49	6,0	115,6	125,4
		0,25	0,5	95,48	91,35	17	117,7	123,0
	Exp	0	0	99,83	98,09	91	70,36	108,3
		0,25	0,5	99,99	99,11	99	56,22	96,42

Pode-se observar na Tabela 4.7 que a versão AES-TEP utilizando os operadores especialistas (“Exp”) apresenta desempenho superior à versão utilizando os operadores evolutivos (“Evol”). Por exemplo, para a população $N_{Pop} = 200$, a

versão “Exp” apresentou um ganho de 82% na TS, gastando menos da metade do tempo para uma execução de sucesso. Pode-se observar ainda que, a utilização do mecanismo adaptativo proporciona ganho de desempenho ao algoritmo, melhorando a qualidade das soluções e/ou reduzindo o tempo computacional para convergência. Ademais, pode-se notar que o aumento do tamanho da população tende a aumentar a qualidade das soluções encontradas e, conseqüentemente, demanda maiores tempos computacionais.

O gráfico de convergência da Figura 4.5 apresenta uma comparação entre as versões adaptativas para “Evol” e “Exp”, utilizando os mesmos parâmetros de controle: $\alpha = 0,25$, $\beta = 0,50$, $N_{Pop} = 200$ e $T_{max} = 300$. Novamente, pode-se notar a superioridade do AES-TEP utilizando o grupo dos operadores especialistas (“Exp”): soluções de melhor qualidade com um menor número de gerações (custo computacional inferior).

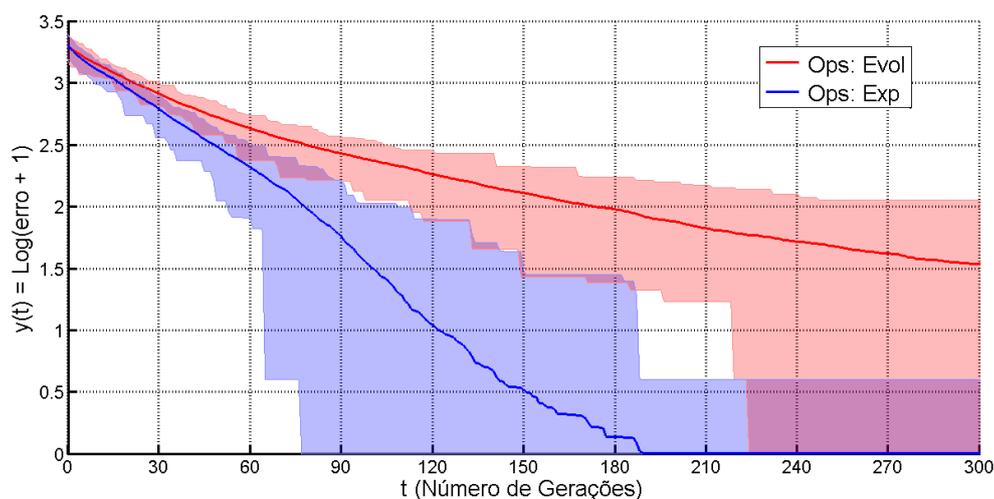


Figura 4.5: Gráfico de convergência comparando o grupo dos operadores evolutivos (Evol) com o grupo dos operadores especialistas (Exp) – Caso IEEE24 “N-1” 0%.

A Tabela 4.8 apresenta os resultados obtidos com a aplicação de duas versões do AES-TEP: 1) “Evol”, que é a versão utilizando o grupo dos operadores evolutivos; e 2) “Exp”, que é a versão utilizando o grupo dos operadores especialistas. Nestas versões, utiliza-se o seguinte conjunto de parâmetros: $\alpha = 0,25$, $\beta = 0,50$, $N_{Pop} = 100$ e $T_{max} = 300$. Na coluna “Rnd” tem-se a indicação do tipo de inicialização da população utilizado: 1) “100%”, quando 100% dos indivíduos foram inicializados de forma aleatória; 2) “0%”, quando 100% dos indivíduos

foram inicializados pelo All; e 3) “50%”, quando a inicialização é mista, ou seja, 50% dos indivíduos foram aleatórios e 50% foram criados pelo All.

Tabela 4.8: Comparação entre as inicializações 100% aleatória (“100%”), mista (“50%”) e 100% inteligente (“0%”) – Caso IEEE24 “N-1” 0%.

Ops	Rnd	IQ(%)	ITT(%)	TS(%)	TM _s (s)	TM _c (s)
Evol	100%	93,35	89,21	4,0	54,91	61,22
Exp	100%	99,80	97,99	94	30,82	49,60
Evol	50%	97,16	92,06	30	42,31	52,14
Exp	50%	99,77	96,94	94	29,87	47,46
Evol	0%	96,98	92,06	34	48,88	55,07
Exp	0%	99,92	96,89	96	31,24	48,46

O gráfico de convergência da Figura 4.6 também apresenta uma comparação para as seis versões do algoritmo AES-TEP presentes na Tabela 4.8: “Ops” indica o uso dos operadores evolutivos (“Evol”) ou dos especialistas (“Exp”); e “Rnd” indica a porcentagem de indivíduos aleatórios na população inicial. Na Tabela 4.8 e na Figura 4.6 pode-se observar que as versões AES-TEP utilizando os operadores especialistas (“Exp”) foram as três melhores configurações para o algoritmo, onde a versão com inicialização 100% inteligente (“Rnd: 0%”) apresentou o melhor resultado em termos da *TS* e do *IQ*. Pode-se observar também que para a versão “Evol”, o All resulta em significativas melhoras no desempenho do algoritmo, seja para a inicialização mista ou 100% inteligente.

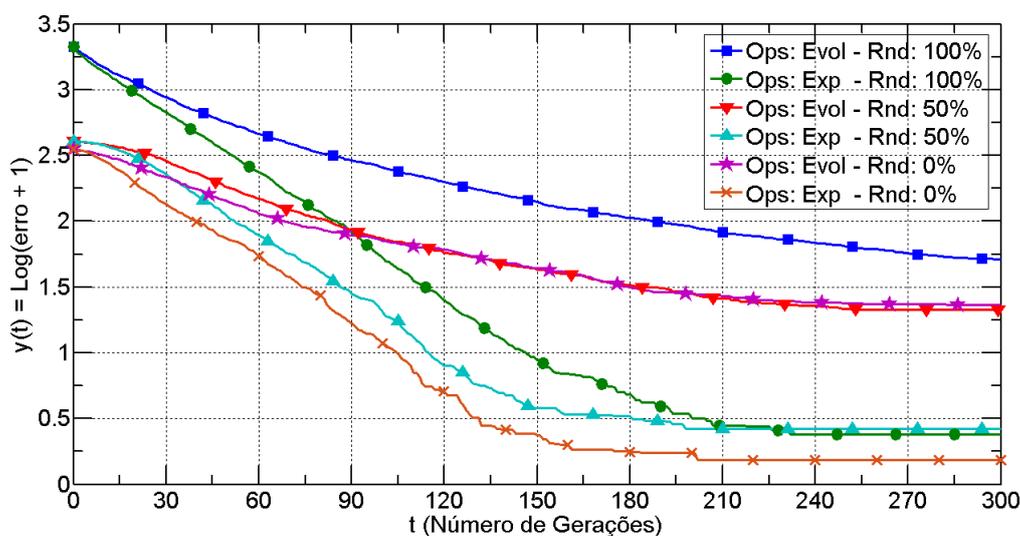


Figura 4.6: Gráfico de convergência comparando as inicializações 100% aleatória (“100%”), mista (“50%”) e 100% inteligente (“0%”) – Caso IEEE24 “N-1” 0%.

Na Tabela 4.9 apresenta-se uma comparação entre versões AES-TEP com multioperadores e com um único operador reprodutivo: na coluna “Ops”, “Evol” identifica a versão AES-TEP utilizando o grupo dos operadores evolutivos, com $\alpha = 0,25$ e $\beta = 0,50$; “Exp” identifica a versão AES-TEP utilizando o grupo dos operadores especialistas, com $\alpha = 0,25$ e $\beta = 0,50$; as outras versões do AES-TEP são versões estáticas ($\alpha = 0$ e $\beta = 0$) utilizando um único operador de reprodução (evolutivo ou especialista). Para todas estas versões utilizou-se: $N_{Pop} = 100$, $T_{max} = 300$, e inicialização aleatória dos indivíduos.

Tabela 4.9: Comparação entre versões AES-TEP com multioperadores e com um único operador reprodutivo (estática) – Caso IEEE24 “N-1” 0%.

Ops	α	β	IQ(%)	ITT(%)	TS(%)	TM _S (s)	TM _C (s)
Evol	0,25	0,5	93,35	89,21	4,0	54,91	61,22
Exp	0,25	0,5	99,80	97,99	94	30,82	49,60
LRX-UNM	0	0	77,00	70,06	0,0	–	57,55
SPX-UNM	0	0	93,60	89,06	15	49,91	61,79
SPX-SWM	0	0	92,86	88,44	14	51,62	62,94
UNX-SMC	0	0	91,62	87,27	0,0	–	58,18
SPX-RMA	0	0	98,92	96,54	72	32,01	49,05

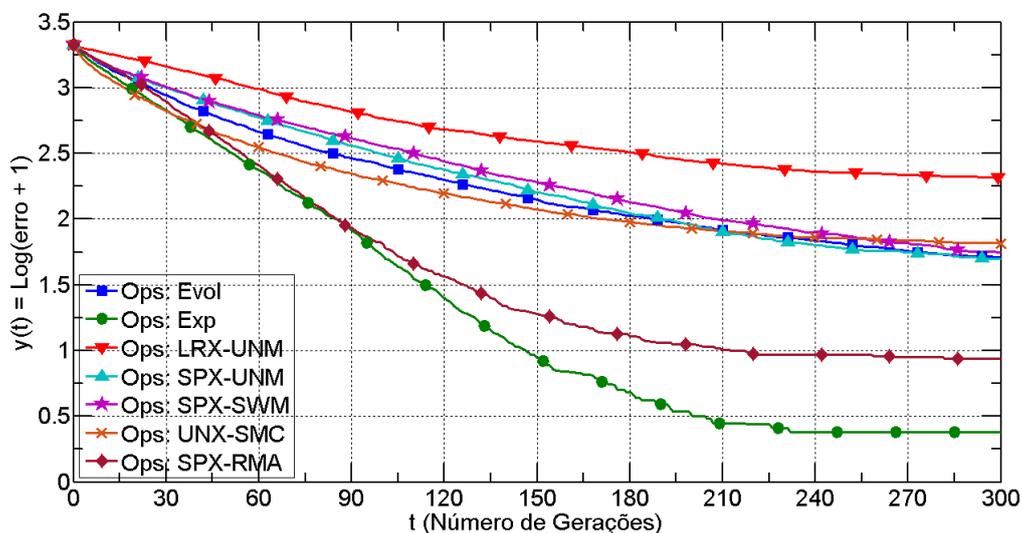


Figura 4.7: Gráfico de convergência comparando versões AES-TEP com multioperadores e com um único operador (estática) – Caso IEEE24 “N-1” 0%.

Observa-se na Tabela 4.9 que a versão “LRX-UNM” representa a versão AES-TEP que mostrou o pior desempenho, obtendo taxa de sucesso nula; já a versão “Exp” resultou no melhor desempenho do algoritmo, indicando assim que existe vantagem em se utilizar multioperadores em um único EA (no caso dos

operadores especialistas). Dentre as versões estáticas (com um único operador), a versão “SPX-RMA” foi a melhor: para este problema PET em questão, pode-se dizer que o operador “SPX-RMA” é o operador mais indicado para ser utilizado por um EA tradicional. Estes resultados podem ser novamente verificados na Figura 4.7, onde um gráfico de convergência compara as sete versões AES-TEP presentes na Tabela 4.9.

4.3.3 Caso 3: IEEE24 “N-1” 10%

Neste caso, a modelagem do problema PET para o sistema IEEE24 considera as perdas ôhmicas dos equipamentos de transmissão e o critério de segurança “N-1” relaxado a 10% ($sc_{max} = 10\%$). As soluções para este problema devem minimizar o custo de investimento, satisfazendo simultaneamente duas restrições: 1) corte de carga nulo para a rede intacta; e 2) sobrecarga de até 10% para qualquer contingência simples. Para a rede intacta, permite-se o redespacho total dos geradores: para um dado plano candidato, realiza-se o redespacho dos geradores de modo a minimizar o custo operacional do sistema (despacho econômico); já no caso de contingência simples, permite-se o redespacho apenas da barra *swing*. Na tabela 4.10 estão listados os 10 melhores planos conhecidos para este caso, ordenados pelo custo de investimento; planos com o mesmo custo são ordenados pelo valor das perdas.

Tabela 4.10: Os 10 melhores planos conhecidos para o caso IEEE24 “N-1” 10%.

N.	Custo (10 ⁶ US\$)	Perdas (MW)	N.Refs	Planos de Expansão - Reforços Adicionados por Ramo (ID)																					
				3	4	6	7	8	9	10	11	14	15	16	17	18	20	21	23	26	32	33	38	39	41
1	551	148,50	14	1	1		1			2	3			1		1				1		1	1	1	
2	589	158,77	15	1	1	2				2	3			1		1	1		1				1	1	
3	591	154,40	16	1	1	2	1			2	3			1		1		1					1	1	1
4	591	158,31	16		1	1			1	2	3			2	1	1							2	1	1
5	594	155,04	16		2	1	1		1	2	3				2		1						1	1	1
6	596	165,00	16	2		1	1	1		2	3			1		1				1		1	1	1	1
7	597	165,07	17	2		1	1	1		2	3			1		1				1	1	2	1		
8	598	150,27	16	2		1	1	1		2	3			1		1				1		1	1	1	1
9	599	150,40	16	1	1	2				2	3	1		1		2			1			1		1	
10	599	150,68	16	1	1	2				2	3			1	1		1	1		1		1		1	1

A Tabela 4.11 apresenta os resultados obtidos com a aplicação de quatro versões do algoritmo AES-TEP: na coluna “Ops”, “Evol” identifica versão utilizando o grupo dos operadores evolutivos, e “Exp” identifica versão utilizando o grupo

dos operadores especialistas; nas colunas α e β , tem-se $\alpha = 0,25$ e $\beta = 0,5$ para versão adaptativa, ou $\alpha = 0$ e $\beta = 0$ para versão estática (sem adaptação das probabilidades). A fim de comparar o desempenho destas versões, dois diferentes tamanhos de população foram utilizados: $N_{Pop} = 100$ ou 200 , onde todos dos indivíduos foram inicializados de forma aleatória. O número máximo de gerações permitido foi fixado em $T_{max} = 300$.

Tabela 4.11: Comparação entre versões AES-TEP utilizando operadores evolutivos (Evol) ou operadores especialistas (Exp) – Caso IEEE24 “N-1” 10%.

N_{Pop}	Ops	α	β	IQ(%)	ITT(%)	TS(%)	TM _s (s)	TM _c (s)
100	Evol	0	0	92,38	86,21	40	50,31	61,03
		0,25	0,5	93,95	87,59	54	48,59	59,49
	Exp	0	0	98,85	91,53	85	38,02	54,04
		0,25	0,5	99,26	91,86	99	27,47	45,11
200	Evol	0	0	95,23	88,54	46	105,4	123,8
		0,25	0,5	96,47	89,63	65	96,15	119,7
	Exp	0	0	99,55	92,11	90	71,41	103,3
		0,25	0,5	99,79	92,43	99	53,13	88,00

Pode-se observar na Tabela 4.11 que a versão AES-TEP utilizando os operadores especialistas (“Exp”) apresenta desempenho superior à versão utilizando os operadores evolutivos (“Evol”). Por exemplo, para a população $N_{Pop} = 200$, a versão “Exp” apresentou um ganho de 34% na TS, com uma redução de 45% no TM_s. Pode-se observar ainda que, para todas as versões testadas, a utilização do mecanismo adaptativo proporciona ganho de desempenho ao algoritmo, melhorando a qualidade das soluções e reduzindo o custo computacional do algoritmo. Ademais, pode-se notar que o aumento do tamanho da população tende a aumentar a qualidade das soluções encontradas e, conseqüentemente, demanda maiores tempos computacionais.

O gráfico de convergência da Figura 4.8 apresenta uma comparação entre as versões adaptativas para “Evol” e “Exp”, utilizando os mesmos parâmetros de controle: $\alpha = 0,25$, $\beta = 0,50$, $N_{Pop} = 200$ e $T_{max} = 300$. Novamente, pode-se notar a superioridade do AES-TEP utilizando o grupo dos operadores especialis-

tas (“Exp”): soluções de melhor qualidade com um menor número de gerações (custo computacional inferior).

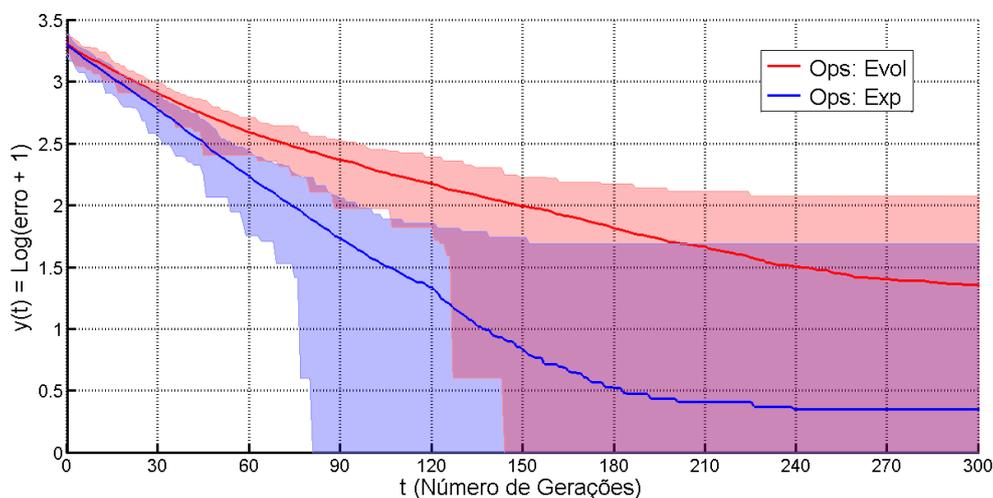


Figura 4.8: Gráfico de convergência comparando o grupo dos operadores evolutivos (Evol) com o grupo dos operadores especialistas (Exp) – Caso IEEE24 “N-1” 10%.

A Tabela 4.12 apresenta os resultados obtidos com a aplicação de duas versões do AES-TEP: 1) “Evol”, que é a versão utilizando o grupo dos operadores evolutivos; e 2) “Exp”, que é a versão utilizando o grupo dos operadores especialistas. Nestas versões, utiliza-se o seguinte conjunto de parâmetros: $\alpha = 0,25$, $\beta = 0,50$, $N_{Pop} = 100$ e $T_{max} = 300$. Na coluna “Rnd” tem-se a indicação do tipo de inicialização da população utilizado: 1) “100%”, quando 100% dos indivíduos foram inicializados de forma aleatória; 2) “0%”, quando 100% dos indivíduos foram inicializados pelo All; e 3) “50%”, quando a inicialização é mista, ou seja, 50% dos indivíduos foram aleatórios e 50% foram criados pelo All.

Tabela 4.12: Comparação entre as inicializações 100% aleatória (“100%”), mista (“50%”) e 100% inteligente (“0%”) – Caso IEEE24 “N-1” 10%.

Ops	Rnd	IQ(%)	ITT(%)	TS(%)	TM _s (s)	TM _c (s)
Evol	100%	93,95	87,59	54	48,59	59,49
Exp	100%	99,26	91,86	99	27,47	45,11
Evol	50%	99,92	90,93	98	29,14	41,55
Exp	50%	99,86	91,59	99	22,46	36,64
Evol	0%	99,88	90,91	98	29,43	42,02
Exp	0%	99,94	91,63	98	23,73	37,81

O gráfico de convergência da Figura 4.9 também apresenta uma comparação para as seis versões do algoritmo AES-TEP presentes na Tabela 4.12: “Ops” indica o uso dos operadores evolutivos (“Evol”) ou dos especialistas (“Exp”); e “Rnd” indica a porcentagem de indivíduos aleatórios na população inicial. Na Tabela 4.12 e na Figura 4.9 pode-se observar que as versões AES-TEP que fazem uso do All (“Rnd = 50%” ou “Rnd = 0%”) obtiveram os melhores resultados: melhores soluções e redução do custo computacional. A versão “Exp” com “Rnd = 50%” se destacou com a melhor dentre as testadas. Pode-se observar também que, especificamente para a versão “Evol”, a utilização do All resulta em significativas melhoras no desempenho do algoritmo.

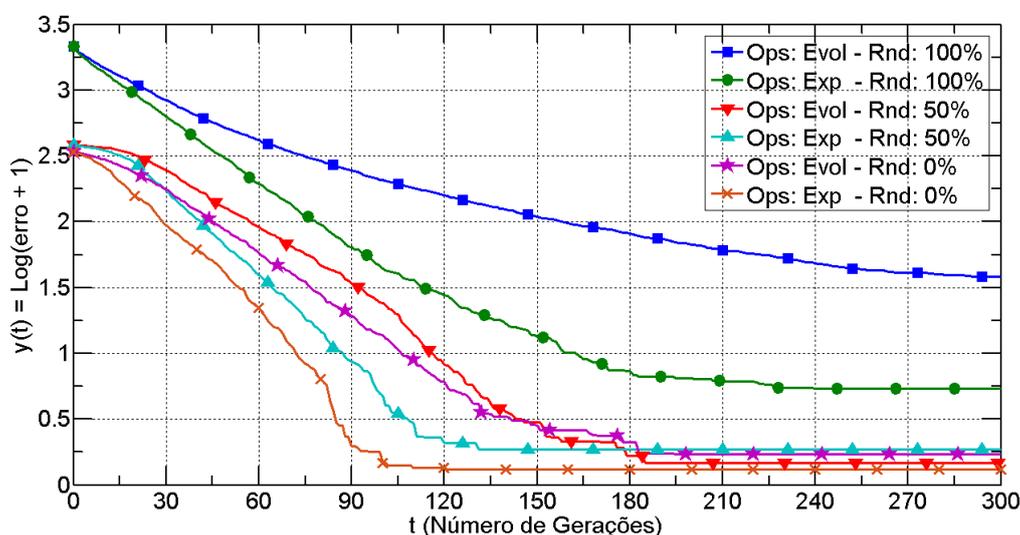


Figura 4.9: Gráfico de convergência comparando as inicializações 100% aleatória (“100%”), mista (“50%”) e 100% inteligente (“0%”) – Caso IEEE24 “N-1” 10%.

Na Tabela 4.13 apresenta-se uma comparação entre versões AES-TEP com multioperadores e com um único operador reprodutivo: na coluna “Ops”, “Evol” identifica a versão AES-TEP utilizando o grupo dos operadores evolutivos, com $\alpha = 0,25$ e $\beta = 0,50$; “Exp” identifica a versão AES-TEP utilizando o grupo dos operadores especialistas, com $\alpha = 0,25$ e $\beta = 0,50$; as outras versões do AES-TEP são versões estáticas ($\alpha = 0$ e $\beta = 0$) utilizando um único operador de reprodução (evolutivo ou especialista). Em todas estas versões, utilizou-se: $N_{Pop} = 100$, $T_{max} = 300$, e inicialização aleatória dos indivíduos.

Tabela 4.13: Comparação entre versões AES-TEP com multioperadores e com um único operador reprodutivo (estática) – Caso IEEE24 “N-1” 10%.

Ops	α	β	IQ(%)	ITT(%)	TS(%)	TM _s (s)	TM _c (s)
Evol	0,25	0,5	93,95	87,59	54	48,59	59,49
Exp	0,25	0,5	99,26	91,86	99	27,47	45,11
LRX-UNM	0	0	78,89	73,17	0,0	–	56,95
SPX-UNM	0	0	87,66	83,27	32	46,14	57,84
SPX-SWM	0	0	90,52	85,30	43	46,87	60,48
UNX-SMC	0	0	91,58	85,99	3,0	53,58	56,58
SPX-RMA	0	0	96,59	90,53	93	27,96	47,09

Observa-se na Tabela 4.13 que a versão “LRX-UNM” foi a versão AES-TEP que apresentou o pior desempenho, obtendo taxa de sucesso nula; já a versão “Exp” resultou no melhor desempenho do algoritmo, indicando assim que existe vantagem em se utilizar multioperadores em um único EA (no caso dos operadores especialistas). Dentre as versões estáticas (com um único operador), a versão “SPX-RMA” foi a melhor: para este problema PET em questão, pode-se dizer que o operador “SPX-RMA” é o operador mais indicado para ser utilizado por um EA tradicional. Estes resultados podem ser novamente verificados na Figura 4.10, onde um gráfico de convergência compara as sete versões AES-TEP presentes na Tabela 4.13.

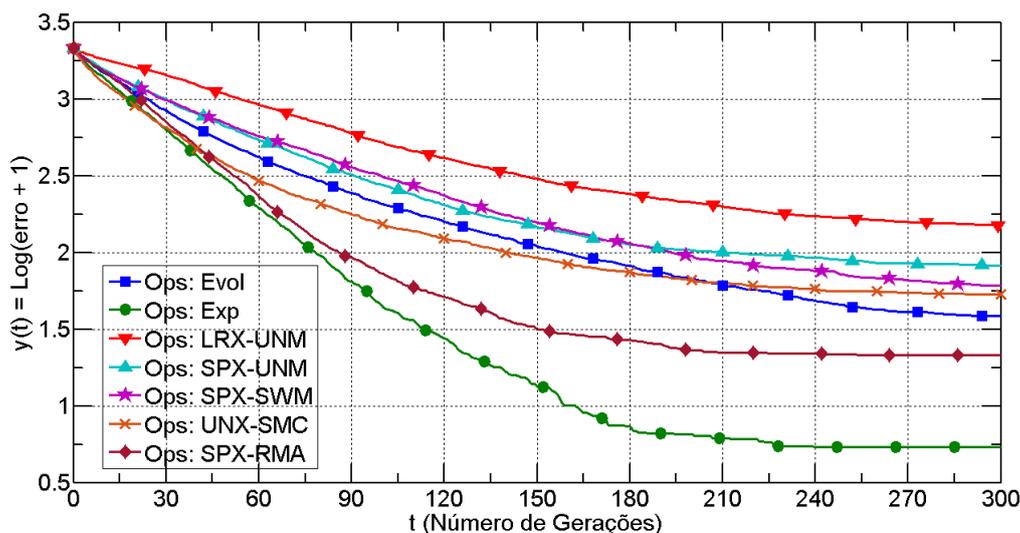


Figura 4.10: Gráfico de convergência comparando versões AES-TEP com multioperadores e com um único operador (estática) – Caso IEEE24 “N-1” 10%.

4.3.4 Caso 4: IEEE24 “N-1” 20%

Neste caso, a modelagem do problema PET para o sistema IEEE24 considera as perdas ôhmicas dos equipamentos de transmissão e o critério de segurança “N-1” relaxado a 20% ($sc_{max} = 20\%$). As soluções para este problema devem minimizar o custo de investimento, satisfazendo simultaneamente duas restrições: 1) corte de carga nulo para a rede intacta; e 2) sobrecarga de até 20% para qualquer contingência simples. Para a rede intacta, permite-se o redespacho total dos geradores: para um dado plano candidato, realiza-se o redespacho dos geradores de modo a minimizar o custo operacional do sistema (despacho econômico); já no caso de contingência simples, permite-se o redespacho apenas da barra swing. Na tabela 4.14 estão listados os 10 melhores planos conhecidos para este caso, ordenados pelo custo de investimento; planos com o mesmo custo são ordenados pelo valor das perdas.

Tabela 4.14: Os 10 melhores planos conhecidos para o caso IEEE24 “N-1” 20%.

N.	Custo (10 ⁶ US\$)	Perdas (MW)	N.Refs	Planos de Expansão - Reforços Adicionados por Ramo (ID)																
				3	4	6	7	8	9	10	11	15	16	17	18	21	33	38	39	
1	461	162,31	13		1	1				1	2	3		1		1		1	1	1
2	486	170,56	13	1		1		1		2	3	1		1		1	1	1		1
3	490	172,56	13	1		1		1		2	3	1		1	1	1	1			
4	492	160,96	14	1		1	1	1		2	3	1	1		1		1			1
5	492	167,41	13	1	1	1				2	3	1		1		1	1	1	1	
6	493	156,32	14	1	2	1				2	3		1		1		1	1	1	1
7	496	169,52	13	1	1	1				2	3	1		1	1	1	1	1		
8	498	157,37	14	1	1	1	1			2	3		1	1	1	1		1		1
9	498	157,61	14	1	1	1	1			2	3	1	1		1		1			1
10	499	160,90	14		1	1	1		1	2	3		1	1	1		1			1

A Tabela 4.15 apresenta os resultados obtidos com a aplicação de quatro versões do algoritmo AES-TEP: na coluna “Ops”, “Evol” identifica versão utilizando o grupo dos operadores evolutivos, e “Exp” identifica versão utilizando o grupo dos operadores especialistas; nas colunas α e β tem-se, $\alpha = 0,25$ e $\beta = 0,5$ para versão adaptativa, ou $\alpha = 0$ e $\beta = 0$ para versão estática (sem adaptação das probabilidades). A fim de comparar o desempenho destas versões, dois diferentes tamanhos de população foram utilizados: $N_{Pop} = 100$ ou 200 , onde todos dos indivíduos foram inicializados de forma aleatória. Além disso, o número máximo de gerações permitido foi fixado em $T_{max} = 300$.

Tabela 4.15: Comparação entre versões AES-TEP utilizando operadores evolutivos (Evol) ou operadores especialistas (Exp) – Caso IEEE24 “N-1” 20%.

N_{Pop}	Ops	α	β	IQ(%)	ITT(%)	TS(%)	$TM_s(s)$	$TM_c(s)$
100	Evol	0	0	90,07	85,34	35	50,90	60,50
		0,25	0,5	91,18	86,65	37	46,57	57,61
	Exp	0	0	95,52	91,89	87	30,50	52,14
		0,25	0,5	96,82	92,63	95	26,08	47,61
200	Evol	0	0	92,85	87,58	44	110,2	124,2
		0,25	0,5	92,80	88,27	49	98,10	117,1
	Exp	0	0	95,71	92,45	87	60,87	99,45
		0,25	0,5	97,36	93,16	97	47,30	96,58

Pode-se observar na Tabela 4.15 que a versão AES-TEP utilizando os operadores especialistas (“Exp”) apresenta desempenho superior à versão utilizando os operadores evolutivos (“Evol”). Por exemplo, para a população $N_{Pop} = 200$, a versão “Exp” apresentou um ganho de 48% na TS, gastando menos da metade do tempo para uma execução de sucesso. Pode-se observar ainda que, a utilização do mecanismo adaptativo proporciona ganho de desempenho ao algoritmo, melhorando a qualidade das soluções e reduzindo o custo computacional. Ademais, pode-se notar que o aumento do tamanho da população tende a aumentar a qualidade das soluções encontradas e, conseqüentemente, demanda maiores tempos computacionais.

O gráfico de convergência da Figura 4.11 apresenta uma comparação entre as versões adaptativas para “Evol” e “Exp”, utilizando os mesmos parâmetros de controle: $\alpha = 0,25$, $\beta = 0,50$, $N_{Pop} = 200$ e $T_{max} = 300$. Novamente, pode-se observar a superioridade do AES-TEP utilizando o grupo dos operadores especialistas (“Exp”): soluções de melhor qualidade com um menor número de gerações (custo computacional inferior).

A Tabela 4.16 apresenta os resultados obtidos com a aplicação de duas versões do AES-TEP: 1) “Evol”, que é a versão utilizando o grupo dos operadores evolutivos; e 2) “Exp”, que é a versão utilizando o grupo dos operadores especialistas. Nestas versões, utiliza-se o seguinte conjunto de parâmetros: $\alpha = 0,25$, $\beta = 0,50$, $N_{Pop} = 100$ e $T_{max} = 300$. Na coluna “Rnd” tem-se a indicação do

tipo de inicialização da população utilizado: 1) “100%”, quando 100% dos indivíduos foram inicializados de forma aleatória; 2) “0%”, quando 100% dos indivíduos foram inicializados pelo All; e 3) “50%”, quando a inicialização é mista, ou seja, 50% dos indivíduos foram aleatórios e 50% foram criados pelo All.

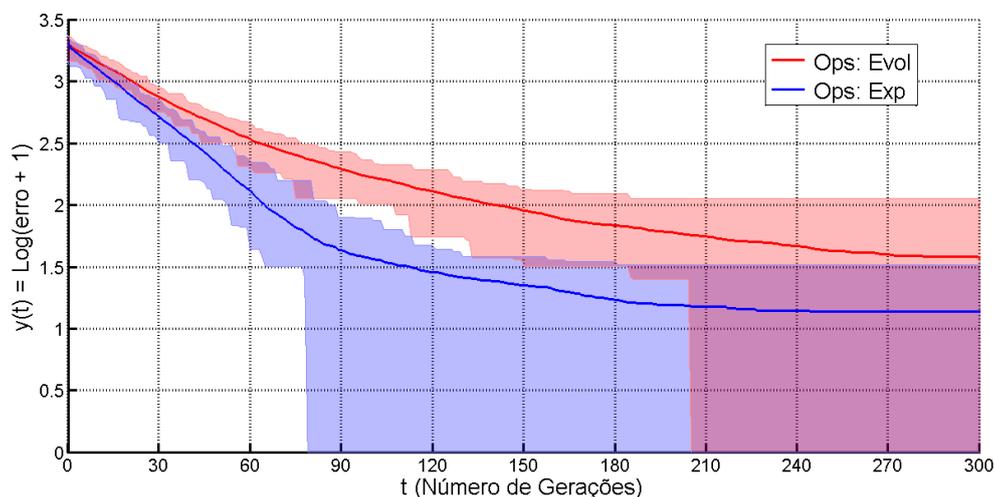


Figura 4.11: Gráfico de convergência comparando o grupo dos operadores evolutivos (Evol) com o grupo dos operadores especialistas (Exp) – Caso IEEE24 “N-1” 20%.

Tabela 4.16: Comparação entre as inicializações 100% aleatória (“100%”), mista (“50%”) e 100% inteligente (“0%”) – Caso IEEE24 “N-1” 20%.

Ops	Rnd	IQ(%)	ITT(%)	TS(%)	TM _s (s)	TM _c (s)
Evol	100%	91,18	86,65	37,0	46,57	57,61
Exp	100%	96,82	92,63	95,0	26,08	47,61
Evol	50%	93,80	90,48	97,0	25,24	42,06
Exp	50%	94,93	92,07	99,0	18,76	41,14
Evol	0%	93,80	90,61	100	26,58	44,66
Exp	0%	94,66	91,96	100	20,26	44,11

O gráfico de convergência da Figura 4.12 também apresenta uma comparação para as seis versões do algoritmo AES-TEP presentes na Tabela 4.16: “Ops” indica o uso dos operadores evolutivos (“Evol”) ou dos especialistas (“Exp”); e “Rnd” indica a porcentagem de indivíduos aleatórios na população inicial. Na Tabela 4.16 e na Figura 4.12 pode-se observar que a versão “Ops: Exp - Rnd: 100%” obteve o melhor valor para o IQ: maior capacidade de busca pelo ótimo global. A grande vantagem da utilização do All é a redução do custo computacional, principalmente no caso “Rnd: 50%”: a versão “Ops: Exp - Rnd: 50%” foi

a que apresentou o melhor desempenho computacional. Pode-se observar também que, para a versão “Evol”, o All resulta em significativas melhoras no desempenho do algoritmo, seja para “Rnd: 50%” ou “Rnd: 0%”.

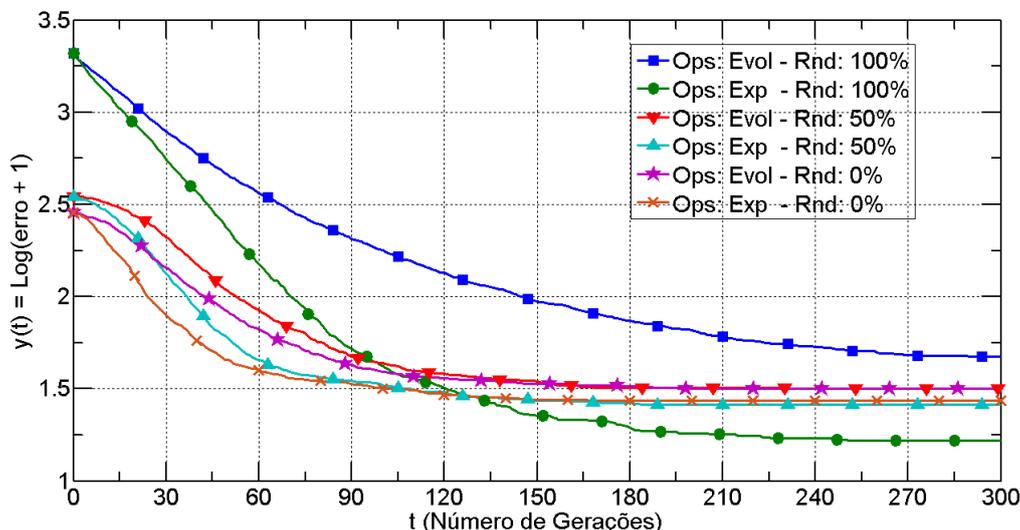


Figura 4.12: Gráfico de convergência comparando as inicializações 100% aleatória (“100%”), mista (“50%”) e 100% inteligente (“0%”) – Caso IEEE24 “N-1” 20%.

Na Tabela 4.17 apresenta-se uma comparação entre versões AES-TEP com multioperadores e com um único operador reprodutivo: na coluna “Ops”, “Evol” identifica a versão AES-TEP utilizando o grupo dos operadores evolutivos, com $\alpha = 0,25$ e $\beta = 0,50$; “Exp” identifica a versão AES-TEP utilizando o grupo dos operadores especialistas, com $\alpha = 0,25$ e $\beta = 0,50$; as outras versões do AES-TEP são versões estáticas ($\alpha = 0$ e $\beta = 0$) utilizando um único operador de reprodução (evolutivo ou especialista). Para todas estas versões utilizou-se: $N_{Pop} = 100$, $T_{max} = 300$, e inicialização aleatória dos indivíduos.

Tabela 4.17: Comparação entre versões AES-TEP com multioperadores e com um único operador reprodutivo (estática) – Caso IEEE24 “N-1” 20%.

Ops	α	β	IQ(%)	ITT(%)	TS(%)	TM _s (s)	TM _c (s)
Evol	0,25	0,5	91,18	86,65	37	46,57	57,61
Exp	0,25	0,5	96,82	92,63	95	26,08	47,61
LRX-UNM	0	0	81,54	74,57	2,0	54,85	56,56
SPX-UNM	0	0	89,15	83,88	38	43,96	55,75
SPX-SWM	0	0	91,16	86,23	45	47,12	57,74
UNX-SMC	0	0	90,62	86,18	17	50,47	56,63
SPX-RMA	0	0	94,53	90,72	94	24,86	43,56

Observa-se na Tabela 4.17 que a versão “LRX-UNM” foi a versão AES-TEP que apresentou o pior desempenho, obtendo taxa de sucesso nula; já a versão “Exp” resultou no melhor desempenho do algoritmo, indicando assim que existe vantagem em se utilizar multioperadores em um único EA (no caso dos operadores especialistas). Dentre as versões estáticas (com um único operador), a versão “SPX-RMA” foi a melhor, com resultado muito próximo da versão “Exp”; para este problema PET em questão, pode-se dizer que o operador “SPX-RMA” é o operador mais indicado para ser utilizado por um EA tradicional. Estes resultados podem ser novamente verificados na Figura 4.13, onde um gráfico de convergência compara as sete versões presentes na Tabela 4.17.

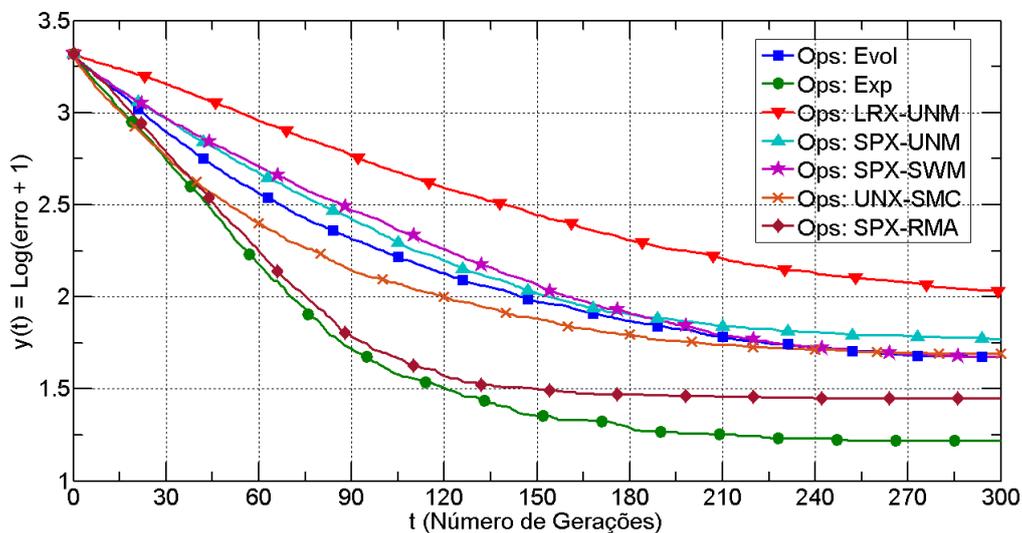


Figura 4.13: Gráfico de convergência comparando versões AES-TEP com multioperadores e com um único operador (estática) – Caso IEEE24 “N-1” 20%.

4.4 SISTEMA SUL BRASILEIRO

O sistema de transmissão Sul Brasileiro (SBR – configuração da década de 1980 e planejamento para 1990) [RMGH02], o qual está representado pelo diagrama unifilar da Figura 4.14, possui em seu horizonte futuro uma previsão de demanda total de 6.880 MW e capacidade máxima de geração de 10.545 MW. Este sistema é composto de 46 barras e 79 ramos candidatos à expansão (47 ramos existentes na topologia original e mais 32 ramos novos). Independentemente dos equipamentos existentes na topologia original (linhas ou transformadores), cada um dos 79 ramos candidatos pode receber, no máximo, até

três reforços. Todos os dados utilizados nas simulações deste sistema estão listados no Apêndice A.2.

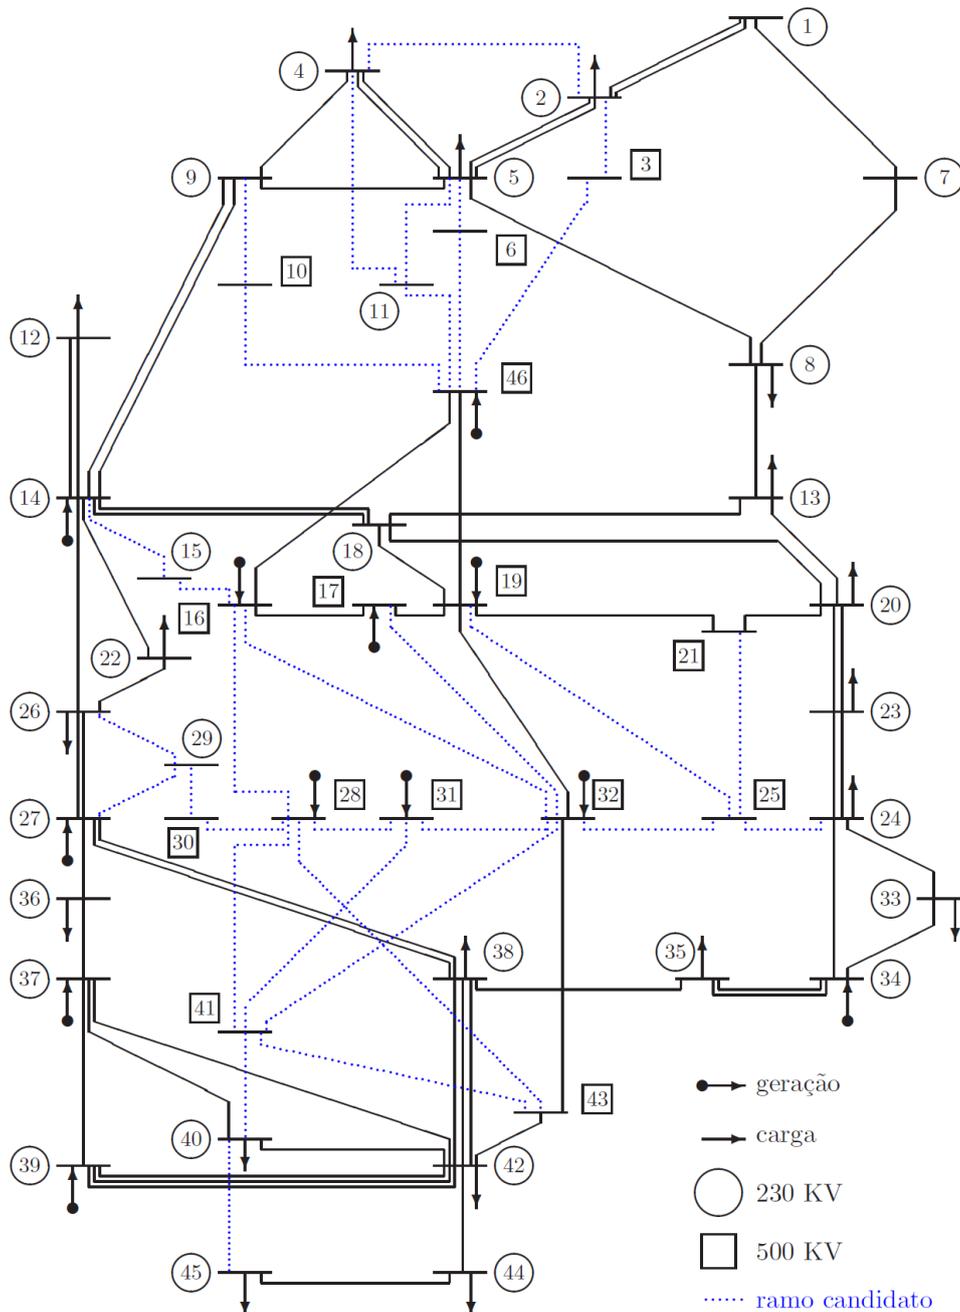


Figura 4.14: Diagrama unifilar para o sistema SBR – topologia original.

4.4.1 Caso 5: SBR “N-0”

Neste caso, o planejamento da expansão do sistema SBR não considera em sua modelagem as perdas ôhmicas dos equipamentos de transmissão, nem considera qualquer critério de segurança. Desta forma, as soluções para o problema PET devem minimizar o custo de investimento, satisfazendo apenas a

restrição de corte de carga nulo para a rede intacta. Para tanto, permite-se o redespacho total dos geradores: para um dado plano de expansão candidato, realiza-se o redespacho dos geradores de modo a minimizar o custo operacional do sistema (despacho econômico – vide Seção 3.2). Na Tabela 4.18 estão listados os 10 melhores planos conhecidos para este caso, ordenados pelo custo de investimento.

Tabela 4.18: Os 10 melhores planos conhecidos para o caso SBR “N-0”.

N.	Custo (10 ⁶ US\$)	Perdas (MW)	N.Refs	Planos de Expansão - Reforços Adicionados por Ramo (ID)													
				5	6	8	13	14	15	22	27	46	47	52	53	73	78
1	72,870	0,0	9			1		1		1		2	1		1		2
2	74,733	0,0	8				1			1		2	1		1		2
3	75,895	0,0	8						1	1		2	1		1		2
4	77,112	0,0	9		1			1		1		2	1		1		2
5	77,415	0,0	9					2		1		2	1		1		2
6	77,769	0,0	9	1				1		1		2	1		1		2
7	78,391	0,0	10						1	1		2	1	3			2
8	78,467	0,0	9					1		1		2	1		1		3
9	78,467	0,0	9					1		1		3	1		1		2
10	78,577	0,0	9					1		1	1	2	1		1		2

A Tabela 4.19 apresenta os resultados obtidos com a aplicação do algoritmo AES-TEP utilizando o grupo dos operadores evolutivos (“Evol”): todos os 12 operadores evolutivos definidos pela Seção 2.3. Nesta tabela, duas versões do algoritmo são comparadas: 1) versão adaptativa, onde $\alpha = 0,2$ e $\beta = 0,9$; e 2) versão estática, onde $\alpha = 0$ e $\beta = 0$ (não tem adaptação das probabilidades). Esta comparação é feita para três diferentes tamanhos de população (parâmetro $N_{Pop} = 120, 200$ ou 280), nas quais todos os indivíduos foram inicializados de forma aleatória; o número máximo de gerações permitido para este caso foi fixado em $T_{max} = 250$.

Semelhantemente à Tabela 4.19, na Tabela 4.20 apresenta-se os resultados obtidos com a aplicação do algoritmo AES-TEP utilizando o grupo dos operadores especialistas (“Exp” - todos os oito operadores especialistas definidos pela Seção 3.3.2). Novamente, duas versões do algoritmo são comparadas: 1) versão adaptativa, onde $\alpha = 0,2$ e $\beta = 0,9$; e 2) versão estática, onde $\alpha = 0$ e $\beta = 0$ (sem adaptação). Para esta comparação, defini-se três diferentes tamanhos

para a população (parâmetro $N_{Pop} = 80, 160$ ou 240), nas quais 100% dos indivíduos foram inicializados de forma aleatória. O número máximo de gerações permitido também foi fixado em $T_{max} = 250$.

Tabela 4.19: Comparação do AES-TEP com e sem adaptação de probabilidades – Grupo dos operadores evolutivos – Caso SBR “N-0”.

α	β	N_{Pop}	IQ(%)	ITT(%)	TS(%)	$TM_S(s)$	$TM_C(s)$
0	0	120	89,42	75,57	29,0	46,63	54,35
0,2	0,9	120	88,07	68,36	20,0	39,43	50,92
0	0	200	89,57	80,05	28,0	80,30	90,98
0,2	0,9	200	89,78	77,63	31,0	67,23	84,15
0	0	280	89,93	81,86	22,0	107,0	128,7
0,2	0,9	280	90,36	81,44	33,0	96,14	119,5

Tabela 4.20: Comparação do AES-TEP com e sem adaptação de probabilidades – Grupo dos operadores especialistas – Caso SBR “N-0”.

α	β	N_{Pop}	IQ(%)	ITT(%)	TS(%)	$TM_S(s)$	$TM_C(s)$
0	0	80	96,09	83,73	40,0	25,54	31,48
0,2	0,9	80	96,70	84,84	46,0	19,64	28,26
0	0	160	98,13	88,85	52,0	46,77	62,82
0,2	0,9	160	98,56	91,04	67,0	38,31	55,17
0	0	240	98,90	91,06	70,0	71,38	95,96
0,2	0,9	240	99,24	92,11	76,0	57,09	82,76

Nas Tabelas 4.19 e 4.20 pode-se observar que, para este caso de estudo, a utilização do mecanismo de seleção adaptativa dos operadores ($\alpha = 0,2$ e $\beta = 0,9$) gera melhoras no desempenho do algoritmo para a maioria das configurações testadas: reduz o tempo computacional em todos os casos e aumenta a qualidade das soluções encontradas em quase todos os casos. Como esperado, pode-se observar também que, com o aumento do tamanho da população, a qualidade das soluções tende a aumentar e, conseqüentemente, o algoritmo demanda maiores tempos computacionais. Além disso, comparando a Tabela 4.19 com a 4.20, fica evidente a superioridade do AES-TEP utilizando o grupo dos operadores especialistas: são encontradas soluções de melhor qualidade a um custo computacional inferior.

No gráfico de convergência da Figura 4.15 apresenta-se uma comparação de duas versões do algoritmo AES-TEP: “Ops: Evol”, que é a versão utilizando o grupo dos operadores evolutivos, onde $\alpha = 0,2$, $\beta = 0,9$, $N_{Pop} = 280$ e $T_{max} = 250$; e “Ops: Exp”, que é a versão utilizando o grupo dos operadores especialistas, onde $\alpha = 0,2$, $\beta = 0,9$, $N_{Pop} = 240$ e $T_{max} = 250$. Novamente, pode-se observar a superioridade dos operadores especialistas em relação aos operadores evolutivos, pois, mesmo utilizando uma população menor, o algoritmo apresenta uma melhor eficiência computacional: atinge baixos valores para o erro médio com um número menor de gerações, além de possuir um valor final menor para o erro médio.

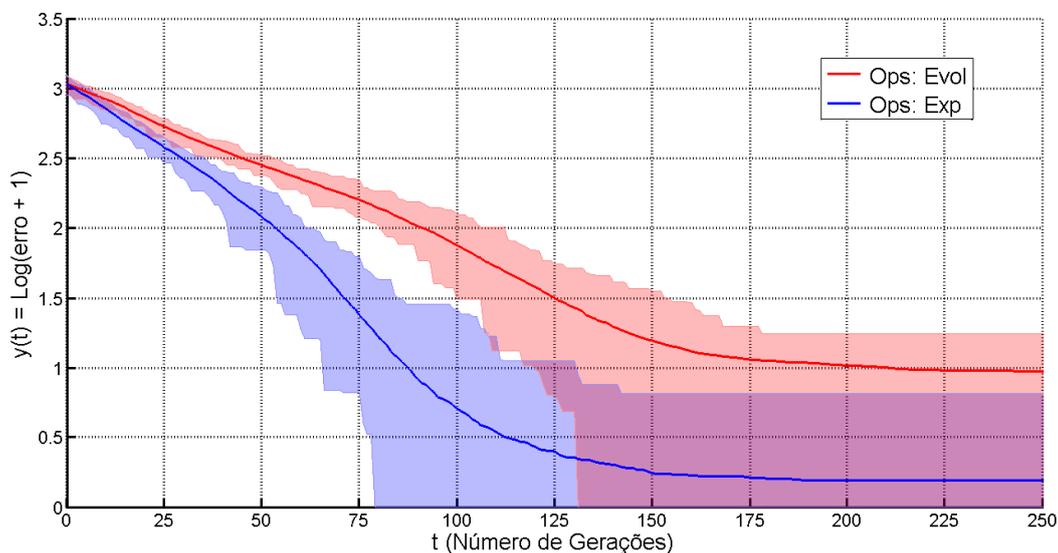


Figura 4.15: Gráfico de convergência comparando o grupo dos operadores evolutivos (Evol) com o grupo dos operadores especialistas (Exp) – Caso SBR “N-0”.

A Tabela 4.21 apresenta os resultados obtidos com a aplicação de duas versões do algoritmo AES-TEP: 1) “Evol”, que é a versão utilizando o grupo dos operadores evolutivos; e 2) “Exp”, que é a versão utilizando o grupo dos operadores especialistas. Nestas versões, utiliza-se o seguinte conjunto de parâmetros: $\alpha = 0,2$, $\beta = 0,9$, $N_{Pop} = 200$ e $T_{max} = 250$. Na coluna “Rnd” tem-se a indicação do tipo de inicialização da população utilizado: a) “100%”, quando 100% dos indivíduos foram inicializados de forma aleatória; b) “0%”, quando 100% dos indivíduos foram inicializados pelo All (vide Seção 3.3.1); e c) “50%”, quando a inicialização é mista, ou seja, 50% dos indivíduos são aleatórios e 50% são gerados pelo All.

Tabela 4.21: Comparação entre as inicializações 100% aleatória (“100%”), mista (“50%”) e 100% inteligente (“0%”) – Caso SBR “N-0”.

Ops	Rnd	IQ(%)	ITT(%)	TS(%)	TM _s (s)	TM _c (s)
Evol	100%	89,78	77,63	31,0	67,23	84,15
Exp	100%	98,95	91,44	71,0	50,19	70,59
Evol	50%	83,00	73,98	0,00	–	75,49
Exp	50%	94,65	82,70	0,00	–	74,56
Evol	0%	80,08	72,07	0,00	–	71,70
Exp	0%	91,54	80,02	0,00	–	71,86

Pode-se observar na Tabela 4.21 que, neste caso, a utilização de indivíduos gerados pelo All compromete muito o desempenho do AES-TEP, reduzindo significativamente a capacidade do algoritmo de encontrar a melhor solução conhecida para o problema (taxas de sucesso nulas para Rnd = 50% ou 0%). Pode-se notar ainda que, com o aumento da quantidade de indivíduos gerados pelo All, de “100%” para “50%”, e de “50%” para “0%”, houve uma redução dos índices IQ e ITT para as duas versões AES-TEP testadas, o que representa uma redução na qualidade das soluções obtidas.

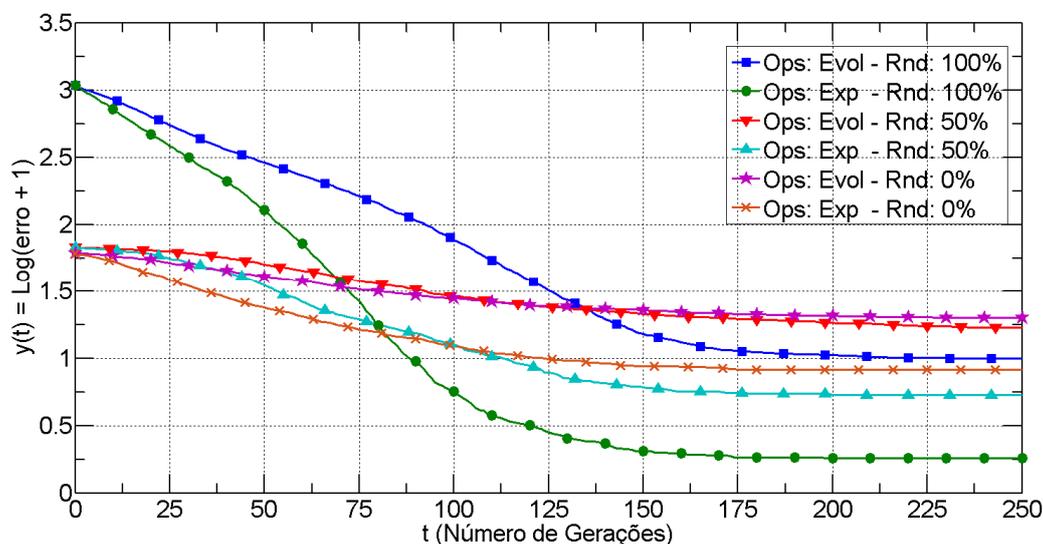


Figura 4.16: Gráfico de convergência comparando as inicializações 100% aleatória (“100%”), mista (“50%”) e 100% inteligente (“0%”) – Caso SBR “N-0”.

A Figura 4.16 apresenta um gráfico de convergência comparando as seis versões do algoritmo AES-TEP presentes na Tabela 4.21: “Ops” indica o uso dos operadores evolutivos (“Evol”) ou dos especialistas (“Exp”); e “Rnd” indica a porcentagem de indivíduos aleatórios que compõe a população inicial. Em to-

dos os casos, $\alpha = 0,2$, $\beta = 0,9$, $N_{Pop} = 200$ e $T_{max} = 250$. Pode-se verificar neste gráfico que, neste caso, independentemente dos operadores reprodutivos utilizados (operadores evolutivos ou especialistas), a melhor forma de inicializar a população é através da distribuição aleatória dos indivíduos pelo espaço de busca (produz um erro médio final menor).

Na Tabela 4.22 apresenta-se uma comparação entre versões AES-TEP utilizando multioperadores e também utilizando um único operador reprodutivo: na coluna “Ops”, “Evol”, identifica a versão AES-TEP utilizando o grupo dos operadores evolutivos, com $\alpha = 0,2$ e $\beta = 0,9$; “Exp” identifica a versão AES-TEP utilizando o grupo dos operadores especialistas, com $\alpha = 0,2$ e $\beta = 0,9$; as outras versões do AES-TEP são versões estáticas ($\alpha = 0$ e $\beta = 0$) utilizando um único operador de reprodução (e.g., “UNX-SMC” é a versão AES-TEP utilizando apenas o operador especialista UNX-SMC – vide Seção 3.3.2). Para todas estas versões utilizou-se: $N_{Pop} = 200$, $T_{max} = 250$, e inicialização da população com 100% dos indivíduos gerados de forma aleatória.

Tabela 4.22: Comparação entre versões AES-TEP com multioperadores e com um único operador reprodutivo (estática) – Caso SBR “N-0”.

Ops	α	β	IQ(%)	ITT(%)	TS(%)	TM _s (s)	TM _c (s)
Evol	0,2	0,9	89,78	77,63	31,0	67,23	84,15
Exp	0,2	0,9	98,95	91,44	71,0	50,19	70,59
LRX-UNM	0	0	32,09	28,00	0,00	–	88,84
SPX-UNM	0	0	82,51	55,63	0,00	–	87,08
SPX-SWM	0	0	88,91	69,42	5,00	70,14	80,63
UNX-SMC	0	0	94,08	86,55	19,0	77,21	92,43
SPX-RMA	0	0	94,92	81,77	5,00	63,34	77,09

Observa-se na Tabela 4.22 que a versão “LRX-UNM” foi a versão AES-TEP que apresentou o pior desempenho, obtendo taxa de sucesso nula (i.e., não encontrou a melhor solução conhecida para o problema em nenhuma das 100 execuções realizadas) e também o menor índice de qualidade; já a versão “UNX-SMC” resultou no melhor desempenho entre as versões estáticas; contudo, a versão “Exp” foi a melhor entre as sete versões testadas. Estes resultados podem ser novamente observados na Figura 4.17, onde um gráfico de

convergência compara as sete versões AES-TEP que foram apresentadas pela Tabela 4.22. Verifica-se ainda que, neste caso de estudo, a utilização de vários operadores de reprodução em um único EA gera melhores resultados que os tradicionais EAs estáticos e com um único operador, especialmente no caso dos operadores especialistas.

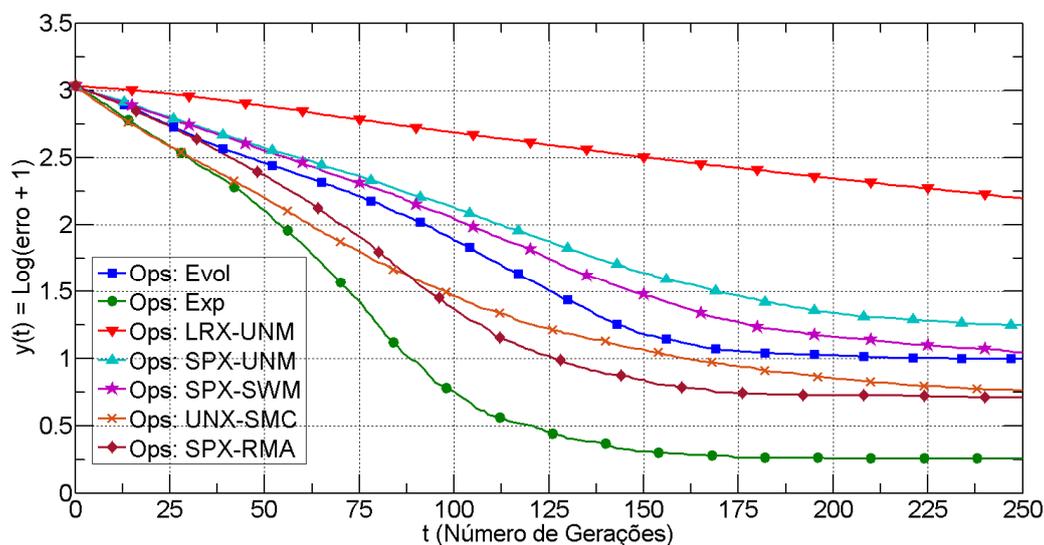


Figura 4.17: Gráfico de convergência comparando versões AES-TEP com multioperadores e com um único operador (estática) – Caso SBR “N-0”.

4.4.2 Caso 6: SBR “N-1” 0%

Neste caso, a modelagem do problema PET para o sistema SBR considera as perdas ôhmicas dos equipamentos de transmissão e o tradicional critério de segurança “N-1” sem relaxamento ($sc_{max} = 0\%$ - vide Seção 3.2.2). As soluções para este problema devem minimizar o custo de investimento, satisfazendo simultaneamente duas restrições: 1) corte de carga nulo para a rede intacta; e 2) sobrecarga nula para qualquer contingência simples. Para a rede intacta, permite-se o redespacho total dos geradores: para um dado plano candidato, realiza-se o redespacho dos geradores de modo a minimizar o custo operacional do sistema (despacho econômico); já no caso de contingência simples, permite-se o redespacho apenas da barra *swing*. Na tabela 4.23 estão listados os 10 melhores planos conhecidos para este caso, ordenados em função do custo de investimento.

Tabela 4.23: Os 10 melhores planos conhecidos para o caso SBR “N-1” 0%.

N.	Custo (10 ⁶ US\$)	Perdas (MW)	N. Refs	Planos de Expansão - Reforços Adicionados por Ramo (ID)																			
				8	11	16	22	25	26	27	33	34	37	39	40	41	46	47	53	61	68	70	71
1	239,02	184,78	22	1	1	1	2		1	1			1	1	1	3	3	2	1				3
2	239,43	185,02	22	1	1	1	2		1	1			1	1		3	3	2	1		1		3
3	240,23	181,11	22	1	1	1	2	1		1			1	1	1	3	3	2	1				3
4	240,64	181,36	22	1	1	1	2	1		1			1	1		3	3	2	1		1		3
5	242,56	181,90	22	1	1	1	2	2					1	1	1	3	3	2	1				3
6	242,96	182,15	22	1	1	1	2	2					1	1		3	3	2	1		1		3
7	245,09	176,04	23	1	1	1	2	1		1	1	1		1		3	3	2	1		1		3
8	246,46	179,11	24	2	1	1	2		1	1	1	1		1		3	3	2	1		1		3
9	247,12	184,10	22	1	1	1	2		1	1					3	2	2	1	1	1	1	1	3
10	247,41	176,84	23	1	1	1	2	2		1	1		1		3	3	2	1		1			3

A Tabela 4.24 apresenta os resultados obtidos com a aplicação de quatro versões do algoritmo AES-TEP: na coluna “Ops”, “Evol” identifica versão utilizando o grupo dos operadores evolutivos, e “Exp” identifica versão utilizando o grupo dos operadores especialistas; nas colunas α e β tem-se, $\alpha = 0,25$ e $\beta = 0,6$ para versão adaptativa, ou $\alpha = 0$ e $\beta = 0$ para versão estática (sem adaptação das probabilidades). A fim de comparar o desempenho destas versões, dois diferentes tamanhos de população foram utilizados: $N_{Pop} = 200$ ou 350 , onde todos os indivíduos foram inicializados de forma aleatória. Além disso, o número máximo de gerações permitido foi fixado em $T_{max} = 500$.

Tabela 4.24: Comparação entre versões AES-TEP utilizando operadores evolutivos (Evol) ou operadores especialistas (Exp) – Caso SBR “N-1” 0%.

N_{Pop}	Ops	α	β	IQ(%)	ITT(%)	TS(%)	$TM_s(m)$	$TM_c(m)$
200	Evol	0	0	81,20	79,57	0,0	–	8,028
		0,25	0,6	81,14	79,19	1,0	6,983	7,460
	Exp	0	0	93,41	87,85	51	6,254	8,345
		0,25	0,6	95,35	88,90	65	6,190	8,084
350	Evol	0	0	81,38	79,81	0,0	–	14,29
		0,25	0,6	81,14	79,54	0,0	–	13,19
	Exp	0	0	95,61	89,36	70	10,73	14,17
		0,25	0,6	95,83	89,47	72	10,46	13,82

Pode-se observar na Tabela 4.24 que a versão AES-TEP utilizando os operadores especialistas (“Exp”) apresenta desempenho significativamente melhor do que a versão utilizando os operadores evolutivos (“Evol”). Como a versão

“Evol” apresenta uma TS muito pequena, fica difícil a comparação entre os tempos computacionais: pode-se dizer apenas que a “Exp” tem uma maior capacidade de busca pelas melhores soluções do problema. Em relação ao mecanismo de adaptação das probabilidades de seleção dos operadores, pode-se observar que há uma redução do tempo computacional para todas as versões do algoritmo; especificamente para “Exp”, o mecanismo adaptativo além de reduzir os tempos ainda gera melhoras nos índices de qualidade (IQ e ITT), ou seja, melhora a qualidade das soluções encontradas. Ademais, pode-se notar que o aumento do tamanho da população aumenta a qualidade das soluções encontradas e, conseqüentemente, demanda maiores tempos computacionais.

O gráfico de convergência da Figura 4.18 apresenta uma comparação entre as versões adaptativas para “Evol” e “Exp”, utilizando os mesmos parâmetros de controle: $\alpha = 0,25$, $\beta = 0,60$, $N_{Pop} = 350$ (inicialização aleatória) e $T_{max} = 500$. Novamente, pode-se notar a superioridade do AES-TEP utilizando o grupo dos operadores especialistas (“Exp”): encontra soluções de melhor qualidade. Pode-se observar também que a versão “Evol” apresenta um comportamento “limitado”, devido à estreita faixa para a “margem de variação” que acompanha o valor do erro médio: isto mostra que, mesmo com a inicialização inteligente, esta versão possui baixíssima capacidade de exploração do espaço de busca.

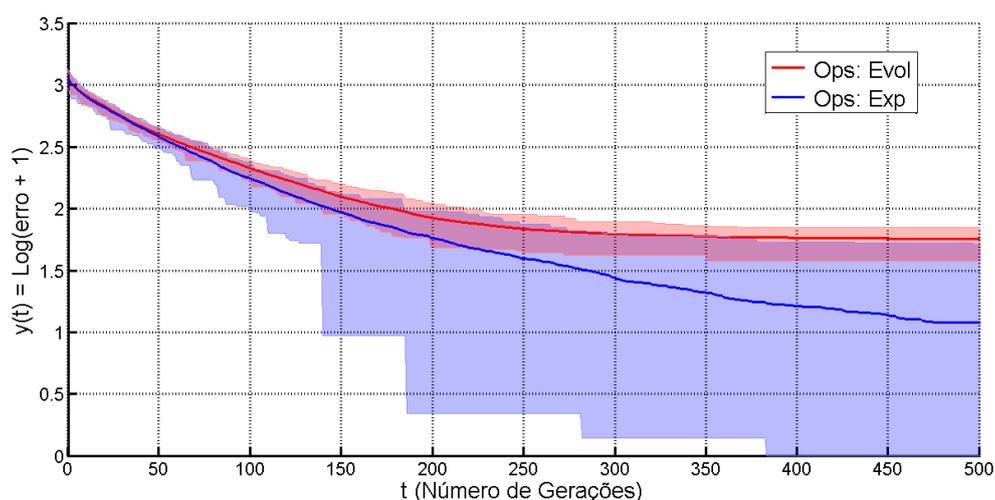


Figura 4.18: Gráfico de convergência comparando o grupo dos operadores evolutivos (Evol) com o grupo dos operadores especialistas (Exp) – Caso SBR “N-1” 0%.

A Tabela 4.25 apresenta os resultados obtidos com a aplicação de duas versões do AES-TEP: 1) “Evol”, que é a versão utilizando o grupo dos operadores evolutivos; e 2) “Exp”, que é a versão utilizando o grupo dos operadores especialistas. Nestas versões, utiliza-se o seguinte conjunto de parâmetros: $\alpha = 0,25$, $\beta = 0,60$, $N_{Pop} = 200$ e $T_{max} = 500$. Na coluna “Rnd” tem-se a indicação do tipo de inicialização da população utilizado: 1) “100%”, quando 100% dos indivíduos foram inicializados de forma aleatória; 2) “0%”, quando 100% dos indivíduos foram inicializados pelo All; e 3) “50%”, quando a inicialização é mista (50% dos indivíduos são aleatórios e 50% foram criados pelo All).

Tabela 4.25: Comparação entre as inicializações 100% aleatória (“100%”), mista (“50%”) e 100% inteligente (“0%”) – Caso SBR “N-1” 0%.

Ops	Rnd	IQ(%)	ITT(%)	TS(%)	TM _s (m)	TM _c (m)
Evol	100%	81,14	79,19	1,0	6,983	7,460
Exp	100%	95,35	88,90	65	6,190	8,084
Evol	50%	80,18	78,69	0,0	–	8,481
Exp	50%	84,89	81,28	5,0	8,142	9,552
Evol	0%	80,18	78,53	0,0	–	9,502
Exp	0%	83,40	80,43	1,0	11,09	10,75

O gráfico de convergência da Figura 4.19 também apresenta uma comparação para as seis versões do algoritmo AES-TEP presentes na Tabela 4.25: “Ops” indica o uso dos operadores evolutivos (“Evol”) ou dos especialistas (“Exp”); e “Rnd” indica a porcentagem de indivíduos aleatórios na população inicial. Na Tabela 4.25 e na Figura 4.19 pode-se observar que, tanto para a versão “Evol” como para “Exp”, a inclusão de indivíduos gerados pelo All na população inicial deteriora o desempenho do algoritmo: para todos os casos, reduz a qualidade das soluções encontradas e aumenta o tempo computacional. Particularmente para a versão “Exp”, a utilização do All reduz drasticamente a capacidade do algoritmo de encontrar boas soluções para o problema. Assim, para este caso, a melhor opção é a utilização da versão “Exp” com 100% da população distribuída aleatoriamente pelo espaço de busca.

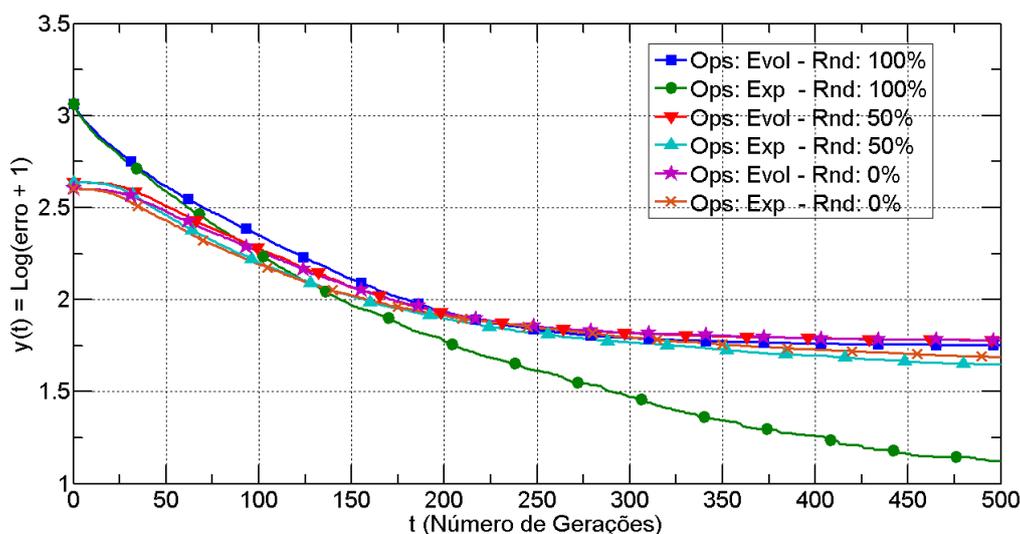


Figura 4.19: Gráfico de convergência comparando as inicializações 100% aleatória (“100%”), mista (“50%”) e 100% inteligente (“0%”) – Caso SBR “N-1” 0%.

Na Tabela 4.26 apresenta-se uma comparação entre versões AES-TEP com multioperadores e com um único operador reprodutivo: na coluna “Ops”, “Evol” identifica a versão AES-TEP utilizando o grupo dos operadores evolutivos, com $\alpha = 0,25$ e $\beta = 0,60$; “Exp” identifica a versão AES-TEP utilizando o grupo dos operadores especialistas, com $\alpha = 0,25$ e $\beta = 0,60$; as outras versões do AES-TEP são versões estáticas ($\alpha = 0$ e $\beta = 0$) utilizando um único operador de reprodução (evolutivo ou especialista). Para todas estas versões utilizou-se: $N_{Pop} = 200$, $T_{max} = 500$, e inicialização aleatória dos indivíduos.

Tabela 4.26: Comparação entre versões AES-TEP com multioperadores e com um único operador reprodutivo (estática) – Caso SBR “N-1” 0%.

Ops	α	β	IQ(%)	ITT(%)	TS(%)	TM _S (m)	TM _C (m)
Evol	0,25	0,6	81,14	79,19	1,0	6,983	7,460
Exp	0,25	0,6	95,35	88,90	65	6,190	8,084
LRX-UNM	0	0	70,85	66,81	0,0	–	7,816
SPX-UNM	0	0	79,63	76,45	6,0	7,814	8,257
SPX-SWM	0	0	80,28	76,83	6,0	6,851	8,214
UNX-SMC	0	0	92,32	88,35	41	5,600	8,099
SPX-RMA	0	0	86,39	82,38	14	6,164	8,593

Observa-se na Tabela 4.26 que a versão “LRX-UNM” foi a versão AES-TEP que apresentou o pior desempenho, obtendo taxa de sucesso nula; já a versão “Exp” resultou no melhor desempenho do algoritmo, indicando assim que existe

vantagem em se utilizar multioperadores em um único EA (no caso dos operadores especialistas). Dentre as versões estáticas (com um único operador), a versão “UNX-SMC” foi a melhor: para este problema PET em questão, pode-se dizer que o operador “UNX-SMC” é o operador mais indicado para ser utilizado por um EA tradicional. Estes resultados podem ser novamente verificados na Figura 4.20, onde um gráfico de convergência compara as sete versões AES-TEP presentes na Tabela 4.26.

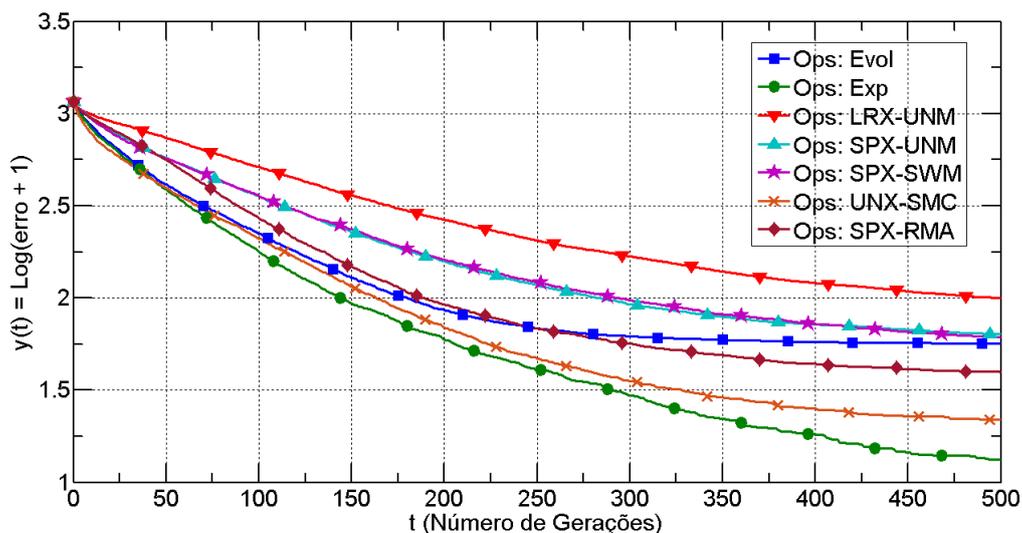


Figura 4.20: Gráfico de convergência comparando versões AES-TEP com multioperadores e com um único operador (estática) – Caso SBR “N-1” 0%.

4.4.3 Caso 7: SBR “N-1” 10%

Neste caso, a modelagem do problema PET para o sistema SBR considera as perdas ôhmicas dos equipamentos de transmissão e o critério de segurança “N-1” relaxado a 10% ($sc_{max} = 10\%$). As soluções para este problema devem minimizar o custo de investimento, satisfazendo simultaneamente duas restrições: 1) corte de carga nulo para a rede intacta; e 2) sobrecarga de até 10% para qualquer contingência simples. Para a rede intacta, permite-se o redespacho total dos geradores: para um dado plano candidato, realiza-se o redespacho dos geradores de modo a minimizar o custo operacional do sistema (despacho econômico); já no caso de contingência simples, permite-se o redespacho apenas da barra *swing*. Na tabela 4.27 estão listados os 10 melhores planos conhecidos para este caso, ordenados pelo custo de investimento.

Tabela 4.27: Os 10 melhores planos conhecidos para o caso SBR “N-1” 10%.

N.	Custo (10 ⁶ US\$)	Perdas (MW)	N. Refs	Planos de Expansão - Reforços Adicionados por Ramo (ID)																		
				8	11	16	22	23	25	27	31	34	37	39	40	41	46	47	53	61	71	78
1	231,95	184,89	21	1	1	1	2		1					1	1	1	3	3	2	1	3	
2	232,35	185,14	21	1	1	1	2		1					1	1		3	3	2	1	1	3
3	233,21	184,91	22	1	1	1	2			1	1			1	1	1	3	3	2	1		3
4	233,62	185,16	22	1	1	1	2			1	1			1	1		3	3	2	1	1	3
5	234,02	184,65	21	1	1	1	2		1					1	1		3	3	2	1	1	3
6	234,47	180,55	21	1	1	1	2		1			1		1			3	3	2	1	1	3
7	234,93	184,75	22	1	1	1	2	1		1				1	1	1	3	3	2	1		3
8	235,28	184,67	22	1	1	1	2			1	1			1	1		3	3	2	1	1	3
9	235,33	185,00	22	1	1	1	2	1		1				1	1		3	3	2	1	1	3
10	235,74	180,57	22	1	1	1	2			1	1	1		1			3	3	2	1	1	3

A Tabela 4.28 apresenta os resultados obtidos com a aplicação de quatro versões do algoritmo AES-TEP: na coluna “Ops”, “Evol” identifica versão utilizando o grupo dos operadores evolutivos, e “Exp” identifica versão utilizando o grupo dos operadores especialistas; nas colunas α e β , tem-se $\alpha = 0,25$ e $\beta = 0,6$ para versão adaptativa, ou $\alpha = 0$ e $\beta = 0$ para versão estática (sem adaptação das probabilidades). A fim de comparar o desempenho destas versões, dois diferentes tamanhos de população foram utilizados: $N_{Pop} = 200$ ou 350 , onde todos dos indivíduos foram inicializados de forma aleatória. O número máximo de gerações permitido foi fixado em $T_{max} = 500$.

Tabela 4.28: Comparação entre versões AES-TEP utilizando operadores evolutivos (Evol) ou operadores especialistas (Exp) – Caso SBR “N-1” 10%.

N_{Pop}	Ops	α	β	IQ(%)	ITT(%)	TS(%)	TM _s (m)	TM _c (m)
200	Evol	0	0	91,03	89,91	0,0	–	6,787
		0,25	0,6	91,10	89,61	0,0	–	6,347
	Exp	0	0	96,44	93,29	57	4,964	7,176
		0,25	0,6	96,92	93,71	61	4,600	6,887
350	Evol	0	0	91,04	90,09	0,0	–	12,65
		0,25	0,6	91,19	89,95	0,0	–	11,63
	Exp	0	0	96,60	93,40	58	8,642	11,76
		0,25	0,6	97,62	94,21	76	7,912	10,75

Pode-se observar na Tabela 4.28 que a versão AES-TEP utilizando os operadores especialistas (“Exp”) apresenta desempenho significativamente melhor do que a versão utilizando os operadores evolutivos (“Evol”). Como a versão “Evol” apresenta uma TS muito pequena, fica difícil a comparação entre os

tempos computacionais: pode-se dizer apenas que a “Exp” tem uma maior capacidade de busca pelas melhores soluções do problema. Em relação ao mecanismo de adaptação das probabilidades de seleção dos operadores, pode-se observar que há uma redução do tempo computacional para todas as versões do algoritmo; especificamente para “Exp”, o mecanismo adaptativo além de reduzir os tempos ainda gera melhoras nos índices de qualidade (*IQ* e *ITT*), ou seja, melhora a qualidade das soluções encontradas. Ademais, pode-se notar que o aumento do tamanho da população aumenta a qualidade das soluções encontradas e, conseqüentemente, demanda maiores tempos computacionais.

O gráfico de convergência da Figura 4.21 apresenta uma comparação entre as versões adaptativas para “Evol” e “Exp”, utilizando os mesmos parâmetros de controle: $\alpha = 0,25$, $\beta = 0,60$, $N_{Pop} = 350$ (inicialização aleatória) e $T_{max} = 500$. Novamente, pode-se notar a superioridade do AES-TEP utilizando o grupo dos operadores especialistas (“Exp”): encontra soluções de melhor qualidade. Pode-se observar também que a versão “Evol” apresenta um comportamento “limitado”, devido à estreita faixa para a “margem de variação” que acompanha o valor do erro médio: isto mostra que, mesmo com a inicialização inteligente, esta versão possui baixíssima capacidade de exploração do espaço de busca. Contudo, pode-se notar que a versão “Exp” não encontra a melhor solução conhecida para o problema ($231,95 \cdot 10^6$ US\$) em nenhuma das 100 execuções, motivo pelo qual seu erro mínimo não chega a ser nulo.

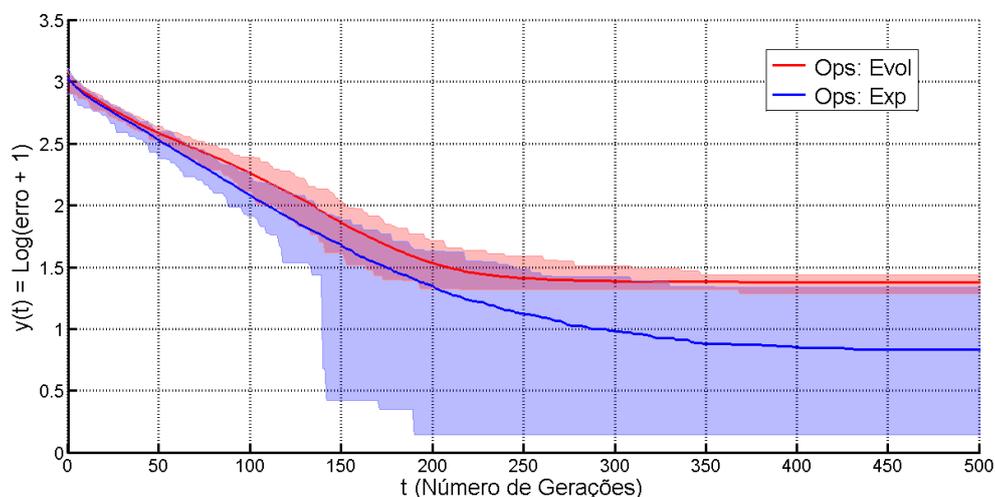


Figura 4.21: Gráfico de convergência comparando o grupo dos operadores evolutivos (Evol) com o grupo dos operadores especialistas (Exp) – Caso SBR “N-1” 10%.

A Tabela 4.29 apresenta os resultados obtidos com a aplicação de duas versões do AES-TEP: 1) “Evol”, que é a versão utilizando o grupo dos operadores evolutivos; e 2) “Exp”, que é a versão utilizando o grupo dos operadores especialistas. Nestas versões, utiliza-se o seguinte conjunto de parâmetros: $\alpha = 0,25$, $\beta = 0,60$, $N_{Pop} = 200$ e $T_{max} = 500$. Na coluna “Rnd” tem-se a indicação do tipo de inicialização da população utilizado: 1) “100%”, quando 100% dos indivíduos foram inicializados de forma aleatória; 2) “0%”, quando 100% dos indivíduos foram inicializados pelo All; e 3) “50%”, quando a inicialização é mista (50% dos indivíduos são aleatórios e 50% foram criados pelo All).

Tabela 4.29: Comparação entre as inicializações 100% aleatória (“100%”), mista (“50%”) e 100% inteligente (“0%”) – Caso SBR “N-1” 10%.

Ops	Rnd	IQ(%)	ITT(%)	TS(%)	TM _s (m)	TM _c (m)
Evol	100%	91,10	89,61	0,0	–	6,347
Exp	100%	96,92	93,71	61	4,600	6,887
Evol	50%	91,98	90,03	0,0	–	7,680
Exp	50%	93,43	90,98	4,0	6,251	8,405
Evol	0%	92,40	90,19	0,0	–	9,058
Exp	0%	92,92	90,42	5,0	7,443	9,392

O gráfico de convergência da Figura 4.22 também apresenta uma comparação para as seis versões do algoritmo AES-TEP presentes na Tabela 4.29: “Ops” indica o uso dos operadores evolutivos (“Evol”) ou dos especialistas (“Exp”); e “Rnd” indica a porcentagem de indivíduos aleatórios na população inicial. Na Tabela 4.29 e na Figura 4.22 pode-se observar que, para a versão “Exp”, a inclusão de indivíduos gerados pelo All na população inicial deteriora o desempenho do algoritmo: para todos os casos, reduz a qualidade das soluções encontradas e aumenta o tempo computacional. Já para a “Evol”, o All gera uma pequena melhora no desempenho; contudo, a *TS* ainda continua nula. Pode-se notar ainda que, para a versão “Exp”, a utilização do All reduz drasticamente a capacidade do algoritmo de encontrar boas soluções para o problema. Assim, para este caso, a melhor opção é a utilização da versão “Exp” com 100% da população distribuída aleatoriamente pelo espaço de busca.

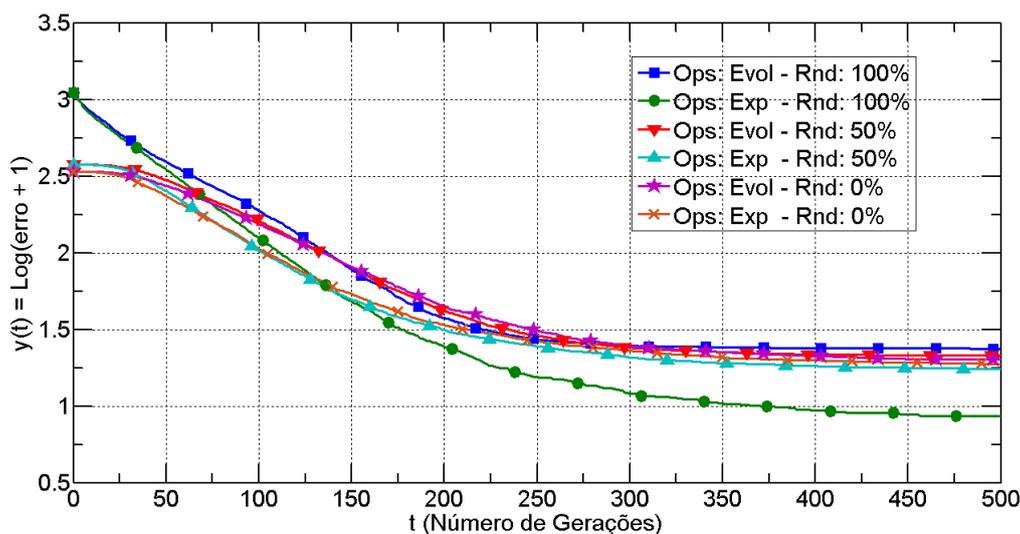


Figura 4.22: Gráfico de convergência comparando as inicializações 100% aleatória (“100%”), mista (“50%”) e 100% inteligente (“0%”) – Caso SBR “N-1” 10%.

Na Tabela 4.30 apresenta-se uma comparação entre versões AES-TEP com multioperadores e com um único operador reprodutivo: na coluna “Ops”, “Evol” identifica a versão AES-TEP utilizando o grupo dos operadores evolutivos, com $\alpha = 0,25$ e $\beta = 0,60$; “Exp” identifica a versão AES-TEP utilizando o grupo dos operadores especialistas, com $\alpha = 0,25$ e $\beta = 0,60$; as outras versões do AES-TEP são versões estáticas ($\alpha = 0$ e $\beta = 0$) utilizando um único operador de reprodução (evolutivo ou especialista). Em todas estas versões, utilizou-se: $N_{Pop} = 200$, $T_{max} = 500$, e inicialização aleatória dos indivíduos.

Tabela 4.30: Comparação entre versões AES-TEP com multioperadores e com um único operador reprodutivo (estática) – Caso SBR “N-1” 10%.

Ops	α	β	IQ(%)	ITT(%)	TS(%)	TM _s (m)	TM _c (m)
Evol	0,25	0,6	91,10	89,61	0,0	–	6,347
Exp	0,25	0,6	96,92	93,71	61	4,600	6,887
LRX-UNM	0	0	77,64	72,16	0,0	–	7,656
SPX-UNM	0	0	85,08	82,43	3,0	5,539	7,880
SPX-SWM	0	0	90,19	87,32	21	5,210	7,702
UNX-SMC	0	0	92,96	89,92	30	5,137	7,744
SPX-RMA	0	0	94,24	91,09	40	5,091	7,339

Observa-se na Tabela 4.30 que a versão “LRX-UNM” foi a versão AES-TEP que apresentou o pior desempenho, obtendo taxa de sucesso nula; já a versão “Exp” resultou no melhor desempenho do algoritmo, indicando assim que existe

vantagem em se utilizar multioperadores em um único EA (no caso dos operadores especialistas). Dentre as versões estáticas (com um único operador), a versão “SPX-RMA” foi a melhor: para este problema PET em questão, pode-se dizer que o operador “SPX-RMA” é o operador mais indicado para ser utilizado por um EA tradicional. Estes resultados podem ser novamente verificados na Figura 4.23, onde um gráfico de convergência compara as sete versões AES-TEP presentes na Tabela 4.30.

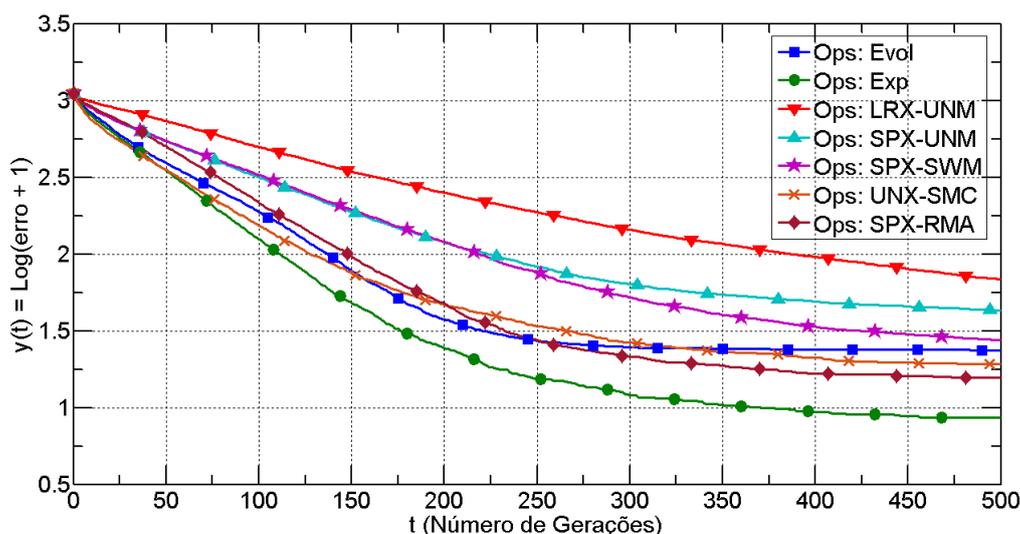


Figura 4.23: Gráfico de convergência comparando versões AES-TEP com multioperadores e com um único operador (estática) – Caso SBR “N-1” 10%.

4.4.4 Caso 8: SBR “N-1” 20%

Neste caso, a modelagem do problema PET para o sistema SBR considera as perdas ôhmicas dos equipamentos de transmissão e o critério de segurança “N-1” relaxado a 20% ($sc_{max} = 20\%$). As soluções para este problema devem minimizar o custo de investimento, satisfazendo simultaneamente duas restrições: 1) corte de carga nulo para a rede intacta; e 2) sobrecarga de até 20% para qualquer contingência simples. Para a rede intacta, permite-se o redespacho total dos geradores: para um dado plano candidato, realiza-se o redespacho dos geradores de modo a minimizar o custo operacional do sistema (despacho econômico); já no caso de contingência simples, permite-se o redespacho apenas da barra swing. Na tabela 4.31 estão listados os 10 melhores planos conhecidos para este caso, ordenados pelo custo de investimento.

Tabela 4.31: Os 10 melhores planos conhecidos para o caso SBR “N-1” 20%.

N.	Custo (10 ⁶ US\$)	Perdas (MW)	N. Refs	Planos de Expansão - Reforços Adicionados por Ramo (ID)																			
				8	11	16	20	22	25	27	38	39	40	41	46	47	48	50	52	53	61	71	73
1	206,69	205,77	20	1	1	1	1	1	1	3	2	1	3	1	1	2	1						
2	209,02	205,06	20	1	1	1	1	1	1	3	2	1	3	1	1	2	1						
3	211,64	191,06	18	1	1	1	1	1	1	3	2			2	1	1	3						
4	212,56	205,14	21	1	1	1	1	1	1	1	1	3	2	1	3	1	2	1					
5	214,88	204,43	21	1	1	1	1	1	1	1	1	3	2	1	3	1	2	1					
6	215,02	191,08	19	1	1	1	1	1	1	3	2			2	1	1	3						
7	215,43	191,66	19	1	1	1	1	1	1	3	2			2	1	1	3						
8	215,58	188,02	19	1	1	1	2	1	1	3	2			2	1	1	3						
9	216,04	206,61	21		1	1	1	1	1	3	2	2	1	3	1	1	2	1					
10	217,49	189,71	19	1	1	1	1	1	1	3	3			2	1	1	3						

A Tabela 4.32 apresenta os resultados obtidos com a aplicação de quatro versões do algoritmo AES-TEP: na coluna “Ops”, “Evol” identifica versão utilizando o grupo dos operadores evolutivos, e “Exp” identifica versão utilizando o grupo dos operadores especialistas; nas colunas α e β tem-se, $\alpha = 0,25$ e $\beta = 0,6$ para versão adaptativa, ou $\alpha = 0$ e $\beta = 0$ para versão estática (sem adaptação das probabilidades). A fim de comparar o desempenho destas versões, dois diferentes tamanhos de população foram utilizados: $N_{Pop} = 200$ ou 350 , onde todos dos indivíduos foram inicializados de forma aleatória. O número máximo de gerações permitido foi fixado em $T_{max} = 500$.

Tabela 4.32: Comparação entre versões AES-TEP utilizando operadores evolutivos (Evol) ou operadores especialistas (Exp) – Caso SBR “N-1” 20%.

N_{Pop}	Ops	α	β	IQ(%)	ITT(%)	TS(%)	TM _S (m)	TM _C (m)
200	Evol	0	0	92,17	86,71	7,0	5,782	7,336
		0,25	0,6	92,85	85,19	17	5,324	6,952
	Exp	0	0	98,49	93,14	85	3,982	6,078
		0,25	0,6	98,95	93,27	94	3,558	5,824
350	Evol	0	0	94,10	88,61	22	10,88	12,96
		0,25	0,6	93,91	88,61	25	10,23	12,35
	Exp	0	0	99,58	94,16	98	6,546	10,42
		0,25	0,6	99,60	94,42	98	6,011	10,15

Pode-se observar na Tabela 4.32 que a versão AES-TEP utilizando os operadores especialistas (“Exp”) apresenta desempenho superior à versão utilizando os operadores evolutivos (“Evol”). Por exemplo, para a população $N_{Pop} = 350$, a

versão “Exp” apresentou um ganho de 73% na TS, gastando menos de 60% do tempo computacional para uma execução de sucesso. Em relação ao mecanismo de adaptação das probabilidades de seleção dos operadores, pode-se observar que há uma redução do tempo computacional para todas as versões do algoritmo; especificamente para “Exp”, o mecanismo adaptativo além de reduzir os tempos ainda gera melhoras nos índices de qualidade (IQ e ITT), ou seja, melhora a qualidade das soluções encontradas. Ademais, pode-se notar que o aumento do tamanho da população aumenta a qualidade das soluções encontradas e, conseqüentemente, demanda maiores tempos computacionais.

O gráfico de convergência da Figura 4.24 apresenta uma comparação entre as versões adaptativas para “Evol” e “Exp”, utilizando os mesmos parâmetros de controle: $\alpha = 0,25$, $\beta = 0,60$, $N_{Pop} = 350$ (inicialização aleatória) e $T_{max} = 500$. Novamente, pode-se observar a superioridade do AES-TEP utilizando o grupo dos operadores especialistas (“Exp”): soluções de melhor qualidade com um menor número de gerações (custo computacional inferior).

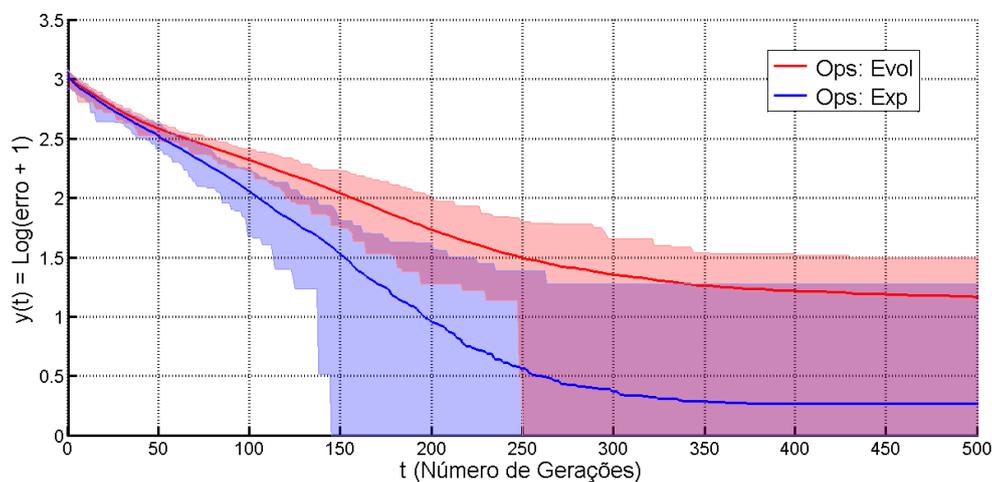


Figura 4.24: Gráfico de convergência comparando o grupo dos operadores evolutivos (Evol) com o grupo dos operadores especialistas (Exp) – Caso SBR “N-1” 20%.

A Tabela 4.33 apresenta os resultados obtidos com a aplicação de duas versões do AES-TEP: 1) “Evol”, que é a versão utilizando o grupo dos operadores evolutivos; e 2) “Exp”, que é a versão utilizando o grupo dos operadores especialistas. Nestas versões, utiliza-se o seguinte conjunto de parâmetros: $\alpha = 0,25$, $\beta = 0,60$, $N_{Pop} = 200$ e $T_{max} = 500$. Na coluna “Rnd” tem-se a indicação do

tipo de inicialização da população utilizado: 1) “100%”, quando 100% dos indivíduos foram inicializados de forma aleatória; 2) “0%”, quando 100% dos indivíduos foram inicializados pelo All; e 3) “50%”, quando a inicialização é mista (50% dos indivíduos são aleatórios e 50% foram criados pelo All).

Tabela 4.33: Comparação entre as inicializações 100% aleatória (“100%”), mista (“50%”) e 100% inteligente (“0%”) – Caso SBR “N-1” 20%.

Ops	Rnd	IQ(%)	ITT(%)	TS(%)	TM _s (m)	TM _c (m)
Evol	100%	92,85	85,19	17	5,324	6,952
Exp	100%	98,95	93,27	94	3,558	5,824
Evol	50%	96,23	89,51	59	6,302	8,191
Exp	50%	95,78	90,44	43	5,140	7,622
Evol	0%	94,96	89,40	47	7,571	9,310
Exp	0%	94,91	89,48	34	6,982	9,094

O gráfico de convergência da Figura 4.25 também apresenta uma comparação para as seis versões do algoritmo AES-TEP presentes na Tabela 4.33: “Ops” indica o uso dos operadores evolutivos (“Evol”) ou dos especialistas (“Exp”); e “Rnd” indica a porcentagem de indivíduos aleatórios na população inicial. Na Tabela 4.33 e na Figura 4.25 pode-se observar que, para a versão “Exp”, a inclusão de indivíduos gerados pelo All na população inicial deteriora o desempenho do algoritmo: para todos os casos, reduz a qualidade das soluções encontradas e aumenta o tempo computacional. Já para a “Evol”, o All gera uma melhora no desempenho, principalmente para a versão “Rnd: 50%”. Pode-se notar ainda que, para a versão “Exp”, a utilização do All reduz significativamente a capacidade do algoritmo de encontrar boas soluções para o problema. Assim, para este caso, a melhor opção é a utilização da versão “Exp” com 100% da população distribuída aleatoriamente pelo espaço de busca.

Na Tabela 4.34 apresenta-se uma comparação entre versões AES-TEP com multioperadores e com um único operador reprodutivo: na coluna “Ops”, “Evol” identifica a versão AES-TEP utilizando o grupo dos operadores evolutivos, com $\alpha = 0,25$ e $\beta = 0,60$; “Exp” identifica a versão AES-TEP utilizando o grupo dos operadores especialistas, com $\alpha = 0,25$ e $\beta = 0,60$; as outras versões do AES-TEP são versões estáticas ($\alpha = 0$ e $\beta = 0$) utilizando um único operador de re-

produção (evolutivo ou especialista). Para todas estas versões utilizou-se: $N_{Pop} = 200$, $T_{max} = 500$, e inicialização aleatória dos indivíduos.

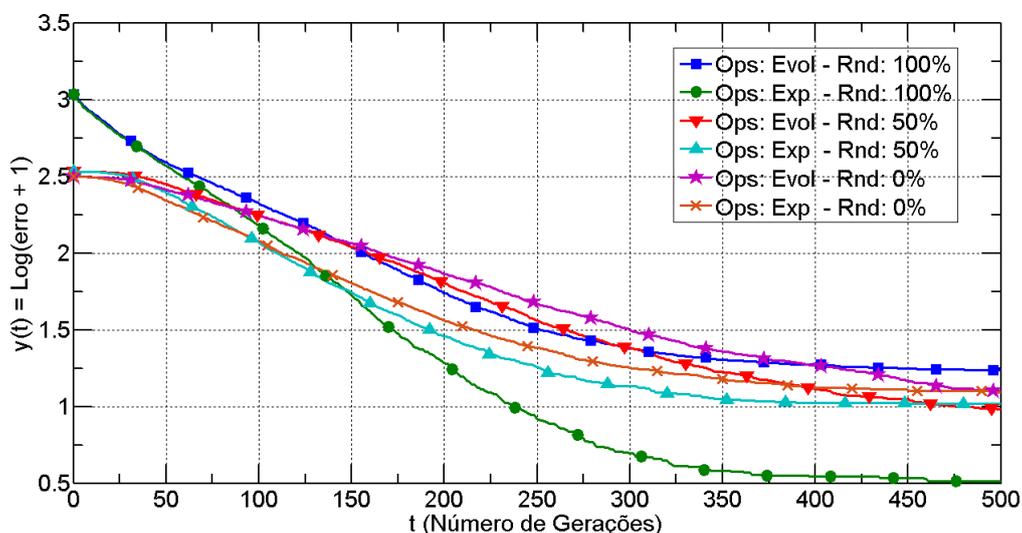


Figura 4.25: Gráfico de convergência comparando as inicializações 100% aleatória (“100%”), mista (“50%”) e 100% inteligente (“0%”) – Caso SBR “N-1” 20%.

Tabela 4.34: Comparação entre versões AES-TEP com multioperadores e com um único operador reprodutivo (estática) – Caso SBR “N-1” 20%.

Ops	α	β	IQ(%)	ITT(%)	TS(%)	TM _s (m)	TM _c (m)
Evol	0,25	0,6	92,85	85,19	17	5,324	6,952
Exp	0,25	0,6	98,95	93,27	94	3,558	5,824
LRX-UNM	0	0	74,42	69,56	0,0	–	7,431
SPX-UNM	0	0	82,32	78,42	0,0	–	7,539
SPX-SWM	0	0	86,45	82,02	3,0	5,778	7,503
UNX-SMC	0	0	97,79	92,62	85	4,531	6,487
SPX-RMA	0	0	91,39	86,03	17	4,682	7,265

Observa-se na Tabela 4.34 que a versão “LRX-UNM” foi a versão AES-TEP que apresentou o pior desempenho, obtendo taxa de sucesso nula; já a versão “Exp” resultou no melhor desempenho do algoritmo, indicando assim que existe vantagem em se utilizar multioperadores em um único EA (no caso dos operadores especialistas). Dentre as versões estáticas (com um único operador), a versão “UNX-SMC” foi a melhor, com resultado próximo da versão “Exp”; para este problema PET em questão, pode-se dizer que o operador “UNX-SMC” é o operador mais indicado para ser utilizado por um EA tradicional. Estes resultados podem ser novamente verificados na Figura 4.26, onde um gráfico de convergência compara as sete versões presentes na Tabela 4.34.

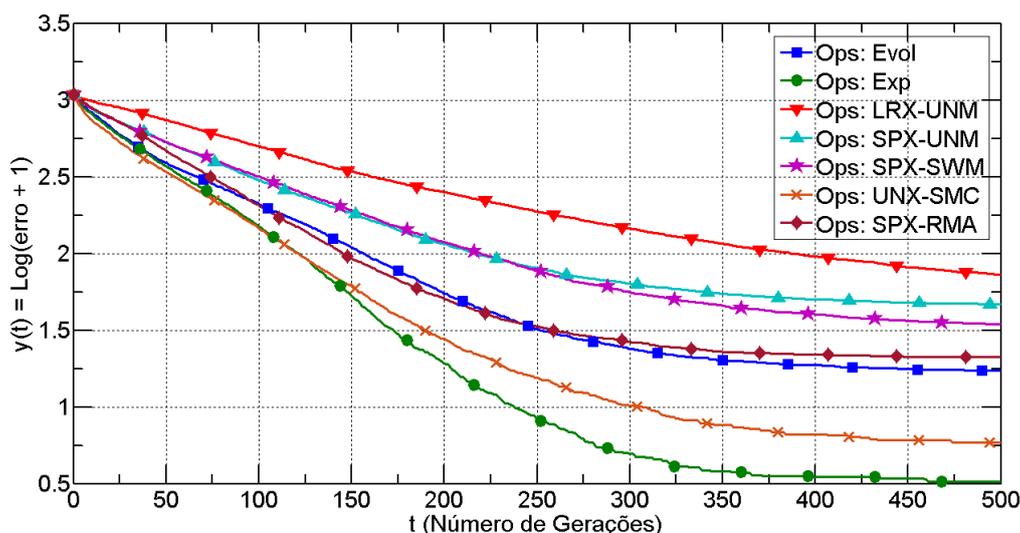


Figura 4.26: Gráfico de convergência comparando versões AES-TEP com multioperadores e com um único operador (estática) – Caso SBR “N-1” 20%.

4.5 CONSIDERAÇÕES FINAIS

Este capítulo teve como objetivo apresentar e discutir os resultados obtidos com a aplicação do algoritmo AES-TEP, o qual é proposto por este trabalho de tese para a resolução de problemas PET de longo prazo. Este algoritmo está baseado nos conceitos dos EAs com multioperadores de busca e utiliza um mecanismo dinâmico para adaptação das probabilidades de seleção de seus operadores. A formulação do PET está baseada numa modelagem estática e determinística, considera as perdas na transmissão e o critério de segurança “N-1”, e visa à minimização dos custos de investimento em novos equipamentos de transmissão. A fim de avaliar o desempenho do algoritmo proposto, o AES-TEP foi aplicado a oito problemas PET diferentes (chamados de casos de estudo), os quais foram definidos a partir de dois sistemas elétricos bastante conhecidos na literatura especializada: o sistema teste IEEE RTS-79 (IEEE24) e o Sistema Sul Brasileiro (SBR).

Primeiramente, os resultados apresentados neste capítulo demonstram a superioridade do algoritmo AES-TEP utilizando o grupo dos operadores especialistas. Assim, a utilização de heurísticas específicas aos sistemas elétricos, incorporadas nos operadores de busca estocásticos, parece ser uma estratégia bastante vantajosa ao processo de resolução dos problemas PET. Em todos os

casos estudados, verificou-se que a utilização dos operadores especialistas proporciona ao AES-TEP a obtenção de resultados significativamente melhores aos obtidos com o uso dos tradicionais operadores evolutivos (também chamados de operadores genéticos): encontraram-se planos de expansão de melhor qualidade, a um custo computacional inferior.

Em relação à estratégia adaptativa de seleção dos operadores de busca (estratégia AP para adaptação da taxa de utilização dos operadores), pode-se dizer que sua principal vantagem é a redução do custo computacional demandado pelo algoritmo AES-TEP, visto que utiliza-se o operador mais eficiente para cada estágio do processo de busca. Observa-se que, para a grande maioria dos casos estudados, a ativação do mecanismo adaptativo (i.e., parâmetros α e β diferentes de zero) proporcionou uma redução do tempo computacional demandado, seja para se obter uma execução de sucesso (TM_S) ou para a convergência do processo de busca (TM_C). Além disso, verifica-se que a utilização da estratégia adaptativa pode gerar melhoras nos índices de qualidade (IQ e ITT) e/ou na taxa de sucesso (TS).

Em todos os casos onde o AES-TEP utilizou os operadores especialistas, a ativação da estratégia adaptativa proporcionou melhoras no desempenho do algoritmo, aumentando a qualidade das soluções encontradas e, ao mesmo tempo, reduzindo o custo computacional do problema. Contudo, em parte dos casos estudados onde o AES-TEP utilizou os operadores evolutivos, principalmente nos casos PET para o SBR, além da redução do tempo computacional, a ativação da estratégia adaptativa também deteriorou levemente os índices de qualidade. Nestes casos (operadores evolutivos), é importante notar que as taxas de sucesso (TS) foram baixas: provavelmente, o aumento do tamanho da população fará a TS aumentar e assim permitir que a ativação da estratégia adaptativa possa gerar também ganhos nos índices de qualidade do algoritmo.

Na maioria dos casos de PET para o sistema IEEE24, a utilização do Algoritmo de Inicialização Inteligente (All) gerou bons resultados, reduzindo o custo computacional e melhorando os índices de qualidade do algoritmo AES-TEP: no

caso dos operadores evolutivos, estas melhoras foram mais significativas; já para os operadores especialistas, em alguns casos houve deterioração da qualidade dos planos. Especificamente para o IEEE24, a inicialização mista (metade aleatória e metade pelo All) obteve destaque, produzindo a melhor relação entre custo computacional e qualidade dos planos. Contudo, nos casos de PET para o sistema SBR, a utilização do All, seja a inicialização mista ou 100% inteligente, compromete muito o desempenho computacional do algoritmo, reduzindo significativamente os índices de qualidade e a taxa de sucesso. Estes resultados indicam que, para sistemas reais de médio ou grande porte, a estratégia de inicialização aleatória da população proporciona maior robustez ao processo de busca: a diminuição da diversidade genética gerada pelo All pode comprometer a capacidade do algoritmo de realizar busca global, ou seja, reduz a capacidade do algoritmo de exploração do espaço de busca do problema.

Ademais, os resultados apontam que a utilização de diversas estratégias de busca em um único EA (configuração esta chamada de multioperadores: utilização de múltiplos operadores de busca), aliada à estratégia adaptativa, apresenta grandes vantagens em relação aos tradicionais EAs estáticos utilizando um único operador de busca. Para a maioria dos casos estudados, observou-se que a versão AES-TEP multioperadores foi a que obteve os melhores resultados, principalmente para a versão utilizando os operadores especialistas. Além disso, o algoritmo AES-TEP se mostrou relativamente robusto em relação ao ajuste dos parâmetros de controle para seu sistema adaptativo: deve-se observar que, ao invés de se ajustar os valores de probabilidade para cada um dos operadores (12 valores para o grupo dos operadores evolutivos, e oito para o grupo dos especialistas), o usuário do algoritmo deve ajustar apenas dois parâmetros (α e β).

A partir dos resultados apresentados neste capítulo, pode-se concluir que o algoritmo proposto AES-TEP, na sua versão adaptativa e multioperadores, pode ser eficientemente aplicado ao problema PET, visto que é um algoritmo que apresenta desempenho superior aos tradicionais algoritmos evolutivos (estáti-

cos e com um único operador de busca). Este fato, aliado à sua robustez ao ajuste de parâmetros, demonstra que a ferramenta proposta é de fácil utilização e pode ser aplicada a um grande número de problemas de busca e otimização. Nesse sentido, independentemente da modelagem adotada para o problema PET, espera-se que o algoritmo proposto apresente um bom desempenho, tanto em relação à qualidade das soluções encontradas, como em relação ao custo computacional.

Vale salientar que, independentemente do problema PET a ser resolvido, o AES-TEP possui apenas quatro parâmetros a serem ajustados pelo usuário: α , β , N_{Pop} e T_{max} . Ademais, recomenda-se a utilização do grupo dos operadores especialistas e a inicialização aleatória da população; os parâmetros da estratégia adaptativa podem estar dentro das faixas: $0,2 \leq \alpha \leq 0,4$ e $0,5 \leq \beta \leq 0,9$.

CAPÍTULO 5

ASPECTOS COMPLEMENTARES

5.1 INTRODUÇÃO

A partir de um cenário futuro de demanda e geração de energia elétrica, o principal objetivo do PET (Planejamento da Expansão da Transmissão) é encontrar o melhor conjunto de reforços para o sistema de transmissão que garanta um adequado fornecimento de energia aos consumidores. Assim, de forma a satisfazer as necessidades do mercado de energia, a melhor solução para um determinado problema PET especifica onde e quantos equipamentos de transmissão devem ser instalados na rede elétrica. Numa abordagem multiestágio para o PET, o plano deve especificar também a cronologia das adições de reforços ao sistema. Contudo, além de possuir o menor custo de investimento possível, a solução ótima para um problema PET real deve atender a certas especificações de qualidade e segurança nos serviços [LRM11, HHK13].

Atualmente, a resolução de problemas PET para sistemas de transmissão reais é uma tarefa de otimização combinatória estocástica altamente complexa [HHK13]. Devido às grandes dimensões dos atuais sistemas, ao mercado de energia competitivo e às incertezas envolvidas na modelagem matemática do problema (e.g., crescimento da carga e da geração, novos tipos e a localização de geradores, comportamento aleatório dos equipamentos de transmissão e geração, entre outras), a solução ótima do PET se torna quase inacessível. Mesmo quando as incertezas são desconsideradas, a complexidade em termos de dados, modelos e custo computacional ainda se mostra bastante elevada, especialmente se a cronologia da adição dos reforços é considerada [LRM11].

Técnicas de otimização baseadas em meta-heurísticas têm demonstrado ser uma excelente ferramenta na resolução de problemas PET para sistemas de

médio e grande porte, encontrando soluções de alta qualidade com um custo computacional relativamente baixo [HHK13]. A grande vantagem destas técnicas é a capacidade de realizar busca global, evitando ótimos locais e explorando eficientemente o espaço de busca do problema. Diversos algoritmos têm sido propostos para o problema PET, como por exemplo: *Genetic Algorithms* (GA) [SRRGM05, SA15], *Evolution Strategies* (ES) [LSRMSR06], *Differential Evolution* (DE) [DLLW06], *Artificial Immune Systems* (AIS) [RLH09], e *Adaptive Evolutionary Systems* (AES) [LFH16]. Meta-heurísticas baseadas nos GA, ES, DE, AIS e AES fazem parte da família dos Algoritmos Evolutivos (EA), pois utilizam algum método probabilístico para simular o processo de evolução natural das espécies [ES03].

Tradicionalmente, de forma a garantir os critérios de segurança, os problemas PET têm sido resolvidos através de modelos determinísticos tais como os conhecidos “N-1” e “N-2” [SRRGM05, TGS08]. Em muitos casos, entretanto, os planos obtidos por estes modelos podem levar a altos custos de investimento. Por outro lado, embora modelos probabilísticos [LMMB00, ML04] sejam capazes de medir adequadamente a qualidade de um sistema de transmissão, ainda não existe uma definição de quão confiável um sistema deve ser baseado em índices de confiabilidade tais como LOLE (*Loss of Load Expectation*), EPNS (*Expected Power not Supplied*), ou LOLC (*Loss of Load Cost*), principalmente porque estes índices são dependentes, por exemplo, do modelo de carga adotado, das ações corretivas em caso de contingência, entre outros. Uma vez que as companhias elétricas não chegam a um consenso sobre este assunto, os modelos determinísticos têm sido preferidos em relação aos probabilísticos [LRM11].

Como foi discutido no Capítulo 1, sabe-se que, independentemente do modelo matemático adotado, é importante que a metodologia escolhida para a resolução do problema PET forneça ao planejador um conjunto de boas alternativas para expansão do sistema, ao invés de uma única solução (ótimo global ou local). A partir do conjunto dos melhores planos encontrados para um determinado problema PET, o planejador deverá realizar uma rigorosa análise técnica visando escolher o plano de expansão com o melhor custo/benefício para a

sociedade: programas de fluxo de potência não-linear (fluxo AC), análise de curto-circuito, análise do nível de confiabilidade, estudo de estabilidade transitória, entre outros, são algumas das ferramentas computacionais que podem ser utilizadas nesta tarefa [LRM11].

Um plano de expansão que proporciona o menor custo de investimento pode não apresentar a melhor relação custo/benefício quando avaliado por algum índice de confiabilidade, nível de perdas ôhmicas, critérios de segurança, impacto ambiental, ou até mesmo políticas de investimento público. Além disso, a opção por um plano com o menor custo pode, futuramente, demandar gastos adicionais em equipamentos, tornando-o inviável ou até mesmo economicamente desinteressante: por exemplo, a necessidade de suporte de potência reativa e a regulação de tensão podem aumentar o custo do investimento.

O algoritmo proposto por este trabalho de tese, chamado de AES-TEP [LFH16], foi baseado nos EAs e convenientemente adaptado para manter em sua população apenas soluções distintas. Esta característica, aliado à estratégia de substituição de indivíduos (um novo indivíduo substitui o indivíduo que estiver mais próximo - vide Capítulo 3), visa preservar a diversidade genética da população e, assim, evitar a convergência prematura do algoritmo. Contudo, uma característica adicional foi obtida: a busca simultânea por soluções ótimas e subótimas, fornecendo ao usuário do algoritmo um conjunto com os melhores planos encontrados para o PET. Ao final do processo de busca, o algoritmo entrega ao usuário as 10 melhores soluções encontradas para o problema.

Assim, o presente capítulo tem como objetivo verificar se existe alguma vantagem em se fornecer ao planejador do sistema um conjunto de boas soluções, ao invés de uma única solução para o problema PET. Neste sentido, para os casos estudados pelo Capítulo 4 aonde se considera o critério de segurança “N-1” (tradicional e relaxado), estudos de confiabilidade e de compensação reativa serão realizados com os planos de expansão presentes nos conjuntos dos 10 melhores planos conhecidos para cada problema. Ao final, uma análise de custos será realizada para cada um dos sistemas de transmissão estudados, objetivando assim definir a melhor opção de investimento.

5.2 ESTUDO DE CONFIABILIDADE

Esta seção tem como objetivo avaliar a confiabilidade dos melhores planos de expansão encontrados para os casos: IEEE24 “N-1” 0%, IEEE24 “N-1” 10%, IEEE24 “N-1” 20%, SBR “N-1” 0%, SBR “N-1” 10% e SBR “N-1” 20%. A partir da definição dos conjuntos dos 10 melhores planos para cada caso estudado (vide Capítulo 4, Tabelas 4.6, 4.10, 4.14, 4.23, 4.27 e 4.31), realizou-se a avaliação da confiabilidade do sistema de transmissão via Simulação Monte Carlo Não Sequencial (MCS – *Non-Sequential Monte Carlo Simulation*) [LMMB00, ML04]. Todos os dados topológicos e estocásticos que foram utilizados neste estudo estão apresentados no Apêndice A.

A valoração numérica de indicadores de confiabilidade permite ao planejador realizar a diagnose do sistema em estudo; os índices de confiabilidade possuem três atributos fundamentais: frequência de eventos, duração de eventos e severidade de eventos. Os índices tradicionalmente utilizados em análises de confiabilidade são [LMMB00, ML04]:

1. PPS - Probabilidade de Problemas no Sistema;
2. LOLP - Probabilidade de Perda de Carga;
3. LOLE - Expectativa de Perda de Carga (horas/ano);
4. LOLC - Custo de Perda de Carga (US\$/ano);
5. LOLF - Frequência de Perda de Carga (ocorrências/ano);
6. LOLD - Duração de Perda de Cargas (horas);
7. EPNS - Valor Esperado de Potência Não Suprida (MW);
8. EENS - Valor Esperado de Energia Não Suprida (MWh/ano);
9. SEV - Índice de Severidade (minutos/ano).

Este último índice, SEV, é calculado como $SEV = (60 \times EENS) / \text{Carga Pico (MW)}$, e visa exprimir um tempo fictício de uma perturbação imaginária que seria necessária para acumular uma energia não suprida exatamente equivalente àquela calculada, se toda a carga do sistema, na condição de pico anual, fosse afetada. Este índice serve como balizador de referência para diagnose do risco preditivo probabilístico dos sistemas em estudo: é um índice normalizado e, portanto, um indicador relativo que permite a comparação de sistemas de por-

tes e naturezas distintas. Ademais, o SEV é um dos poucos indicadores probabilísticos que já dispõe de uma escala internacional de valoração classificatória, mostrada na Tabela 5.1 [FBG89].

Tabela 5.1: Classificação do Nível do Risco pela Severidade (SEV).

Classificação	Severidade (min/ano)	Interpretação	Comentário
Grau 0	$SEV < 1$	Favorável	Condição operativa de baixíssimo risco
Grau 1	$1 \leq SEV < 10$	Satisfatório	Condição operativa de baixo risco
Grau 2	$10 \leq SEV < 100$	Limítrofe	Condição operativa de risco médio
Grau 3	$100 \leq SEV < 1000$	Grave	Sério impacto para alguns agentes consumidores
Grau 4	$SEV \geq 1000$	Muito Grave	Sério impacto para muitos agentes consumidores

O fluxograma da Figura 5.1 apresenta, de forma simplificada, as principais etapas da metodologia utilizada para a avaliação da confiabilidade [LMMB00]:

1. Definir o espaço de estados a ser analisado, o que depende: dos dados determinísticos e probabilísticos para o sistema, da escolha do nível hierárquico (análise da geração e transmissão ou apenas transmissão), do modelo de carga adotado (carga pico ou curva horária), dos níveis de tensão e das áreas do sistema que serão consideradas;
2. Selecionar um estado operativo para o sistema (estado de operação para os elementos de transmissão e/ou geração), onde a técnica utilizada é a MCS: os estados de contingência são selecionados por amostragem (seleção aleatória); o nível de contingência não é limitado, e contingências de ordens mais elevadas podem ser obtidas (“N-2”, “N-3”, etc.); os resultados obtidos representam estimativas para o comportamento real do sistema;
3. Executar o módulo de fluxo de potência DC para o sistema, avaliando o desempenho do estado operativo (buscar por violação dos limites de fluxo nas linhas ou transformadores, ilhamentos de cargas, cortes de carga, etc.);
4. Verificar se existe alguma violação para o estado: caso sim, o estado operativo é considerado como estado de falha, e o algoritmo segue para

- próxima etapa; caso contrário, o estado é um estado de sucesso e volta-se à etapa 2;
5. Executar o módulo de Fluxo de Potência Ótimo DC (FPO DC) buscando encontrar o corte de carga mínimo para o estado: como medida corretiva, permite-se ainda ao sistema o redespacho total de potência ativa;
 6. Verificar se após o FPO DC existe algum corte de carga no sistema: caso sim, o estado operativo é considerado como estado de falha e segue-se à próxima etapa; caso contrário, o estado é um estado de sucesso e volta-se à etapa 2;
 7. Estimar os valores para os índices de confiabilidade do sistema em questão (PPS, LOLP, LOLE, EENS, etc.); é importante notar que apenas os estados de falhas são utilizados para o cálculo dos índices de confiabilidade;
 8. Se a precisão especificada para os índices é alcançada (adotou-se um coeficiente de variação $\beta = 3\%$ para o índice EENS), o algoritmo é finalizado, caso contrário, volta-se à etapa 2.

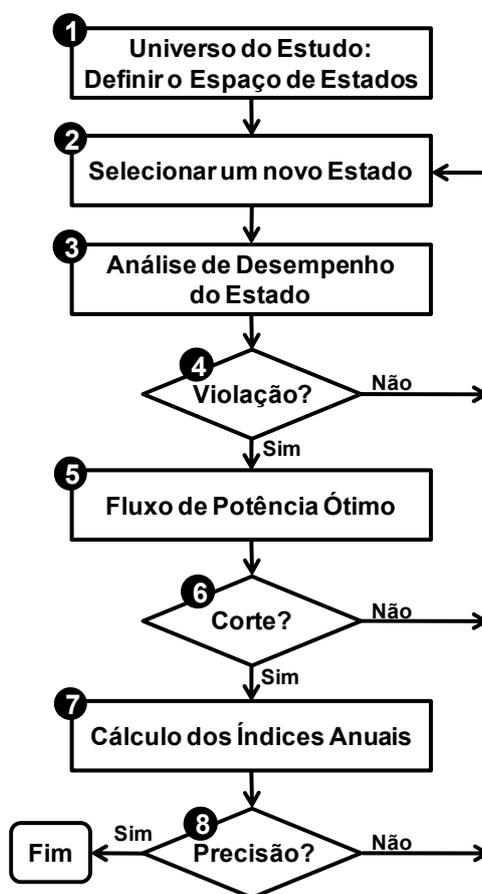


Figura 5.1: Fluxograma simplificado para o algoritmo de avaliação da confiabilidade.

Por fim, neste trabalho considerou-se na análise de confiabilidade apenas o sistema de transmissão (não se permite contingências/falhas para a geração), todos os níveis de tensão presentes nos sistemas estudados e o modelo de curva de carga constante (patamar de carga pesada/pico: utilizam-se os mesmos valores do planejamento da expansão da transmissão). Através do programa REAL (*Reliability Analysis of Power Systems*) [REAL99], todos os nove índices de confiabilidade que estão listados acima foram estimados para os planos analisados. Contudo, nas tabelas a seguir, optou-se pela utilização dos seguintes índices de confiabilidade: PPS, LOLP, LOLF, EENS e SEV.

5.2.1 Avaliação da Confiabilidade para o Sistema IEEE RTS-79

A Tabela 5.2 apresenta os índices de confiabilidade estimados para os 10 melhores planos de expansão conhecidos para o caso IEEE24 “N-1” 0% (Caso 2): a Tabela 4.6 apresenta os reforços adicionados para cada um destes planos; para identificação dos planos, utiliza-se a sua classificação (“Plano N.”), seu custo de investimento (“Custo”), e o total das perdas ativas para o modelo DC (“Perdas”). Neste caso, o algoritmo de avaliação da confiabilidade analisou, em média, aproximadamente $2,2 \times 10^7$ estados para cada um dos planos.

Tabela 5.2: Índices de confiabilidade para o caso IEEE24 “N-1” 0% (Caso 2).

Plano N.	Custo (10 ⁶ US\$)	Perdas (MW)	PPS (×10 ⁻⁴)	LOLP (×10 ⁻⁴)	LOLF (×10 ⁻² oc./ano)	EENS (MWh/ano)	SEV (min/ano)
1	681	138,90	0,876	0,691	3,204	56,58	0,397
2	681	138,98	0,886	0,639	3,141	57,59	0,404
3	681	139,01	0,950	0,707	3,122	63,70	0,447
4	681	139,18	0,867	0,672	2,972	57,12	0,401
5	681	139,20	1,011	0,680	3,682	67,26	0,472
6	681	139,21	0,899	0,702	3,602	68,48	0,481
7	681	139,39	0,997	0,692	3,264	61,58	0,432
8	681	139,47	0,867	0,599	2,979	66,07	0,464
9	681	139,83	1,039	0,692	3,770	68,78	0,483
10	681	139,91	1,054	0,687	3,484	68,21	0,479

Pode-se observar na Tabela 5.2 que, de acordo com a classificação estabelecida pela Tabela 5.1, todos os planos estão classificados como Grau 0 (Favorável), possuindo então uma condição operativa de baixíssimo risco. Observa-

se ainda que todos os planos possuem o mesmo custo de investimento e seus índices de confiabilidade estão relativamente próximos, o que dificulta a escolha do melhor plano para o caso. Em termos dos índices PPS, LOLP e LOLF, o plano 8 se destaca como o melhor plano para a expansão do sistema, tendo como forte concorrente o plano 4; já em termos da EENS e das perdas, o plano 1 se destaca: provavelmente será o plano com o menor custo de interrupção de energia e de perdas ôhmicas.

Na Tabela 5.3 apresentam-se os índices de confiabilidade obtidos para os 10 melhores planos de expansão conhecidos para o caso IEEE24 “N-1” 10% (Caso 3): na Tabela 4.10 estão detalhados todos os reforços adicionados para cada um destes planos. Neste caso, o algoritmo de avaliação da confiabilidade MCS analisou, em média, aproximadamente $1,6 \times 10^6$ estados para cada um dos planos de expansão estudado.

Tabela 5.3: Índices de confiabilidade para o caso IEEE24 “N-1” 10% (Caso 3).

Plano N.	Custo (10^6 US\$)	Perdas (MW)	PPS ($\times 10^{-2}$)	LOLP ($\times 10^{-2}$)	LOLF (oc./ano)	EENS (MWh/ano)	SEV (min/ano)
1	551	148,50	1,579	0,680	0,095	1427,2	10,02
2	589	158,77	1,306	0,747	0,505	1909,7	13,40
3	591	154,40	0,687	0,397	0,509	1458,8	10,24
4	591	158,31	0,935	0,687	1,306	5038,1	35,36
5	594	155,04	0,559	0,277	0,850	975,8	6,848
6	596	165,00	1,450	0,468	1,088	1576,0	11,06
7	597	165,07	1,449	0,466	1,060	1537,6	10,79
8	598	150,27	1,536	0,015	0,079	144,0	1,011
9	599	150,40	0,653	0,513	0,086	2087,9	14,65
10	599	150,68	0,502	0,361	0,089	2408,5	16,90

Pode-se observar na Tabela 5.3 que, de acordo com a classificação proposta pela Tabela 5.1, os planos 5 e 8 estão classificados como Grau 1 (Satisfatório: condição operativa de baixo risco), e o restante dos planos estão classificados com Grau 2 (Limítrofe: condição operativa de risco médio). Para o planejador deste sistema, pode ser mais interessante a escolha do plano 8 como o melhor plano de expansão: em relação ao plano 1 (mais barato), o plano 8 possui um custo de investimento 8,5% maior e uma EENS quase 10 vezes menor, o que significa um menor custo de interrupção de energia; além disso, o plano 8 se

destaca em termos dos índices LOLP, LOLF e SEV. Pode-se observar ainda que o plano 1 possui o maior valor para a PPS, ou seja, é o plano com a maior probabilidade de problemas na operação.

Por fim, na Tabela 5.4 apresenta-se os índices de confiabilidade obtidos para os 10 melhores planos de expansão conhecidos para o caso IEEE24 “N-1” 20% (Caso 4): na Tabela 4.14 estão detalhados todos os reforços adicionados para cada um destes planos. Neste caso, o algoritmo de avaliação da confiabilidade MCS analisou, em média, aproximadamente $2,0 \times 10^5$ estados para cada um dos planos de expansão estudado. Pode-se observar que, com o aumento do relaxamento do critério “N-1”, o número de estados de falha aumenta, necessitando assim da avaliação de um menor número de estados (falha e sucesso) para a estimação dos índices.

Tabela 5.4: Índices de confiabilidade para o caso IEEE24 “N-1” 20% (Caso 4).

Plano N.	Custo (10 ⁶ US\$)	Perdas (MW)	PPS ($\times 10^{-2}$)	LOLP ($\times 10^{-2}$)	LOLF (oc./ano)	EENS (MWh/ano)	SEV (min/ano)
1	461	162,31	1,531	1,245	1,593	17553	123,2
2	486	170,56	1,083	0,828	2,494	4340	30,46
3	490	172,56	1,421	0,893	2,977	5802	40,71
4	492	160,96	0,797	0,505	1,405	3722	26,12
5	492	167,41	1,277	1,021	2,602	5897	41,38
6	493	156,32	1,380	1,224	1,611	16971	119,1
7	496	169,52	1,420	1,059	2,968	6950	48,77
8	498	157,37	0,743	0,522	1,396	3878	27,22
9	498	157,61	0,886	0,507	1,407	4544	31,89
10	499	160,90	0,842	0,518	1,407	3082	21,63

De acordo com a classificação proposta pela Tabela 5.1, pode-se observar na Tabela 5.4 que a maioria dos planos está classificada com Grau 2 (Limítrofe: condição operativa de risco médio); apenas os planos 1 e 6 estão classificados com Grau 3 (Grave: risco grave para alguns agentes), o que os torna muito desinteressantes. Para o planejador deste sistema, pode ser mais vantajoso a escolha do plano 4 como o melhor plano de expansão: em relação ao plano mais barato (plano 1), o plano 4 possui um custo de investimento 6,7% maior, com uma EENS aproximadamente 5 vezes menor (20% do custo de interrupção de energia); além disso, o plano 4 se destaca em termos dos índices PPS, LOLP, LOLF e SEV. Pode-se observar ainda que o plano 1 possui o maior va-

lor para a PPS, ou seja, é o plano com a maior probabilidade de problemas na operação.

5.2.2 Avaliação da Confiabilidade para o Sistema Sul Brasileiro

A Tabela 5.5 apresenta os índices de confiabilidade estimados para os 10 melhores planos de expansão conhecidos para o caso SBR “N-1” 0% (Caso 6): a Tabela 4.23 apresenta os reforços adicionados para cada um destes planos; para identificação dos planos, utiliza-se a sua classificação (“Plano N.”), seu custo de investimento (“Custo”), e o total das perdas ativas para o modelo DC (“Perdas”). Neste caso, o algoritmo de avaliação da confiabilidade analisou, em média, aproximadamente $9,9 \times 10^6$ estados para cada um dos planos.

Tabela 5.5: Índices de confiabilidade para o caso SBR “N-1” 0% (Caso 6).

Plano N.	Custo (10 ⁶ US\$)	Perdas (MW)	PPS (×10 ⁻⁴)	LOLP (×10 ⁻⁴)	LOLF (×10 ⁻¹ oc./ano)	EENS (MWh/ano)	SEV (min/ano)
1	239,02	184,78	4,990	1,489	3,287	441,77	3,853
2	239,43	185,02	5,126	1,527	3,418	448,03	3,907
3	240,23	181,11	4,544	1,281	1,764	410,28	3,578
4	240,64	181,36	4,702	1,300	1,829	417,29	3,639
5	242,56	181,90	4,560	1,297	2,071	411,76	3,591
6	242,96	182,15	4,726	1,307	1,870	410,26	3,578
7	245,09	176,04	4,679	1,303	1,808	414,08	3,611
8	246,46	179,11	5,137	1,519	3,586	443,52	3,868
9	247,12	184,10	3,285	2,214	4,409	578,05	5,041
10	247,41	176,84	4,729	1,319	2,006	406,95	3,549

Pode-se observar na Tabela 5.5 que, de acordo com a classificação proposta pela Tabela 5.1, todos os planos do Caso 6 estão classificados como de Grau 1 (Satisfatório), possuindo então uma condição operativa de baixo risco. Observa-se ainda que, em termos do índice PPS (probabilidade de problemas no sistema), o plano 9 se destaca como o melhor; contudo, este plano possui o pior valor para o índice EENS, e provavelmente terá o maior custo de interrupção de energia, o que o torna desinteressante em relação aos demais. Já o plano 3 seria uma boa opção ao planejador do sistema: em relação ao plano 1 (menor custo), o plano 3 gera um aumento de apenas 0,5% no custo do investimento e ainda se destaca em relação os índices PPS, LOLP, LOLF e EENS.

Na Tabela 5.6 apresentam-se os índices de confiabilidade obtidos para os 10 melhores planos de expansão conhecidos para o caso SBR “N-1” 10% (Caso 7): na Tabela 4.27 estão detalhados todos os reforços adicionados para cada um destes planos. Para este caso, o algoritmo de avaliação da confiabilidade MCS analisou, em média, aproximadamente $9,5 \times 10^6$ estados para cada um dos planos de expansão estudado.

Tabela 5.6: Índices de confiabilidade para o caso SBR “N-1” 10% (Caso 7).

Plano N.	Custo (10 ⁶ US\$)	Perdas (MW)	PPS (×10 ⁻³)	LOLP (×10 ⁻³)	LOLF (×10 ⁻¹ oc./ano)	EENS (MWh/ano)	SEV (min/ano)
1	231,95	184,89	2,081	0,141	2,767	423,20	3,691
2	232,35	185,14	2,099	0,150	3,120	440,47	3,841
3	233,21	184,91	1,034	0,177	4,408	446,03	3,890
4	233,62	185,16	1,047	0,184	4,594	464,53	4,051
5	234,02	184,65	2,440	0,152	3,420	444,60	3,877
6	234,47	180,55	4,304	0,151	3,323	447,95	3,907
7	234,93	184,75	1,032	0,177	4,284	448,94	3,915
8	235,28	184,67	1,388	0,186	4,863	471,50	4,112
9	235,33	185,00	1,048	0,183	4,710	474,42	4,137
10	235,74	180,57	3,258	0,188	5,151	467,58	4,078

Pode-se observar na Tabela 5.6 que, de acordo com a classificação estabelecida pela Tabela 5.1, todos os planos estão classificados como Grau 1 (Satisfatório), possuindo então uma condição operativa de baixo risco. Verifica-se ainda que, para o planejador deste sistema, o plano 1 parece ser bastante vantajoso, pois, além de possuir o menor custo de investimento, apresenta o melhor índice EENS e ainda se destaca em termos da LOLP, LOLF e SEV. Como opção, o planejador pode escolher o plano 3: com um aumento de 0,5% no custo do investimento, este plano se destaca em termos da PPS, LOLP e SEV, sem deteriorar muito a EENS.

Comparando os planos da Tabela 5.5 com os da Tabela 5.6, pode-se observar a vantagem da utilização do critério de segurança “N-1” relaxado: apesar da redução do número de reforços quando se relaxa o critério “N-1” de 0% para 10%, os valores para o índice SEV nas duas tabelas ficaram próximos. Em relação ao plano 1 da Tabela 5.5 (“N-1” tradicional), pode observar que o plano 1 da Tabela 5.6 (“N-1” relaxado a 10%) se mostra com um plano bastante vanta-

joso: apresenta menor custo de investimento (redução de 3%) e menor valor de EENS (provavelmente terá um menor custo de interrupção de energia).

Por fim, na Tabela 5.7 apresenta-se os índices de confiabilidade obtidos para os 10 melhores planos de expansão conhecidos para o caso SBR “N-1” 20% (Caso 8): na Tabela 4.31 estão detalhados todos os reforços adicionados para cada um destes planos. Neste caso, o algoritmo de avaliação da confiabilidade MCS analisou, em média, aproximadamente $1,4 \times 10^6$ estados para cada um dos planos de expansão estudado. Pode-se observar que, com o aumento do relaxamento do critério “N-1”, o número de estados problemáticos (estados de falha) tende a aumentar, necessitando assim da avaliação de um menor número de estados para a estimação dos índices.

Tabela 5.7: Índices de confiabilidade para o caso SBR “N-1” 20% (Caso 8).

Plano N.	Custo (10 ⁶ US\$)	Perdas (MW)	PPS (×10 ⁻²)	LOLP (×10 ⁻²)	LOLF (oc./ano)	EENS (MWh/ano)	SEV (min/ano)
1	206,69	205,77	2,908	1,183	30,66	3315,0	28,91
2	209,02	205,06	2,709	0,975	23,70	2706,6	23,60
3	211,64	191,06	1,509	0,174	13,66	1601,1	13,96
4	212,56	205,14	2,781	1,128	26,09	3146,4	27,44
5	214,88	204,43	2,593	0,922	19,33	2520,9	21,98
6	215,02	191,08	1,501	0,175	13,61	1758,3	15,33
7	215,43	191,66	1,504	0,177	13,80	1811,4	15,80
8	215,58	188,02	1,393	0,075	4,985	777,9	6,784
9	216,04	206,61	2,922	1,201	33,23	3029,2	26,42
10	217,49	189,71	0,416	0,169	13,48	1610,5	14,05

De acordo com a classificação proposta pela Tabela 5.1, pode-se observar na Tabela 5.7 que a grande maioria dos planos está classificada com Grau 2 (Limítrofe: condição operativa de risco médio); apenas o plano 8 está classificados como Grau 1 (Satisfatório: condição operativa de baixo risco). Para o planejador deste sistema, parece ser mais interessante a escolha do plano 8 como o melhor plano de expansão: em relação ao plano mais barato (plano 1), o plano 8 possui um custo de investimento 4,3% maior e uma EENS aproximadamente 4,3 vezes menor (menor custo de interrupção de energia); além disso, o plano 8 se destaca em todos os índices: PPS, LOLP, LOLF, EENS e SEV. Pode-se observar ainda que o plano 1 possui um das piores PPS (maior probabi-

lidade de problemas na operação do sistema) e a pior EENS (maior custo de interrupção de energia).

5.3 ESTUDO DE COMPENSAÇÃO REATIVA

A presente seção tem como objetivo realizar um estudo de compensação de reativos para os conjuntos dos 10 melhores planos de expansão da transmissão encontrados nos casos IEEE24 “N-1” 0%, 10% e 20%, e SBR “N-1” 0%, 10% e 20%, os quais estão listados nas Tabelas 4.6, 4.10, 4.14, 4.23, 4.27 e 4.31 (Capítulo 4). Para tanto, adotou-se uma abordagem que considera a alocação ótima de bancos de capacitores *shunt* nas barras de carga do sistema [Q14], visando assim obter, para cada um dos planos encontrados para o PET, um plano de alocação ótima de reativos que minimiza a quantidade de potência reativa (MVar) necessária a uma adequada operação do sistema elétrico. Sujeito às principais restrições operativas do sistema de transmissão, e considerando apenas a operação em regime permanente da rede intacta (não considera contingências), o plano ótimo deve indicar a localização das barras e a quantidade de bancos que devem ser adicionados ao sistema.

Os bancos de capacitores *shunt* são amplamente utilizados para o planejamento de curto prazo do sistema de transmissão, e seu comportamento no modelo matemático deve ser representado por variáveis discretas (são comutados por meio de chaves mecânicas ou disjuntores) [Q14]. Estes bancos são conjuntos de capacitores ligados em blocos e instalados, geralmente, em uma subestação com carga, provendo o suporte de tensão por injeção de potência reativa no sistema elétrico. O fornecimento de potência reativa dos capacitores é proporcional ao quadrado da tensão na barra. Neste trabalho, se considera que o custo de investimento para a compensação de reativos via bancos de capacitores é proporcional da quantidade de MVar adicionados ao sistema (no valor nominal: MVar injetado para a tensão de 1,0 p.u.), o que por sua vez vai depender dos tamanhos dos bancos (susceptância *shunt*) e da quantidade de bancos alocados.

Baseado em um modelo de fluxo de potência AC, o problema global para o Planejamento Ótimo da Alocação de Reativos (POAR) é classificado como um problema de Programação Não Linear Inteiro Misto (PNLIM) [GRRG09]. Semelhantemente à modelagem adotada para o problema PET (vide Capítulo 3), visando resolver o problema POAR via meta-heurística EA, este problema pode ser desacoplado em dois subproblemas: Subproblema de Alocação de Reativos (SPAR) e Subproblema de Operação (SPO_{AC}). O SPAR é um problema de otimização combinatória que tem por objetivo a minimização do total de reativo alocado no sistema (soma do MVAR nominal adicionados pelos bancos de capacitores), restrito ao completo atendimento da demanda futura por potência ativa e reativa. Já no SPO_{AC} , para um determinado plano de alocação candidato (quantidade e localização dos bancos), resolve-se um problema de Programação Não Linear (PNL) com o objetivo de encontrar o estado ótimo de operação do sistema (despacho dos geradores, módulo e ângulo das tensões nas barras) que minimize os custos de geração e de corte de carga nas barras. Assim, define-se o SPAR da seguinte forma:

$$\text{Min } f(q) = \sum_{k \in \Gamma} (q_k b_k) \quad (5.1)$$

sujeito a:

$$\begin{cases} cc(q) = 0 \\ 0 \leq q_k \leq q_k^{max} \end{cases} \quad (5.2)$$

onde:

- q é o vetor plano de alocação de reativos (solução candidata para o POAR), e seu elemento q_k representa o número de bancos de capacitores *shunt* adicionados na barra k ;
- $f(q)$ é o total de MVAR alocado no sistema pelo plano q , o qual se deseja minimizar (função objetivo do problema POAR);
- q_k^{max} é o número máximo de bancos que podem ser adicionados na barra k ;
- b_k é a susceptância *shunt* nominal (tamanho do banco) para cada um dos bancos alocados na barra k (MVAR);
- Γ é o conjunto de todas as barras do sistema de transmissão;

- $cc(q)$ é total de corte de carga para a rede intacta (potência ativa mais reativa), tal que: $cc(q) = \sum (P_{R,k} + |Q_{R,k}|)$; $P_{R,k}$ e $Q_{R,k}$ são, respectivamente, o corte de carga ativa e o corte de carga reativa para a barra k : estes valores são obtidos a partir da resolução do SPO_{AC} (definido a seguir).

Para o SPAR, o plano q representa o conjunto das variáveis de decisão do problema (apenas valores inteiros), o que define o seu espaço de busca como: $0 \leq q_k \leq q_k^{max}$. Ademais, para que um plano q seja considerado factível, o mesmo deve possuir corte de carga nulo para todas as barras do sistema, ou seja: $cc(q) = 0$. A avaliação de um plano candidato q (indivíduo para o EA) é feita de maneira iterativa: primeiro se resolve o SPO_{AC} para o plano, depois se calcula o valor da função objetivo dada pela Eq. 5.1 e se define a factibilidade do plano através da Eq. 5.2.

Defini-se o SPO_{AC} como um problema de Fluxo de Potência Ótimo AC (FPO AC), também chamado de despacho econômico, onde o objetivo é encontrar o estado operativo do sistema elétrico que minimiza o custo total de geração e corte de carga (potência ativa mais reativa). Para este problema, o plano candidato q é fixo, ou seja, não é uma variável de decisão e sim um dado de entrada. Desta forma, pode-se formular o SPO_{AC} como um problema PNL, tal que:

$$\text{Min } C_{Op}(q) = \sum_{k \in \Gamma} \{cg_k(P_{G,k} + |Q_{G,k}|) + cr_k(P_{R,k} + |Q_{R,k}|)\} \quad (5.3)$$

sujeito a:

$$\left\{ \begin{array}{l} P(V, \theta) - P_G - P_R + P_D = 0 \\ Q(V, \theta, q) - Q_G - Q_R + Q_D = 0 \\ S^{DE}(V, \theta) \leq S^{max} \\ S^{PARA}(V, \theta) \leq S^{max} \\ V^{min} \leq V \leq V^{max} \\ P_G^{min} \leq P_G \leq P_G^{max} \\ Q_G^{min} \leq Q_G \leq Q_G^{max} \\ 0 \leq P_R \leq P_D \\ 0 \leq |Q_R| \leq |Q_D| \end{array} \right. \quad (5.4)$$

onde:

- $C_{Op}(q)$ é a função objetivo do SPO_{AC} , chamada de custo operacional: custo total da geração e do corte de carga para o plano q ;
- cg_k é o custo de geração de potência ativa ou reativa na barra k ;
- cr_k é o custo do corte de carga (ativa ou reativa) para a barra k ;
- $P(V,\theta)$ é o vetor de potência ativa (MW) injetada nas barras do sistema;
- $Q(V,\theta,q)$ é o vetor de potência reativa (MVar) injetada nas barras, já considerando o reativo injetado pelos bancos de capacitores do plano q ;
- P_G e Q_G são, respectivamente, os vetores de potência ativa (MW) e reativa (MVar) fornecida pelos geradores do sistema (despacho dos geradores);
- P_R e Q_R são, respectivamente, os vetores de potência ativa (MW) e reativa (MVar) fornecida pelos geradores fictícios: corte de carga ativa e reativa;
- P_D e Q_D são, respectivamente, os vetores de potência ativa (MW) e reativa (MVar) demandada pelas cargas do sistema;
- $S^{DE}(V,\theta)$ e $S^{PARA}(V,\theta)$ são os vetores de fluxo de potência aparente (MVA) pelos ramos do sistema, considerando os valores injetados em cada uma das barras terminais (barras DE e PARA) ;
- S^{max} é o vetor com o limite máximo permitido para o fluxo de potência aparente (MVA) nos ramos do sistema;
- V e θ são, respectivamente, os vetores de módulo e o ângulo das tensões nas barras do sistema (módulo em p.u. e ângulo em radiano);
- V^{max} e V^{min} são, respectivamente, vetores com os limites máximos e mínimos para o módulo das tensões das barras; neste trabalho, adotou-se a seguinte restrição: $0,95 \leq V \leq 1,05$ p.u.;
- P_G^{max} e P_G^{min} são, respectivamente, vetores com as capacidades máximas e mínimas para a geração de potencia ativa (MW);
- Q_G^{max} e Q_G^{min} são, respectivamente, vetores com as capacidades máximas e mínimas para a geração de potencia reativa (MVar).

Neste modelo, os vetores $P(V, \theta)$ e $Q(V, \theta, q)$ fazem parte das tradicionais equações de fluxo de potência AC [M83]. Além disso, um ponto importante deste modelo é a adição do custo de geração cg_k , pois é através dele que se define a “ordem de mérito” para o redespacho dos geradores. Os custos do corte de carga cr_k são ajustados com valores significativamente maiores que cg_k , de modo a forçar a minimização do corte (FPO AC de mínimo corte).

Dado os melhores planos conhecidos para a expansão da transmissão (planos PET), busca-se nesta seção definir para cada um deles um plano ótimo de alocação de reativos (plano POAR). Para realizar esta tarefa, utilizou-se uma adaptação do algoritmo AES-TEP para resolver o problema SPAR, onde: 1) apenas os operadores evolutivos foram considerados; 2) a inicialização da população foi feita de forma totalmente aleatória; e 3) ao fim do processo evolutivo, o algoritmo retorna a melhor solução que foi encontrada para o problema. Além disso, informa-se que, para realizar as simulações necessárias aos estudos desta seção, utilizou-se as bibliotecas MATPOWER [ZM15] (para modelagem da rede AC) e IPOPT (para resolução dos problemas PNL), via software MATLAB, para resolver os problemas SPO_{AC} decorrentes das avaliações de planos de alocação de reativos candidatos. Todos os dados para os sistemas de transmissão estudados neste trabalho estão apresentados no Apêndice A.

5.3.1 Alocação de Banco de Capacitores para o Sistema IEEE RTS-79

Nos problemas de POAR para o sistema IEEE RTS-79, casos IEEE24 “N-1” 0%, 10% e 20%, consideram-se as seguintes barras candidatas à compensação reativa via bancos de capacitores *shunt*: 3, 4, 5, 8, 9, 10, 11, 12, 17, 19, 20, 24. Para cada uma destas barras, pode-se adicionar, no máximo, até quatro bancos de capacitores; a susceptância *shunt* nominal de cada banco é fixa em 35 MVar, independentemente da barra onde foi alocado.

A Tabela 5.8 apresenta os planos de alocação de reativos (planos POAR) encontrados para cada um dos 10 melhores planos de expansão da transmissão (planos PET) conhecidos para o caso IEEE24 “N-1” 0% (Caso 2): os reforços

adicionados pelos planos PET deste caso foram apresentados pela Tabela 4.6; para identificação, utiliza-se a classificação do plano PET (“N.”), o custo de investimento (“Custo”), e o total das perdas ativas para o modelo de rede DC (“Perdas^{DC}”). Na Tabela 5.8, “N_B” identifica as barras onde os bancos foram alocados, “N. Total” é a quantidade total de bancos do plano POAR, “MVar Total” é o total de susceptância adicionada ao sistema pelos bancos, e “Perdas^{AC}” é o valor das perdas ativas para o modelo de rede AC. Como exemplo, para o plano PET N. 1, o plano ótimo POAR adiciona três bancos na barra 3 e um banco na barra 9, possuindo um total de quatro bancos de 35 MVar, o que adiciona ao sistema 140 MVar (nominal) e gera 133,6 MW de perdas ativa para o regime permanente da rede intacta.

Tabela 5.8: Planos de alocação de reativos para o caso IEEE24 “N-1” 0% (Caso 2).

N.	Planos para o PET		Planos de Alocação de Reativos				
	Custo (10 ⁶ US\$)	Perdas ^{DC} (MW)	Bancos Adic. (N _B)		N. Total	MVar Total	Perdas ^{AC} (MW)
			3	9			
1	681	138,90	3	1	4	140,0	133,60
2	681	138,98	4		4	140,0	144,04
3	681	139,01	3	1	4	140,0	133,53
4	681	139,18	3	1	4	140,0	133,60
5	681	139,20	3	1	4	140,0	133,81
6	681	139,21	4		4	140,0	135,32
7	681	139,39	3	1	4	140,0	134,07
8	681	139,47	4		4	140,0	143,66
9	681	139,83	3	1	4	140,0	134,54
10	681	139,91	4		4	140,0	145,74

De maneira análoga à Tabela 5.8, a Tabela 5.9 apresenta os melhores planos de alocação de reativos (planos POAR) encontrados para cada um dos 10 melhores planos de expansão da transmissão (planos PET) conhecidos para o caso IEEE24 “N-1” 10% (Caso 3). Os reforços adicionados pelos planos PET deste caso foram apresentados pela Tabela 4.10. Já na Tabela 5.10, apresenta-se os melhores planos POAR encontrados para cada um dos 10 melhores planos PET conhecidos para o caso IEEE24 “N-1” 20% (Caso 4). Os reforços adicionados pelos planos PET deste caso foram apresentados pela Tabela 4.14.

Tabela 5.9: Planos de alocação de reativos para o caso IEEE24 “N-1” 10% (Caso 3).

Planos para o PET			Planos de Alocação de Reativos						
N.	Custo (10 ⁶ US\$)	Perdas ^{DC} (MW)	Bancos Adicionados (N _B)				N. Total	MVAR Total	Perdas ^{AC} (MW)
			3	4	9	24			
1	551	148,50	3				3	105,0	145,95
2	589	158,77	4		1		5	175,0	160,46
3	591	154,40	3				3	105,0	152,34
4	591	158,31	4	1	2	1	8	280,0	152,61
5	594	155,04	4				4	140,0	154,35
6	596	165,00	2		4		6	210,0	156,28
7	597	165,07	2		4		6	210,0	156,65
8	598	150,27	2	2	1		5	175,0	144,75
9	599	150,40	4				4	140,0	151,77
10	599	150,68	4				4	140,0	151,01

Tabela 5.10: Planos de alocação de reativos para o caso IEEE24 “N-1” 20% (Caso 4).

Planos para o PET			Planos de Alocação de Reativos								
N.	Custo (10 ⁶ US\$)	Perdas ^{DC} (MW)	Bancos Adicionados (N _B)						N. Total	MVAR Total	Perdas ^{AC} (MW)
			3	4	8	9	12	24			
1	461	162,31	4			2		2	8	280,0	159,06
2	486	170,56	4			4			8	280,0	167,66
3	490	172,56	4	1		1		1	7	245,0	167,64
4	492	160,96	3	1				1	5	175,0	155,53
5	492	167,41	4					2	6	210,0	166,34
6	493	156,32	4	1		1		2	8	280,0	151,71
7	496	169,52	4	1				1	6	210,0	164,47
8	498	157,37	4		1				5	175,0	151,78
9	498	157,61	3					1	4	140,0	157,33
10	499	160,90	4					1	5	175,0	155,83

Pode-se observar na Tabela 5.8 que todos os dez planos PET para este caso possuem o mesmo custo de investimento para expansão da transmissão e também o mesma quantidade de bancos de capacitores adicionados para a compensação de reativos, o que dificulta a definição do melhor plano. Neste caso, outros critérios devem ser utilizados. Já para o caso da Tabela 5.9, o planejador do sistema possui duas opções interessantes para escolha, os planos 1 e 3, visto que estes planos necessitam de um menor número de bancos para a compensação de reativos. Além disso, comparando as Tabelas 5.8 e 5.9, pode-se observar que os planos 1 e 3 da Tabela 5.9 são mais baratos e necessitam de uma menor compensação reativa. Por fim, pode-se observar na Tabela 5.10 que, para este caso, do ponto de vista da compensação reativa, o plano 9 parece ser mais interessante que o plano 1, pois demanda uma menor quan-

tidade de bancos de capacitores (provavelmente, terá um menor custo para de compensação de reativos).

5.3.2 Alocação de Banco de Capacitores para o Sistema Sul Brasileiro

Nos problemas de POAR para o Sistema Sul Brasileiro, casos SBR “N-1” 0%, 10% e 20%, as seguintes barras candidatas à compensação reativa (via bancos de capacitores *shunt*) são consideradas: 2, 4, 5, 8, 12, 13, 20, 22, 23, 24, 26, 33, 35, 36, 38, 40, 42, 44, 45. Para cada uma destas barras, pode-se adicionar, no máximo, até quatro bancos de capacitores; a susceptância *shunt* nominal de cada banco é fixa em 50 MVar, independentemente da barra onde foi instalado.

Tabela 5.11: Planos de alocação de reativos para o caso SBR “N-1” 0% (Caso 6).

Planos para o PET			Planos de Alocação de Reativos														
N.	Custo (10 ⁶ US\$)	Perdas ^{DC} (MW)	Bancos Adicionados (N _B)											N. Total	MVar Total	Perdas ^{AC} (MW)	
			8	13	20	23	24	33	35	38	40	42	44				45
1	239,02	184,78		1		4	3			4	1		2		15	750,0	186,90
2	239,43	185,02		2		4	3					3	1	2	15	750,0	187,88
3	240,23	181,11		1			4	2	1			3	1	2	14	700,0	183,34
4	240,64	181,36		1		1	3	2	1			4	1	1	14	700,0	184,09
5	242,56	181,90			1	1	4		2			1	2	2	14	700,0	187,31
6	242,96	182,15			1		2	4				3		2	14	700,0	185,14
7	245,09	176,04					4	2	2		1	2		1	13	650,0	177,31
8	246,46	179,11		1			4	4				3		1	13	650,0	183,56
9	247,12	184,10			1		4	3				3	1	1	15	750,0	185,46
10	247,41	176,84			1		2	4				1		4	13	650,0	176,27

A Tabela 5.11 apresenta os planos de alocação de reativos (planos POAR) encontrados para cada um dos 10 melhores planos de expansão da transmissão (planos PET) conhecidos para o caso SBR “N-1” 0% (Caso 6). Os reforços adicionados pelos planos PET deste caso foram apresentados pela Tabela 4.23. Para identificação, utiliza-se a classificação do plano PET (“N.”), o custo de investimento (“Custo”), e o total das perdas ativas para o modelo de rede DC (“Perdas^{DC}”). Na Tabela 5.11, “N_B” identifica as barras onde os bancos foram alocados, “N. Total” é a quantidade total de bancos do plano POAR, “MVar Total” é o total de susceptância adicionada ao sistema pelos bancos, e “Perdas^{AC}” é o valor das perdas ativas para o modelo de rede AC. Como exemplo, para o

plano 1 da Tabela 5.11, o plano ótimo POAR é dado por: $q_{13} = 1$, $q_{23} = 4$, $q_{24} = 3$, $q_{38} = 4$, $q_{40} = 1$ e $q_{44} = 2$; possuindo um total de 15 bancos de 50 MVar, o que adiciona ao sistema 750 MVar (nominal) e produz 186,90 MW de perdas ativa para o regime permanente (rede intacta).

De maneira análoga à Tabela 5.11, a Tabela 5.12 apresenta os melhores planos de alocação de reativos (planos POAR) encontrados para cada um dos 10 melhores planos de expansão da transmissão (planos PET) conhecidos para o caso SBR “N-1” 10% (Caso 7). Os reforços adicionados pelos planos PET deste caso foram apresentados pela Tabela 4.27. Já na Tabela 5.13, apresenta-se os melhores planos POAR encontrados para cada um dos 10 melhores planos PET conhecidos para o caso SBR “N-1” 20% (Caso 8). Os reforços adicionados pelos planos PET deste caso foram apresentados pela Tabela 4.31.

Para o caso representado na Tabela 5.11, pode-se observar que, do ponto de visto do custo para a compensação de reativos, os planos 7, 8 e 10 parecem ser as melhores opções, visto que estes planos adicionam ao sistema um menor número de bancos de capacitores. Já para o caso da Tabela 5.12, o planejador do sistema pode optar por escolher o plano 10 como o melhor dos planos. Por fim, pode-se observar na Tabela 5.13 que, para este caso, do ponto de vista da compensação reativa, o plano 8 parece ser mais interessante que o plano 1 (mais barato): demanda uma menor quantidade de bancos de capacitores e provavelmente terá um menor custo para de compensação de reativos.

Tabela 5.12: Planos de alocação de reativos para o caso SBR “N-1” 10% (Caso 7).

Planos para o PET			Planos de Alocação de Reativos														
N.	Custo (10 ⁶ US\$)	Perdas ^{DC} (MW)	Bancos Adicionados (N _B)											N. Total	MVar Total	Perdas ^{AC} (MW)	
			13	20	23	24	33	35	38	40	42	44	45				
1	231,95	184,89	1		4	2	1		2	1	2	2			15	750,0	187,24
2	232,35	185,14	1		4	4			2	3				1	15	750,0	187,47
3	233,21	184,91	1	1	4	2	1			1	2	3			15	750,0	187,14
4	233,62	185,16	1		4	4			1		3	1	1		15	750,0	189,23
5	234,02	184,65	1	1	4	1	1	1		4				1	14	700,0	189,59
6	234,47	180,55	1		3	4			2	2		1	1		14	700,0	181,20
7	234,93	184,75	1		4	3	1			1	2	3			15	750,0	186,58
8	235,28	184,67			3	3	4				3		1	1	15	750,0	185,98
9	235,33	185,00			3	3	4				3		1	1	15	750,0	187,47
10	235,74	180,57	1		4	4				3				1	13	650,0	184,72

Tabela 5.13: Planos de alocação de reativos para o caso SBR “N-1” 20% (Caso 8).

Planos para o PET			Planos de Alocação de Reativos														N. Total	MVA _r Total	Perdas ^{AC} (MW)
N.	Custo (10 ⁶ US\$)	Perdas ^{DC} (MW)	Bancos Adicionados (N _B)																
			2	4	5	8	13	20	23	24	33	36	40	42	44	45			
1	206,69	205,77	1	1		1	1	2	4	4		1	2		2	1	20	1000	212,93
2	209,02	205,06		1		3		2	4	1	2		4		2		19	950	214,47
3	211,64	191,06					1		4	4			2	3	2		16	800	193,64
4	212,56	205,14	2		1		2		4	4			1	4	2		20	1000	210,25
5	214,88	204,43	2	1		1		2	4	4			3	1	2		20	1000	209,42
6	215,02	191,08					1	1	4	3	1		3	2	1		16	800	196,80
7	215,43	191,66				1		1	4	4			2	1	2	1	16	800	197,10
8	215,58	188,02				1			4	4			3	1	2		15	750	192,35
9	216,04	206,61		3			2	1	4	4			1	2	2	1	20	1000	215,20
10	217,49	189,71				1		2	4	4			4		1		16	800	192,85

5.4 ANÁLISE DOS CUSTOS

Como exemplo teórico de um possível processo decisório para escolha do melhor plano de expansão para o sistema, a presente seção tem como objetivo realizar uma análise de custos considerando quatro componentes básicos: 1) C_{Exp} , custo de investimento na expansão da transmissão (linhas de transmissão e transformadores); 2) C_{MVA_r} , custo para a compensação de reativos (alocação de bancos de capacitores); 3) C_{Perdas} , custo das perdas ôhmicas nos elementos de transmissão (perdas ativas para o modelo AC); e 4) LOLC, custo esperado de interrupção de energia (valor estimado por método probabilístico). Somando-se estes componentes tem-se o custo “Total” para cada uma das opções de investimento. Para tanto, utilizou-se os dados obtidos com a análise de confiabilidade da Seção 5.2 e com o estudo de compensação de reativos da Seção 5.3: os planos de expansão são os mesmo dos casos estudados pelas seções anteriores (Casos 2, 3, 4, 6, 7 e 8), agora agrupados em uma única tabela por sistema.

Na escolha pela melhor opção para a expansão do sistema de transmissão (planos PET), o planejador busca encontrar um bom balanço entre a minimização do custo de investimento, a minimização do custo operacional, e o atendimento da demanda com um nível de confiabilidade adequado. Para ponderar a confiabilidade de cada uma das opções de investimento encontradas no PET,

adotou-se o valor esperado do custo de interrupção do fornecimento de energia (LOLC - *Loss of Load Cost*), o qual é calculado a partir do valor esperado de energia não suprida (índice EENS para carga pico: apresentado pelas tabelas da Seção 5.2). Este índice LOLC é o resultado do produto entre o EENS, dado em MWh por ano, e o custo unitário de interrupção de energia (UC - *Unit Cost*), dado em US\$ por MWh. Neste trabalho, considera-se que o UC é um valor fixo e independe do tipo da unidade consumidora (tipo da carga: industrial, comercial, etc.) ou da duração da interrupção [MARL12].

Visando a consideração do custo operacional na análise, para cada opção de investimento, adiciona-se ao custo total do plano o custo das perdas ôhmicas, calculado como: $C_{\text{Perdas}} = 8736 \times T_{\text{MWh}} \times (\text{Perdas}^{\text{AC}} - P_{\text{Ref}})$, onde 8736 representa o número total de horas em um ano; T_{MWh} corresponde a uma tarifa de compra de energia para as perdas ôhmicas, dado em US\$ por MWh; $\text{Perdas}^{\text{AC}}$ é o total para as perdas ativas (MW) no elementos do sistema, obtido pelo modelo de rede AC (após a compensação reativa); e P_{Ref} é um valor fixo de referência para as perdas. Uma vez que os custos das perdas ôhmicas estão diretamente relacionados à carga do sistema e são similares para qualquer plano de expansão, adotou-se P_{Ref} para referenciar estes custos: para um determinado sistema, considera-se P_{Ref} como o valor mínimo para $\text{Perdas}^{\text{AC}}$ entre todas as opções de investimento analisadas [LRM11].

Sabe-se que o ideal para o PET é a utilização da abordagem multiestágio (dinâmica), onde a solução para o problema deve indicar não somente a localização e quais reforços serão necessários, mas também a evolução temporal destas decisões. Neste caso, busca-se a minimização do valor presente dos custos envolvidos na expansão do sistema de transmissão. Contudo, neste trabalho, adotou-se a utilização da abordagem estática, visando assim minimizar o custo computacional dos problemas e permitir uma análise mais detalhada das opções de investimento (critério “N-1”, confiabilidade, etc.). Assim, neste trabalho, os custos envolvidos com a expansão do sistema já representam o valor presente do investimento. No caso do investimento na expansão da transmissão, o valor presente considerado é o mesmo utilizado nas análises anteriores, identificado nas tabelas por “Custo” (em milhões de US\$). Já para o investi-

mento na compensação de reativos, o valor presente é considerado como sendo proporcional ao valor total da susceptância *shunt* (nominal) adicionada ao sistema elétrico (identificado nas tabelas anteriores como “MVA_r Total”): neste caso, considera-se um custo fixo dado em milhões de US\$ por MVA_r alocado [GRRG09].

Para viabilizar a inserção dos custos das perdas ôhmicas (C_{Perdas}) e da interrupção de energia (LOLC) na análise de custos dos planos candidatos, dado que estes componentes são obtidos de forma anualizada (milhões de US\$ por ano), se faz necessário a decomposição dos custos de investimento na expansão da transmissão (C_{Exp}) e de alocação de reativos (C_{MVA_r}) em desembolsos anuais. Desta forma, adotou-se a tabela “Price” para calcular parcelas fixas para C_{Exp} e C_{MVA_r} (pagamento do investimento), onde o valor presente do investimento é decomposto em 25 parcelas anuais (período de vida útil dos equipamentos) com uma taxa de juros de 10% ao ano [MARL12]. É importante observar que C_{Perdas} e LOLC são obtidos apenas para um ano de operação do sistema, que no caso é o ano final do horizonte de planejamento (previsão para a carga pico constante no final do horizonte).

Na Tabela 5.14 apresenta-se a análise de custos para o Sistema IEEE RTS-79, onde: “Planos” identifica o plano de expansão candidato (de A1 a A10 são os planos do Caso 2; IEEE24 “N-1” 0%; de B1 a B10 são os planos do Caso 3; IEEE24 “N-1” 10%; de C1 a C10 são os planos do Caso 4; IEEE24 “N-1” 20%), “Custo” é o valor presente para o investimento na expansão da transmissão, e “Perdas^{DC}” é o valor total para as perdas ativas do modelo DC. Nesta tabela, considerou-se: custo para compensação de reativos de 6000 US\$/MVA_r, tarifa das perdas ativas (T_{MWh}) de 25 US\$/MWh, e custo unitário de interrupção (UC) de 5000 US\$/MWh. A coluna “Ord” indica a classificação dos planos em função do custo total.

Tabela 5.14: Análise de custos para o Sistema IEEE RTS-79.

Planos	Custo (10 ⁶ US\$)	Perdas ^{DC} (MW)	Custos (x10 ⁶ US\$ / ano)					Ord.
			C _{Exp}	C _{MVA_r}	C _{perdas}	LOLC	Total	
A1	681	138,90	75,024	0,093	0,017	0,283	75,417	5
A2	681	138,98	75,024	0,093	2,295	0,288	77,700	14
A3	681	139,01	75,024	0,093	0,000	0,318	75,435	7
A4	681	139,18	75,024	0,093	0,016	0,286	75,418	6
A5	681	139,20	75,024	0,093	0,062	0,336	75,516	8
A6	681	139,21	75,024	0,093	0,392	0,342	75,852	11
A7	681	139,39	75,024	0,093	0,119	0,308	75,544	9
A8	681	139,47	75,024	0,093	2,213	0,330	77,660	13
A9	681	139,83	75,024	0,093	0,222	0,344	75,683	10
A10	681	139,91	75,024	0,093	2,667	0,341	78,125	16
B1	551	148,50	60,703	0,069	2,714	7,136	70,622	2
B2	589	158,77	64,889	0,116	5,882	9,548	80,435	20
B3	591	154,40	65,109	0,069	4,108	7,294	76,581	12
B4	591	158,31	65,109	0,185	4,168	25,191	94,653	27
B5	594	155,04	65,440	0,093	4,547	4,879	74,959	3
B6	596	165,00	65,660	0,139	4,969	7,880	78,648	19
B7	597	165,07	65,770	0,139	5,050	7,688	78,647	18
B8	598	150,27	65,881	0,116	2,450	0,720	69,166	1
B9	599	150,40	65,991	0,093	3,984	10,440	80,507	21
B10	599	150,68	65,991	0,093	3,818	12,042	81,944	22
C1	461	162,31	50,787	0,185	5,575	87,767	144,315	30
C2	486	170,56	53,542	0,185	7,454	21,700	82,881	24
C3	490	172,56	53,982	0,162	7,450	29,009	90,603	25
C4	492	160,96	54,203	0,116	4,805	18,610	77,733	15
C5	492	167,41	54,203	0,139	7,167	29,484	90,992	26
C6	493	156,32	54,313	0,185	3,971	84,853	143,322	29
C7	496	169,52	54,643	0,139	6,757	34,751	96,291	28
C8	498	157,37	54,864	0,116	3,987	19,391	78,358	17
C9	498	157,61	54,864	0,093	5,199	22,720	82,875	23
C10	499	160,90	54,974	0,116	4,872	15,408	75,369	4

De maneira análoga à Tabela 5.14, a Tabela 5.15 apresenta a análise de custos para o Sistema Sul Brasileiro, onde: A1 a A10 são os planos do Caso 6 (SBR “N-1” 0%); B1 a B10 são os planos do Caso 7 (SBR “N-1” 10%); e C1 a C10 são os planos do Caso 8 (SBR “N-1” 20%). Para este sistema, considerou-se: custo para compensação de reativos de 4000 US\$/MVA_r, tarifa das perdas ativas (T_{MWh}) de 25 US\$/MWh, e custo unitário de interrupção (UC) de 2000 US\$/MWh.

Tabela 5.15: Análise de custos para o Sistema Sul Brasileiro.

Planos	Custo (10 ⁶ US\$)	Perdas ^{DC} (MW)	Custos (x10 ⁶ US\$ / ano)					Ord.
			C _{Exp}	C _{MVA_r}	C _{perdas}	LOLC	Total	
A1	239,02	184,78	26,332	0,331	2,323	0,884	29,870	16
A2	239,43	185,02	26,377	0,331	2,537	0,896	30,141	19
A3	240,23	181,11	26,466	0,308	1,544	0,821	29,139	6
A4	240,64	181,36	26,511	0,308	1,710	0,835	29,363	11
A5	242,56	181,90	26,722	0,308	2,413	0,824	30,267	20
A6	242,96	182,15	26,766	0,308	1,938	0,821	29,834	15
A7	245,09	176,04	27,001	0,286	0,227	0,828	28,342	2
A8	246,46	179,11	27,152	0,286	1,592	0,887	29,917	18
A9	247,12	184,10	27,224	0,331	2,008	1,156	30,719	22
A10	247,41	176,84	27,257	0,286	0,000	0,814	28,357	3
B1	231,95	184,89	25,553	0,331	2,397	0,846	29,127	5
B2	232,35	185,14	25,597	0,331	2,446	0,881	29,255	8
B3	233,21	184,91	25,693	0,331	2,375	0,892	29,290	9
B4	233,62	185,16	25,737	0,331	2,832	0,929	29,828	14
B5	234,02	184,65	25,781	0,308	2,910	0,889	29,888	17
B6	234,47	180,55	25,831	0,308	1,078	0,896	28,114	1
B7	234,93	184,75	25,882	0,331	2,253	0,898	29,363	12
B8	235,28	184,67	25,921	0,331	2,121	0,943	29,315	10
B9	235,33	185,00	25,926	0,331	2,446	0,949	29,652	13
B10	235,74	180,57	25,971	0,286	1,845	0,935	29,038	4
C1	206,69	205,77	22,771	0,441	8,007	6,630	37,849	29
C2	209,02	205,06	23,027	0,419	8,344	5,413	37,203	27
C3	211,64	191,06	23,315	0,353	3,794	3,202	30,664	21
C4	212,56	205,14	23,417	0,441	7,422	6,293	37,573	28
C5	214,88	204,43	23,673	0,441	7,240	5,042	36,395	26
C6	215,02	191,08	23,689	0,353	4,484	3,517	32,042	24
C7	215,43	191,66	23,733	0,353	4,550	3,623	32,259	25
C8	215,58	188,02	23,750	0,331	3,513	1,556	29,149	7
C9	216,04	206,61	23,801	0,441	8,503	6,058	38,803	30
C10	217,49	189,71	23,960	0,353	3,621	3,221	31,155	23

Da Tabela 5.14, pode-se concluir que o plano de expansão B8 (plano 8 da Tabela 4.10: IEEE “N-1” 10%) representa a melhor opção de investimento para o Sistema IEEE RTS-79, possuindo a melhor relação de custo/benefício. Para o cenário considerado, B8 possui a melhor relação entre o custo do investimento em novos equipamentos, custo operacional, e o nível de confiabilidade do sistema. Já na Tabela 5.15, pode-se observar que para o sistema Sul Brasileiro a melhor opção de investimento está no plano de expansão B6 (plano 6 da Tabela 4.27: SBR “N-1” 10%). Entretanto, deve-se ter em mente que a ordenação

destas opções de investimento (“Ord”) dependente dos parâmetros utilizados para o cálculo dos custos (tarifas de perdas, custo unitário de interrupção, etc.). Como exemplo, na Tabela 5.15, a alteração da tarifa de perdas para 10 US\$/MWh, faz com que o plano C8 (plano 8 da Tabela 4.31, SBR “N-1” 20%) seja a melhor opção de investimento para o Sistema Sul Brasileiro, visto que este plano apresenta um baixo valor para a EENS e possui SEV < 10 (Grau 1: Satisfatório).

A partir dos estudos apresentados nesta seção, pode-se concluir que o relaxamento do critério de segurança “N-1” é uma boa metodologia para encontrar opções de investimento de menor custo e com um bom nível de confiabilidade. Observa-se que o relaxamento do critério “N-1” permite a redução do número de reforços adicionados, o que, conseqüentemente, reduz o custo do investimento e pode levar a uma deterioração do nível de confiabilidade do sistema. Contudo, nota-se que esta deterioração da confiabilidade não possui uma relação linear com o número de reforços e também pode ter um impacto mais “global”, comprometendo grande parte dos elementos do sistema, ou mais “local”, comprometendo poucos elementos. Além disso, a inclusão da confiabilidade diretamente na função objetivo do PET (consideração da LOLC durante o processo de busca: “*a priori*”) [MARL12] gera um aumento significativo no custo computacional do problema, aumento este que se mostra maior que a inclusão de critérios determinísticos como o “N-1”.

De fato, em relação ao critério de segurança “N-1” tradicional, o relaxamento do “N-1” permite que se encontrem planos com boa confiabilidade global e com baixo custo de investimento. Nestes planos, alguns de seus ramos, eventualmente, podem estar fragilizados (i.e., em caso de contingências, uma eventual sobrecarga significativa, devido ao relaxamento do critério). Entretanto, pode-se adicionar ao sistema equipamentos de monitoração, como os DLR (*Dynamic Line Rating*) [FABML16], nos ramos que estejam fragilizados (circuitos críticos: com maior probabilidade de sobrecarga ou mais sobrecarregados). Tendo em vista o baixo custo para a adição destes novos equipamentos, esta possibilidade se mostra muito interessante, pois permite uma redução do custo total de

investimento no sistema. Com a monitoração em tempo real feita através das novas tecnologias DLR, é possível operar equipamentos de transmissão com até 30% de sobrecarga em quase 90% do tempo.

Como sugestão de metodologia para escolha da melhor opção de investimento, a partir de um conjunto com os melhores planos encontrados (exemplo: os 50 melhores planos, considerando o “N-1” relaxado a 5, 10, 15 e 20%), o planejador pode, primeiramente, eliminar parte destes planos considerando apenas os planos com $SEV < 10$, o que define um nível mínimo para a confiabilidade do sistema. Posteriormente, o planejador pode analisar os planos restantes, verificando a confiabilidade para cada ramo ou barra do sistema (o que seria uma análise da confiabilidade “local”), e excluir os planos operacionalmente inviáveis: por exemplo, pode-se verificar, para cada ramo, o nível máximo de sobrecarga para o critério “N-1”, adicionando nos casos críticos, quando possível, equipamentos de monitoração. Por fim, o planejador pode fazer a escolha do plano com o menor custo total, ponderando o custo do investimento em novos equipamentos (transmissão, monitoração, compensação reativa, etc.), custo operacional (geração, perdas, etc.) e também o custo de interrupção de energia (LOLC). Alguns cenários para as tarifas de perdas e interrupção de energia, prazos e taxas dos investimentos também podem ser consideradas neste estudo.

5.5 CONSIDERAÇÕES FINAIS

Este capítulo teve como objetivo verificar se existe vantagem em, ao fim do processo de busca pelas melhores soluções do PET de longo prazo, fornecer ao planejador do sistema um conjunto de boas soluções para o problema, ao invés de uma única solução. Para tanto, nos casos estudados pelo Capítulo 4 onde se considera o critério de segurança “N-1” (relaxado ou não), estudos de confiabilidade e compensação reativa foram realizados com os planos de expansão presentes nos conjuntos dos 10 melhores planos conhecidos para cada problema. Os resultados indicam que planos de expansão que proporcionam o menor custo de investimento para um determinado problema PET podem não

apresentar a melhor relação custo/benefício quando avaliados por algum índice de confiabilidade ou pelo custo da compensação de potência reativa. Assim, fica demonstrado que existem vantagens em se fornecer ao planejador um conjunto de boas soluções, ao invés de se apresentar apenas a melhor solução encontrada. A partir deste conjunto, o planejador deve realizar um estudo mais rigoroso de modo a escolher a melhor opção de investimento.

Adicionalmente, realizou-se uma análise de custos, considerando quatro componentes básicos: o custo de investimento na expansão da transmissão, o custo da compensação de reativos, o custo das perdas ôhmicas nos elementos de transmissão, e o custo esperado de interrupção de energia (LOLC). Observou-se que, normalmente, planos obtidos pelo critério “N-1” tradicional (sem relaxamento) possuem um custo de investimento mais elevado e um alto nível de confiabilidade. Já os planos obtidos pelo “N-1” relaxado têm um menor custo de investimento, mas com um menor nível de confiabilidade. Neste sentido, os resultados obtidos apontam que a grande vantagem da utilização do critério de segurança “N-1” relaxado é a obtenção de planos de expansão com uma melhor relação entre o custo do investimento e o nível de confiabilidade (i.e., esta metodologia permite reduzir o custo de investimento na transmissão sem comprometer, de forma significativa, a confiabilidade do sistema).

CAPÍTULO 6

CONCLUSÕES E TRABALHOS FUTUROS

Os sistemas de transmissão são de fundamental importância para o suprimento de energia elétrica aos consumidores, pois são responsáveis pelo fluxo de potência entre as subestações, fornecendo os caminhos para o escoamento da energia produzida pelos geradores. Para o atendimento dos consumidores com um nível adequado de continuidade no serviço, se faz necessário o bom desempenho da rede elétrica. Neste sentido, o Planejamento da Expansão do Sistema de Transmissão (PET) é uma tarefa de extrema relevância, pois visa atender a demanda futura com um bom nível de confiabilidade e com o menor custo de investimento possível.

Dado o atual cenário do setor elétrico, com toda a sua complexidade para geração, transmissão e distribuição de energia, a exploração de soluções otimizadas para os diversos problemas da área pode ser facilmente justificada quando se consideram aspectos específicos como: restrição de investimentos, custos de operação e manutenção, concorrência e competitividade de mercado de energia, restrições socioambientais, crescimento de demanda, entre outros. Por outro lado, os avanços observados na ciência da computação, aliado a uma maior oferta de recursos computacionais, contribuem significativamente para a evolução dos modelos matemáticos e algoritmos para planejamento dos sistemas elétricos de potência.

No PET, a escolha de um modelo matemático adequado ao problema em estudo, além da adoção de um método de otimização eficiente, robusto e flexível, tem como objetivo a determinação de um grupo de planos de expansão candidatos: as melhores opções encontradas para a expansão do sistema devem fazer parte de um processo de decisão, onde a relação custo/benefício será adequadamente avaliada pelo planejador.

No Capítulo 1 desta tese de doutorado foi apresentado um levantamento bibliográfico dos principais trabalhos encontrados na literatura abordando a modelagem e resolução de problemas PET. Várias metodologias são adotadas por diversos autores, envolvendo análises estáticas e dinâmicas, estudos determinísticos e não-determinísticos, consideração da influência de incertezas internas e externas, entre outras. As limitações e principais dificuldades de cada abordagem, bem como suas principais vantagens, foram apresentadas e discutidas, resultando em uma importante base de conhecimento para a comunidade científica. Ademais, foram apresentadas as motivações da proposição de um novo Algoritmo Evolutivo Adaptativo (AEA) para resolução de problemas PET, o qual é inédito para esta área de pesquisa. Tendo em vista a complexidade computacional dos atuais problemas PET e a dificuldade dos planejadores para ajustar de forma eficiente os parâmetros de controle de meta-heurísticas de otimização, como os Algoritmos Evolutivos (Evolutionary Algorithms - EAs), conclui-se que uma metodologia baseada em um AEA será de grande utilidade no planejamento de sistemas elétricos de transmissão.

O Capítulo 2 destinou-se a apresentar uma introdução teórica a respeito dos EAs, discutindo-se as principais estratégias para ajuste de parâmetros, a influência destes parâmetros no desempenho do algoritmo, e a possibilidade da utilização de múltiplos operadores de reprodução em um único EA. Além disso, realizou-se uma revisão bibliográfica sobre as principais técnicas que já foram propostas para a adaptação de parâmetros em EAs, tendo como objetivo principal as estratégias para seleção adaptativa de operadores de reprodução.

A adoção de uma estratégia para seleção adaptativa dos múltiplos operadores de reprodução configura-se como uma abordagem muito interessante para um EA. Quando se considera todos os tipos de problemas de otimização existentes, não há nenhum operador que claramente apresente um desempenho superior aos demais: cada operador é particularmente eficiente para uma determinada classe de problemas, e extremamente ineficiente para outras. Além disso, um determinado operador pode ser eficiente para um dos estágios do processo de busca e ineficiente para os demais estágios. Desta forma, a adap-

tação das probabilidades de seleção e aplicação dos operadores se torna algo bastante vantajoso em um EA com múltiplos operadores, visto que pode aumentar o desempenho computacional do algoritmo.

No Capítulo 3 foi apresentada, detalhadamente, toda a metodologia adotada para a modelagem e resolução dos problemas PET. A formulação matemática utilizada inclui um modelo de fluxo DC com perdas e um método relaxado para avaliação do critério de segurança “N-1”, garantindo assim a obtenção de planos de expansão robustos e com um bom nível de confiabilidade. O AEA via Multioperadores proposto, chamado de AES-TEP, foi detalhadamente descrito, juntamente com as metodologias que foram adotadas para viabilizar sua aplicação ao problema PET. Visando melhorar o desempenho do AES-TEP, apresentou-se também um novo conjunto de operadores reprodutivos, especializados no PET. Os chamados operadores especialistas utilizam heurísticas específicas aos sistemas elétricos, de modo a guiar os mecanismos estocásticos na busca pelas melhores soluções. Ademais, informa-se que este trabalho resultou na publicação do seguinte artigo em periódico internacional [LFH16].

No algoritmo AES-TEP e no grupo de operadores especialistas, pode-se identificar algumas contribuições inovadoras para o atual estado da arte do PET: 1) utilização de diversas estratégias de busca em um único algoritmo, onde os operadores de busca (reprodução) são obtidos com a associação de um operador de recombinação com um operador de mutação; 2) utilização de mecanismo adaptativo e dinâmico para a seleção dos operadores de busca; 3) critério de substituição do indivíduo filho pelo indivíduo da população que esteja mais próximo; 4) manutenção da população com apenas indivíduos distintos; 5) utilização de heurísticas específicas ao PET diretamente inseridas nos operadores de busca estocásticos; e 6) metodologia simples e robusta para manipulação das restrições do problema (extinção do parâmetro de penalização da infactibilidade na função objetivo do PET).

Para cada estágio do processo de busca pelas melhores soluções do problema, o AES-TEP tenta, automaticamente, maximizar o uso do operador que

produz melhores resultados. Observou-se que a metodologia proposta é de simples implementação e de fácil configuração, possuindo apenas quatro parâmetros para ajuste. Além disso, esta metodologia libera o usuário (planejador) da tarefa de ajustar os valores das probabilidades de seleção dos operadores, o que dá certa robustez à ferramenta de busca proposta.

É importante ressaltar que, especificamente na área de planejamento de sistemas elétricos, a principal contribuição desta tese de doutorado é a proposição de um novo EA utilizando múltiplos operadores de busca e adaptação dinâmica das probabilidades de seleção destes operadores. Além das contribuições que já foram listadas acima, deve-se destacar ainda que este trabalho apresentou uma nova metodologia para, de maneira simples e eficiente, fazer a avaliação estatística do desempenho computacional de meta-heurísticas aplicadas ao PET. A maioria dos trabalhos encontrados na literatura ou não possui uma metodologia para avaliação ou a faz de forma bastante simplificada.

O Capítulo 4 teve como objetivo apresentar e discutir os resultados obtidos com a aplicação do algoritmo AES-TEP em problemas PET de longo prazo. A fim de avaliar o desempenho do algoritmo proposto, o AES-TEP foi eficientemente aplicado a oito problemas PET distintos (casos de estudo), os quais foram definidos a partir de dois sistemas elétricos bastantes conhecidos na literatura especializada: sistema IEEE RTS-79 e sistema Sul Brasileiro. Além disso, vários testes foram realizados com o AES-TEP, variando-se parâmetros de controle, tipo de inicialização da população e operadores de busca. Independentemente do problema a ser resolvido, observou-se que o AES-TEP apresenta um bom desempenho, tanto em relação à qualidade das soluções encontradas, como em relação ao custo computacional. Este fato, aliado à sua robustez ao ajuste de parâmetros, demonstraram que a ferramenta proposta é de fácil utilização e pode ser aplicada a um grande número de problemas de planejamento.

Primeiramente, os resultados obtidos com o AES-TEP indicaram a superioridade computacional do grupo dos operadores especialistas em relação ao grupo

dos operadores evolutivos. Desta forma, pode-se concluir que a utilização de heurísticas específicas aos sistemas elétricos, incorporadas diretamente nos operadores de busca (operadores estocásticos), é uma estratégia bastante vantajosa ao processo de resolução dos problemas PET. Em todos os casos estudados, verificou-se que a utilização dos operadores especialistas proporciona ao AES-TEP a obtenção de resultados significativamente melhores aos obtidos com o uso dos tradicionais operadores evolutivos (conhecidos com operadores genéticos ou evolutivos “puros”).

A maioria das meta-heurísticas que já foram propostas para o PET utiliza algum algoritmo heurístico construtivo para fazer a inicialização da população. O Algoritmo de Inicialização Inteligente (All) adotado se mostrou como uma boa estratégia para iniciação da população em alguns dos casos estudados (sistema IEEE RTS-79), reduzindo o custo computacional do algoritmo e/ou melhorando a qualidade das soluções encontradas. Contudo, os resultados obtidos indicam que, para sistemas reais de médio ou grande porte, a estratégia de inicialização aleatória da população proporciona maior robustez ao processo de busca. A diminuição da diversidade genética gerada pelo All compromete a capacidade do algoritmo de realizar busca global, ou seja, menor capacidade de exploração do espaço de busca do problema.

Em relação à estratégia adaptativa para seleção dos operadores de busca (adaptação da taxa de aplicação dos operadores), pode-se dizer que sua principal vantagem é a redução do custo computacional demandado pelo algoritmo AES-TEP, acelerando a convergência do algoritmo. Observou-se que para a grande maioria dos casos estudados, a ativação do mecanismo adaptativo proporcionou uma redução do tempo computacional demandado pelo algoritmo, seja para obter uma execução de sucesso ou para a convergência do processo de busca. Além disso, verificou-se que a utilização da estratégia adaptativa, em alguns casos, faz com que o algoritmo encontre soluções de melhor qualidade (planos de expansão de menor custo).

Ademais, os resultados obtidos apontam que a utilização de diversas estratégias de busca em um único EA (configuração esta chamada de multioperadores), aliada à estratégia adaptativa, apresenta grandes vantagens em relação aos tradicionais EAs estáticos utilizando um único operador de busca. Para a maioria dos casos estudados, observou-se que a versão AES-TEP multioperadores foi aquela que obteve os melhores resultados, principalmente para a versão utilizando os operadores especialistas. Além disso, o algoritmo AES-TEP se mostrou relativamente robusto em relação ao ajuste dos parâmetros de controle de seu mecanismo adaptativo. Deve-se observar que, ao invés de se ajustar os valores de probabilidade para cada um dos operadores, o usuário do algoritmo deve ajustar apenas dois parâmetros de controle (α e β).

Por fim, no Capítulo 5 foi demonstrado que existe vantagem em, ao fim do processo de busca, fornecer ao planejador do sistema um conjunto de boas soluções para o problema PET, ao invés de uma única solução. Para tanto, estudos de confiabilidade e de compensação de reativos foram realizados com os planos de expansão presentes nos conjuntos dos 10 melhores planos conhecidos para cada problema estudado. Para a maioria dos problemas PET, observou-se que planos de expansão que proporcionam o menor custo de investimento em equipamentos de transmissão podem não apresentar a melhor relação entre o custo e o benefício quando avaliados por algum índice de confiabilidade ou pelo custo da compensação de potência reativa.

Adicionalmente, realizou-se uma análise de custos com os melhores planos encontrados para os problemas PET estudados, considerando quatro componentes básicos: o custo de investimento na expansão da transmissão, o custo da compensação de reativos, o custo das perdas ôhmicas nos elementos de transmissão, e o custo esperado de interrupção de energia (LOLC). Os resultados obtidos indicaram que a grande vantagem da utilização do critério de segurança “N-1” relaxado é a obtenção de planos de expansão com uma melhor relação entre o custo do investimento e o nível de confiabilidade, permitindo ao planejador reduzir o custo do investimento em transmissão sem comprometer, de forma significativa, a confiabilidade do sistema.

Embora o critério de segurança “N-1” pareça não ser a melhor opção para o PET, visto que há uma elevada tarifa a ser recuperada (alto custo do investimento em novos elementos de transmissão), esta tem sido a estratégia adotada pela maioria das companhias ao redor do mundo, já que as mesmas não possuem um consenso sobre quais valores de índices de confiabilidade indicam um sistema de potência com uma qualidade aceitável. Neste sentido, para viabilizar a busca por opções de investimento de menor custo e, ao mesmo tempo, com uma boa qualidade de fornecimento de energia, o critério de segurança denominado “N-1” relaxado, também proposto nesta tese de doutorado, se mostra como de fácil aceitação pelas empresas, visto que esta metodologia guarda forte semelhança com o critério “N-1” tradicional e é de fácil interpretação pelos planejadores.

Mediante ao trabalho desenvolvido nesta tese de doutorado, é possível apontar as seguintes sugestões para estudos futuros:

- ✓ Aprimorar o algoritmo AES-TEP com técnicas mais avançadas para avaliação da produtividade dos operadores, considerando, por exemplo, o ganho de diversidade gerado pelos mesmos;
- ✓ Aprimorar a estratégia para seleção adaptativa dos operadores através da pesquisa de novos critérios e técnicas; pode-se realizar uma comparação entre as diversas técnicas que já foram propostas;
- ✓ O conjunto dos operadores de busca pode ser melhorado pela adição de novos operadores. Uma maior variedade de heurísticas em um mesmo algoritmo pode aumentar a robustez do processo de busca;
- ✓ Desenvolver novos operadores especialistas, considerando novas heurísticas específicas aos sistemas elétricos. Neste sentido, operadores que utilizem alguma informação proveniente da avaliação do critério “N-1” podem aumentar ainda mais o desempenho do algoritmo;
- ✓ Desenvolver operadores especialistas específicos para a compensação de reativos: neste caso, se faz necessário a utilização de um modelo de rede AC;

- ✓ Aplicar o algoritmo AES-TEP na resolução de problemas PET para novos sistemas de transmissão, principalmente para sistemas reais de grande porte;
- ✓ Adaptar a metodologia desenvolvida para o caso da abordagem dinâmica (multiestágio), na qual o principal objetivo é definir onde, quando e quais reforços deverão ser adicionados ao sistema;
- ✓ Desenvolver uma metodologia capaz de incluir de forma eficiente a avaliação da confiabilidade, expressa pelo índice LOLC, diretamente na função objetivo do problema PET (consideração “*a priori*” da confiabilidade);
- ✓ Desenvolver uma nova metodologia que considere a presença de incertezas externas, como indefinições nas projeções de mercado (demanda e energia), no estudo de planejamento do sistema. O objetivo é obter planos mais flexíveis ou robustos, capazes de suportar os diferentes cenários futuros, produzindo assim uma melhor estratégia para a expansão do sistema.

REFERÊNCIAS BIBLIOGRÁFICAS

- [APM79] IEEE APM Subcommittee, "IEEE Reliability Test System", IEEE Trans. on PAS, vol. PAS-98, no. 6, pp. 2047-2054, Nov./Dec 1979.
- [BOA01] S. Binato, G.C. Oliveira, J.L. Araújo, "A Greedy Randomized Adaptive Search Procedure for Transmission Expansion Planning", IEEE Trans. on Power Syst., Vol. 16, pp. 247–253, May 2001.
- [BPG01] S. Binato, M.V.F. Pereira, S. Granville, "A New Benders Decomposition Approach to Solve Power Transmission Network Design Problems", IEEE Trans. on Power Syst., Vol. 16, pp. 235–240, May 2001.
- [BS00] H.J.C. Barbosa, A.M. Sá, "On Adaptive Operator Probabilities in Real Coded Genetic Algorithms", In Workshop on Advances and Trends in AI for Problem Solving, XX Int. Conf. of the Chilean Computer Science Society, 2000.
- [BS03] A.S. Braga, J.T. Saraiva, "Transmission Expansion Planning and Long Term Marginal Prices Calculation Using Simulated Annealing", IEEE Bologna Power Tech Conf., Bologna, Italy, June 2003.
- [BS05] A.S. Braga, J.T. Saraiva, "A Multiyear Dynamic Approach for Transmission Expansion Planning and Long-Term Marginal Costs Computation", IEEE Trans. on Power Syst., Vol. 20, No. 3, pp. 1631 – 1639, Aug. 2005.
- [CN99] J.L. Ceciliano, R. Nieva, "Transmission Network Planning Using Evolutionary Programming", Proc. of the 1999 Congress on Evolutionary Computation, Vol. 3, pp. 1796 – 1803, 1999.
- [D89] L. Davis, "Adapting Operator Probabilities in Genetic Algorithms", in Proc. 3rd International Conf. on Genetic Algorithms, Morgan Kaufmann Publishers Inc., pp. 61-69, 1989.
- [DE73] Y.P. Dusonchet, A.H. El-Abiad, "Transmission Planning Using Discrete Dynamic Optimization", IEEE Trans. on PAS, Vol. PAS-92, pp. 1358–1371, July 1973.
- [DLLW06] Z.Y. Dong, M. Lu, Z. Lu, K.P. Wong, "A Differential Evolution Based Method for Power System Planning", IEEE Congress on Evolutionary Computation, pp. 2699 – 2706, Vancouver, Canada, July 2006.
- [DR14] M.A.J. Delgado, M.J. Rider, "Algoritmo Branch and Bound Não Linear para Resolver o Problema de Planejamento da Expansão de Sistemas de Transmissão", Anais do V SBSE, Foz do Iguaçu, pp. 1-6, 2014.

- [EGR04] A.H. Escobar, R.A. Gallego, R. Romero, "Multistage and Coordinated Planning of the Expansion of Transmission Systems", *IEEE Trans. on Power Syst.*, Vol. 19, No. 2, pp. 735-744, May 2004.
- [EMSS07] A.E. Eiben, Z. Michalewicz, M. Schoenauer, J.E. Smith, "Parameter Control in Evolutionary Algorithms", In *Parameter setting in evolutionary algorithms*, Springer Berlin Heidelberg, pp. 19-46, 2007.
- [ES03] A.E. Eiben, J.E. Smith, "Introduction to Evolutionary Computing", Book: Springer Science & Business Media, 2003.
- [F07] A.R.S. Fialho, "Exploração de Relações entre as Técnicas Nebulosas e Evolutivas da Inteligência Computacional", *Dissertação de Mestrado*, USP, 2007.
- [F10] A.R.S. Fialho, "Adaptive Operator Selection for Optimization", Ph.D. Thesis, Université Paris-Sud XI, Orsay, France, 2010.
- [FABML16] E. Fernandez, I. Albizu, M.T. Bedialauneta, A.J. Mazon, P.T. Leite, "Review of Dynamic Line Rating Systems for Wind Power Integration", *Renewable and Sustainable Energy Reviews*, vol. 53, pp. 80-92, 2016.
- [FBG89] C.C. Fong, R. Billinton, R.O. Gunderson, P.M. O'Neill, J. Raksany, A.W. Schneider, B. Silverstein, "Bulk System Reliability-Measurement and Indices", *IEEE Transactions on Power Systems*, vol. 4, No.3, pp. 829-835, 1989.
- [FBRF05] H. Faria Jr., S. Binato, M.G.C. Resende, D.M. Falcão, "Power Transmission Network Design by Greedy Randomized Adaptive Path Relinking", *IEEE Trans. on Power Syst.*, vol. 20, no. 1, pp. 43-49, Feb. 2005.
- [FCSS08] A. Fialho, L. Costa, M. Schoenauer, M. Sebag, "Extreme Value Based Adaptive Operator Selection" in *Proc. of the 10th Int. Conf. on Parallel Problem Solving from Nature: PPSN X*. Berlin, Heidelberg: Springer-Verlag, 2008.
- [FRSS10] A. Fialho, R. Ros, M. Schoenauer, M. Sebag, "Comparison-Based Adaptive Strategy Selection with Bandits in Differential Evolution", In *Proc. 11th Int. Conf. on Parallel Problem Solving from Nature" - PPSN'10*, Springer, LNCS, p. 194-203, 2010.
- [G70] L.L. Garver, "Transmission Network Estimation Using Linear Programming", *IEEE Trans. on PAS*, Vol. PAS-89, No. 7, Sep. 1970.
- [GFC10] W. Gong, A. Fialho, Z. Cai, "Adaptive Strategy Selection in Differential Evolution", in *Proc. of the 12th GECCO*, New York, NY, USA, ACM, pp. 409-416, 2010.
- [GMR98a] R.A. Gallego, A. Monticelli, R. Romero, "Transmission Expansion Planning by Extended Genetic Algorithm", *IEE Proceedings: Generation, Transmission and Distribution*, Vol. 145, No. 3, pp. 329-335, May 1998.

- [GMR98b] R.A. Gallego, A. Monticelli, R. Romero, "Comparative Studies on Non-convex Optimization Methods for Transmission Network Expansion Planning", *IEEE Trans. Power Syst.*, Vol. 13, pp. 822–828, Aug. 1998.
- [GRRG09] L.A. Gallego, M.J. Rider, R. Romero, A.V.Garcia, "A Specialized Genetic Algorithm to Solve the Short Term Transmission Network Expansion Planning". In: *PowerTech 2009*, IEEE Bucharest, pp. 1-7, 2009.
- [H15] H. Khorasani, "Algoritmo Tabu Search Especializado para o Problema de Planejamento da Expansão de Sistemas de Transmissão.", Tese de Doutorado, UNESP, Ilha Solteira, SP, Fev. 2015.
- [HHK13] R. Hemmati, R.A. Hooshmand, A. Khodabakhshian, "State-of-the-Art of Transmission Expansion Planning: Comprehensive Review." *Renewable and Sustainable Energy Reviews*, v. 23, p. 312-319, 2013.
- [HMGR01] S. Haffner, A. Monticelli, A. Garcia, R. Romero, "Specialised Branch-and-Bound Algorithm for Transmission Network Expansion Planning", *IEE P. GTD*, Vol. 148, No. 5, pp. 482-488, 2001.
- [HW03] A. Hertz, M. Widmer, "Guidelines for the Use of Meta-Heuristics in Combinatorial Optimization", *European Journal of Operational Research*, v. 151, n. 2, p. 247-252, 2003.
- [J95] B.A. Julstrom, "What Have You Done For Me Lately? Adapting Operator Probabilities in A Steady-State Genetic Algorithm.", in *Proc. 6th Int. Conf. on Genetic Algorithms*, Morgan Kaufmann Publishers Inc., pp. 81-87, 1995.
- [JCYZ07] Y.X. Jin, H.Z. Cheng, J.Y. Yan, L. Zhang, "New Discrete Method for Particle Swarm Optimization and Its Application in Transmission Network Expansion Planning", *Electric Power Systems Research*, Vol. 77, pp. 227 – 233, 2007.
- [KPR13] H. Khorasani, M. Pourakbari-Kasmaei, R. Romero, "A Heuristic Method for Transmission Network Expansion Planning under Security Constraints.", in *Proceedings of IEPEN*, Istanbul, pp. 1-7, 2013.
- [LCAV03] G. Latorre, R.D. Cruz, J.M. Areiza, A. Villegas, "Classification of Publications and Models on Transmission Expansion Planning", *IEEE Trans. on Power Syst.*, Vol. 18, 2, pp. 938 – 946, May 2003.
- [LFH16] A.M. Leite da Silva, M.R. Freire, L.M. Honório, "Transmission Expansion Planning Optimization by Adaptive Multi-Operator Evolutionary Algorithms", *Electr. Power Syst. Res.*, vol. 133, pp. 173-181, April 2016.
- [LFK11] K. Li, A. Fialho, S. Kwong, "Multi-Objective Differential Evolution with Adaptive Control of Parameters and Operators.", In *Learning and Intelligent Optimization*, pp. 473-487, Springer, 2011.

- [LMMB00] A.M. Leite da Silva, L.A.F. Manso, J.C.O. Mello, R. Billinton, "Pseudo-Chronological Simulation for Composite Reliability Analysis with Time Varying Loads", *IEEE Trans. on Power Syst.*, Vol. 15, No. 1, pp. 73-80, Feb. 2000.
- [LMRR08] A.M. Leite da Silva, L.A.F. Manso, L.C. Resende, L.S. Rezende, "Tabu Search Applied to Transmission Expansion Planning Considering Losses and Interruption Costs", *Proc. of the 10th PMAPS, Puerto Rico*, May 2008.
- [LRHM11] A.M. Leite da Silva, L.S. Rezende, L.M. Honório, L.A.F. Manso, "Performance Comparison of Metaheuristics to Solve the Multi-Stage Transmission Expansion Planning Problem", *IET Gener. Transm. Distrib.*, vol. 5, Iss. 3, pp. 360–367, 2011.
- [LRM11] A.M. Leite da Silva, L.S. Rezende, L.A.F. Manso, "Transmission Expansion Planning: A Methodology to Include Security Criteria and Uncertainties Using Optimization Techniques", *Innovations in Power Systems Reliability*, Springer London, pp. 191-220, 2011.
- [LSMRRS08] A.M. Leite da Silva, C.E. Sacramento, L.A.F. Manso, L.S. Rezende, L.C. Resende, W.S. Sales, "Metaheuristic-Based Optimization Methods for Transmission Expansion Planning Considering Unreliability Costs", Chapter 4, In E.D. Castronuovo, *Optimization Advances in Electric Power Systems*, Nova Publishers, USA, pp 59 – 86, 2008.
- [LSRMSR06] A.M. Leite da Silva, W.S. Sales, L.C. Resende, L.A.F. Manso, C.E. Sacramento, L.S. Rezende, "Evolution Strategies to Transmission Expansion Planning Considering Unreliability Costs", *Proc. of the 9th PMAPS*, Stockholm, Sweden, Jun 2006.
- [M14] L.A.F. Manso, et al., "Metodologia para o Planejamento de Reforços em Sistemas de Subtransmissão", in *Anais do XIII SEPOPE*, Foz do Iguaçu, 2014.
- [M83] A.J. Monticelli, "Fluxo de Carga em Redes de Energia Elétrica", Editora Edgar Bucher Ltda, São Paulo, 1983.
- [MALRS14] L.A.F. Manso, F.A. Assis, A.M. Leite da Silva, L.C. Resende, F.L. Santos, "Constructive Heuristic Algorithm for Sub-Transmission System Planning", In: *Power Systems Computation Conference (PSCC)*, IEEE, pp. 1-7, 2014.
- [MARL12] L.A.F. Manso, P.E. Abreu, L.C. Resende, A.M. Leite da Silva, "Transmission Expansion Planning Including Unreliability Costs", *Proc. of the 12th PMAPS*, IEEE, Istanbul, pp. 1-6, Jun. 2012.
- [MFSSS09] J. Maturana, A. Fialho, F. Saubion, M. Schoenauer, M. Sebag, "Extreme Compass and Dynamic Multi-Armed Bandits for Adaptive Operator Selection", *Evolutionary Computation*, CEC'09, IEEE, 2009.

- [MI07] H. Mori, Y. Iimura, "Transmission Network Expansion Planning with a Hybrid Meta-heuristic Method of Parallel Tabu Search and Ordinal Optimization", Int. Conf. on Intelligent Syst. App. to Power Syst., Vol. 5, No. 8, pp. 1-6, 2007.
- [ML04] L.A.F. Manso, A.M. Leite da Silva, "Probabilistic Criteria for Power System Expansion Planning", Electric Power Systems Research, Vol. 69, No. 1, pp. 51-58, April 2004.
- [MLS94] Z. Michalewicz, T. Logan, S. Swaminathan, "Evolutionary Operators for Continuous Convex Parameter Spaces", Proc. of the 3rd Annual Conference on Evolutionary Programming, p. 84-97, 1994.
- [MS01] H. Mori, Y. Sone, "A Parallel Tabu Search Based Approach to Transmission Network Expansion Planning", IEEE Porto Power Tech Conference, Porto, Portugal, 2001.
- [MSA15] A. Moreira, A. Street, J.M. Arroyo, "An Adjustable Robust Optimization Approach for Contingency-Constrained Transmission Expansion Planning.", IEEE Transactions on Power Systems, Vol. 30, pp. 2013-2022, 2015.
- [MSLRSR07] L.A.F. Manso, C.E. Sacramento, A.M. Leite da Silva, L.C. Resende, W.S. Sales, L.S. Rezende, "Planejamento da Expansão da Transmissão via Estratégias de Evolução Considerando o Valor da Confiabilidade e os Custos de Perdas", XIX SNTPEE, Grupo VII, GPL/026, RJ, 2007.
- [MSPCPP82] A. Monticelli, A. Santos Jr., M.V.F. Pereira, S.H.F. Cunha, B.J. Parker, J.C.G. Praça, "Interactive Transmission Network Planning Using a Least-Effort Criterion", IEEE Trans. on PAS, Vol. PAS-101 pp. 3919-3925, 1982.
- [POHS15] R.P.B. Poubel, E.J. Oliveira, L.M. Honório, I.C. Siva Jr, "A Coupled Model to Multistage Transmission Expansion Planning.", Journal of Control, Automation and Electrical Systems - SBA, Vol. 26, pp. 272-282, 2015.
- [PP85] M.V.F. Pereira, L.M.V.G. Pinto, "Application of Sensitivity Analysis of Load Supplying Capability to Interactive Transmission Expansion Planning", IEEE Trans. on PAS, Vol. PAS-104, pp. 381-389, Feb. 1985.
- [Q14] J.C.L. Quizhpi, "Planejamento de Reativos em Sistemas Elétricos de Potência Multi-Área Através de Modelos Estocásticos", Tese de Doutorado, UNESP, Ilha Solteira, SP, 2014.
- [R06] L.S. Rezende, "Planejamento da Expansão de Sistemas de Transmissão Através de Otimização por Colônia de Formigas", Dissertação de Mestrado, UNIFEI, Itajubá, MG, 2006.

- [R11] L.S. Rezende, “Planejamento da Expansão de Sistemas de Transmissão: Avaliação de Metaheurísticas e Critérios de Segurança”, Tese de Doutorado, UNIFEI, Itajubá, MG, 2011.
- [REAL99] REAL: “Reliability Analysis of Electric Power Systems”, User’s Manual, Version 2.0, Itajubá, MG, 1999.
- [RGM96] R. Romero, R.A. Gallego, A. Monticelli, “Transmission System Expansion Planning by Simulated Annealing”, IEEE Trans. on Power Syst., Vol. 11, pp. 364–369, Feb. 1996.
- [RGR07] M.J. Rider, A.V. Garcia, R. Romero, “Power System Transmission Network Expansion Planning Using AC Model”, IET Gener. Transm. Distrib., Vol. 1, No. 5, pp. 731 – 742, Sep. 2007.
- [RLH09] L.S. Rezende, A.M. Leite da Silva, L.M. Honório, “Artificial Immune System Applied to the Multi-stage Transmission Expansion Planning”, Lecture Notes in Computer Science, Springer-Verlag, Vol. 5666, pp. 178 – 191, Aug. 2009.
- [RLM08] L.S. Rezende, A.M. Leite da Silva e L.A.F. Manso, “Aplicação de Colônia de Formigas ao Planejamento Cronológico da Expansão da Transmissão Considerando Restrições de Confiabilidade”, XVII CBA – Congresso Brasileiro de Automática, Juiz de Fora, MG, Set. 2008.
- [RLMSR06] L.S. Rezende, A.M. Leite da Silva, L.A.F. Manso, W.S. Sales e L.C. Resende, “Planejamento da Expansão da Transmissão Utilizando Colônia de Formigas”, XVI CBA – Congresso Brasileiro de Automática, Salvador, BA, Out. 2006.
- [RMGH02] R. Romero, A. Monticelli, A. Garcia, S. Haffner, “Test Systems and Mathematical Models for Transmission Network Expansion Planning”, IEE Proc.-Gener. Transm. Distrib., Vol. 149, No. 1, pp. 27 – 36, Jan. 2002.
- [RPCS96] H. Rudnick, R. Palma, E. Cura, C. Silva, “Economically Adapted Transmission Systems in Open Access Schemes – Application of Genetic Algorithms”, IEEE Trans. Power Syst., vol. 11, pp. 1427–1440, Aug. 1996.
- [RRS07] R. Romero, M.J. Rider, I.J. Silva, “A Metaheuristic to Solve the Transmission Expansion Planning”, IEEE Trans. on Power Syst., Vol. 22, No. 4, pp. 2289 – 2291, Nov. 2007.
- [SA15] A.S. Sousa, E.N. Asada, “Long-Term Transmission System Expansion Planning with Multi-Objective Evolutionary Algorithm”, Electric Power Systems Research, v. 119, p. 149-156, 2015.
- [SB98] A.M. Sá, H.J.C. Barbosa, “Adaptação das Probabilidades dos Operadores Genéticos: Um Problema de Decisão.”, Anais do V seminário sobre Elementos Finitos e Métodos Numéricos em Engenharia, pp. 31-44, UFJF, 1998.

- [SLFG14] R.C. Silva, R. Lopes, A.R. Freitas, F.G. Guimarães, "A Study on Self-Configuration in the Differential Evolution Algorithm", in Differential Evolution (SDE) 2014, IEEE Symposium, pp. 1-8, 2014.
- [SRC02] P.S. Sensarma, M. Rahmani, A. Carvalho, "A Comprehensive Method for Optimal Expansion Planning Using Particle Swarm Optimization", IEEE Power Eng. Society Winter Meeting, Vol. 2, pp. 1317-1322, 2002.
- [SRRGM05] I.J. Silva, M.J. Rider, R. Romero, A.V. Garcia, C.A. Murari, "Transmission Network Expansion Planning with Security Constraints", IEE Proc.-Gener. Transm. Distrib., Vol. 152, No. 6, pp. 828 – 836, Nov. 2005.
- [SSL89] A. Seifu, S. Salon, G. List, "Optimization of Transmission Line Planning Including Security Constraints", IEEE Trans. on Power Syst., Vol. 4, pp.1507 – 1513, 1989.
- [STIS07] T. Sum-Im, G.A. Taylor, M.R. Irving, Y.H. Song, "A Differential Evolution Algorithm for Multistage Transmission Expansion Planning", UPEC 2007, pp. 357 – 364, Sep. 2007.
- [T05] D. Thierens, "An Adaptive Pursuit Strategy for Allocating Operator Probabilities", in Proceedings of the 2005 Conference on Genetic and Evolutionary Computation - GECCO'05, p. 1539, 2005.
- [TGS08] O.B. Tor, A.N. Guven, M. Shahidehpour, "Congestion-Driven Transmission Planning Considering the Impact of Generator Expansion", IEEE Trans. on Power Syst., Vol. 23, pp. 781 – 789, May 2008.
- [TS10] T. Takahama, S. Sakai, "Constrained Optimization by the ϵ Constrained Differential Evolution with an Archive and Gradient-based Mutation", In Evolutionary Computation CEC-2010, IEEE Congress, pp. 1-9, 2010.
- [VGS85] R. Villasana, L.L. Garver, S.J. Salon, "Transmission Network Planning Using Linear Programming", IEEE Trans. on PAS, Vol. PAS-104, pp. 349-356, 1985.
- [VTSR14] G. Vinasco, D. Tejada, E. Silva, M. Rider, "Transmission Network Expansion Planning for the Colombian Electrical System: Connecting the Ituango Hydroelectric Power Plant.", Electric Power Systems Research, 110, 94-103, 2014.
- [VZ00] F.J. Von Zuben, "Computação Evolutiva: Uma Abordagem Pragmática" Anais da I Jornada de Estudos em Computação de Piracicaba e Região (1a JECOMP), 2000.
- [W07] J.M. Whitacre, "Adaptation and Self-Organization in Evolutionary Algorithms", Ph.D. Thesis, University of New South Wales, 2007.
- [WM97] D.H. Wolpert, W.G. Macready, "No Free Lunch Theorems for Optimization", Evolutionary Computation, IEEE Transactions on, vol. 1, n. 1, p. 67-82, 1997.

- [WPS06] J.M. Whitacre, T.Q. Pham, R.A. Sarker, "Use of Statistical Outlier Detection Method in Adaptive Evolutionary Algorithms", In Proceedings of the 8th GECCO, pp. 1345-1352, ACM, 2006.
- [XDW06] Z. Xu, Z.Y. Dong, K.P. Wong, "Transmission Planning in a Deregulated Environment", IEE Proc.-Gener. Transm. Distrib., Vol. 153, No. 3, pp. 326 – 334, May 2006.
- [Y01] H.K.M. Youssef, "Dynamic Transmission Planning Using a Constrained Genetic Algorithm", Electrical Power and Energy Systems, Vol. 23, pp. 857 – 862, 2001
- [YGD08] Q. Yu, J. Guo, X. Duan, "Dynamic Multi-stage Transmission Network Expansion Planning", DRPT 2008, pp. 635 – 640, April 2008.
- [YH89] H.K. Youssef, R. Hackam, "New Transmission Planning Model", IEEE Trans. on Power Syst., Vol. 4, pp. 9–18, Feb. 1989.
- [YHJX05] C. Yuehui, C. Haiyan, C. Jinfu, D. Xianzhong, "An Improved Particle Swarm Optimization Algorithm for Multistage and Coordinated Planning of Transmission Systems", IEEE/PES Trans. Distrib. Conf. and Exh., pp. 1 – 6, 2005.
- [ZM15] R.D. Zimmerman, C.E. Murillo-Sanchez, "Matpower 5.1 - User's Manual", Power Systems Engineering Research Center (PSERC), 2015.

APÊNDICE A

DADOS PARA OS SISTEMAS TESTES

Neste Apêndice são apresentadas tabelas com os dados de barras, linhas e transformadores para os sistemas elétricos estudados, sendo:

- N_B é o número de identificação da barra;
- **Tipo** identifica o tipo da barra: PV (geração), PQ (carga) ou V θ (*swing*);
- **Nível** é o nível de tensão da barra (kV);
- P_D e Q_D são, respectivamente, as potências ativa (MW) e reativa (MVAr) demandas pela carga na barra;
- P_G^{\max} e P_G^{\min} são, respectivamente, as capacidades máxima e mínima para a geração de potência ativa (MW) na barra;
- Q_G^{\max} e Q_G^{\min} são, respectivamente, as capacidades máxima e mínima para a geração de potência reativa (MVAr) na barra;
- **OM** é a prioridade da barra (“ordem mérito”) no redespacho de geração;
- **ID** é o número de identificação do ramo (linha de transmissão ou transformador);
- $i - j$ é a identificação das barras terminais do ramo;
- n_{ij}^0 é o número de elementos presente no caso base (topologia original);
- r_{ij} é a resistência para um único elemento do ramo (p.u.);
- x_{ij} é a reatância para um único elemento do ramo (p.u.);
- b_{ij}^{sh} é a susceptância *shunt* para um único elemento do ramo (p.u.);
- f_{ij}^{\max} é o fluxo de potência ativa (MW) máximo permitido para um único elemento do ramo (utilizado no modelo de rede DC);
- S_{ij}^{\max} é o fluxo de potência aparente (MVA) máximo permitido para um único elemento do ramo (utilizado no modelo de rede AC);
- c_{ij} é o custo para adição de um elemento ao ramo ($\times 10^6$ US\$);
- T_F é a taxa de falha para o ramo (número de falhas por ano);
- T_R é tempo médio de reparo para o ramo (horas);

A.1 SISTEMA IEEE RTS-79 (IEEE24)

Tabela A.1: Dados de barra para o sistema IEEE24.

N_B	Tipo	Nível	P_D	Q_D	P_G^{max}	P_G^{min}	Q_G^{max}	Q_G^{min}	OM
1	PV	138	324,0	66,0	576,0	0,0	240,0	-150,0	3
2	PV	138	291,0	60,0	576,0	0,0	240,0	-150,0	1
3	PQ	138	540,0	111,0	-	-	-	-	-
4	PQ	138	222,0	45,0	-	-	-	-	-
5	PQ	138	213,0	42,0	-	-	-	-	-
6	PV	138	408,0	84,0	0,0	0,0	0,0	-300,0	-
7	PV	138	375,0	75,0	900,0	0,0	540,0	0,0	2
8	PQ	138	513,0	105,0	-	-	-	-	-
9	PQ	138	525,0	108,0	-	-	-	-	-
10	PQ	138	585,0	120,0	-	-	-	-	-
11	PQ	230	0,0	0,0	-	-	-	-	-
12	PQ	230	0,0	0,0	-	-	-	-	-
13	PV	230	795,0	162,0	1773,0	0,0	720,0	0,0	4
14	PV	230	582,0	117,0	0,0	0,0	600,0	-150,0	-
15	PV	230	951,0	192,0	645,0	0,0	330,0	-150,0	5
16	PV	230	300,0	60,0	465,0	0,0	240,0	-150,0	7
17	PQ	230	0,0	0,0	-	-	-	-	-
18	PV	230	999,0	204,0	1200,0	0,0	600,0	-150,0	9
19	PQ	230	543,0	111,0	-	-	-	-	-
20	PQ	230	384,0	78,0	-	-	-	-	-
21	PV	230	0,0	0,0	1200,0	0,0	600,0	-150,0	8
22	PV	230	0,0	0,0	900,0	0,0	288,0	-180,0	10
23	Vθ	230	0,0	0,0	1980,0	0,0	930,0	-375,0	6
24	PQ	230	0,0	0,0	-	-	-	-	-
TOTAL:			8550	1740	10.215	0,0	5328	-1905	-

Tabela A.2: Dados de linhas e transformadores para o sistema IEEE24.

ID	$i-j$	n_{ij}^0	r_{ij}	x_{ij}	b_{ij}^{sh}	f_{ij}^{max}	S_{ij}^{max}	c_{ij}	T_F	T_R
1	1-2	1	0,0026	0,0139	0,4611	175	220	3	0,3300	10
2	1-3	1	0,0546	0,2112	0,0572	175	220	55	0,3900	10
3	1-5	1	0,0218	0,0845	0,0229	175	220	22	0,4800	10
4	2-4	1	0,0328	0,1267	0,0343	175	220	33	0,3800	10
5	2-6	1	0,0497	0,1920	0,0520	175	220	50	0,0200	768
6	3-9	1	0,0308	0,1190	0,0322	175	220	31	0,3600	10
7	3-24	1	0,0023	0,0839	0,0000	400	600	50	0,3400	10
8	4-9	1	0,0268	0,1037	0,0281	175	220	27	0,3300	35
9	5-10	1	0,0228	0,0883	0,0239	175	220	23	0,3000	10
10	6-10	1	0,0139	0,0605	2,4590	175	220	16	0,4400	10
11	7-8	1	0,0159	0,0614	0,0166	175	220	16	0,4400	10
12	8-9	1	0,0427	0,1651	0,0447	175	220	43	0,0200	768
13	8-10	1	0,0427	0,1651	0,0447	175	220	43	0,0200	768
14	9-11	1	0,0023	0,0839	0,0000	400	600	50	0,0200	768
15	9-12	1	0,0023	0,0839	0,0000	400	600	50	0,0200	768
16	10-11	1	0,0023	0,0839	0,0000	400	600	50	0,4000	11
17	10-12	1	0,0023	0,0839	0,0000	400	600	50	0,3900	11
18	11-13	1	0,0061	0,0476	0,0999	500	625	66	0,4000	11
19	11-14	1	0,0054	0,0418	0,0879	500	625	58	0,5200	11
20	12-13	1	0,0061	0,0476	0,0999	500	625	66	0,4900	11
21	12-23	1	0,0124	0,0966	0,2030	500	625	134	0,3800	11
22	13-23	1	0,0111	0,0865	0,1818	500	625	120	0,3300	11
23	14-16	1	0,0050	0,0389	0,0818	500	625	54	0,4100	11
24	15-16	1	0,0022	0,0173	0,0364	500	625	24	0,4100	11
25	15-21	2	0,0063	0,0490	0,1030	500	625	68	0,3500	11
26	15-24	1	0,0067	0,0519	0,1091	500	625	72	0,3400	11
27	16-17	1	0,0033	0,0259	0,0545	500	625	36	0,3200	11
28	16-19	1	0,0030	0,0231	0,0485	500	625	32	0,5400	11
29	17-18	1	0,0018	0,0144	0,0303	500	625	20	0,3500	11
30	17-22	1	0,0135	0,1053	0,2212	500	625	146	0,3800	11
31	18-21	2	0,0033	0,0259	0,0545	500	625	36	0,3400	11
32	19-20	2	0,0051	0,0396	0,0833	500	625	55	0,4500	11
33	20-23	2	0,0028	0,0216	0,0455	500	625	30	0,4385	10
34	21-22	1	0,0087	0,0678	0,1424	500	625	94	0,4134	10
35	1-8	0	0,0174	0,1344	0,0000	500	625	35	0,6264	10
36	2-8	0	0,0164	0,1267	0,0000	500	625	33	0,4818	11
37	6-7	0	0,0249	0,1920	0,0000	500	625	50	0,6684	11
38	13-14	0	0,0058	0,0447	0,0000	500	625	62	0,8860	11
39	14-23	0	0,0080	0,0620	0,0000	500	625	86	0,6528	11
40	16-23	0	0,0106	0,0822	0,0000	500	625	114	0,3300	10
41	19-23	0	0,0078	0,0606	0,0000	500	625	84	0,3900	10

A.2 SISTEMA SUL BRASILEIRO (SBR)

Tabela A.3: Dados de barra para o sistema SBR.

N_B	Tipo	Nível	P_D	Q_D	P_G^{max}	P_G^{min}	Q_G^{max}	Q_G^{min}	OM
1	PQ	230	0,0	0,0	-	-	-	-	-
2	PQ	230	443,1	66,5	-	-	-	-	-
3	PQ	500	0,0	0,0	-	-	-	-	-
4	PQ	230	300,7	45,1	-	-	-	-	-
5	PQ	230	238,0	35,7	-	-	-	-	-
6	PQ	500	0,0	0,0	-	-	-	-	-
7	PQ	230	0,0	0,0	-	-	-	-	-
8	PQ	230	72,2	10,8	-	-	-	-	-
9	PQ	230	0,0	0,0	-	-	-	-	-
10	PQ	500	0,0	0,0	-	-	-	-	-
11	PQ	230	0,0	0,0	-	-	-	-	-
12	PQ	230	511,9	76,8	-	-	-	-	-
13	PQ	230	185,8	27,9	-	-	-	-	-
14	PV	230	0,0	0,0	1257,0	0,0	377,1	-125,7	10
15	PQ	230	0,0	0,0	-	-	-	-	-
16	Vθ	500	0,0	0,0	2000,0	0,0	600,0	-200,0	11
17	PV	500	0,0	0,0	1050,0	0,0	315,0	-105,0	2
18	PQ	230	0,0	0,0	-	-	-	-	-
19	PV	500	0,0	0,0	1670,0	0,0	501,0	-167,0	1
20	PQ	230	1091,2	163,7	-	-	-	-	-
21	PQ	500	0,0	0,0	-	-	-	-	-
22	PQ	230	81,9	12,3	-	-	-	-	-
23	PQ	230	458,1	68,7	-	-	-	-	-
24	PQ	230	478,2	71,7	-	-	-	-	-
25	PQ	500	0,0	0,0	-	-	-	-	-
26	PQ	230	231,9	34,8	-	-	-	-	-
27	PV	230	0,0	0,0	220,0	0,0	66,0	-22,0	6
28	PV	500	0,0	0,0	800,0	0,0	240,0	-80,0	12
29	PQ	230	0,0	0,0	-	-	-	-	-
30	PQ	500	0,0	0,0	-	-	-	-	-
31	PV	500	0,0	0,0	700,0	0,0	210,0	-70,0	8
32	PV	500	0,0	0,0	500,0	0,0	150,0	-50,0	7
33	PQ	230	229,1	34,4	-	-	-	-	-
34	PV	230	0,0	0,0	748,0	0,0	224,4	-74,8	5
35	PQ	230	216,0	32,4	-	-	-	-	-
36	PQ	230	90,1	13,5	-	-	-	-	-
37	PV	230	0,0	0,0	300,0	0,0	90,0	-30,0	9

(Continuação da Tabela A.3)

N_B	Tipo	Nível	P_D	Q_D	P_G^{\max}	P_G^{\min}	Q_G^{\max}	Q_G^{\min}	OM
38	PQ	230	216,0	32,4	–	–	–	–	–
39	PV	500	0,0	0,0	600,0	0,0	180,0	-60,0	3
40	PQ	230	262,1	39,3	–	–	–	–	–
41	PQ	500	0,0	0,0	–	–	–	–	–
42	PQ	230	1607,9	241,2	–	–	–	–	–
43	PQ	230	0,0	0,0	–	–	–	–	–
44	PQ	500	79,1	11,9	–	–	–	–	–
45	PQ	230	86,7	13,0	–	–	–	–	–
46	PV	500	0,0	0,0	700,0	0,0	210,0	-70,0	4
TOTAL:			6880	1032,1	10.545	0,0	3163,5	-1054,5	–

Tabela A.4: Dados de linhas e transformadores para o sistema SBR.

ID	$i-j$	n_{ij}^0	r_{ij}	x_{ij}	b_{ij}^{sh}	f_{ij}^{\max}	S_{ij}^{\max}	c_{ij}	T_F	T_R
1	1-7	1	0,00616	0,0616	0,0006	270	324	4,349	1,9312	1,0114
2	1-2	2	0,01065	0,1065	0,0011	270	324	7,076	3,3389	1,0114
3	4-9	1	0,00924	0,0924	0,0009	270	324	6,217	2,8969	1,0114
4	5-9	1	0,01173	0,1173	0,0012	270	324	7,732	3,6775	1,0114
5	5-8	1	0,01132	0,1132	0,0011	270	324	7,480	3,5490	1,0114
6	7-8	1	0,01023	0,1023	0,0010	270	324	6,823	3,2072	1,0114
7	4-5	2	0,00566	0,0566	0,0006	270	324	4,046	1,7745	1,0114
8	2-5	2	0,00324	0,0324	0,0003	270	324	2,581	1,0158	1,0114
9	8-13	1	0,01348	0,1348	0,0013	240	288	8,793	4,2262	1,0114
10	9-14	2	0,01756	0,1756	0,0018	220	264	11,267	5,5053	1,0114
11	12-14	2	0,00740	0,0740	0,0007	270	324	5,106	2,3200	1,0114
12	14-18	2	0,01514	0,1514	0,0015	240	288	9,803	4,7466	1,0114
13	13-18	1	0,01805	0,1805	0,0018	220	264	11,570	5,6589	1,0114
14	13-20	1	0,01073	0,1073	0,0011	270	324	7,126	3,3640	1,0114
15	18-20	1	0,01997	0,1997	0,0020	200	240	12,732	6,2609	1,0114
16	19-21	1	0,00278	0,0278	0,0003	1500	1800	32,632	4,0058	2,3547
17	16-17	1	0,00078	0,0078	0,0001	2000	2400	10,505	1,1239	2,3547
18	17-19	1	0,00061	0,0061	0,0001	2000	2400	8,715	0,8790	2,3547
19	14-26	1	0,01614	0,1614	0,0016	220	264	10,409	5,0601	1,0114
20	14-22	1	0,00840	0,0840	0,0008	270	324	5,712	2,6335	1,0114
21	22-26	1	0,00790	0,0790	0,0008	270	324	5,409	2,4768	1,0114
22	20-23	2	0,00932	0,0932	0,0009	270	324	6,268	2,9219	1,0114
23	23-24	2	0,00774	0,0774	0,0008	270	324	5,308	2,4266	1,0114
24	26-27	2	0,00832	0,0832	0,0008	270	324	5,662	2,6084	1,0114
25	24-34	1	0,01647	0,1647	0,0016	220	264	10,611	5,1636	1,0114
26	24-33	1	0,01448	0,1448	0,0014	240	288	9,399	4,5397	1,0114
27	33-34	1	0,01265	0,1265	0,0013	270	324	8,288	3,9659	1,0114
28	27-36	1	0,00915	0,0915	0,0009	270	324	6,167	2,8686	1,0114
29	27-38	2	0,02080	0,2080	0,0021	200	240	13,237	6,5211	1,0114
30	36-37	1	0,01057	0,1057	0,0011	270	324	7,025	3,3138	1,0114
31	34-35	2	0,00491	0,0491	0,0005	270	324	3,591	1,5394	1,0114

(Continuação da Tabela A.4)

ID	i - j	n_{ij}^0	r_{ij}	x_{ij}	b_{ij}^{sh}	f_{ij}^{max}	S_{ij}^{max}	C_{ij}	T_F	T_R
32	35-38	1	0,01980	0,1980	0,0020	200	240	12,631	6,2076	1,0114
33	37-39	1	0,00283	0,0283	0,0003	270	324	2,329	0,8872	1,0114
34	37-40	1	0,01281	0,1281	0,0013	270	324	8,389	4,0161	1,0114
35	37-42	1	0,02105	0,2105	0,0021	200	240	13,388	6,5995	1,0114
36	39-42	3	0,02030	0,2030	0,0020	200	240	12,934	6,3643	1,0114
37	40-42	1	0,00932	0,0932	0,0009	270	324	6,268	2,9219	1,0114
38	38-42	3	0,00907	0,0907	0,0009	270	324	6,116	2,8436	1,0114
39	32-43	1	0,00309	0,0309	0,0003	1400	1680	35,957	4,4525	2,3547
40	42-44	1	0,01206	0,1206	0,0012	270	324	7,934	3,7810	1,0114
41	44-45	1	0,01864	0,1864	0,0019	200	240	11,924	5,8439	1,0114
42	19-32	1	0,00195	0,0195	0,0002	1800	2160	23,423	2,8098	2,3547
43	46-19	1	0,00222	0,0222	0,0002	1800	2160	26,365	3,1989	2,3547
44	46-16	1	0,00203	0,0203	0,0002	1800	2160	24,319	2,9251	2,3547
45	18-19	1	0,00125	0,0125	0,0001	600	720	8,178	0,5945	53,655
46	20-21	1	0,00125	0,0125	0,0001	600	720	8,178	0,5945	53,655
47	42-43	1	0,00125	0,0125	0,0001	600	720	8,178	0,5945	53,655
48	2-4	0	0,00882	0,0882	0,0009	270	324	5,965	2,7652	1,0114
49	14-15	0	0,00374	0,0374	0,0004	270	324	2,884	1,1725	1,0114
50	46-10	0	0,00081	0,0081	0,0001	2000	2400	10,889	1,1672	2,3547
51	4-11	0	0,02246	0,2246	0,0022	240	288	14,247	7,0415	1,0114
52	5-11	0	0,00915	0,0915	0,0009	270	324	6,167	2,8686	1,0114
53	46-6	0	0,00128	0,0128	0,0001	2000	2400	16,005	1,8444	2,3547
54	46-3	0	0,00203	0,0203	0,0002	1800	2160	24,319	2,9251	2,3547
55	16-28	0	0,00222	0,0222	0,0002	1800	2160	26,365	3,1989	2,3547
56	16-32	0	0,00311	0,0311	0,0003	1400	1680	36,213	4,4813	2,3547
57	17-32	0	0,00232	0,0232	0,0002	1700	2040	27,516	3,3430	2,3547
58	19-25	0	0,00325	0,0325	0,0003	1400	1680	37,748	4,6831	2,3547
59	21-25	0	0,00174	0,0174	0,0002	2000	2400	21,121	2,5072	2,3547
60	25-32	0	0,00319	0,0319	0,0003	1400	1680	37,109	4,5966	2,3547
61	31-32	0	0,00046	0,0046	0,0000	2000	2400	7,052	0,6628	2,3547
62	28-31	0	0,00053	0,0053	0,0001	2000	2400	7,819	0,7637	2,3547
63	28-30	0	0,00058	0,0058	0,0001	2000	2400	8,331	0,8357	2,3547
64	27-29	0	0,00998	0,0998	0,0010	270	324	6,672	3,1289	1,0114
65	26-29	0	0,00541	0,0541	0,0005	270	324	3,894	1,6961	1,0114
66	28-41	0	0,00339	0,0339	0,0003	1300	1560	39,283	4,8848	2,3547
67	28-43	0	0,00406	0,0406	0,0004	1200	1440	46,701	5,8502	2,3547
68	31-41	0	0,00278	0,0278	0,0003	1500	1800	32,632	4,0058	2,3547
69	32-41	0	0,00309	0,0309	0,0003	1400	1680	35,957	4,4525	2,3547
70	41-43	0	0,00139	0,0139	0,0001	2000	2400	17,284	2,0029	2,3547
71	40-45	0	0,02205	0,2205	0,0022	180	216	13,994	6,9130	1,0114
72	15-16	0	0,00125	0,0125	0,0001	600	720	8,178	0,5945	53,655
73	46-11	0	0,00125	0,0125	0,0001	600	720	8,178	0,5945	53,655
74	24-25	0	0,00125	0,0125	0,0001	600	720	8,178	0,5945	53,655
75	29-30	0	0,00125	0,0125	0,0001	600	720	8,178	0,5945	53,655
76	40-41	0	0,00125	0,0125	0,0001	600	720	8,178	0,5945	53,655
77	2-3	0	0,00125	0,0125	0,0001	600	720	8,178	0,5945	53,655
78	5-6	0	0,00125	0,0125	0,0001	600	720	8,178	0,5945	53,655
79	9-10	0	0,00125	0,0125	0,0001	600	720	8,178	0,5945	53,655