



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

SILVIA MARA LIMA DA SILVA

**META-HEURÍSTICA MULTIPARTIDA COM *PATH RELINKING*
APLICADOS AO PLANEJAMENTO DA EXPANSÃO DE SISTEMAS DE
TRANSMISSÃO DE ENERGIA ELÉTRICA**

Ilha Solteira

2020



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

PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

SILVIA MARA LIMA DA SILVA

**META-HEURÍSTICA MULTIPARTIDA COM *PATH RELINKING*
APLICADOS AO PLANEJAMENTO DA EXPANSÃO DE SISTEMAS DE
TRANSMISSÃO DE ENERGIA ELÉTRICA**

Dissertação apresentada à Faculdade de Engenharia de Ilha Solteira, FEIS-UNESP como parte dos requisitos para obtenção do título de Mestre em Engenharia Elétrica.
Área de Conhecimento: Automação.

Prof. Dr. Rúben Augusto Romero Lázaro.
Orientador

Prof. Dr. Lucas Teles de Faria.
Coorientador

Ilha Solteira

2020

FICHA CATALOGRÁFICA
Desenvolvido pelo Serviço Técnico de Biblioteca e Documentação

S586m Silva, Silvia Mara Lima da.
Meta-heurística Multipartida com *Path Relinking* aplicados ao planejamento da expansão de sistemas de transmissão de energia elétrica / Silvia Mara Lima da Silva. -- Ilha Solteira: [s.n.], 2020
81 f. : il.

Dissertação (mestrado) - Universidade Estadual Paulista. Faculdade de Engenharia de Ilha Solteira. Área de conhecimento: Automação, 2020

Orientador: Rúben Augusto Romero Lázaro

Coorientador: Lucas Teles de Faria

Inclui bibliografia

1. Meta-heurística Multipartida (MMP). 2. *Path Relinking*. 3. Planejamento da Expansão de Sistemas de Transmissão (PEST).


Raiane da Silva Santos

Supervisora Técnica de Engenharia
Serviço Técnico de Biblioteca e Documentação
Diretoria Técnica de Biblioteca e Documentação
13064-9 - 1999

CERTIFICADO DE APROVAÇÃO

TÍTULO DA DISSERTAÇÃO: Meta-heurística multipartida aplicada ao planejamento da expansão de sistemas de transmissão de energia elétrica

AUTORA: SILVIA MARA LIMA DA SILVA

ORIENTADOR: RUBEN AUGUSTO ROMERO LAZARO

COORIENTADOR: LUCAS TELES DE FARIA

Aprovada como parte das exigências para obtenção do Título de Mestra em ENGENHARIA ELÉTRICA, área: Automação pela Comissão Examinadora:



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



Profa. Dra. ANNA DIVA PLASENCIA LOTUFO
Departamento de Engenharia Elétrica / Faculdade de Engenharia de Ilha Solteira - UNESP



Prof. Dr. CARLOS ROBERTO MENDONÇA DA ROCHA
Centro de Engenharias e Ciências Exatas / Universidade Estadual do Oeste do Paraná - UNIOESTE

Ilha Solteira, 17 de agosto de 2020

*“A imaginação é mais importante do que a ciência, porque a ciência é limitada, ao passo que a imaginação abrange o mundo inteiro”
(Albert Einstein).*

AGRADECIMENTOS

A Deus pela oportunidade de trabalhar em uma instituição pública de excelência.

Ao professor Rubén Augusto Romero Lázaro, por ter aceitado orientar-me no mestrado, pela paciência e dedicação a este trabalho.

Ao professor Lucas Teles de Faria, pelo suporte, dedicação e paciência com que me coorientou neste trabalho.

A minha linda filha Manuela, pelo sorriso que me fortalece todos os dias.

A minha mãe Neide que sempre me incentivou em todos os aspectos de minha vida. Obrigada por todo amor e carinho.

Ao meu esposo Alessandro pelo incentivo e compreensão quando precisei me ausentar.

Ao meu irmão Leandro, minha cunhada Alessandra, meus sobrinhos Raissa e Heitor, pelo apoio.

Aos queridos amigos que me acompanharam de perto durante esses anos do mestrado: Érica, Lucas, Marlon, Patrícia e Raiane.

As minhas amigas da época de graduação que sempre torceram muito por mim.

A UNESP, ao Departamento de Engenharia Elétrica da FEIS pela excelente estrutura oferecida para o pleno desenvolvimento deste trabalho.

RESUMO

O Planejamento da Expansão de Sistemas de Transmissão (PEST) é um problema que visa a seleção de novas linhas de transmissão (LTs) para garantir o atendimento ao crescimento da geração e da demanda respeitando os limites técnicos e com um mínimo custo de investimento. Trata-se de um problema de alta complexidade. Encontrar a solução ótima (com menor custo) ou mesmo uma solução de boa qualidade para sistemas elétricos de médio ou de grande porte é desafiador. Neste trabalho, apresenta-se a Meta-heurística Multipartida com *Path Relinking* (MMP+PR) como estratégia de otimização para resolver o problema de Planejamento da Expansão de Sistemas de Transmissão (PEST). A proposta central deste estudo consiste em utilizar como método de resolução a Meta-heurística Multipartida (MMP) para gerar *diversidade* como estratégia para explorar o espaço de busca de soluções e obter soluções factíveis de boa qualidade. A estratégia de busca *Path Relinking* é utilizada no processo de *intensificação* explorando regiões que conectam pares de soluções de elite. Em relação ao problema abordado foram empregados os modelos de transportes, híbrido e o modelo CC para o planejamento estático ao longo prazo da expansão de sistemas de transmissão de energia elétrica. Para implementar a estratégia multipartida comumente empregam-se heurísticas construtivas generalizadas. Nesse contexto é feita uma análise dos algoritmos heurísticos construtivos de Garver e de Villasana-Garver-Salon (VGS). As simulações foram implementadas utilizando os sistemas teste de Garver de 6 barras, sistema IEEE de 24 barras e o sistema real Sul-Brasileiro de 46 barras. Foram obtidos resultados muito relevantes em termos de redução do número de problemas de programação linear (PLs) resolvidos e redução do tempo computacional para execução dos mesmos em comparação aos trabalhos da literatura especializada avaliados.

Palavras-chave: Meta-heurística Multipartida (MMP). Modelo CC. Modelo Híbrido. Modelo de Transportes. *Path Relinking*. Planejamento da Expansão de Sistemas de Transmissão (PEST).

ABSTRACT

The transmission system expansion planning is a problem that aims at the construction of new transmission lines to guarantee the attendance to the generation and demand growth, respecting the technical limits, and with minimum investment cost. This is a highly complex problem. Finding the optimal and lowest cost solution or even a good quality solution for medium or large electrical systems is challenging. In this work, Multi-Start metaheuristic with Path Relinking is presented as an optimization strategy for the transmission system expansion planning. The central purpose of this study is to use Multi-Start Metaheuristics to generate diversity as a strategy to explore the space for finding good quality feasible solutions. Path Relinking search strategy is used in the intensification process exploring regions that connect pairs of elite solutions. The electrical systems were represented by the transport, hybrid, and DC models for the long-term static planning of the expansion of transmission power systems. To implement a Multi-Start metaheuristic, generalized constructive heuristics are used. In this context, an analysis is made of the constructive heuristic algorithms of Garver and Villasana-Garver-Salon. The simulations were implemented using test systems of Garver 6-bus, IEEE 24-bus, and Southern-Brazilian 46-bus. The results obtained were promising. There was a reduction in the number of linear programming problems solved and a reduction in computational time compared to other studies in the specialized literature evaluated.

Keywords – DC Model. Hybrid Model. Metaheuristic Multi-Start. *Path Relinking*. Transmission System Expansion Planning. Transport Model.

LISTA DE FIGURAS

Figura 1 – Representação do comportamento das meta-heurísticas GRASP e Multipartida.	42
Figura 2 – Exemplo ilustrativo das etapas de execução da estratégia de busca intensiva Path Relinking: sistema teste Garver 6 barras representado via modelo CC para resolução do PEST e sem reprogramação da geração – geração fixa.	51
Figura 3 – Configuração inicial do sistema teste de Garver com 6 barras e 15 caminhos.	56
Figura 4 – Configuração inicial do sistema IEEE com 24 barras e 41 caminhos.	59
Figura 5 – Configuração inicial do sistema teste Sul-Brasileiro com 46 barras e 79 caminhos.	61

LISTA DE TABELAS

Tabela 1 – Soluções ótimas para o sistema teste Garver 6 barras para o modelo de transportes: com e sem reprogramação da geração. _____	58
Tabela 2 – Soluções ótimas para o sistema IEEE 24 barras para o modelo de transportes: com e sem reprogramação da geração. _____	60
Tabela 3 – Soluções ótimas para o sistema teste Sul-Brasileiro 46 barras para o modelo de transportes: com e sem reprogramação da geração. _____	62
Tabela 4 – Soluções ótimas para o sistema teste de Garver 6 barras para o modelo CC com e sem reprogramação da geração. _____	64
Tabela 5 – Cenários de geração para o sistema teste IEEE 24 barras para o modelo CC sem reprogramação da geração. _____	64
Tabela 6 – Soluções ótimas para o sistema teste IEEE 24 barras para o modelo CC Com Reprogramação da Geração (CRC) e Sem Reprogramação da Geração (SRG). _____	65
Tabela 7 – Soluções ótimas para o sistema teste Sul-Brasileiro para o modelo CC com e sem reprogramação da geração. _____	66
Tabela 8 – Resumo das 100 execuções da estratégia proposta MMP+PR para resolução do PEST para os sistemas teste de Garver 6 barras, IEEE 24 barras e Sul-Brasileiro 46 barras com e sem reprogramação da geração para o modelo CC. _____	68
Tabela 9 – Comparação entre as soluções ótimas de investimento para os sistemas teste de Garver 6 Barras, IEEE 24 Barras, Sul-Brasileiro 46 Barras com e sem reprogramação da geração para o modelo CC. _____	69
Tabela 10 – Dados de barras do sistema teste de Garver 6 barras e 15 caminhos. _____	78
Tabela 11 – Dados de ramos do sistema teste de Garver 6 barras e 15 caminhos. _____	78
Tabela 12 – Dados de barras do sistema teste IEEE com 24 barras e 41 caminhos. _____	79
Tabela 13 – Dados de ramos do sistema teste IEEE com 24 barras e 41 caminhos. _____	80
Tabela 14 – Dados de barras do sistema teste Sul-Brasileiro de 46 Barras e 79 caminhos. _____	81
Tabela 15 – Dados de ramos do sistema teste Sul-Brasileiro de 46 barrase 79 caminhos. _____	82

LISTA DE SIGLAS

AG	Algoritmo Genético
AHC	Algoritmo Heurístico Construtivo
AMP	<i>Adaptive Memory Programming</i>
AMS	<i>Adaptive Multi-Start</i>
ART	<i>Adaptive Reasonong Techniques</i>
B&B	<i>Branch and Bound</i>
CA	Corrente Alternada
CC	Corrente Contínua
CAMS	<i>Clustering Adaptive Multi-Start</i>
GRASP	<i>Greedy Randomized Adaptive Search Procedure</i>
LRC	Lista Restrita de Candidatos
LTs	Linhas de Transmissão
MMP	Meta-heurística Multipartida
MMP+PR	Meta-heurística Multipartida com <i>Path Relinking</i>
MRPS	<i>Metaheuristic for Randomized Priority Search</i>
PEST	Planejamento da Expansão de Sistemas de Transmissão
PL	Programação Linear
PLIM	Programação Linear Inteira Mista
PNL	Programação Não Linear
PNLIM	Programação Não Linear Inteira Mista
PR	<i>Path Relinking</i>
PSO	<i>Particle Swarm Optimization</i>
SDH	<i>Steepest Descend Heuristic</i>
SEP	Sistema Elétrico de Potência
VGS	Villasana, Garver e Salon

LISTA DE SÍMBOLOS

Conjuntos:

- Ω_b Conjuntos de barras.
- Ω_l Conjuntos dos caminhos onde podem ser adicionadas linhas de transmissão.
- Ω_l^0 Conjunto dos circuitos presentes na configuração inicial acrescido daqueles adicionados durante o processo iterativo.

Parâmetros Constantes:

- c_{ij} Custo para construção de linhas de transmissão no caminho $i - j$.
- n_{ij}^0 Número de circuitos existentes na configuração inicial acrescido daqueles adicionados durante o processo iterativo.
- $\bar{f}_{ij}$ Fluxo de potência ativa máximo permitido no caminho $i - j$.
- g_i Geração na barra i (para o caso sem reprogramação da geração).
- $\bar{g}_i$ Geração máxima na barra i .
- $\bar{n}_{ij}$ Número máximo de circuitos que podem ser adicionados no caminho $i - j$.
- d_i Demanda na barra i .
- γ_{ij} Susceptância de um circuito no caminho $i - j$.
- k_1 Número de soluções obtidas na fase construtiva.
- k_2 Número de soluções empregadas na fase de Busca Local I (permutação simples).
- k_3 Número de soluções empregadas na fase de Busca Local II (*Path Relinking*).

Variáveis:

- n_{ij} Número de circuitos adicionados nos caminhos $i - j$ que permitem a adição de circuitos.
- f_{ij} Fluxo de potência ativa total no caminho $i - j$.
- g_i Geração na barra i (para o caso com reprogramação da geração).
- θ_j Ângulo da tensão na barra j .

Função:

- v Investimento para construção de novas linhas de transmissão.

SUMÁRIO

1	ESCOPO DO TRABALHO	15
1.1	PLANEJAMENTO DA EXPANSÃO DE SISTEMAS DE TRANSMISSÃO _____	15
1.2	MODELOS MATEMÁTICOS PARA O PLANEJAMENTO DA EXPANSÃO DE SISTEMAS DE TRANSMISSÃO _____	16
1.3	TÉCNICAS DE OTIMIZAÇÃO EMPREGADAS _____	17
1.4	ESTRUTURA DA DISSERTAÇÃO _____	18
2	MODELAGEM MATEMÁTICA PARA O PLANEJAMENTO DA EXPANSÃO DE SISTEMAS DE TRANSMISSÃO DE ENERGIA ELÉTRICA	19
2.1	INTRODUÇÃO _____	19
2.2	MODELAGEM MATEMÁTICA _____	20
2.2.1	Modelo de Transportes	21
2.2.2	Modelo CC	22
2.2.3	Modelo Híbrido	24
2.3	TÉCNICAS DE OTIMIZAÇÃO APLICADAS AO PLANEJAMENTO DA EXPANSÃO DE SISTEMAS DE TRANSMISSÃO _____	26
2.4	REVISÃO DOS TRABALHOS DA LITERATURA ESPECIALIZADA PARA O PLANEJAMENTO DA EXPANSÃO DE SISTEMAS DE TRANSMISSÃO _____	27
2.5	CONSIDERAÇÕES FINAIS _____	29
3	META-HEURÍSTICA MULTIPARTIDA PARA O PLANEJAMENTO DA EXPANSÃO DE SISTEMAS DE TRANSMISSÃO	31
3.1	HEURÍSTICAS EMPREGADAS NO PLANEJAMENTO DA EXPANSÃO DE SISTEMAS DE TRANSMISSÃO _____	31
3.1.1	O Algoritmo Heurístico Construtivo	32
3.1.2	A Heurística de Busca através de Vizinhança	33
3.2	META-HEURÍSTICAS _____	34
3.2.1	Meta-Heurísticas Multipartida	35
3.2.2	Estratégia Multipartida Básica	37
3.2.3	Estratégia Multipartida Avançada	38
3.2.4	Meta-heurística Multipartida versus GRASP	41
3.3	CONSIDERAÇÕES FINAIS _____	43

4	ESTRATÉGIA DE OTIMIZAÇÃO PARA O PLANEJAMENTO DA EXPANSÃO DE SISTEMAS DE TRANSMISSÃO	44
4.1	INTRODUÇÃO	44
4.2	ALGORITMO HEURÍSTICO CONSTRUTIVO DE GARVER PARA O MODELO DE TRANSPORTES	45
4.3	ALGORITMO HEURÍSTICO CONSTRUTIVO DE VILLASANA, GARVER E SALON PARA O MODELO CC	46
4.4	META-HEURÍSTICA MULTIPARTIDA PARA O PLANEJAMENTO DA EXPANSÃO DE SISTEMAS DE TRANSMISSÃO	48
4.4.1	Fase de Busca Local I: Permutação Simples	49
4.4.2	Fase de Busca Local II: <i>Path Relinking</i>	49
4.5	CONSIDERAÇÕES FINAIS	54
5	TESTES E RESULTADOS	55
5.1	INTRODUÇÃO	55
5.2	META-HEURÍSTICA MULTIPARTIDA COM O ALGORITMO HEURÍSTICO CONSTRUTIVO DE GARVER PARA O MODELO DE TRANSPORTES	56
5.2.1	Sistema Teste Garver de 6 Barras	56
5.2.2	Sistema Teste IEEE 24 Barras	57
5.2.3	Sistema Teste Sul Brasileiro 46 Barras	60
5.3	META-HEURÍSTICA MULTIPARTIDA APLICADA AO PLANEJAMENTO DA EXPANSÃO DE SISTEMAS DE TRANSMISSÃO USANDO ALGORITMO HEURÍSTICO CONSTRUTIVO DE VILLASANA-GARVER-SALON PARA O MODELO CC	63
5.3.1	Sistema Teste Garver 6 Barras	63
5.3.2	Sistema Teste IEEE de 24 Barras	64
5.3.3	Sistema Teste Sul-Brasileiro 46 Barras	65
5.3.4	Análise Comparativa dos Resultados	67
5.4	CONSIDERAÇÕES FINAIS	70
6	CONCLUSÕES	71
6.1	TRABALHOS FUTUROS	72
	APÊNDICE A – DADOS ELÉTRICOS DOS SISTEMAS-TESTE	78
	APÊNDICE B – ARTIGOS PUBLICADOS E SUBMETIDOS	83

1 ESCOPO DO TRABALHO

Este capítulo de apresentação fornece uma introdução abrangente à proposta deste trabalho que consiste na resolução eficiente do planejamento estático ao longo prazo da expansão de sistemas de transmissão de energia elétrica através da Meta-heurística Multipartida (MMP) ou *Multi-Start* em conjunto com a estratégia de busca *Path Relinking* (MMP+PR).

O sistema elétrico é representado neste estudo por meio de modelos matemáticos consagrados na literatura especializada para o Planejamento da Expansão de Sistemas de Transmissão (PEST) de energia elétrica. São eles: modelo de transportes, modelo híbrido e modelo CC.

1.1 PLANEJAMENTO DA EXPANSÃO DE SISTEMAS DE TRANSMISSÃO

O Planejamento da Expansão de Sistemas de Transmissão (PEST) tem como objetivo minimizar os custos de investimento na instalação de novos recursos (circuitos e/ou transformadores) no sistema, propondo um plano que promova equilíbrio entre a capacidade de geração e a demanda. Com a edificação de novas usinas hidrelétricas, por exemplo, exige-se a construção de novas linhas de interligações no sistema elétrico. O aumento da população, a expansão do setor comercial e industrial implica em um aumento da carga. A partir desses aspectos que se verifica a necessidade de ampliar e de fortalecer a rede de transmissão atual e; nesse cenário, o PEST torna-se de fundamental importância.

O PEST é um problema de alta complexidade. A expansão do sistema de transmissão é feita considerando as seguintes informações: aumento de demanda e da geração para acolher essa demanda, de que maneira serão construídas novas linhas e/ou transformadores e, consequentemente nos custos desses investimentos, na instituição de itens de segurança na rede elétrica podendo prevenir futuros apagões ou irregularidades no sistema, entre outras. Observa-se que todas essas incertezas resultam em variáveis estocásticas, cujo valor futuro não é conhecido *a priori*.

Ademais, a representação matemática ideal para o PEST é um modelo complexo de Programação Não Linear Inteira Mista (PNLIM). Esse problema possui o fenômeno da explosão combinatória e apresenta estrutura multimodal com a presença de um número elevado de soluções ótimas locais. Portanto, é um problema de difícil resolução para as técnicas clássicas de otimização. Nesse contexto, as técnicas de computação flexível ou *soft computing* tais como as meta-heurísticas tornam-se atrativas e são empregadas neste estudo.

1.2 MODELOS MATEMÁTICOS PARA O PLANEJAMENTO DA EXPANSÃO DE SISTEMAS DE TRANSMISSÃO

Os modelos matemáticos que representam o PEST devem representar de forma adequada o problema real. Além disso, contêm restrições, por exemplo, da natureza das variáveis envolvidas, do horizonte de planejamento considerado entre outras. Seguem alguns comentários introdutórios sobre os modelos clássicos para o PEST.

Modelo de Transportes: Foi inicialmente apresentado por Garver (1970) para resolver o problema de PEST. Neste modelo considera-se somente a primeira Lei de Kirchhoff ou balanço de potência ativa. Observa-se que um sistema está operando adequadamente quando estão sendo atendidas simultaneamente a primeira e a segunda Leis de Kirchhoff. Portanto, o modelo de transportes é uma representação simplificada ou relaxada por não considerar a segunda Lei de Kirchhoff. Essa modelagem matemática consiste em um problema de Programação Linear Inteiro Misto (PLIM) que contém restrições lineares e variáveis de decisão inteiras e reais.

Modelo CC: É considerado o modelo mais adequado para resolver o problema de PEST (ROMERO, 1999). Nessa representação, as duas Leis de Kirchhoff são satisfeitas. No entanto, nesse modelo, a modelagem matemática é mais complexa sendo um problema de Programação Não Linear Inteiro Misto (PNLIM).

Modelo Híbrido: Uma das mais relevantes propostas do modelo híbrido foi apresentada por Villasana, Garver e Salon (1985). Esse modelo apresenta características do modelo de transportes e do modelo CC. A ideia de utilizar este modelo consiste em encontrar soluções mais próximas das soluções ótimas do modelo CC. No modelo híbrido somente uma parcela dos circuitos satisfazem a segunda Lei de Kirchhoff.

Modelo Linear Disjuntivo: O modelo linear disjuntivo é uma versão linearizada correspondente ao modelo CC. Esse modelo tem a particularidade de fornecer a mesma solução ótima do que o modelo CC (BINATO, 2000). No entanto, essa representação possui um número de restrições e de variáveis maior do que a formulação não linear. Além disso, nesse modelo, as duas Leis de Kirchhoff são satisfeitas.

A modelagem matemática ideal para o PEST são as relações matemáticas de fluxo de carga CA. Todavia, em geral, se utiliza pouco o fluxo de carga CA por várias razões: (i) a topologia inicial do sistema elétrico para o planejamento em geral é um sistema não conexo e esse fato aumenta a complexidade do modelo AC e, (ii) o problema de PEST resolve somente o fornecimento do fluxo de potência ativa no sistema elétrico. O fornecimento de reativos é

resolvido *a posteriori*. Portanto, mesmo que o sistema elétrico seja conexo, a convergência do modelo CA, torna-se dificultosa, pois o problema não teria solução com frequência (ROMERO, 1999).

Nesse estudo, o sistema elétrico será representado pelos modelos matemáticos clássicos de transportes, híbrido e modelo CC. Portanto, a ênfase maior será dada nesses modelos.

1.3 TÉCNICAS DE OTIMIZAÇÃO EMPREGADAS

As técnicas de otimização aplicadas para resolver o problema de PEST encontram-se definidas em três grupos. Essas técnicas são as seguintes:

Algoritmos Heurísticos: Os métodos heurísticos simbolizam um campo de pesquisa relevante, pois são de fácil compreensão e implementação, robustos e muito rápidos. Além disso, podem ser utilizados como ponto de partida para algoritmos que exigem maior esforço computacional como, por exemplo, as meta-heurísticas. É importante ressaltar que todas as heurísticas encontram apenas soluções de boa qualidade para sistemas de grande porte; entretanto, as soluções encontradas podem ficar distantes da solução ótima global. O Algoritmo Heurístico Construtivo (AHC) de Garver para o modelo de transportes foi inicialmente o mais importante método usado em PEST.

Algoritmos de Otimização Clássicos: Geralmente utilizam técnicas de decomposição matemática. Embora encontrem a solução ótima do problema de planejamento e demonstrem eficácia na modelagem de sistemas de pequeno e médio porte, os mesmos apresentam problemas de convergência e de elevado esforço computacional para sistemas de grande porte (ROMERO, 1999). Dentre os algoritmos de otimização clássica destaca-se a técnica de decomposição de Benders, que analisa a decomposição do problema em duas parcelas: um subproblema de operação e outro subproblema de investimento. Outra técnica de otimização clássica usual é o algoritmo *Branch and Bound* (B&B) que pode encontrar as soluções ótimas dos modelos de transporte e do modelo linear disjuntivo de sistemas de baixa complexidade onde é relativamente rápido atingir a convergência. Para sistemas elétricos de elevada complexidade, devido principalmente a característica da explosão combinatória, o tempo de processamento para atingir a convergência geralmente torna-se proibitivo. Entretanto, nos últimos anos estão aparecendo *solvers* comerciais com capacidade de resolver modelos complexos e sistemas testes de tamanho razoável, tais como o CPLEX e o KNITRO.

Meta-heurísticas: A ideia fundamental desses algoritmos consiste em gerar um método heurístico para exploração do espaço de busca de soluções do problema, com o intuito

de escapar de ótimos locais ainda distantes dos ótimos globais. Apesar de apresentarem grande diversidade de tempo de processamento, muitas vezes exigindo um alto esforço computacional, possuem a vantagem de serem de fácil compreensão e implementação, robustas e geram soluções de boa qualidade. São exemplos dessas técnicas de otimização: algoritmos genéticos, busca tabu, GRASP, entre outros.

1.4 ESTRUTURA DA DISSERTAÇÃO

Neste estudo será abordado o problema de PEST estático e ao longo prazo. Nesse contexto, todos os investimentos são realizados em um único horizonte de planejamento, para sistemas teste de pequeno e médio porte. A saber: Garver 6 barras, IEEE 24 barras e Sul-Brasileiro 46 barras. Empregam-se os seguintes modelos matemáticos clássicos: modelo de transportes, híbrido e CC.

Este trabalho encontra-se estruturado da seguinte forma:

- ❖ No Capítulo 2, abordam-se os conceitos teóricos que fundamentam o estudo e cuja revisão visa auxiliar na compreensão do leitor acerca do problema tratado e da solução proposta para o mesmo. Ênfases são dadas aos modelos matemáticos para representação do PEST: modelo de transportes, híbrido e CC.
- ❖ No Capítulo 3, abordam-se as estratégias de solução para o PEST com ênfase na família das Meta-Heurísticas Multipartida (MMP) ou *Multi-Start* utilizadas para gerar soluções factíveis distantes uma das outras – com diversidade.
- ❖ No Capítulo 4, apresentam-se a estratégia de resolução dos modelos matemáticos para o PEST. A primeira parte do capítulo consiste na resolução do modelo de transportes (mais simplificado). Na segunda parte, apresenta-se a segunda modelagem deste estudo que consiste no emprego do modelo híbrido em conjunto com a MMP em uma estratégia construtiva para encontrar soluções factíveis e de boa qualidade para o modelo CC. Estratégias de intensificação são utilizadas a partir das soluções factíveis encontradas para atingir a solução ótima global em conjunto com as estratégias de solução MMP e *Path Relinking* (MMP+PR).
- ❖ No Capítulo 5, são apresentadas simulações e análises com os seguintes sistemas teste: Garver 6 Barras, IEEE 24 barras e Sul-Brasileiro 46 barras.
- ❖ No Capítulo 6, apresentam-se as conclusões, principais contribuições da pesquisa e sugestões para trabalhos futuros.

2 MODELAGEM MATEMÁTICA PARA O PLANEJAMENTO DA EXPANSÃO DE SISTEMAS DE TRANSMISSÃO DE ENERGIA ELÉTRICA

Fundamental para o PEST é a modelagem matemática empregada para representar o sistema elétrico. Neste capítulo são apresentados três modelos clássicos para o PEST. São eles: modelo de transportes, modelo CC e modelo híbrido. Além da modelagem matemática, apresenta-se também uma síntese a respeito das principais estratégias de solução para o PEST e a revisão da literatura especializada.

2.1 INTRODUÇÃO

O objetivo do PEST é a obtenção de um plano ótimo de expansão do sistema elétrico. O plano ideal de expansão indica onde deverão ser instalados novos equipamentos (linhas de transmissão e/ou transformadores) para que o sistema opere de forma adequada e que satisfaça as restrições operacionais e financeiras.

Para resolver o PEST é fundamental a construção de um modelo matemático que represente o problema real. A precisão e a complexidade são consideradas na construção do modelo. Modelos mais precisos ou mais próximos da realidade em geral são mais complexos. A complexidade excessiva de um modelo matemático e o alto custo computacional para resolvê-lo pode inviabilizar a utilização do mesmo, em especial para sistemas elétricos de grande porte.

Modelos matemáticos relaxados do problema usando somente a parte ativa (potência ativa e ângulos das tensões complexas) são empregados com frequência na literatura especializada e serão também empregados neste estudo.

O PEST é representado idealmente por um modelo complexo de Programação Não Linear Inteiro Misto (PNLIM) que apresenta o fenômeno da explosão combinatória. Logo, há uma quantidade elevadíssima de alternativas para investimento. Ademais, o problema de planejamento apresenta uma estrutura multimodal com elevado número de ótimos locais.

Nesse contexto, as técnicas de otimização chamadas de meta-heurísticas, são adaptadas para resolver problemas que apresentam um espaço de busca praticamente infinito com muitos ótimos locais.

2.2 MODELAGEM MATEMÁTICA

O PEST é composto por duas etapas fundamentais: a modelagem matemática e a técnica de solução escolhida para resolver o modelo matemático. A modelagem matemática deve reproduzir de maneira adequada o problema real e admitir sua resolução por meio de técnicas de solução acessíveis.

A modelagem clássica para o PEST tem a finalidade de determinar como ampliar a capacidade do sistema, ou seja, onde e que tipos de circuitos devem ser incorporados ao sistema de forma a atender um crescente aumento da demanda, com custo de investimento mínimo e de forma a manter o fornecimento contínuo de potência.

O PEST é classificado com respeito ao horizonte considerado para os custos de investimentos em: estático, multiestágio ou dinâmico. O planejamento estático possui apenas um estágio, isto é, em uma única etapa avaliam-se o local e o tipo de dispositivo que deve ser instalado na rede. Outra possibilidade é quando o horizonte de planejamento pode ser separado em vários estágios, ou seja, determinam-se o local e o tipo de equipamento instalado na rede e avalia-se também quando instalar novos equipamentos. Esse último caso denomina-se planejamento multiestágio da expansão de sistemas de transmissão (SILVA, 2013).

Comumente, os dados necessários para esse problema são: a topologia atual (ano base), os circuitos candidatos, a geração, as restrições de investimento e a previsão de carga futura, ou seja, a demanda para o fim do período de planejamento.

O modelo matemático mais indicado para realizar o PEST consiste na representação do problema através de relações matemáticas de fluxo de carga CA usualmente empregadas na análise da operação do sistema elétrico. No entanto, por ser um PNLIM, seu uso para o PEST, não é empregado com frequência, sendo considerado apenas quando as topologias mais significativas já foram obtidas via modelagens mais simplificadas (ROMERO *et al.*, 2002).

Os modelos matemáticos denominados modelo de transportes, modelo CC e modelo híbrido são empregados neste estudo para resolução do problema de PEST ao longo prazo. É consensual nas referências consultadas de que o modelo CC é considerado o modelo mais adequado para representar o PEST. Esses três modelos matemáticos clássicos são abordados nas seções subsequentes.

2.2.1 Modelo de Transportes

No início da década de 1970, Garver propôs uma representação relaxada do modelo de fluxo de carga CA, que sugere o uso de modelos distintos para os problemas de operação e para o problema de planejamento (GARVER, 1970). Essa proposta foi fundamental na pesquisa de PEST, pois permitiu encontrar topologias otimizadas de expansão do sistema usando uma proposta aproximada.

No modelo de transportes, considera-se somente a primeira Lei de Kirchhoff; segundo a qual, a somatória dos fluxos de potência que entram em uma barra é igual à somatória dos fluxos de potência que saem da barra. Estabelece também que os circuitos e as unidades geradoras operem dentro dos seus limites estabelecidos. Esse modelo foi amplamente aceito e ficou conhecido como modelo de transportes, também denominado como modelo de síntese. O planejamento é feito considerando apenas o fluxo de potência ativa e; portanto, resolve-se somente o problema da capacidade de transmissão de potência ativa.

A principal limitação do modelo de transportes refere-se ao nível de infactibilidade da solução encontrada em comparação à solução encontrada pelo modelo CC, pois o primeiro, ao contrário do segundo modelo, não necessita satisfazer a segunda Lei de Kirchhoff. Segundo Romero *et al.* (2002), ainda que o modelo de transportes possua a característica combinatória do modelo CC ele é normalmente mais simples de resolver por se tratar de um modelo linear inteiro misto.

O modelo de transportes foi o primeiro a utilizar Programação Linear (PL), pois a função objetivo e suas restrições são lineares. Por meio dessa modelagem, não há distinção entre resolver problemas de sistemas conexos ou sistemas não conexos – ou sistemas ilhados.

A representação matemática para o PEST com o modelo de transportes assume a formulação matemática apresentada em (1)–(7). Nessa formulação Ω_b e Ω_l são o conjunto de barras e o conjunto de caminhos onde podem ser adicionadas Linhas de Transmissão (LTs), respectivamente. As variáveis c_{ij} , n_{ij} , n_{ij}^0 , f_{ij} e $\bar{f}_{ij}$ representam, respectivamente, o custo de construção de novas linhas de transmissão (LTs), o número de circuitos adicionados nos caminhos em que é permitida a adição de circuitos, o número de circuitos existentes na configuração inicial, o fluxo total de potência ativa e o fluxo máximo de potência ativa permitida por linha no ramo $i - j$. A variável g_i é a geração na barra i com seu valor máximo $\bar{g}_i$, $\bar{n}_{ij}$ é o número máximo de circuitos que podem ser adicionados no ramo $i - j$ e d_i é a demanda na barra i .

$$\text{Minimizar } v = \sum_{ij \in \Omega_l} c_{ij} n_{ij} \quad (1)$$

Sujeito a:

$$\sum_{ji \in \Omega_l} f_{ji} - \sum_{ij \in \Omega_l} f_{ij} + g_i = d_i \quad \forall i \in \Omega_b, \forall ij \in \Omega_l \quad (2)$$

$$|f_{ij}| \leq (n_{ij} + n_{ij}^0) \bar{f}_{ij} \quad \forall ij \in \Omega_l \quad (3)$$

$$0 \leq g_i \leq \bar{g}_i \quad \forall i \in \Omega_b \quad (4)$$

$$0 \leq n_{ij} \leq \bar{n}_{ij} \quad \forall ij \in \Omega_l \quad (5)$$

$$n_{ij} \text{ inteiro} \quad \forall ij \in \Omega_l \quad (6)$$

$$f_{ij} \text{ irrestrito} \quad \forall ij \in \Omega_l \quad (7)$$

A função objetivo em (1) especifica que o investimento depende do custo de cada linha e do número de linhas que podem ser adicionadas ao sistema. O conjunto de restrições (2) representam as equações da primeira Lei de Kirchhoff, sendo uma equação para cada barra. As restrições de desigualdade (3) representam as restrições para a capacidade de transmissão de fluxo de potência ativa nos circuitos. As demais restrições são triviais e referem-se às restrições de limites de geração (4) e de circuitos adicionados em cada caminho candidato $i - j$ (5). Em (6), define-se a variável número de LTs n_{ij} que assume valores inteiros e em (7), define-se o fluxo de potência ativa f_{ij} que assumem quaisquer valores reais.

2.2.2 Modelo CC

O modelo CC é a representação matemática mais indicada para resolver o PEST ao longo prazo, sendo os outros modelos variantes simplificadas dessa modelagem. Esse modelo fundamenta-se no acoplamento entre os fluxos de potência ativa e as aberturas angulares.

Testes experimentais mostram que as configurações encontradas com o uso do modelo CC apresentam desempenho satisfatório quando analisadas frente aos modelos tradicionais de operação de rede de energia elétrica, como por exemplo, o fluxo de carga CA. Além disso, existem várias técnicas de solução que permitem resolver de maneira adequada o modelo CC. A formulação matemática do modelo CC para o PEST, levando em consideração

apenas a instalação de linhas de transmissão e/ou transformadores, é definida conforme (8)–(17).

$$\text{Minimizar } v = \sum_{ij \in \Omega_l} c_{ij} n_{ij} \quad (8)$$

Sujeito a:

$$\sum_{ji \in \Omega_l} f_{ji} - \sum_{ij \in \Omega_l} f_{ij} + g_i = d_i \quad \forall i \in \Omega_b, \forall ij \in \Omega_l \quad (9)$$

$$f_{ij} = \gamma_{ij} (n_{ij}^0 + n_{ij}) (\theta_i - \theta_j) \quad \forall i \in \Omega_b, \forall j \in \Omega_b, \forall ij \in \Omega_l \quad (10)$$

$$|f_{ij}| \leq (n_{ij}^0 + n_{ij}) \bar{f}_{ij} \quad \forall ij \in \Omega_l \quad (11)$$

$$0 \leq g_i \leq \bar{g}_i \quad \forall i \in \Omega_b \quad (12)$$

$$0 \leq n_{ij} \leq \bar{n}_{ij} \quad \forall ij \in \Omega_l \quad (13)$$

$$\theta_{ref} = 0 \quad (14)$$

$$n_{ij} \text{ inteiro} \quad \forall ij \in \Omega_l \quad (15)$$

$$f_{ij} \text{ irrestrito} \quad \forall ij \in \Omega_l \quad (16)$$

$$\theta_i \text{ e } \theta_j \text{ irrestritos} \quad \forall i \in \Omega_b, \forall j \in \Omega_b \quad (17)$$

A função objetivo em (8) especifica que o custo da expansão depende do custo de cada linha e do número de linhas que podem ser adicionadas ao sistema. A restrição (9) representa a primeira Lei de Kirchhoff para cada barra do sistema elétrico, (10) representa uma aproximação da segunda Lei de Kirchhoff para cada laço fundamental formado por uma LT e as demandas conectadas com a terra sendo uma equação para cada ramo $i - j$. As restrições de desigualdade (11) representam as restrições para a capacidade de transmissão de fluxo de potência ativa nos circuitos. As restrições (12) e (13) são triviais e, referem-se às restrições de limites de geração e o número máximo de circuitos que podem ser adicionados em cada caminho candidato $i - j$. A restrição (14) identifica a barra de referência; (15) define a variável número de linhas n_{ij} que assume valores inteiros e (16)–(17) definem as variáveis fluxo de potência ativa f_{ij} e os ângulos das tensões nas barras θ_i que assumem valores reais.

A principal diferença com respeito à modelagem matemática entre o modelo CC e o modelo de transportes encontra-se no conjunto das equações (10). Nessas γ_{ij} é a susceptância de um circuito no caminho $i - j$ e θ_j é o ângulo da tensão na barra j . Essa restrição representa

a segunda Lei de Kirchhoff, uma equação para cada caminho $i - j$. Nesta restrição, observa-se que o produto entre a variável n_{ij} e a variável θ_j faz com que a equação (10) seja *não linear*, resultando assim em um problema de PNLIM.

Em último, ressalta-se que o modelo CC foi apresentado nesta seção apenas para contextualizar o problema do PEST, pois ele não será utilizado diretamente no processo de solução neste estudo. Observa-se que uma meta-heurística nem sempre emprega diretamente um modelo matemático para resolver um modelo complexo. Em uma fase construtiva, a resolução de uma versão modificada e relaxada do modelo híbrido linear fornecerá um indicador de sensibilidade através do qual será alcançada uma solução factível para o modelo híbrido e também para o modelo CC. Essa fase construtiva é uma versão relaxada do algoritmo heurístico construtivo (AHC) de Villasana, Garver e Salon (1985). O modelo híbrido linear será abordado em detalhes na seção subsequente.

2.2.3 Modelo Híbrido

O modelo híbrido surgiu como uma forma de contornar alguns problemas observados no estudo de outras modelagens matemáticas como, por exemplo, a dificuldade do modelo CC em representar de forma adequada redes elétricas não conexas. Em contraposição, o modelo de transportes apresenta flexibilidade para representar esse tipo de rede elétrica; no entanto, as soluções obtidas podem ter uma qualidade muito inferior e podem estar distantes da solução ótima apresentada pelo modelo CC. Neste contexto, a proposta do modelo híbrido é permitir encontrar soluções mais próximas da solução ótima do modelo CC e trabalhar de forma eficaz na parcela correspondente à parte não conexa do problema de PEST.

Em resumo, o modelo híbrido é uma combinação entre o modelo de transportes e o modelo CC. A modelagem matemática do modelo híbrido especifica o seguinte: a parcela do sistema elétrico correspondente aos caminhos n_{ij}^0 nos quais já existem circuitos na configuração inicial, assim como aqueles que foram adicionados em paralelo a esses circuitos devem satisfazer as duas Leis de Kirchhoff. A outra parcela n_{ij} correspondente aos caminhos em que não existem circuitos na configuração inicial deve satisfazer apenas a primeira Lei de Kirchhoff. Assim, por exemplo, se no processo de planejamento foi adicionado um circuito novo, então os laços que eventualmente podem surgir, como consequência da adição de um circuito, não está obrigada a satisfazer a segunda Lei de Kirchhoff.

Originalmente apresentado por Villasana, Garver e Salon (1985) para o problema de PEST, o modelo híbrido foi aplicado como uma forma de auxílio para o indicador de

sensibilidade do algoritmo heurístico proposto pelos autores. O modelo híbrido pode apresentar uma estrutura de um problema de programação linear ou não linear. Neste trabalho a ênfase será no modelo híbrido linear.

Com o objetivo de facilitar a resolução do modelo híbrido, alguns pesquisadores fazem uso de uma versão relaxada. Para isso, utilizam um problema cuja modelagem matemática corresponde a um Problema Linear Inteiro Misto (PLIM).

A formulação do modelo híbrido linear é apresentada em (18)–(28). Observa-se que nesse modelo os fluxos nos circuitos estão separados em dois grupos: fluxos em circuitos existentes na topologia inicial, f_{ij}^0 e os fluxos nos circuitos que não estão presentes na topologia inicial, f_{ij} . O mesmo acontece com os circuitos adicionados: n_{ij}^0 e n_{ij} que representam, respectivamente, o número de circuitos presentes no caminho $i-j$ na configuração inicial e os circuitos candidatos que podem ser adicionados durante o processo de otimização.

$$\text{Minimizar } v = \sum_{ij \in \Omega_l} c_{ij} n_{ij} \quad (18)$$

Sujeito a:

$$\sum_{ji \in \Omega_l} f_{ji} - \sum_{ij \in \Omega_l} f_{ij} + \sum_{ji \in \Omega_l^0} f_{ji}^0 - \sum_{ij \in \Omega_l^0} f_{ij}^0 + g_i = d_i \quad \forall i \in \Omega_b \quad (19)$$

$$f_{ij}^0 = \gamma_{ij} n_{ij}^0 (\theta_i - \theta_j) \quad \forall i \in \Omega_b, \forall j \in \Omega_b, \forall ij \in \Omega_l^0 \quad (20)$$

$$|f_{ij}^0| \leq n_{ij}^0 \bar{f}_{ij}^0 \quad \forall ij \in \Omega_l^0 \quad (21)$$

$$|f_{ij}| \leq n_{ij} \bar{f}_{ij} \quad \forall ij \in \Omega_l \quad (22)$$

$$0 \leq g_i \leq \bar{g}_i \quad \forall i \in \Omega_b \quad (23)$$

$$0 \leq n_{ij} \leq \bar{n}_{ij} \quad \forall ij \in \Omega_l \quad (24)$$

$$\theta_{ref} = 0 \quad (25)$$

$$n_{ij} \text{ inteiro} \quad \forall ij \in \Omega_l \quad (26)$$

$$f_{ij} \text{ irrestrito} \quad \forall ij \in \Omega_l \quad (27)$$

$$\theta_i \text{ e } \theta_j \text{ irrestritos} \quad \forall i \in \Omega_b, \forall j \in \Omega_b \quad (28)$$

O conjunto Ω_l^0 representa o conjunto dos circuitos presentes na configuração inicial e Ω_l representa o conjunto de caminhos nos quais podem ser adicionados circuitos.

Observa-se que no modelo de transportes, o conjunto de equações (20) não aparece; no modelo híbrido, aparece somente uma parcela dessas equações constituídas pelos circuitos existentes na configuração inicial e aqueles adicionados durante o processo iterativo n_{ij}^0 e; finalmente, no modelo CC aparecem todas as equações desse tipo, uma para cada caminho existente e/ou novos caminhos candidatos à adição de circuitos.

Convém ressaltar que a solução ótima para o modelo híbrido linear apresentado nesta seção, em geral, será infactível para o modelo CC. Portanto, este trabalho, não visa encontrar a solução ótima para o modelo híbrido. A ideia central consiste em utilizar uma versão modificada e relaxada do modelo híbrido linear que será incorporado em uma estratégia construtiva com o intuito de gerar soluções factíveis e de boa qualidade para o modelo CC. Essa proposta consiste em uma generalização do AHC de Villasana-Garver-Salon (VGS).

2.3 TÉCNICAS DE OTIMIZAÇÃO APLICADAS AO PLANEJAMENTO DA EXPANSÃO DE SISTEMAS DE TRANSMISSÃO

Definida a modelagem apropriada (modelo de transportes, híbrido e CC), o próximo passo consiste na escolha da técnica de otimização que será utilizada e que se encontram dispostas da seguinte forma: (i) Algoritmos heurísticos ou aproximados, (ii) algoritmos de otimização clássica e (iii) meta-heurísticas – planejadas para resolver problemas complexos para os quais os métodos heurísticos são pouco eficientes.

Um método heurístico é uma técnica de otimização que se baseia na intuição e em relações matemáticas aproximadas. Geralmente não alcançam uma solução ótima global para problemas difíceis. No entanto, são métodos de fácil implementação e compreensão, são robustos, com esforço computacional normalmente baixo. Existem diferentes tipos de heurísticas, que podem ser divididas em dois grupos:

- ❖ **Métodos construtivos:** Consistem na adição de componentes da solução até obtenção de uma solução viável ou factível. O mais popular dos Algoritmos Heurísticos Construtivos (AHC) é do tipo guloso, cujo artifício é escolher, passo a passo, aquela solução que fornece o máximo benefício.
- ❖ **Busca local ou busca por vizinhança:** Inicia-se com apenas uma geração da solução factível e constrói-se uma vizinhança que contém novas soluções factíveis através de um mecanismo de transição que altera a solução inicial.

As meta-heurísticas ou métodos combinatórios representam um conjunto de técnicas de otimização empregadas na resolução de problemas complexos, que exibem o fenômeno da explosão combinatória. Define-se meta-heurística como um meio de otimização constituído por uma generalização e/ou agregação das técnicas heurísticas. São métodos inteligentes, pois fazem o uso de mecanismos de melhoria da vizinhança capazes de saírem de um ponto ótimo local e encontrar a solução ótima global ou as soluções ótimas locais de excelente qualidade.

Inúmeros métodos meta-heurísticos foram aplicados ao problema de PEST. Citam-se: GRASP (BINATO; OLIVEIRA; ARAUJO, 2001), algoritmos genéticos (GALLEGO *et al.*, 2017), *simulated annealing* (GALLEGO *et al.*, 1997), busca tabu (DA SILVA *et al.*, 2001), *Particle Swarm Optimization* (PSO) (DE MENDONÇA; JUNIOR; MARCATO, 2014), busca dispersa (MORI; SHIMOMUGI, 2007), colônia de formiga (LIMSAKUL; POTHIIYA; LEEPRECHANON, 2009), entre outros.

As meta-heurísticas são técnicas de fácil compreensão e implementação, robustas e encontram soluções de ótima qualidade. Possuem reduzido tempo de processamento computacional; no entanto, não garantem o alcance da solução ótima global.

As técnicas de otimização clássica comumente atingem a solução ótima para problemas de programação lineares inteiros mistos (PLIM); no entanto, o esforço computacional é elevado e são relativamente difíceis de implementar. Essas técnicas de otimização podem ter problemas de convergência e podem não alcançar a solução ótima global para sistemas elétricos de grande porte. Acresce a necessidade de utilizarem *solvers* comerciais para a execução do método. Destacam-se as seguintes técnicas de otimização clássica: *branch and bound* (B&B), técnicas de decomposição de Benders (BINATO; PEREIRA; GRANVILLE, 2001), métodos de planos de cortes, entre outros.

2.4 REVISÃO DOS TRABALHOS DA LITERATURA ESPECIALIZADA PARA O PLANEJAMENTO DA EXPANSÃO DE SISTEMAS DE TRANSMISSÃO

Em Garver (1970) tem-se uma das primeiras pesquisas para resolver o PEST. Nesse estudo considerou-se apenas a primeira Lei de Kirchhoff na modelagem matemática que foi resolvida utilizando um AHC. Em cada passo, resolve-se um problema de PL e, seleciona-se o circuito mais vantajoso para ser adicionado ao sistema – em geral é aquele circuito que transporta o maior fluxo de potência ativa.

Em Monticelli *et al.* (1982) propõe-se o uso de ferramentas iterativas para o PEST. O estudo apresenta o algoritmo de mínimo esforço cujo intuito consiste em ordenar as

possibilidades de adições de LTs. Este algoritmo baseia-se na análise de sensibilidade em relação às susceptâncias dos circuitos em um problema de otimização cujo resultado é idêntico ao modelo de fluxo de carga linearizado.

Em Romero e Monticelli (1994), apresenta-se uma heurística para tratar a não convexidade do problema de PEST. É feita uma decomposição hierárquica que utiliza três classes de modelagem de rede: modelo de transportes, modelo híbrido e modelo CC. Inicialmente, é utilizada a decomposição de Benders para resolver o problema de planejamento considerando apenas o modelo de transporte para o subproblema de operação e relaxando a integralidade das variáveis de investimento, ou seja, a decomposição de Benders. Primeiro é resolvido o problema de operação utilizando o modelo de transportes e logo após migra-se para outras classes de modelos matemáticos até resolver o modelo CC.

Em Villasana, Garver e Salon (1985), apresenta-se um novo método que combina um modelo linear e fluxo de potência CC com o modelo de transportes. O estudo emprega o modelo CC para os circuitos da rede que obedecem as duas Leis de Kirchhoff. O modelo de transportes é empregado para as sobrecargas que obedecem somente à primeira Lei de Kirchhoff, minimizando uma função objetivo de custo. A junção dos dois modelos identifica onde existe falta de capacidade e onde adicionar novos circuitos. Para resolver as duas formulações do modelo foram usados um *software* de programação linear padrão.

Os métodos heurísticos representam um vasto campo de pesquisa para resolução do PEST por serem de muito fácil compreensão e também de implementação, rápidos e, além disso, encontram soluções de boa qualidade. No entanto, a qualidade dessas soluções pode ficar distante das soluções ótimas. Os estudos de Villasana, Garver e Salon (1985), Garver (1970), Levi e Calovic (1991), Monticelli *et al.* (1982) e Pereira e Pinto (1985) entre outros, podem ser citados como trabalhos que utilizaram métodos heurísticos para o PEST.

Rider, Garcia e Romero (2007) desenvolveram uma técnica de solução usando o modelo CA para resolver o PEST. Um AHC e um método de pontos interiores foram propostos na resolução dos problemas de programação não linear (PNL) durante os passos do algoritmo.

Em Binato e Oliveira (1995) foi proposto um método de busca, *backward/forward* para o PEST multiestágio. Utilizou-se uma forma organizada de dois passos para uma análise de planejamento a dois estágios: o passo *backward* e o passo *forward*. O passo *backward* baseia-se em antecipações de circuitos já definidos para os anos seguintes. O passo *forward* consiste em uma análise no tempo progressivo, com o intuito de explorar a região de viabilidade do problema.

Entre os anos de 1990 e 2000, surgiram novos métodos heurísticos e meta-heurísticos, diferentes dos tradicionais, geralmente mais eficazes e, com reduzido tempo de processamento. Citam-se algumas técnicas de otimização: *simulated annealing*, busca tabu, GRASP, algoritmos genéticos e evolutivos em geral e, *particle swarm optimization* (PSO). Inúmeros estudos com meta-heurísticas foram propostos para resolver o PEST. Citam-se: *simulated annealing* (ROMERO; GALLEGO; MONTICELLI, 1996; Gallego *et al.*, 1997), algoritmo genético (GALLEGO; MONTICELLI; ROMERO, 1998; BINATO; ROMERO, 1998), GRASP (BINATO; OLIVEIRA, 2001) e busca tabu (GALLEGO; MONTICELLI; ROMERO, 2000).

Em Binato, Oliveira e Araújo (2001) a meta-heurística GRASP foi utilizada para resolver o PEST. Esse método consiste em duas fases: a primeira, a fase construtiva, que encontra uma solução factível para o problema; a segunda, melhora a solução gerada durante a fase construtiva através de uma estratégia de otimização a nível local.

Um algoritmo genético (AG) para resolver o problema PEST, planejamento estático e o multiestágio foi proposto em Romero, Rider e Silva (2007). Os resultados obtidos para sistemas de médio e grande porte demonstraram excelente desempenho do AG sugerido para o problema de planejamento estático e multiestágio, comparado com as aplicações de outras meta-heurísticas. O método resolveu um menor número de problemas de PL, a fim de encontrar melhores soluções, como foi o caso para problemas de planejamento multiestágio.

A meta-heurística *Particle Swarm Optimization* (PSO) foi utilizada em várias pesquisas na literatura especializada. Em Ren *et al.* (2005), a meta-heurística PSO foi aplicada para executar o PEST com modelo de otimização multiobjetivo. São eles: (i) custo de investimentos, (ii) confiabilidade e (iii) impacto ambiental. A meta-heurística PSO foi empregada em cada passo e demonstra ser eficaz na obtenção de soluções próximas da ideal, com baixo tempo de busca comparado com outros métodos para os problemas de planejamento existentes.

2.5 CONSIDERAÇÕES FINAIS

Essencial para o PEST é a definição do modelo matemático para representar o sistema elétrico e a estratégia de solução para o mesmo. Neste capítulo abordaram-se os modelos clássicos para o PEST: modelos de transportes, híbrido e CC.

As estratégias para resolução dos modelos matemáticos que representam o sistema elétrico para o PEST são agrupadas em três categorias: (i) heurísticas, (ii) meta-heurísticas e

(iii) otimização clássica. Neste capítulo, abordaram-se algumas técnicas de resolução pertencentes a esses três grupos através da revisão de trabalhos da literatura especializada.

Os modelos matemáticos clássicos para representação do sistema de transmissão abordados nesse capítulo são a base para o entendimento deste estudo.

No capítulo subsequente são abordadas as técnicas para resolução dos modelos matemáticos para o PEST apresentados neste capítulo. Essas técnicas são baseadas na meta-heurística Multipartida ou *Multi-Start* como artifício para obtenção de soluções factíveis, muito diferentes entre si e de boa qualidade. Utiliza-se também a estratégia de busca *Path Relinking* para o processo de intensificação com emprego de soluções de elite de altíssima qualidade.

3 META-HEURÍSTICA MULTIPARTIDA PARA O PLANEJAMENTO DA EXPANSÃO DE SISTEMAS DE TRANSMISSÃO

Fundamental para o PEST é a estratégia de solução para os modelos matemáticos que representam o sistema elétrico o mais próximo possível da realidade. Conforme o Capítulo 2, neste estudo o sistema elétrico para o PEST será representado por meio dos modelos matemáticos: transportes, híbrido e CC.

Esses modelos matemáticos são resolvidos através da Meta-Heurística Multipartida (MMP) que atuará em uma fase construtiva por meio de um Algoritmo Heurístico Construtivo (AHC). Em uma segunda fase de intensificação local, empregam-se a heurística de busca em vizinhança ou *Steepest Descend Heuristic* (SDH) em conjunto com uma estratégia de busca *Path Relinking* para melhorar as soluções factíveis (ótimos locais) encontradas na fase construtiva.

Portanto, neste capítulo abordam-se as heurísticas AHC, a heurística de busca em vizinhança SDH e a MMP. Todas essas ferramentas são empregadas em conjunto em uma metodologia robusta para resolução do PEST.

3.1 HEURÍSTICAS EMPREGADAS NO PLANEJAMENTO DA EXPANSÃO DE SISTEMAS DE TRANSMISSÃO

Tendo em vista a natureza não linear e não convexa do problema de PEST surgiram algoritmos aproximados, com o intuito de contornar as dificuldades para determinar as soluções ótimas para o problema. Entre as décadas de 1960 e 1970, as heurísticas foram as técnicas de solução mais utilizadas e com maior sucesso para resolver problemas complexos relacionados à otimização matemática (GARVER, 1970).

Todos os métodos heurísticos encontram apenas soluções de boa qualidade para sistemas de grande porte. Ademais, eles não conseguem identificar se a solução encontrada é um ótimo global ou o quanto a mesma está distante da solução ótima. Como vantagem destaca-se que as heurísticas são de fácil entendimento e implementação, exigindo um tempo computacional reduzido.

Uma técnica heurística pode ser muito simples com o uso da intuição e levando em conta a experiência do especialista. Por outro lado, em outras situações uma heurística pode ser considerada sofisticada, geralmente envolvendo a solução de modelos matemáticos aproximados em relação ao modelo original.

As técnicas heurísticas são recomendadas nos seguintes casos:

- ❖ Quando não existe um método exato de otimização para resolver o problema.
- ❖ A solução ótima não é muito importante do ponto de vista prático por diferentes motivos como, por exemplo, a existência de muitas soluções ótimas locais de qualidade muito próximas da solução ótima global.
- ❖ Os dados utilizados no problema apresentam altas incertezas como, por exemplo, os problemas de planeamento de transmissão.
- ❖ Quando existem limitações de tempo de processamento e memória de armazenamento de dados suficientes.
- ❖ Quando se tem o intuito de encontrar uma boa solução inicial para ser usada como ponto de partida na utilização de uma técnica de otimização mais sofisticada ou exata.

Os trabalhos de Villasana, Garver e Salon (1985), Garver (1970), Monticelli *et al.* (1982), Pereira e Pinto (1985) são exemplos de estudos que empregaram algoritmos heurísticos para resolver problemas de PEST.

Existem várias técnicas heurísticas de otimização. Neste trabalho, destacam-se três destes métodos: (i) o Algoritmo Heurístico Construtivo (AHC), (ii) o algoritmo heurístico construtivo de Villasana-Garver-Salon (VSG) e (iii) o algoritmo heurístico de busca através de vizinhança ou *Steepest Descend Heuristic* (SDH).

3.1.1 O Algoritmo Heurístico Construtivo

Como foi mencionado no Capítulo 2, o problema de PEST pode ser representado utilizando várias modelagens matemáticas. Com o modelo de transportes obtém-se um problema de PLIM; com o modelo CC, obtém-se um problema de PNLIM. Contudo, levando em consideração a complexidade para resolução desses problemas, inicialmente empregaram-se os AHCs para resolver problemas de planeamento de sistemas reais.

Um AHC consiste em ir adicionando, em cada passo, um ou mais circuitos, a partir da configuração base, até que uma boa proposta para expansão do sistema elétrico seja encontrada. Os elementos candidatos são geralmente selecionados através de um índice de sensibilidade. O algoritmo mais conhecido é o chamado algoritmo heurístico do tipo “guloso”, cuja estratégia é escolher, passo a passo, aquele circuito que produz o maior benefício. O processo termina quando é encontrada uma solução factível. Um indicador de sensibilidade estima o benefício da inserção de cada elemento; em cada passo, apenas o melhor elemento é adicionado.

Geralmente, os algoritmos heurísticos são eficientes na determinação de soluções ótimas para sistemas de pequeno porte e apenas encontram boas soluções para sistemas de médio e grande porte. Ademais, as soluções encontradas por esses algoritmos podem servir como ponto de partida para encontrar soluções melhores utilizando algoritmos mais complexos como, por exemplo, as meta-heurísticas.

A forma genérica do AHC pode ser descrita nos seguintes passos:

1. Montam-se os dados do problema. Seleciona-se o indicador de sensibilidade. Identificam-se os elementos que podem ser adicionados na solução em construção – comumente iniciada sem elementos.
2. Se a solução em construção encontrada for factível então pare. Foi encontrada a solução factível procurada.
3. A partir da solução em construção, resolve-se o problema conforme o indicador de sensibilidade adotado de todos os elementos que ainda não foram incorporados na solução em construção.
4. A partir da informação encontrada no passo anterior, identifica-se o elemento que deve ser adicionado na solução em construção. Adiciona-se o elemento e vá para o passo 2.

Um AHC encontra somente soluções factíveis. Conclui-se que a diferença entre os vários AHCs está no indicador de sensibilidade e no modelo matemático escolhido.

3.1.2 A Heurística de Busca através de Vizinhaça

A heurística de busca através de vizinhaça ou SDH inicia-se a partir de uma solução corrente factível e utilizando um mecanismo de transição adequado pelo espaço de busca em direção a uma melhor solução vizinha da solução atual. A melhor solução encontrada é armazenada. Essa é a melhor soluções entre todas as soluções já visitadas e é chamada de incumbente. O processo finaliza quando todos os vizinhos são de pior qualidade.

Para a implementação dessa heurística é necessária uma definição prévia da estrutura de vizinhaça, de modo que seja possível identificar as soluções que são consideradas vizinhas da solução corrente ou solução atual. Além disso, as soluções vizinhas podem ser factíveis ou infactíveis e; nesse caso, é preciso uma estratégia para lidar com as soluções não factíveis.

Seguem as etapas da forma genérica da heurística de busca através de vizinhaça:

1. Montam-se os dados do problema. Seleciona-se uma forma de representar uma proposta de solução denominada *P*. Identifica-se uma maneira de avaliar a qualidade

da função objetivo ou equivalente $f(p)$. Define-se a estrutura de vizinhança que caracteriza o espaço de busca.

2. Encontra-se uma solução P_0 que se transforma na solução corrente P_c .
3. Identificam-se e avaliam-se todas as soluções vizinhas da solução corrente P_c . A melhor solução torna-se P^{best} .
4. Se $f(p^{best}) < f(p)$ então a melhor solução vizinha é melhor do que a solução corrente e, portanto, $P_c = P^{best}$; retorna-se ao passo 3. Caso contrário pare. A solução encontrada pela heurística de busca através da vizinhança é P_c – geralmente um ótimo local.

Observa-se que a solução inicial (passo 2) pode ser encontrada de forma trivial por meio de uma solução gerada aleatoriamente ou pode ser gerada via AHC. Caso seja encontrada uma solução inactivel modifica-se a estratégia de qualidade para avaliar as soluções vizinhas. O passo 3 demanda muito tempo de processamento. Quando se avalia a qualidade de uma solução vizinha, em geral, é preciso resolver um problema de PL ou de PNL. Por fim, no passo 4, se a melhor solução vizinha for de pior qualidade do que a solução corrente, o algoritmo SDH finaliza a busca. Portanto, se a vizinhança for definida inadequadamente, então a heurística pode terminar encontrando uma solução ótima local de pobre qualidade.

Conclui-se que o algoritmo heurístico de busca através de vizinhança é significativamente distinto do AHC do tipo “guloso”. No AHC gera-se apenas uma solução factível através de uma sequência de passos, usando um indicador de sensibilidade, e somente no último passo é encontrada uma solução factível. Na heurística SDH, gera-se um conjunto de soluções factíveis a partir de uma solução inicial, normalmente factível, efetuando transições através de soluções factíveis, percorrendo o espaço de busca e sempre passando para uma solução de melhor qualidade. O processo de busca termina quando todas as propostas de soluções vizinhas são de pior qualidade.

3.2 META-HEURÍSTICAS

As meta-heurísticas são estratégias de busca que exploraram de forma eficaz o espaço das soluções viáveis de um dado problema. São técnicas de otimização que fazem o uso de mecanismos inteligentes de melhoria de vizinhança com o objetivo de evitar confinamento em ótimos locais.

A diferença entre as meta-heurísticas está no tipo de mecanismo de busca. Para realizar esse processo de busca é essencial efetuar modificações para torná-la adaptável a um problema específico.

Para a implementação de uma meta-heurística, deve-se adotar alguns procedimentos gerais:

- ❖ Caracterização de uma forma de representar uma proposta de solução dentro do espaço de busca do problema.
- ❖ Descrição detalhada da vizinhança da solução corrente.
- ❖ Determinar se a forma de efetuar as transições deve ser realizada através de uma única proposta de solução ou de um conjunto de propostas de solução.
- ❖ Estudar e definir se o processo de busca deve ser executado a partir de soluções factíveis ou também se podem ser admitidas soluções infactíveis.

3.2.1 Meta-Heurísticas Multipartida

A proposta de otimização desenvolvida neste estudo baseia-se em uma meta-heurística da família multipartida. As técnicas do tipo multipartida foram propostas em contraposição com as técnicas de partida no mesmo instante, como acontece em outras meta-heurísticas tais como: *simulated annealing*, busca tabu, algoritmos genéticos e outras.

Na proposta multipartida a ideia central consiste em gerar uma proposta de solução de boa qualidade e melhorar essa solução usando uma estratégia de busca local. Esse processo pode ser repetido um número específico de iterações e a resposta da técnica de otimização será a melhor solução encontrada durante esse processo. Observa-se que a MMP procura uma solução de boa qualidade através de uma proposta de otimização rápida.

A proposta MMP torna-se particularmente eficiente caso haja uma forma de gerar soluções iniciais de qualidade e significativamente diversas entre elas. Dessa forma, em cada iteração do processo multipartida é gerada uma proposta de solução que representa um ótimo local que é melhorado através de um processo de intensificação. Portanto, se cada proposta inicial representa uma solução de boa qualidade do espaço de busca e se cada proposta inicial encontra-se afastada das demais; logo, é possível avaliar regiões distantes do espaço de busca.

A Meta-Heurística Multipartida (MMP) ou *Multi-Start* surgiu de algumas propostas iniciais em que os AHC são empregados em processos iterativos para gerar diferentes soluções para um problema complexo. Nesse processo repetitivo deve existir uma estratégia para gerar diferentes soluções e a melhor entre essas soluções é considerada como proposta de solução final do problema para a fase construtiva.

Em uma seguinte fase de evolução da MMP surge uma proposta para melhorar as soluções geradas na fase construtiva. Após gerar uma solução através de um AHC, deve-se implementar uma fase de busca local para melhorar a solução encontrada. Essa fase de busca local geralmente é executada por um algoritmo heurístico de busca através de vizinhança que é significativamente diferente do AHC. Portanto, incorporando um mecanismo que permita que o AHC gere soluções diferentes e diversificadas (ótimos locais), a fase de busca local melhora essa solução. Nesse contexto, a fase de busca local pode incorporar estratégias para realizar buscas diferentes para cada solução encontrada pelo AHC.

A estratégia multipartida permite encontrar soluções diferentes e podem incorporar mecanismos tais como: processo aleatório controlado, estratégias de aprendizado, decomposição orientada e memória adaptativa. A ideia fundamental consiste em montar uma estrutura multipartida que faça uma interação completa entre os processos de diversificação e intensificação.

O processo aleatório controlado normalmente assume duas formas diferentes:

- ❖ O processo é reiniciado usando um mecanismo aleatório, que insere um elemento aleatoriamente na geração de uma proposta de solução inicial. Isso permite que o AHC, a partir de uma decisão diferente para cada caso, gere soluções diferentes para cada situação.
- ❖ Utilizar uma estratégia de perturbação aleatória significativa que, em lugar de reiniciar o processo na forma tradicional, periodicamente é feito um determinado número de transições de forma aleatória proporcionando à estratégia heurística encontrar soluções que normalmente não encontraria usando um método tradicional.

A estratégia multipartida geralmente é um AHC tradicional. Deve-se observar que um AHC agrega em cada passo, uma componente da solução em construção. Nesse processo, é importante ressaltar que a solução inicial está vazia, sem nenhuma componente e, que somente será introduzida a solução que estiver de acordo com algum tipo de indicador de sensibilidade. Entretanto, existem algoritmos heurísticos que iniciam com a adição de todos os componentes na solução inicial e, passo a passo, é retirada uma componente da solução em construção e o processo termina quando for satisfeito um critério de parada. Esse tipo de algoritmo denomina-se algoritmo heurístico destrutivo.

Em resumo, em um algoritmo multipartida, a motivação central para melhorar as soluções encontradas pelos AHCs associada com a concepção de usar várias formas de reconstrução das soluções através da diversificação, fornecem soluções mais interessantes para implementar a busca local. Assim, as meta-heurísticas modernas tipo multipartida controlam

de forma adequada os processos de intensificação e diversificação no processo de busca, o que garante a eficiência da estrutura multipartida.

Os algoritmos multipartida podem ser classificados de várias formas. Uma alternativa é classificar esses métodos de otimização da seguinte maneira: (i) Métodos que usam memória e (ii) métodos que não usam memória. Deve-se observar que existem meta-heurísticas que usam, sistematicamente, a memória do processo de solução como, por exemplo, o algoritmo de Busca Tabu, assim como aquelas meta-heurísticas que não usam memória como o *Simulated Annealing*.

O mecanismo de reinicialização da MMP pode ser implementado de distintas maneiras. Assim, sempre que uma nova solução for gerada ao final da fase construtiva, existe uma variedade de artifícios para melhorar essa solução, desde as mais simples, como um algoritmo SDH, até algoritmos mais complexos, como a estratégia de busca *Path Relinking*, por exemplo.

3.2.2 Estratégia Multipartida Básica

Uma estratégia multipartida básica consiste em repetir um AHC um número determinado de vezes. A melhor solução encontrada representa a solução encontrada pelo método multipartida. Evidentemente em cada iteração do AHC são feitas perturbações aleatórias na função objetivo para gerar diversidade e encontrar soluções distintas dentro do espaço de busca.

O AHC é uma das técnicas heurísticas de otimização mais usadas para resolver problemas complexos e ainda é empregada isoladamente ou integrada a meta-heurísticas mais elaboradas. O mais popular dos AHCs é o tipo guloso.

Assim, uma estratégia multipartida básica para um problema de minimização com a função objetivo $f(x)$ assume a seguinte forma genérica:

1. Armazenar os dados do problema e elaborar uma estratégia para escolher uma componente da solução a ser usada. Seja $f(x^*) \leftarrow \infty$.
2. Escolher as componentes que podem ser incorporadas na nova solução em construção – geralmente o processo é iniciado sem componentes.
3. Verificar se a solução em construção já apresenta uma solução factível. Caso seja factível então vá ao passo 6, pois foi encontrada uma solução factível $f(x)$ procurada. Caso contrário, vá ao passo 4.
4. Usando a solução em construção, resolver o problema que permite aplicar a estratégia definida para escolher uma componente da solução.

5. Identificar a componente que deve ser incorporada na solução em construção. Adicionar a componente identificada na solução em construção e voltar ao passo 3.
6. Se $f(x) < f(x^*)$ então $f(x^*) = f(x)$. Se o critério de convergência for satisfeito então pare o processo. Caso contrário vá ao passo 2.

Na estratégia multipartida básica mostrada anteriormente devem ser observados os seguintes passos:

- ❖ Escolhe-se um artifício para a componente a ser incorporada na solução em construção e esse artifício define a característica da geração de uma solução factível.
- ❖ Um artifício muito conhecido é usar um indicador de sensibilidade de um AHC guloso. Nesse caso, deve-se elaborar um critério adicional para escolher a primeira componente de forma que seja possível encontrar soluções diferentes.
- ❖ A estratégia multipartida básica transforma-se em uma estratégia multipartida aleatória se o artifício para escolher uma componente for realizado de maneira aleatória entre as componentes ainda não escolhidas.

3.2.3 Estratégia Multipartida Avançada

Algumas estratégias multipartida avançadas fazem uso intensivo de memória. Na prática todas as meta-heurísticas usam algum tipo de memória: (i) memória implícita (novas transições são de alguma forma afetadas pelas transições anteriores e (ii) memória explícita – conhecida como programação com memória adaptativa ou *Adaptive Memory Programming* (AMP). Estratégias tipo AMP, encontram-se presentes em meta-heurísticas tais como: busca tabu, busca dispersa, *Evolutionary Path Relinking*, entre outros.

Segundo Marti, Resende e Ribeiro (2013) as meta-heurísticas que usam a estratégia AMP apresentam as seguintes características:

- ❖ Armazenam em memória um conjunto de soluções ou estruturas de dados especiais que informam as particularidades das soluções armazenadas.
- ❖ Uma solução provisória é construída usando os dados armazenados em memória.
- ❖ A solução provisória gerada é melhorada usando um algoritmo de busca através de vizinhança como o algoritmo SDH ou usando uma heurística mais sofisticada.
- ❖ A nova solução é armazenada na memória ou é usada para atualizar a estrutura de dados que armazena o histórico do processo.

Inúmeros recursos de uso de memória foram utilizados pela maioria das meta-heurísticas. Isso ocorre, por exemplo, com todos os algoritmos evolutivos e com os algoritmos

genéticos híbridos. Entre outras formas de memória, essas meta-heurísticas armazenam e usam de forma diferenciada as melhores soluções encontradas no processo de solução. Observa-se que foi a técnica de busca tabu que agregou de maneira explícita as estratégias de AMP.

Um tipo de MMP é o algoritmo multipartida adaptativo ou *Adaptive Multi-Start* (AMS). Essa proposta foi implementada levando-se em conta que existe alguma relação entre um mínimo local e o melhor mínimo local de um problema complexo. Com isso, pode-se implementar um algoritmo multipartida onde, o ponto inicial de otimização do AHC do tipo guloso, seja obtido de forma adaptativa a partir do melhor mínimo local previamente encontrado. Essa estratégia pode ser implementada da seguinte forma:

- ❖ *Estratégia aleatória*: A meta-heurística tipo AMS gera aleatoriamente n pontos iniciais e a partir de cada um desses pontos encontra uma solução usando um AHC. Dessa forma, o processo encontra n soluções ótimas locais.
- ❖ *Estratégia adaptativa*: É usado um artifício adaptativo para iniciar o processo de solução. Esses pontos iniciais são encontrados usando a informação das melhores soluções obtidas nos passos anteriores e são usadas para implementar o AHC.

Outra MMP proposta na literatura é a MMP clusterizado ou *Clustering Adaptive Multi-Start* (CAMS). O algoritmo CAMS apresenta duas fases. Na primeira fase gera-se um conjunto de soluções primárias a partir de pontos iniciais escolhidos de forma aleatória, sendo submetidas a uma busca local e, portanto, encontra-se um conjunto de soluções ótimas locais. Na segunda fase encontram-se soluções iniciando o processo a partir de pontos iniciais escolhidos de forma adaptativa através das melhores soluções de pré-processamento de agrupamento (*clustering*) para reduzir o tamanho do problema.

Fleurent e Glover (1999) apresentaram algumas propostas de busca com estruturas de memória adaptativa, com intuito de melhorar as técnicas multipartida. Os autores propuseram ideias existentes no algoritmo de busca tabu e relacionadas com o conjunto de soluções de elite e com o processo de intensificação baseado no conceito de variáveis fortemente determinadas e consistentes. As variáveis fortemente determinadas são aquelas cujos valores não podem ser modificados sem deteriorar o valor da função objetivo ou de outras variáveis. Uma variável é dita consistente se ela recebe um valor específico, ou particular, em uma parcela considerável das melhores soluções. Os autores recomendam a incorporação de estruturas de memória no algoritmo multipartida, da mesma forma como é implementada na busca tabu, demonstrando uma melhora significativa no desempenho de algoritmos tipo multipartida tais como o GRASP.

Outra estratégia multipartida que usa estruturas de memória é conhecida como método multipartida com técnicas de raciocínio adaptativo ou *Adaptive Reasoning Techniques* (ART) proposto em Patterson *et al.* (1999). Nesse trabalho, os autores implementaram funções de memória de curto e longo prazo. A metodologia ART é um processo iterativo que implementa critérios de aprendizado baseados nas estruturas de memória mencionadas anteriormente e na fase construtiva. O sucesso da metodologia ART está sustentado no fato de que se pode aprender a partir do uso de uma heurística construtiva gulosa e depois mudar o funcionamento da estratégia dessa heurística. O algoritmo heurístico do tipo guloso é usado repetidamente, mas em cada nova iteração, deve-se impor algumas restrições ativas sobre certos elementos de uma solução e de forma probabilística. Por exemplo, determinadas componentes podem ser escolhidas com uma probabilidade elevada já que se encontra presente em muitas soluções anteriores geradas. Assim, essas restrições ativas (aumento da probabilidade de incorporar uma componente) são usadas no processo de intensificação. Essa mesma informação armazenada em memória pode ser usada de forma inversa em processos de memória de longo prazo, isto é, em diversificação.

Outra proposta de meta-heurística tipo multipartida foi proposta por Glover (2000). A proposta é significativamente diferente, porque Glover considera um algoritmo multipartida de uma perspectiva distinta, isto é, como uma versão extrema da técnica de *oscilação estratégica* que compõe o algoritmo busca tabu. A metodologia de oscilação estratégica é usada em busca tabu quando pretendemos resolver problemas altamente restritos tais como o PEST. Um processo de otimização que usa oscilação estratégica deve passar sistematicamente e propositalmente pela região inactivel do problema e depois voltar para a região factível e, logo após, realiza-se a transição de forma inversa. A ideia central da oscilação estratégica consiste em percorrer a fronteira da região factível, pois é nessa região que se encontram as melhores soluções do problema. Na implementação da oscilação estratégica na estrutura busca tabu, assim como na implementação de uma metodologia multipartida existem dois artifícios de busca que devem ser levados em conta:

- ❖ *Atratividade persistente* ou *Persistent Attractiveness*: estabelece que uma boa escolha é decorrente de uma tomada de decisões que muitas vezes aparece como atrativa, mas que previamente não era evidente em uma região particular ou fase de busca. Atratividade persistente também está relacionada com o fato de que uma componente não seja persistentemente selecionada.

- ❖ Validade condicional marginal ou *Marginal Conditional Validity*: estabelece que as principais decisões devem ser feitas na fase inicial e que; portanto, a implementação dessas decisões restringem de forma significativa o problema.

As observações anteriores são importantes para encontrar informações de qualidade durante uma busca inicial. Quando a oscilação estratégica é aplicada em vizinhanças construtivas, o mecanismo de busca deve alternar fases construtivas e destrutivas. Assim, cada solução gerada na fase construtiva é parcialmente desmontada na fase destrutiva e na sequência é iniciada uma nova fase construtiva. Portanto, a conjunção de ambas as fases, assim como o uso adequado das estruturas de memória podem gerar métodos multipartida eficientes. Adicionalmente, a criação de mecanismos adequados para identificar e armazenar informações relacionadas com recência, frequência e atratividade podem produzir meta-heurísticas eficientes tipo multipartida baseados em um uso eficiente de memória.

As MMPs também podem ser usadas formando parte de uma superestrutura tipo times assíncronos em que uma MMP participa juntamente com algoritmos evolutivos onde todos os algoritmos são processados simultaneamente de forma cooperativa para encontrar as melhores soluções. Uma MMP também pode ser usada como base para montar uma superestrutura de otimização. Por exemplo, Lan e Depuy (2006) apresentaram a superestrutura de otimização chamada *Metaheuristic for Randomized Priority Search* (MRPS) onde se encontram presentes vários métodos aleatórios e mecanismos de memória. Nesse contexto, os mecanismos de memória consistem de regras definidas *a priori* relacionadas com a função objetivo e a construção parcial da fase construtiva para encontrar boas soluções iniciais. Na estratégia de construção parcial, algumas componentes fundamentais são fixadas levando em conta a informação obtida em iterações prévias. Dessa forma, podem ser melhoradas a qualidade e a eficiência de técnicas multipartida através do uso de mecanismos de memória e de mecanismos aleatórios.

3.2.4 Meta-heurística Multipartida versus GRASP


Entre as várias propostas de otimização da família multipartida a mais conhecida é o *Greedy Randomized Adaptive Search Procedure* (GRASP). A diferença fundamental entre essas meta-heurísticas, encontra-se na forma de implementar a fase construtiva, isto é, na estratégia usada para encontrar uma proposta de solução de boa qualidade. Essas técnicas também podem ser diferentes na fase de melhoria local ou de intensificação.

O GRASP é uma meta-heurísticas que juntamente com a busca tabu foram desenvolvidas usando apenas conceitos existentes no campo de pesquisa operacional. Trata-se

de uma junção e de uma generalização do AHC do tipo guloso e da heurística SDH. Na análise das heurísticas tradicionais, verifica-se que o AHC do tipo guloso e a heurística SDH são métodos amplamente utilizados devido ao desempenho que apresentam e, porque essas heurísticas podem ser usadas na construção de meta-heurísticas através de um processo de junção e de generalização. Portanto, o GRASP é apresentado usando tópicos conceituais relacionados com o AHC do tipo guloso e da heurística SDH.

Assim como a meta-heurística GRASP, o MMP também possui duas fases: uma construtiva e uma fase de busca local. A diferença principal encontra-se na fase construtiva em que o MMP pode apresentar diversos tipos de estratégias. No algoritmo multipartida modifica-se, por exemplo, um parâmetro de entrada antes de cada iteração. Essa estratégia permite encontrar soluções distintas, percorrendo todo o espaço de busca, não se limitando a apenas a uma região. Como pode ser visualizado na Figura 1.

Figura 1 – Representação do comportamento das meta-heurísticas GRASP e Multipartida.



Fonte: Elaboração da própria autora.

Logo, a MMP pode ser mais robusta do que o algoritmo GRASP. A estratégia de modificação de um parâmetro de entrada possibilita que o algoritmo multipartida percorra um maior espaço da região factível e, conseqüentemente, encontre uma ampla diversidade de soluções.

Uma das primeiras propostas de algoritmos multipartida foi com relação à forma de reiniciar uma iteração. Nessa proposta, um mecanismo de escolha aleatória é usado para gerar soluções diferentes na fase construtiva. Na fase de busca local, normalmente, é implementado um algoritmo de busca através de vizinhança, especialmente se o problema que está sendo resolvido permite gerar vizinhos factíveis com certa facilidade. Esse tipo de linha de pesquisa

acabou gerando a meta-heurística GRASP que na sua formulação original é uma meta-heurística multipartida. O GRASP realiza uma busca repetitiva e utiliza um AHC generalizado para geração de uma solução factível e melhora essa solução usando um algoritmo SDH. Portanto, o GRASP foi uma das primeiras meta-heurísticas do tipo multipartida e atualmente é uma das principais meta-heurísticas para resolver problemas complexos. No entanto, o GRASP encontra soluções variadas com menor diversidade dentro do espaço de busca frente a MMP. Crucial para o controle da diversidade no GRASP é a seleção aleatória de alternativas atraentes no interior da Lista Restrita de Candidatos (LRC) cujo tamanho é regulado pelo parâmetro α e pela qualidade das componentes das propostas de solução. Quanto menor a LRC; mais “guloso” torna-se o GRASP; caso contrário, quanto maior for a LRC, a busca torna-se progressivamente mais aleatória.

3.3 CONSIDERAÇÕES FINAIS

Neste capítulo, apresentaram-se as heurísticas AHC e a heurística de busca em vizinhança SDH. Fez-se também uma abordagem a respeito da MMP e aplicações da mesma em trabalhos da literatura especializada.

No capítulo subsequente, aborda-se a estratégia para resolução dos modelos matemáticos vistos no Capítulo 2 (transportes, híbrido e CC) para o PEST. A MMP abordada neste capítulo é empregada em uma fase construtiva em conjunto com o AHC para geração de soluções factíveis (ótimos locais) de boa qualidade e distantes uma das outras – com o intuito de gerar diversidade. As melhores soluções obtidas na fase construtiva são os dados de entrada para estratégia de otimização a nível local. São elas: heurística de busca em vizinhança SDH e a estratégia de busca *Path Relinking*.

4 ESTRATÉGIA DE OTIMIZAÇÃO PARA O PLANEJAMENTO DA EXPANSÃO DE SISTEMAS DE TRANSMISSÃO

Neste capítulo, apresenta-se a estratégia de otimização para resolução do PEST. Essa estratégia é construída com base nas ferramentas heurísticas (AHC e SDH) e meta-heurísticas (MMP) abordadas no Capítulo 3 acrescida da estratégia de busca local *Path Relinking* para resolução dos modelos matemáticos (transporte, híbrido e CC) abordados no Capítulo 2 para o PEST.

4.1 INTRODUÇÃO

Neste capítulo, apresenta-se uma proposta de meta-heurística multipartida (MMP) aplicada ao PEST. Cada iteração da MMP possui duas fases: (i) fase construtiva e (ii) fase de busca local. Na fase construtiva, geram-se soluções factíveis de boa qualidade; na fase de busca local ou busca na vizinhança SDH, melhoram-se as soluções obtidas na fase anterior. Em cada iteração produz-se uma solução que é tipicamente um ótimo local. A melhor solução entre os vários ótimos locais obtidos durante as diversas iterações da MMP corresponde à saída do algoritmo.

Conforme Marti *et al.* (2013), a execução das duas fases em cada iteração cria um equilíbrio entre a diversificação (fase construtiva) e a intensificação (fase de busca local). Esse equilíbrio é fundamental para a geração de soluções de alta qualidade – em muitos casos atingindo a solução ótima global.

A MMP usualmente incorpora poderosas formas de diversificação na geração de soluções factíveis. Sem a estratégia de diversificação esse método pode permanecer confinado a pequenas regiões do espaço de soluções tornando difícil atingir soluções ótimas.

Na fase de Busca Local, utilizam-se métodos de intensificação envolvendo rotinas de busca em vizinhança baseado em permutação (SDH) em conjunto com a estratégia de busca local *Path Relinking*.

Seguem as etapas da estratégia de otimização para o PEST empregadas neste estudo:

- ❖ **Fase Construtiva:** a partir da execução do AHC em uma estratégia MMP constroem-se k_1 soluções factíveis a partir da adição passo a passo de LTs na configuração inicial.

- ❖ **Fase de Busca Local I:** selecionam-se as k_2 melhores soluções obtidas na fase construtiva – aquelas com menor custo. Permutam-se essas soluções em busca de soluções de melhor qualidade – busca intensiva na vizinhança ou SDH.
- ❖ **Fase de Busca Local II:** aplicação da estratégia de busca *Path Relinking*. Selecionam-se k_3 soluções de elite obtidas nas fases anteriores. Uma delas será a solução inicial; a outra será a solução guia. Parte-se da solução inicial em direção à solução guia e vice-versa. Nesses caminhos, objetiva-se encontrar soluções de melhor qualidade – possivelmente a solução ótima global.

Para implementar o algoritmo *multipartida* para o modelo de transportes foi usado o AHC de Garver de forma generalizada. Por outro lado, para implementação do algoritmo *multipartida* para o modelo CC foi usado o AHC de Villasana-Garver-Salon (VGS). Assim, inicialmente, neste capítulo, serão apresentados o AHC de Garver e de VGS e logo após a estratégia multipartida com *Path Relinking* (MMP+PR).

4.2 ALGORITMO HEURÍSTICO CONSTRUTIVO DE GARVER PARA O MODELO DE TRANSPORTES

O AHC de Garver (1970) utiliza o modelo de transportes e foi o primeiro aplicado ao problema de PEST. Garver propõe resolver o modelo de transportes (vide seção 2.2.1) após relaxar a integralidade das variáveis inteiras de investimento, obtendo assim um problema linear (PL) com variáveis contínuas.

Dessa forma, conhecidas as incógnitas n_{ij} , encontradas resolvendo o PL (1)–(7) do Capítulo 2, encontram-se os fluxos de potência em todos os circuitos da configuração corrente n_{ij}^0 e nos caminhos candidatos n_{ij} . O caminho $i - j$ onde houver o maior fluxo de potência ativa representa o caminho mais atrativo segundo a proposta de Garver. Então, atualiza-se a configuração corrente de acordo com a adição escolhida. O PL será resolvido novamente, e o processo será repetido, adicionando em cada passo um circuito no caminho mais atrativo. O processo finaliza quando a solução do PL correspondente à configuração corrente apresenta uma solução com todas as variáveis relaxadas n_{ij} iguais a zero. Logo, não é necessário realizar mais adições de LTs e o conjunto de adições efetuadas anteriormente representa a proposta de solução factível do algoritmo.

Do ponto de vista da otimização matemática, o algoritmo de Garver é um AHC que encontra configurações de boa qualidade; no entanto, do ponto de vista teórico, não existe a

garantia de encontrar a configuração ótima global. O AHC de Garver é usado neste trabalho para implementação da MMP usando o modelo matemático de transportes.

O AHC de Garver pode ser resumido nos seguintes passos:

1. Assumir uma topologia base n_{ij}^0 , como configuração corrente – ou configuração atual. Escolhe-se o modelo matemático de transportes para o PEST.
2. Resolve-se o problema de PL correspondente à modelagem escolhida para a configuração corrente. Se todos os $n_{ij} = 0$, então pare, pois foi encontrada uma boa configuração.
3. Calculam-se os fluxos em todos os novos circuitos adicionados pelo PL. Para $n_{ij} \neq 0$. Utiliza-se a relação $f_{ij}^v = n_{ij} \bar{f}_{ij}$ – indicador de sensibilidade. O caminho $i - j$ no qual será adicionada uma LT é identificado pelo caminho $i - j$ com o maior f_{ij}^v . Atualiza-se a configuração corrente adicionando um circuito naquele caminho. Regressa-se ao passo 2.

4.3 ALGORITMO HEURÍSTICO CONSTRUTIVO DE VILLASANA, GARVER E SALON PARA O MODELO CC

O método proposto em Villasana, Garver e Salon (1985) é um AHC de VGS que utiliza o modelo híbrido linear (vide seção 2.2.3) como artifício para resolver um PL em cada passo do processo de solução. A estratégia consiste em resolver um PL para verificar se os circuitos já adicionados permitem que o sistema opere adequadamente para o modelo CC ou; caso contrário, identifica-se o circuito mais promissor que deve ser adicionado ao sistema. Esses objetivos são atingidos resolvendo um PL que é um caso especial do modelo híbrido linear após relaxar a integralidade das variáveis de investimento n_{ij} . Assim, em cada passo, o algoritmo VGS resolve o PL (18)–(28) descrito em detalhes na seção 2.2.3 do Capítulo 2.

Se na solução do PL (18)–(28) resultar $v = 0$ e, portanto, $n_{ij} = 0, \forall ij \in \Omega_l$, então, o sistema opera adequadamente apenas com os circuitos presentes na topologia inicial e com os circuitos adicionados durante o processo iterativo. Como esses circuitos obedecem as duas Leis de Kirchhoff, então a proposta de solução, isto é, os circuitos que foram adicionados, também é uma proposta factível para o modelo CC.

O AHC de VGS utiliza um indicador de sensibilidade definido a partir da solução ótima do modelo híbrido linear correspondente à topologia corrente que inclui os circuitos da topologia base e aqueles adicionados durante o processo iterativo.

Relaxando a integralidade das variáveis n_{ij} em (18)–(28) resulta em um PL. O índice de sensibilidade é definido como sendo o indicador do caminho com maior fluxo de potência, apontando para adição de um novo circuito nesse caminho selecionado conforme (29).

$$IS_{ij} = \max\{n_{ij}\bar{f}_{ij}\} \forall n_{ij} \neq 0 \quad (29)$$

Onde n_{ij} é a solução do PL (18)–(28) depois de relaxar a condição de integralidade no AHC. Em cada passo a solução corrente é, então, atualizada, com a junção da topologia base e dos circuitos adicionados durante o processo iterativo.

Em resumo, o algoritmo AHC de VGS pode ser descrito nos seguintes passos:

1. Assumir a topologia base como solução corrente e usar o modelo híbrido linear relaxando a integralidade das variáveis inteiras n_{ij} mostrado em (18)–(28). Todos os circuitos presentes na solução corrente devem satisfazer as duas leis de Kirchhoff.
2. Resolver o PL (18)–(28) para a topologia corrente. Se a solução indicar que o sistema está operando adequadamente com a nova adição e, portanto, $v = 0$, pare. Uma nova solução factível para o modelo CC foi encontrada.
3. Utilizar o índice de sensibilidade (29) para identificar o caminho mais atrativo no qual deve ser adicionada uma LT. Atualizar a topologia corrente com o circuito adicionado. Voltar ao passo 2.

Uma observação importante no algoritmo VGS sobre o índice de sensibilidade é que a solução ótima do PL apresenta um conjunto de $n_{ij} \neq 0$ que identifica a melhor opção para investimento satisfazendo somente a primeira Lei de Kirchhoff. Quando o circuito é incorporado no sistema, ele passa a cumprir ambas as Leis de Kirchhoff. Assim, o índice de sensibilidade utilizado em (29) pode não apresentar o desempenho desejado como o índice utilizado no modelo de transportes – no modelo de transportes todos os circuitos da configuração corrente e os circuitos candidatos obedecem apenas a primeira Lei de Kirchhoff.

Em resumo, a heurística de VSG emprega uma versão modificada do modelo híbrido linear para construir um indicador de sensibilidade para um AHC. O AHC é um algoritmo que adiciona LTs em cada etapa ao problema de PEST. A LT mais conveniente que deve ser adicionada em cada etapa é identificada pelo indicado de sensibilidade em (29). Logo, o algoritmo de VGS resolve uma versão modificada e relaxada do modelo híbrido linear para quantificar o indicador de sensibilidade e; portanto, identifica qual linha que deve ser adicionada em cada etapa do processo iterativo.

O algoritmo VGS será usado neste trabalho para implementação da MMP em uma fase construtiva para encontrar a solução factível para o modelo CC.

4.4 META-HEURÍSTICA MULTIPARTIDA PARA O PLANEJAMENTO DA EXPANSÃO DE SISTEMAS DE TRANSMISSÃO

Nesta seção é apresentada uma versão da MMP para resolver o PEST. Para implementar a MMP para o PEST utiliza-se o AHC de Garver para o modelo de transportes e o AHC de VGS para o Modelo CC. A estrutura global da MMP é a mesma para os dois modelos. A diferença está na estratégia usada para escolher a LT que deve ser adicionada ao sistema elétrico, ou seja, no índice de sensibilidade dos AHCs de Garver ou de VGS dependendo do modelo que está sendo usado para resolver o problema: o modelo de transportes ou o modelo CC. A MMP incorpora as fases de busca local por permutação simples em conjunto com a estratégia de busca intensiva *Path Relinking*.

Seguem os passos da MMP englobando a fase construtiva, a busca local I e a busca local II.

1. Armazenam-se os dados do problema de barras e de ramos do sistema teste. Para gerar soluções diferentes (gerar diversidade) na fase construtiva, em cada iteração modificam-se os custos c_{ij} das LTs usando a relação $c_{ij} = c_{ij} \pm \Delta_{ij}$, portanto, gerando um Δ_{ij} diferente para cada linha candidata. Seja $v(n_{ij}) \leftarrow \infty$ a incumbente inicial.
2. **Fase Construtiva:** Geram-se k_1 soluções factíveis via AHC de Garver para o modelo de transportes e via AHC de VGS para o modelo CC. Para cada solução k_1 gera-se um vetor de custos modificados: $c_{ij} = c_{ij} \pm \Delta_{ij}$.
3. **Fase Destrutiva:** Ao final de cada fase construtiva, simula-se a retirada de cada LT adicionada no decorrer da fase construtiva resolvendo um PL (1)–(7) para o modelo de transportes ou o PL (18)–(28) para o modelo CC e relaxando a integralidade das variáveis de investimento n_{ij} . Caso a retirada gere uma solução factível $v(n_{ij}) = 0$, então retira-se definitivamente essa linha da solução e avalia-se a retirada de outras linhas. Caso contrário, reintroduz-se a linha retirada e simula-se a retirada da linha seguinte.
4. **Fase de Busca Local I:** Permutação Simples. Busca intensiva na vizinhança SDH – conforme Seção 4.4.1.

5. Fase de Busca Local II: Execução da estratégia de busca intensiva *Path Relinking* – conforme Seção 4.4.2.

No Passo 2 gera-se um novo vetor de custos para implementar cada fase construtiva usando a relação $c_{ij} = c_{ij} \pm \Delta_{ij}$. Assim, para gerar cada novo valor de c_{ij} é preciso aumentar ou diminuir em Δ_{ij} o valor original de custo. Essa decisão é realizada de forma aleatória controlada e com igual probabilidade. O valor de Δ máximo é determinado empiricamente ou usando testes preliminares. A ideia central de aumentar ou diminuir um valor Δ_{ij} aos custos originais é permitir que os caminhos que resolvem o mesmo problema de geração ou demanda se tornem competitivos ao mudar os vetores de custos originais. Assim, por exemplo, se em um setor do sistema de transmissão existem três caminhos que resolvem o mesmo problema, então o AHC sempre vai identificar um único caminho – trata-se de um algoritmo guloso que promove otimização a nível local. No entanto, a mudança no vetor de custos permite gerar soluções em que aparecem os três caminhos para construções de LTs como propostas de soluções diferentes e; portanto, dando maior diversidade na geração de soluções na fase construtiva.

Os passos 4 e 5 são explorados em detalhes nas duas subseções a seguir.

4.4.1 Fase de Busca Local I: Permutação Simples

A fase de busca local I ou busca por vizinhança é executada por um algoritmo heurístico de busca através da vizinhança ou *steepest descente heuristic* (SDH) que é significativamente diferente do AHC.

Essa fase consiste na permutação das k_2 melhores soluções factíveis obtidas nas fases construtivas e destrutivas. Resolve-se para cada uma dessas soluções um problema de PL relaxando a integralidade das variáveis de investimento n_{ij} . Se $v(n_{ij}) = 0$, então os circuitos da configuração corrente permitem operar o sistema elétrico adequadamente; portanto, a solução corrente obtida via permutação é factível.

Objetiva-se varrer a vizinhança das melhores soluções obtidas nas fases construtiva e destrutiva (ótimos locais) em busca de soluções de melhor qualidade – soluções factíveis e com menor custo.

4.4.2 Fase de Busca Local II: *Path Relinking*

Adicionalmente, na estratégia MMP é adicionado o *Path Relinking* (PR) que é uma estratégia de busca intensiva que faz parte de estruturas complexas da busca tabu, mas pode ser


usada fazendo parte de outra meta-heurística e também como uma meta-heurística independente (GLOVER, 2000).

O PR realiza uma busca intensiva na vizinhança entre duas soluções de alta qualidade (ou soluções de elite) com o intuito de encontrar soluções de melhor qualidade nesse percurso. Um caminho é gerado entre duas soluções ditas solução inicial (ou solução base) e solução guia. Durante a trajetória entre a solução inicial em direção a solução guia, uma vizinhança é avaliada criteriosamente a fim de se encontrarem soluções de excelente qualidade ou de menor custo.

A *fase de busca local* II implementada via PR será aplicada a todos os pares de soluções de elite formadas a partir de um conjunto com $k_3 \geq 2$ soluções de excelente qualidade com $C_2^{k_3} = k_3!/(2!(k_3 - 2)!)$ onde $C_2^{k_3}$ é o número de pares distintos de soluções de elite. A seguir são descritos os passos da meta-heurística PR apresentados na Figura 2 conforme Arcari (2014):

1. Seleciona-se um dos $C_2^{k_3}$ pares de soluções de elite constituídos pela *solução inicial* e pela *solução guia*.
2. Atribui-se o valor da *solução inicial* à *solução corrente*.
3. Substituem-se os valores em cada posição da *solução corrente* pelos valores das posições correspondentes da *solução guia* uma a uma. Cada substituição representará uma nova *solução candidata*.
4. Verifica-se a factibilidade. Resolve-se o PL relaxando a integralidade das variáveis inteiras n_{ij} em (1)–(7) para o modelo de transportes ou em (18)–(28) para o modelo CC para cada uma das *configurações candidatas* obtidas.
5. Atualiza-se a solução ótima caso haja uma solução factível e de melhor qualidade – com menor custo entre as *soluções candidatas*.
6. Se uma das *soluções candidatas* for igual à *solução guia*, então pare. Caso contrário, a nova *solução corrente* será a *solução candidata* factível e de melhor qualidade.
7. Repetem-se os passos de 3 a 6 até que todas as posições da *solução guia* tenham sido fixadas na *solução inicial*.
8. Após finalizado o processo descrito no passo 7 executa-se a permutação entre as *soluções inicial* e *solução guia*: a *solução inicial* torna-se a *solução guia* e vice-versa. Repetem-se os passos de 2 a 7.

Figura 2 – Exemplo ilustrativo das etapas de execução da estratégia de busca intensiva *Path Relinking*: sistema teste Garver 6 barras representado via modelo CC para resolução do PEST e sem reprogramação da geração – geração fixa.



Fonte: Elaboração da própria autora.

A fim de ilustrar os passos da estratégia de busca intensiva PR emprega-se o sistema teste de Garver de 6 barras representado pelo modelo CC para resolução do PEST e sem reprogramação da geração – geração fixa. Os dados de barras e de ramos do sistema teste de Garver encontram-se no Apêndice A, Seção A.1, Tabela 10 e Tabela 11, respectivamente.

Após a execução das fases anteriores: *Fase Construtiva*, *Fase Destrutiva* e fase de *Busca Local I*; seleciona-se duas soluções de elite: a solução inicial e a solução guia – passo 1. Conforme Figura 2, a solução inicial tem custo US\$ 230 milhões de dólares e adições de LTs em três caminhos: $n_{2-6} = 5$; $n_{3-5} = 1$ e $n_{4-6} = 2$. A solução guia tem custo de US\$ 238 milhões de dólares e adições de LTs em quatro caminhos: $n_{2-6} = 3$; $n_{3-5} = 2$; $n_{3-6} = 1$ e $n_{4-6} = 2$. De acordo com o passo 2 do algoritmo PR, atribui-se o valor da solução inicial à solução corrente. No terceiro passo do algoritmo PR, substituem-se os valores em cada posição

da solução corrente pelos valores das posições correspondentes da solução guia uma a uma. Portanto, o número de LTs adicionadas na primeira posição da solução guia ($n_{2-6} = 3$) é atribuído a esse mesmo caminho na solução corrente. Essa substituição produz a primeira solução candidata com custo de US\$ 170 milhões de dólares e adições de LTs em três caminhos: $n_{2-6} = 3$; $n_{3-5} = 1$ e $n_{4-6} = 2$. Na segunda posição da solução guia, adicionam-se 2 LTs no ramo 3-5 – $n_{3-5} = 2$; valor que é atribuído a esse mesmo caminho na solução corrente. Assim, é produzida a segunda solução candidata com custo de US\$ 250 milhões de dólares e adições de LTs em três caminhos: $n_{2-6} = 5$; $n_{3-5} = 2$ e $n_{4-6} = 2$. Em último, o mesmo número de LTs da terceira posição da solução guia ($n_{3-6} = 1$) é colocado no mesmo caminho da solução corrente. Dessa forma, constrói-se a terceira solução candidata com custo de US\$ 278 milhões de dólares e adições de LTs nos caminhos: $n_{2-6} = 5$; $n_{3-5} = 1$; $n_{3-6} = 1$ e $n_{4-6} = 2$. A quarta solução candidata não pode ser formada, pois a quarta posição da solução guia ($n_{4-6} = 2$) possui igual número de LTs adicionadas nesse mesmo caminho para a solução corrente. Conforme passo 6, a nova solução corrente será a solução candidata factível e de melhor qualidade. Após resolver o PL relaxando a integralidade das variáveis de investimento n_{ij} em (18)–(28) para o modelo CC e para as três configurações candidatas; constata-se que apenas a segunda solução candidata é factível; portanto, essa será a nova solução corrente. A segunda solução candidata foi obtida ao fixar a segunda posição da solução guia ($n_{3-5} = 2$) na segunda posição da solução corrente. Logo, essa substituição permanecerá inalterada nas futuras soluções correntes e soluções candidatas. As posições fixadas da solução guia nas soluções correntes e soluções candidatas estão hachuradas na Figura 2.

Na segunda etapa do algoritmo PR o processo repete-se novamente: os valores em cada posição da solução corrente são substituídos pelos valores das posições correspondentes na solução guia uma a uma – passo 3. Assim, o primeiro valor da solução guia ($n_{2-6} = 3$) entra como adições de LTs no mesmo caminho da nova solução corrente. Portanto, a primeira solução candidata tem custo de US\$ 190 milhões de dólares e adições de LTs em três caminhos: $n_{2-6} = 3$; $n_{3-5} = 2$ e $n_{4-6} = 2$. A segunda posição da solução guia (adições de 2 LTs no ramo 3-5) não entrará na solução corrente, pois esta posição já foi fixada na etapa anterior do algoritmo PR. A adição de LT na terceira posição da solução guia ($n_{3-6} = 1$) é colocada no mesmo caminho 3-6 da solução corrente para construção da segunda solução candidata com custo de US\$ 298 e adições de LTs em 4 caminhos: $n_{2-6} = 5$; $n_{3-5} = 2$; $n_{3-6} = 1$ e $n_{4-6} = 2$.

Conforme passo 6, a nova solução corrente será a solução candidata factível e de melhor qualidade. Após resolver o PL relaxando a integralidade de n_{ij} em (18)–(28) para cada

uma das duas configurações candidatas, constata-se que apenas a segunda solução candidata é factível; portanto, essa será a nova solução corrente para início da terceira etapa do algoritmo PR. A segunda solução candidata foi obtida ao fixar a terceira posição da solução guia ($n_{3-6} = 1$) nesse mesmo caminho da solução corrente. Logo, essa substituição permanecerá inalterada nas futuras soluções correntes e soluções candidatas.

A terceira e última etapa do algoritmo PR inicia com a substituição dos valores da solução corrente pelas posições correspondentes (caminhos) da solução guia uma a uma – passo 3. Assim, o primeiro valor da primeira posição da solução guia ($n_{2-6} = 3$) entra como adições de LTs no mesmo caminho da nova solução corrente. Portanto, a primeira solução candidata apresenta custo de US\$ 238 milhões de dólares e adições de LTs em quatro caminhos: $n_{2-6} = 3$; $n_{3-5} = 2$; $n_{3-6} = 1$ e $n_{4-6} = 2$. As posições 2 e 3 da nova solução corrente foram fixadas nas etapas anteriores do algoritmo PR. A quarta posição da solução guia ($n_{4-6} = 2$) é idêntica ao número de LTs adicionadas nesse mesmo caminho para a solução corrente atual. Portanto, nesta etapa existe somente uma solução candidata.

Conforme passo 6 do algoritmo PR, se uma das soluções candidatas for igual à solução guia, então pare; portanto, como a única solução candidata obtida é igual à solução guia, então o algoritmo PR está encerrado.

Conforme Seção 5.3.1, o sistema teste de Garver de 6 barras representado via modelo CC para o PEST e sem reprogramação da geração possui custo ótimo de US\$ 200 milhões de dólares com adições de LTs em 3 caminhos: $n_{2-6} = 4$; $n_{3-5} = 1$ e $n_{4-6} = 2$. Logo, a execução do algoritmo PR da Figura 2 não alcançou a solução ótima global; somente ótimos locais.

Observa-se que a solução ótima para o sistema teste de Garver de 6 barras representado via modelo CC para resolução do PEST sem reprogramação da geração é alcançada ao final da *Fase Construtiva*, pois esse é um sistema de pequeno porte; portanto, prescinde da execução da fase de Busca Local II – *Path Relinking*.

Logo, ressalta-se que o exemplo apresentado na Figura 2 não visa atingir a solução ótima para o sistema teste de Garver, mas somente apresentar detalhadamente cada um dos passos do algoritmo de busca intensiva PR.

4.5 CONSIDERAÇÕES FINAIS

Neste capítulo foi apresentada a estratégia para otimização do PEST via a Meta-heurística Multipartida com *Path Relinking* (MMP+PR) para resolução dos modelos matemáticos de transportes, híbrido e CC.

No capítulo subsequente, a estratégia abordada neste capítulo será empregada em para resolução do PEST com o emprego de sistemas teste clássicos da literatura especializada.

5 TESTES E RESULTADOS

Neste capítulo, empregam-se a meta-heurística multipartida com *Path Relinking* (MMP+PR) para encontrar a solução ótima global para o PEST que é representado neste estudo pelos modelos de transportes, híbrido e CC. Ressalta-se que o modelo CC não será resolvido diretamente. Resolve-se o modelo híbrido (mais simplificado) em lugar do modelo CC e encontra-se uma solução factível de boa qualidade para ambos.

Na fase construtiva, aplica-se a MMP para resolução do modelo de transportes e para o modelo híbrido para o PEST. A solução factível para o modelo híbrido também será factível para o modelo CC.

Na fase de busca local, emprega-se a estratégia de busca local *Path Relinking* para atingir a solução ótima global. Nessa estratégia de busca percorre-se um caminho entre duas soluções de elite obtidas na fase construtiva.

Os modelos matemáticos para o PEST, modelos de transportes, híbrido e CC estão descritos em detalhes no Capítulo 2; as meta-heurísticas multipartida (MMP) constam no Capítulo 3 e a estratégia de otimização MMP+PR foi descrita no Capítulo 4.

Todas as simulações deste capítulo foram executadas em um computador pessoal com processador *Intel Core i5*; 1,6 GHz e 6,0 GB de memória RAM.

5.1 INTRODUÇÃO

Neste capítulo os sistemas testes de Garver 6 barras, IEEE 24 barras e Sul-Brasileiro 46 barras são representados de acordo com o modelo adotado. Esse modelo é resolvido via MMP+PR.

A estratégia de otimização MMP+PR foi implementada na linguagem de programação MATLAB®. Como não foi utilizado *toolbox* o algoritmo poderia ser implementado em qualquer linguagem de programação de alto nível como C++ ou FORTRAN, por exemplo. Utilizou-se a função *Linear Programming (linprog)* do MATLAB® para resolução dos PLs via método *dual-simplex*.

Os resultados estão apresentados em duas seções. Na primeira seção apresentam-se os resultados obtidos, aplicados em todos os sistemas teste supracitados, via MMP+PR aplicada ao PEST com o AHC de Garver para o modelo de transportes. Na segunda seção, apresentam-se os resultados obtidos via MMP+PR aplicada para resolução do PEST com o AHC de VGS para obter a solução ótima global para o modelo CC.


5.2 META-HEURÍSTICA MULTIPARTIDA COM O ALGORITMO HEURÍSTICO CONSTRUTIVO DE GARVER PARA O MODELO DE TRANSPORTES

Nesta seção apresenta-se a resolução do PEST via MMP+PR para o modelo de transportes. O modelo de transportes foi abordado no Capítulo 2 (seção 2.2.1); os detalhes da MMP constam no Capítulo 3 e; no Capítulo 4, abordaram-se todas as etapas da estratégia de otimização MMP+PR. Os resultados desta seção estão apresentados de forma sintética em Silva, Faria e Romero (2018).

5.2.1 Sistema Teste Garver de 6 Barras

O sistema teste de Garver de 6 barras da Figura 3 possui 15 ramos, 3 geradores, cargas em 5 barras com demanda total de 760 MW e permite a construção de no máximo 5 LTs por ramo. Os dados de barras e de ramos do sistema teste de Garver encontram-se no Apêndice A, Seção A.1, Tabela 10 e Tabela 11, respectivamente.

Figura 3 – Configuração inicial do sistema teste de Garver com 6 barras e 15 caminhos.



Fonte: Elaboração da própria autora.

O sistema teste de Garver é muito elementar para ser resolvido via MMP+PR. Portanto, com essa estratégia de otimização foi possível encontrar todas as soluções ótimas desse sistema teste para os casos com e sem a reprogramação da geração.

Seguem as quatro soluções ótimas para o sistema teste de Garver para o modelo de transportes com reprogramação da geração – geração livre para variar de 0 a $\bar{g}$. Por exemplo: $n_{2-6} = 1$ significa que será adicionada uma LT no ramo 2 – 6.

- $n_{2-6} = 1; n_{3-5} = 1$ e $n_{4-6} = 2$;
- $n_{2-6} = 2; n_{3-5} = 1$ e $n_{4-6} = 1$;
- $n_{3-5} = 1; n_{4-6} = 3$;
- $n_{2-6} = 3; n_{3-5} = 1$.

Como o sistema teste de Garver é muito elementar não foi preciso executar as fases de buscas locais I e II. Apenas uma iteração da fase construtiva do AHC de Garver foi suficiente para encontrar uma das soluções ótimas desse sistema teste para o modelo de transportes.

Simulou-se também esse sistema teste para o cenário mais restrito sem reprogramação da geração – geração fixa. Novamente todas as soluções ótimas globais (incumbentes) foram encontradas com facilidade. São elas:

- $n_{2-3} = 1; n_{2-6} = 3$ e $n_{3-5} = 1$.
- $n_{2-3} = 1; n_{3-5} = 1$ e $n_{4-6} = 3$.
- $n_{2-6} = 3; n_{3-5} = 2$.
- $n_{3-5} = 2; n_{4-6} = 3$.

A Tabela 1 resume as simulações para o sistema teste de Garver com e sem reprogramação da geração. Apresenta-se o valor ótimo da função objetivo, o número de PLs, número de iterações da fase construtiva, constante Δ para a variação aleatória máxima nos custos das LTs durante a fase construtiva e o tempo computacional.

5.2.2 Sistema Teste IEEE 24 Barras

Nesta seção, emprega-se o sistema teste IEEE com 24 barras e 41 caminhos. Nesse sistema teste existem 10 barras com geração de potência ativa com capacidade de geração máxima de 10.215 MW. Há 17 barras com demanda total de 8.550 MW. É permitida a adição máxima de 5 linhas em cada caminho. A Figura 4 apresenta a configuração inicial do sistema teste IEEE 24 barras. Os dados de barras e de ramos do sistema teste IEEE 24 barras encontram-se no Apêndice A, Seção A.2, Tabela 12 e Tabela 13, respectivamente.

Tabela 1 – Soluções ótimas para o sistema teste Garver 6 barras para o modelo de transportes: com e sem reprogramação da geração.

Parâmetros do Modelo	Geração Não Programada	Geração Programada
Custo Ótimo [10^6 US\$]	110	130
Número de PLs Resolvidos	6	9
Variação Aleatória Máxima nos Custos das LTs - Δ [%]	10	10
Tempo Computacional [s]	1	2
Fase Construtiva: k_1 soluções	1	1

Fonte: Elaboração da própria autora.

Esse sistema foi representado via modelo de transportes e solucionado via MMP+PR com e sem reprogramação da geração. De forma análoga ao sistema teste de Garver, todas as soluções ótimas foram encontradas com facilidade. Não foi preciso executar as fases de buscas locais I e II. A fase construtiva da MMP via AHC de Garver foi suficiente para alcançar a solução ótima.

O sistema teste da Figura 4 para o caso com reprogramação da geração possui uma única solução ótima. A saber:


- $n_{6-10} = 1; n_{7-8} = 2$ e $n_{14-16} = 1$.

Para o caso sem reprogramação da geração utilizou-se o “cenário 4” de geração. Esse cenário foi escolhido por ser aquele que requer maior esforço computacional do que os cenários 1, 2 e 3 para atingir a solução ótima. Todos os cenários de geração foram obtidos de Freitas (2017) e encontram-se também no Apêndice A, seção A.2, Tabela 12.

Seguem as quatro soluções ótimas para o sistema teste IEEE 24 barras sem reprogramação da geração e para o “cenário 4” de geração.

- $n_{3-24} = 1; n_{6-10} = 1; n_{7-8} = 2; n_{10-12} = 1; n_{14-16} = 1; n_{16-17} = 1;$
- $n_{3-24} = 1; n_{6-10} = 1; n_{7-8} = 2; n_{10-11} = 1; n_{14-16} = 1; n_{16-17} = 1;$
- $n_{3-24} = 1; n_{6-10} = 1; n_{7-8} = 2; n_{9-12} = 1; n_{14-16} = 1; n_{16-17} = 1;$
- $n_{3-24} = 1; n_{6-10} = 1; n_{7-8} = 2; n_{9-11} = 1; n_{14-16} = 1; n_{16-17} = 1.$

Figura 4 – Configuração inicial do sistema IEEE com 24 barras e 41 caminhos.



Fonte: Elaboração da própria autora.

Na Tabela 2, apresenta-se um resumo das simulações realizadas para o sistema teste IEEE 24 barras com e sem reprogramação da geração. Apresenta-se o valor da função objetivo ótima, número de PLs, iterações da fase construtiva, a constante Δ para variação aleatória máxima nos custos das LTs e o tempo computacional.

Tabela 2 – Soluções ótimas para o sistema IEEE 24 barras para o modelo de transportes: com e sem reprogramação da geração.

Parâmetros do Modelo	Geração Não Programada	Geração Programada
Custo Ótimo [10^6 US\$]	102	238
Número de PLs Resolvidos	8	54
Variação Aleatória Máxima nos Custos das LTs - Δ [%]	10	10
Tempo Computacional [s]	1	2
Fase Construtiva: k_1 soluções	1	5

Fonte: Elaboração da própria autora.

5.2.3 Sistema Teste Sul Brasileiro 46 Barras

O sistema teste Sul Brasileiro, apresentado na Figura 5, possui 46 barras e 79 caminhos. Há 12 barras de geração de potência ativa com capacidade de geração máxima de 10.545 MW. Existem 19 barras de cargas com demanda total 6.880 MW. Os dados de barras e de ramos do sistema teste Sul-Brasileiro de 46 barras encontram-se no Apêndice A, Seção A.3, Tabela 14 e Tabela 15, respectivamente.

O sistema foi representado via modelo transportes e resolvido via MMP+PR para os casos com e sem reprogramação da geração.


Para o caso com reprogramação da geração há apenas uma solução ótima para o sistema de 46 barras com custo de US\$ 53,334 milhões de dólares e adição de 7 LTs. A saber:

- $n_{33-34} = 1; n_{20-21} = 2; n_{42-43} = 1; n_{5-11} = 2; n_{46-11} = 1.$

De forma análoga aos casos anteriores, para encontrá-la não foi preciso executar as fases de buscas locais I e II mesmo para um sistema teste de médio porte. Foram executadas $k_1 = 40$ fases construtivas (em cada uma delas encontra-se uma solução factível) resultando na resolução de 306 PLs em um tempo computacional de 9,7 segundos.

O sistema teste de 46 barras sem reprogramação da geração diverge das demais simulações com respeito ao nível de dificuldade para alcançar a solução ótima. Apenas a fase construtiva é insuficiente para encontrar as soluções ótimas desse sistema. Esse sistema teste possui duas soluções ótimas para geração não programável com custo de US\$ 127,272 milhões de dólares. São elas:

Figura 5 – Configuração inicial do sistema teste Sul-Brasileiro com 46 barras e 79 caminhos.



Fonte: Elaboração da própria autora.

- $n_{5-11} = 2$; $n_{46-11} = 1$; $n_{14-22} = 1$; $n_{20-21} = 2$; $n_{28-31} = 1$; $n_{31-32} = 1$;
 $n_{24-25} = 2$; $n_{25-32} = 1$ e $n_{42-43} = 1$;
- $n_{5-11} = 2$; $n_{46-11} = 1$; $n_{14-22} = 1$; $n_{18-19} = 2$; $n_{20-21} = 1$; $n_{28-31} = 1$;
 $n_{31-32} = 1$; $n_{24-25} = 2$; $n_{25-32} = 1$ e $n_{42-43} = 2$.

Tabela 3 – Soluções ótimas para o sistema teste Sul-Brasileiro 46 barras para o modelo de transportes: com e sem reprogramação da geração.

Parâmetros do Modelo	Geração Não Programada	Geração Programada
Custo Ótimo [10^6 US\$]	53,334	127,272
Número de PLs Resolvidos	306	5.389
Variação Aleatória Máxima nos Custos das LTs - Δ [%]	40	40
Tempo Computacional [s]	9,7	270
Fase Construtiva: k_1 soluções	40	120
Busca Local I: k_2 Permutações	0	3
Busca Local II: <i>Path Relinking</i> com k_3 soluções de elite	0	3

Fonte: Elaboração da própria autora.

Essas soluções foram encontradas com $k_1 = 120$ iterações da fase construtiva, 3 buscas locais I (seleção das $k_2 = 3$ soluções factíveis de melhor qualidade para serem permutadas) e 3 buscas locais II – seleção de $k_3 = 3$ soluções de alta qualidade para execução do *Path Relinking*. Como o *Path Relinking* é executado em pares; portanto, essas etapas foram executadas três vezes, pois com três soluções diferentes formam-se três pares distintos. As soluções ótimas foram alcançadas após a solução de 5.389 PLs em um tempo computacional de 270 segundos.

Na Tabela 3 estão resumidas algumas informações relevantes das simulações com o sistema teste Sul-Brasileiro com e sem reprogramação da geração. São elas: valor da função objetivo, número de PLs resolvidos, número de iterações nas fases construtivas, valor da constante Δ para variação aleatória máxima nos custos das LTs, tempo computacional e número de iterações das buscas locais I e II.

A estratégia MMP+PR, mostrou-se eficaz para resolução dos sistemas teste de Garver 6 barras, IEEE 24 barras e Sul-Brasileiro 46 barras; todos, apresentados nesta seção para o modelo de transportes em termos de redução de PLs resolvidos e de tempo computacional.

Em Tagliaenha (2008), por exemplo, na Tabela 4.3 resolveram-se 2.496 PLs e 155.920 PLs para o sistema teste Sul-Brasileiro 46 barras com e sem reprogramação da geração, respectivamente; números de PLs resolvidos muito superiores em comparação aos apresentados na Tabela 3.

5.3 META-HEURÍSTICA MULTIPARTIDA APLICADA AO PLANEJAMENTO DA EXPANSÃO DE SISTEMAS DE TRANSMISSÃO USANDO ALGORITMO HEURÍSTICO CONSTRUTIVO DE VILLASANA-GARVER-SALON PARA O MODELO CC

Nesta seção, apresenta-se a resolução do PEST via MMP+PR para obtenção da solução ótima para o modelo CC (seção 2.2.2). Apesar de serem encontradas as soluções ótimas para o modelo CC, o mesmo não será utilizado diretamente. Emprega-se o modelo híbrido (seção 2.2.3) em lugar do modelo CC. Ressalta-se que não se pretende encontrar a solução ótima do modelo híbrido. Esse modelo é utilizado em uma estratégia construtiva – AHC de VGS (seção 4.3). Ao relaxar a integralidade das variáveis inteiras do modelo híbrido n_{ij} , o mesmo torna-se um simples PL de fácil resolução mesmo para sistemas de grande porte. A resolução do PL indica os caminhos com maior fluxo de potência; portanto, mais atrativos para adição de LTs em uma estratégia construtiva. Após a fase construtiva, obtém-se uma solução factível para o modelo híbrido, a qual também será factível para o modelo CC. Após a aplicação das fases de buscas locais I e II, a estratégia MMP+PR atinge a solução ótima global para o modelo CC conforme detalhado nas seções subsequentes.

5.3.1 Sistema Teste Garver 6 Barras

Segue a solução ótima para o sistema teste de Garver da Figura 3 para o modelo CC com reprogramação da geração (geração livre para variar de 0 a $\bar{g}$) com custo de US\$ 110 milhões de dólares e adição de 4 LTs.

- $n_{3-5} = 1; n_{4-6} = 3$.

Segue a solução ótima para o sistema teste de Garver para o modelo CC sem reprogramação da geração (geração fixa) com custo de US\$ 200 milhões de dólares e adição de 7 LTs.

- $n_{2-6} = 4; n_{3-5} = 1; n_{4-6} = 2$.

A Tabela 4 resume as simulações realizadas para o sistema teste de Garver com e sem reprogramação da geração para o modelo CC. Apresentam-se a solução ótima, o número de PLs, número de iterações da FC, a constante Δ para variação aleatória máxima nos custos das LTs durante a FC e o tempo computacional.

Tabela 4 – Soluções ótimas para o sistema teste de Garver 6 barras para o modelo CC com e sem reprogramação da geração.

Parâmetros do Modelo	Geração Não Programada	Geração Programada
Custo Ótimo [10^6 US\$]	110	200
Número de PLs Resolvidos	13	17
Tempo Computacional [s]	0,30	0,36
Varição Aleatória Máxima nos Custos das LTs Δ [%]	30	30
Fase Construtiva: k_1 Soluções	2	1

Fonte: Elaboração da própria autora.

Como o sistema teste de Garver é muito elementar não foi preciso executar as fases de *Busca Local I* e *Busca Local II*.

5.3.2 Sistema Teste IEEE de 24 Barras

O sistema da Figura 4 para o caso com reprogramação da geração possui uma única solução ótima para o modelo CC com custo total de US\$ 152 milhões de dólares e adição de 5 LTs. A saber:

- $n_{6-10} = 1; n_{7-8} = 2; n_{10-12} = 1; n_{14-16} = 1.$

Tabela 5 – Cenários de geração para o sistema teste IEEE 24 barras para o modelo CC sem reprogramação da geração.

Cenários de Geração	Novas Linhas Adicionadas	Custo Ótimo [10^6 US\$]
G1	$n_{1-5} = 1, n_{3-24} = 1, n_{6-10} = 1, n_{7-8} = 2, n_{14-16} = 1,$ $n_{15-24} = 1, n_{16-17} = 2, n_{16-19} = 1, n_{17-18} = 2$	390
G2	$n_{1-5} = 1, n_{3-24} = 1, n_{6-10} = 1, n_{7-8} = 1, n_{10-12} = 1,$ $n_{14-16} = 1, n_{15-24} = 1, n_{16-17} = 2, n_{17-18} = 2$	392
G3	$n_{6-10} = 1, n_{7-8} = 2, n_{10-12} = 1, n_{14-16} = 1,$ $n_{16-17} = 1, n_{20-23} = 1$	218
G4	$n_{3-24} = 1, n_{6-10} = 1, n_{7-8} = 2, n_{9-11} = 1,$ $n_{10-12} = 1, n_{14-16} = 2, n_{16-17} = 1$	342

Fonte: Elaboração da própria autora.

Tabela 6 – Soluções ótimas para o sistema teste IEEE 24 barras para o modelo CC Com Reprogramação da Geração (CRG) e Sem Reprogramação da Geração (SRG).

Parâmetros do Modelo	CRG	Cenários SRG			
		G1	G2	G3	G4
Custo Ótimo [10^6 US\$]	152	390	392	218	342
Número PLs Resolvidos	26	44	143	32	172
Tempo Computacional [s]	0,73	1,4	4,3	0,9	7,3
Variação Aleatória Máxima nos Custos das LTs, Δ [%]	30	50	80	80	80
Fase Construtiva: k_1 Soluções	2	2	3	1	5
Busca Local I: k_2 Permutações	0	0	1	0	1
Busca Local II: <i>Path Relinking</i> com k_3 Soluções de Elite	0	0	2	0	2

Fonte: Elaboração da própria autora.

Para o caso mais restrito sem reprogramação da geração simulam-se quatro cenários para geração G1-G4 apresentados na Tabela 5 juntamente com as novas linhas adicionadas e os custos ótimos (FREITAS, 2017).

Na Tabela 6, apresenta-se um resumo das simulações realizadas para o sistema teste de IEEE 24 barras com e sem reprogramação da geração. Apresenta-se o valor da solução ótima para cada cenário, o número de PLs, número de iterações da FC, a variação aleatória máxima no custo das LTs Δ e o tempo computacional.

5.3.3 Sistema Teste Sul-Brasileiro 46 Barras

Para o caso com reprogramação da geração há apenas uma solução ótima para o sistema de 46 barras com custo de US\$ 72,87 milhões de dólares e adição de 9 LTs.

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

Para encontrar a solução ótima supracitada foram necessárias $k_1 = 20$ fases construtivas; $k_2 = 1$ (*Busca Local I* – permutação de 1 solução de ótima qualidade) e $k_3 = 2$ (*Busca Local II* – execução *Path Relinking* com 2 soluções de elite) resultando na resolução de 374 PLs com tempo computacional de 15,61 segundos.

O sistema teste Sul-Brasileiro 46 barras sem reprogramação da geração também possui apenas uma solução ótima para geração não programável com adição de 16 LTs com custo total de US\$ 154,42 milhões de dólares.

Tabela 7 – Soluções ótimas para o sistema teste Sul-Brasileiro para o modelo CC com e sem reprogramação da geração.

Parâmetros do Modelo	Geração Não Programada	Geração Programada
Custo Ótimo [10^6 US\$]	72,87	154,42
Número de PLs Resolvidos	374	434
Tempo Computacional [s]	15,61	17,23
Variação Aleatória Máxima nos Custos das LTs Δ [%]	80	80
Fase Construtiva: k_1 Soluções	20	10
Busca Local I: k_2 Permutações	1	1
Busca Local II: <i>Path Relinking</i> com k_3 Soluções de Elite	2	2

Fonte: Elaboração da própria autora.

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

A solução supracitada foi encontrada com $k_1 = 10$ execuções da FC, 1 Busca Local I (permutação de $k_2 = 1$ soluções factíveis de melhor qualidade) e 2 Buscas Locais II – seleção de $k_3 = 2$ ou 1 par de soluções de elite para execução do *Path Relinking*. As soluções ótimas foram alcançadas após a solução de 434 PLs em um tempo computacional de 17,23 segundos!

Na Tabela 7 estão resumidas as informações relevantes das simulações com o sistema teste Sul-Brasileiro para os cenários com e sem reprogramação da geração. São elas: solução ótima, número de PLs resolvidos, número de iterações da FC, variação aleatória máxima nos custos das LTs Δ , tempo computacional e número de iterações das fases de Buscas Locais I e II.

Observa-se que os valores atribuídos para os parâmetros k_1 , k_2 e k_3 são obtidos de maneira empírica após uma quantidade expressiva de simulações. Não há limite máximo para esses parâmetros; existem somente limites mínimos. Obviamente, à medida em que esses parâmetros aumentam, eleva-se também o esforço computacional; portanto, esses parâmetros devem ser minimizados para garantir o alcance da solução ótima global em um tempo computacional não proibitivo.

O parâmetro k_1 representa o número de soluções factíveis obtidas na FC sendo que $k_1 \geq 1$ – se for necessária a execução da fase de Busca Local II (*Path Relinking*) tem-se que $k_1 \geq 2$. O parâmetro k_2 é o número de soluções de melhor qualidade (menor custo) que

participarão da fase de Busca Local I (permutação simples – SDH) sendo que $k_2 \leq k_1$. O parâmetro k_3 é o número de soluções de elite obtidas nas fases anteriores que participarão da fase de Busca Local II (*Path Relinking*) sendo que $k_3 \geq 2$.

Em último, observa-se que a MMP+PR, mostrou-se eficaz para resolução dos sistemas testes apresentados nesta seção para o modelo CC com respeito à redução do número de PLs resolvidos e de tempo computacional.

5.3.4 Análise Comparativa dos Resultados

Nesta seção é feita uma análise comparativa a partir dos resultados obtidos nas seções 5.3.1 – 5.3.3 para resolução do PEST via modelo CC por meio da estratégia MMP+PR e a comparação desses resultados com outros trabalhos da literatura especializada.

Com o intuito de avaliar o desempenho da estratégia proposta MMP+PR para o PEST foram feitas 100 simulações para os sistemas teste de Garver 6 barras, IEEE 24 barras (cenário G4) e sistema Sul-Brasileiro de 46 barras com e sem reprogramação da geração. Esses dados estão apresentados na Tabela 8.

A partir da análise da Tabela 8, observa-se que a estratégia proposta MMP+PR converge para a solução ótima em todas as simulações dos sistemas teste supracitados para os casos com e sem reprogramação da geração.

No entanto, conforme esperado, a solução ótima não é alcançada em todas as simulações realizadas. Devido a isso, apresenta-se na Tabela 8: custo médio das soluções obtidas, o pior custo, a diferença percentual entre o pior e o melhor custo e o desvio padrão obtido ao longo das 100 execuções da estratégia proposta.

Ressalta-se o excelente desempenho da estratégia de otimização MMP+PR para o cenário mais restrito do sistema teste Sul-Brasileiro de 46 barras sem reprogramação da geração de mais difícil resolução. Outras meta-heurísticas executam uma grande quantidade de PLs (milhares ou até milhões) para encontrar a solução ótima global. No entanto, a estratégia proposta MMP+PR resolve este caso rapidamente (com a resolução de centenas de PLs) e com esforço computacional compatível com a resolução desse mesmo sistema teste para o caso com geração programável – caso menos restrito.

Finalmente, na Tabela 9 é feita uma análise comparativa da proposta deste trabalho MMP+PR com outras propostas da literatura especializada para os três sistemas teste apresentados neste capítulo: Garver de 6 barras, IEEE 24 barras e Sul-brasileiro de 46 barras. Comparam-se os seguintes parâmetros: custo ótimo, número de PLs resolvidos e tempo

computacional. Outras informações tais como a estratégia de solução e a linguagem de programação utilizada também são apresentadas para cada trabalho.

Evidentemente não é trivial realizar uma análise comparativa principalmente com respeito ao tempo computacional. Nesse contexto, o número de PLs resolvidos e a qualidade da solução encontrada são empregues para realizar a análise comparativa entre os diferentes trabalhos da literatura especializada.

A partir da Tabela 9, conclui-se que a estratégia proposta MMP+PR tem um desempenho robusto apresentando menor número de PLs resolvidos e alcançando a solução ótima global em todos os casos simulados para todos os sistemas teste empregados.

Existe um caso especial onde se destaca o desempenho da estratégia MMP+PR. O sistema teste Sul-Brasileiro sem reprogramação da geração é o mais complexo entre todos os casos simulados. A maioria das meta-heurísticas resolvem uma grande quantidade de PLs para alcançar a solução ótima global. No entanto, a estratégia MMP+PR encontra a solução ótima global para esse caso mais restrito com número pequeno de PLs resolvidos e com esforço compatível para o caso menos restrito com geração programável.

Tabela 8 – Resumo das 100 execuções da estratégia proposta MMP+PR para resolução do PEST para os sistemas teste de Garver 6 barras, IEEE 24 barras e Sul-Brasileiro 46 barras com e sem reprogramação da geração para o modelo CC.

Parâmetros		Garver 6 Barras	IEEE 24 Barras	Sul-Brasileiro 46 Barras
Custo Ótimo [10^6 US\$]	CRG	110,00	152,00	72,87
	SRG	200,00	342,00	154,42
Custo Médio [10^6 US\$]	CRG	122,60	206,97	78,44
	SRG	200,00	353,90	165,79
Pior Custo [10^6 US\$]	CRG	130,00	271,00	94,02
	SRG	200,00	376,00	166,04
Diferença Entre o Pior e o Melhor Custo [%]	CRG	18,18	78,29	29,02
	SRG	0,00	9,94	7,53
Desvio Padrão [10^6 US\$]	CRG	9,66	54,87	6,58
	SRG	0,00	3,25	1,63
N.º Médio PLs Executados	CRG	13,4	32,3	390,0
	SRG	17,0	196,2	480,5
Tempo Computacional Médio [s]	CRG	0,39	1,15	20,19
	SRG	0,36	7,51	21,15

CRG: Com Reprogramação da Geração. SRG: Sem Reprogramação da Geração. Fonte: Elaboração da própria autora.

Tabela 9 – Comparação entre as soluções ótimas de investimento para os sistemas teste de Garver 6 Barras, IEEE 24 Barras, Sul-Brasileiro 46 Barras com e sem reprogramação da geração para o modelo CC.

Parâmetros		Garver 6 Barras					IEEE 24 Barras			Sul-Brasileiro 46 Barras				
		Este Estudo	[12]	[29]	[32]	[44]	Este Estudo	[32]	[44]	Este Estudo	[12]	[18]	[29]	[44]
Custo [10 ⁶ US\$]	CRG	110	NI	NI	110	110	152	152	152	72,87	NI	72,87	NI	72,87
	SRG	200	200	200	200	200	342	562	NI	154,42	154,42	NI	154,42	NI
PLs Resolvidos	CRG	13	NI	NI	NI	117	26	NI	80	374	NI	400	NI	910
	SRG	17	NI	NI	NI	51	172	NI	NI	434	NI	NI	NI	NI
Tempo Comp. [s]	CRG	0,30	NI	NI	46,36	NI	0,73	846,9	NI	15,61	NI	1,2	NI	NI
	SRG	0,36	180	20	0,65	NI	7,29	54,9	NI	17,23	2105	NI	360	NI
Método de Solução		MMP+PR	OEP	OCF	BD	AGE	MMP+PR	BD	AGE	MMP+PR	OEP	AGCB	OCF	AGE
Linguagem		Matlab	Matlab	Matlab	NI	NI	Matlab	NI	NI	Matlab	Matlab	C++	Matlab	NI

Nota: CRG: Com Reprogramação da Geração. SRG: Sem Reprogramação da Geração. NI: Não Informado. MMP+PR: Meta-heurística Multipartida com *Path Relinking*. AGE: Algoritmo Genético Especializado. AGCB: Algoritmo Genético Chu-Beasley. BD: Busca Dispersa. OCF: Otimização de Colônia de Formigas. OEP: Otimização de Enxame de Partículas.

Fonte: Elaboração da própria autora.

5.4 CONSIDERAÇÕES FINAIS

Neste capítulo, apresentou-se a resolução do PEST via estratégia de resolução MMP+PR. Empregaram-se os sistemas teste de Garver 6 barras, IEEE 24 barras e Sul-Brasileiro 46 barras para os cenários com e sem reprogramação da geração. Os sistemas teste foram representados pelos modelos matemáticos para o PEST de transporte, híbrido e CC.

A estratégia de resolução adotada MMP+PR mostrou-se altamente promissora. Todas as soluções ótimas globais de todos os sistemas teste empregados para os cenários com e sem reprogramação da geração foram alcançadas com a resolução de poucos PLs e com tempo computacional reduzido em comparação aos trabalhos da literatura especializada avaliados.

6 CONCLUSÕES

Neste trabalho foi apresentada a aplicação da Meta-heurística Multipartida com a estratégia de busca *Path Relinking* (MMP+PR) para resolução do Problema de Planejamento da Expansão de Sistemas de Transmissão (PEST) e a determinação da adição ótima de Linhas de Transmissão (LTs).

Inicialmente, foi feita uma abordagem do problema de planejamento estático da expansão de sistemas de transmissão: um problema clássico de sistemas de energia elétrica. Esse problema está associado ao fornecimento de energia com qualidade e investimento mínimo no plano de expansão. Um problema considerado complexo e de difícil resolução, que está relacionado com a natureza combinatória do processo de planejamento e sua estrutura multimodal com elevado número de ótimos locais.

Foi elaborada uma estratégia MMP+PR especializada para resolver o PEST. Empregaram-se os modelos matemáticos clássicos de transportes, híbrido e CC para representar os sistemas teste de Garver 6 barras, IEEE 24 barras e Sul-Brasileiro 46 barras. O Algoritmo Heurístico Construtivo (AHC) de Garver e de Villasana-Garver-Salon (VGS) foram implementados a fim de construir propostas de soluções na fase inicial do algoritmo Multipartida.

Para contornar as dificuldades apontadas na resolução desse problema, neste trabalho realiza-se uma perturbação aleatória controlada nos custos de instalação das LTs, com intuito de gerar diversidade e para obter soluções factíveis de boa qualidade. Em uma fase seguinte incorpora-se estratégias de melhoramento local, promovendo intensificação que visa melhorar as soluções obtidas na fase inicial, completando a implementação da Meta-heurística Multipartida (MMP).

Foram empregados dois artifícios de melhoramento local neste trabalho: Busca Local I (Permutação Simples – SDH) e Busca Local II – *Path Relinking*. Essas estratégias atuam nas propostas de soluções obtidas na fase inicial (fase construtiva) encontrando soluções de excelente qualidade ou de menor custo em muitos casos alcançando a solução ótima global.

A proposta MMP+PR, mostrou-se robusta e eficaz para resolução dos modelos de transportes e CC, pois todas as soluções ótimas de todos os sistemas teste simulados foram encontradas para os cenários com e sem reprogramação da geração – caso mais oneroso. A MMP+PR foi executada com número reduzido de PLs resolvidos e com tempo computacional igualmente reduzido em comparação a trabalhos relevantes da literatura para o PEST.

6.1 TRABALHOS FUTUROS

A principal contribuição deste trabalho foi a aplicação da meta-heurística MMP+PR para o PEST. O modelo mais simplificado de planejamento estático ao longo prazo empregado neste estudo incorpora os modelos matemáticos de transporte, híbrido e CC. Esse modelo foi escolhido para facilitar a apresentação da estratégia proposta e para mostrar de forma clara o desempenho da estratégia MMP+PR e a execução de uma análise comparativa com outros trabalhos da literatura especializada.

Doravante, a MMP+PR pode ser estendida para modelos mais complexos como aqueles apresentados em Das, Verna e Bijwe (2019); Farrag, Ali e Omran (2019); Mortaz e Valenzuela (2019); Aguado, De La Torre e Trivino (2017); Choi *et al.* (2005) e Jirutitijaroen e Singh (2008).

REFERÊNCIAS

- [1] AGUADO, J.A.; DE LA TORRE, S.; TRIVINO, A. *Battery energy storage systems in transmission network expansion*. **Electric Power Systems Research**, Amsterdam, v. 145, p. 63-72, 2017.
- [2] ARCARI, I. **A meta-heurística de busca dispersa aplicada no planejamento da expansão de sistemas de transmissão**. 2014. 139 f. Tese (Doutorado em Engenharia Elétrica) – Faculdade de Engenharia, Universidade Estadual Paulista, Ilha Solteira, 2014.
- [3] BINATO, S. **Expansão ótima de sistemas de transmissão através de decomposição de benders e técnicas de planos cortantes**. 2000. 223 f. Tese (Doutorado em Engenharia de Sistemas e Computação) – Instituto Alberto Luiz Coimbra de Pós-Graduação e Pesquisa de Engenharia – COPPE, Universidade Federal do Rio de Janeiro - UFRJ, Rio de Janeiro, 2000.
- [4] BINATO, S.; OLIVEIRA, G.C. A heuristic procedure to cope with multi-year transmission expansion planning. *In: IEEE/KTH Stockholm Power Tech Conference, Stockholm, 1995. Proceedings [...]* Piscataway: IEEE, 1995.
- [5] BINATO, S.; OLIVEIRA, G.C. A Reactive GRASP for transmission network expansion planning. *In: RIBEIRO, C. C.; HANSEN, P. (ed.) Essays and surveys on metaheuristics*. Norwell: Kluwer, 2001. p. 81–100,
- [6] BINATO, S.; OLIVEIRA, G.C.; ARAUJO, J.L. A greedy randomized adaptive search procedure for transmission expansion planning. **IEEE Transactions on Power Systems**, New York, v. 16, n. 2, p. 247–253, 2001.
- [7] BINATO, S.; PEREIRA, M.V.F.; GRANVILLE, S. A new Benders decomposition approach to solve power transmission network design problems. **IEEE Transactions on Power Systems**, New York, v. 2, p. 235-240, 2001.
- [8] BINATO, S.; ROMERO, S.P. Power Transmission Network Expansion Planning by a Hybrid Genetic Algorithm. *In: IX Latin-Iberoamerican Congress On Operations Research (IX CLAIO)*, 1998. Buenos Aires, Argentina, 1998.
- [9] CHOI, J.; TRAN, T.; EL-LEIB, A.A.; THOMAS, R.; OH, H.; BILLINTON, R. A method for transmission system expansion planning considering probabilistic reliability criteria. **IEEE Trans. Power Syst.**, New York, v. 20, p. 1606-1615, 2005.
- [10] DA SILVA, E.L.; ORTIZ, J.M.A.; DE OLIVEIRA, G.C., BINATO, S. Transmission Network Expansion Planning under a Tabu Search Approach. **IEEE Trans. Power Syst.**, New York, v. 16, p. 62-68, 2001.
- [11] DAS S.; VERNA; A.; BIJWE, P.R. Security constrained AC transmission network expansion planning. **Electric Power Systems Research**, Lausanne, v. 172, p. 277-289, 2019.
- [12] DE MENDONÇA, I.M.; JUNIOR, I.C.S.; MARCATO, A.L. Static planning of the expansion of electrical energy transmission systems using particle swarm optimization. **International Journal of Electrical Power & Energy Systems**, Oxford, v. 60, p. 234-244, 2014.

- [13] FARRAG, M.A.; ALI, K.M.; OMRAN, S. AC load flow based model for transmission expansion planning. **Electric Power Systems Research**, Amsterdam, v. 171, p. 26-35, 2019.
- [14] FLEURENT, C.; GLOVER, F. Improved constructive multipartida strategies for the quadratic assignment problem using adaptive memory, **INFORMS Journal on Computing**, Linthicum, v.11, p. 198-204, 1999.
- [15] FREITAS, P.F.S. **Planejamento da expansão de sistemas de transmissão considerando múltiplos cenários de geração**. 2017. 100 f. Tese (Doutorado em Engenharia Elétrica) – Faculdade de Engenharia, Universidade Estadual Paulista, Ilha Solteira, 2017.
- [16] GARVER, L.L. Transmission network estimation using linear programming. **IEEE Transactions on Power Apparatus and Systems**, New York, n. 7, p. 1688–1697, 1970.
- [17] GALLEGO, R.A.; ALVES, A.B.; MONTICELLI, A.; ROMERO, R. Parallel simulated annealing applied to long term transmission network expansion planning. **IEEE Transactions on Power Systems**, New York, v. 12, n. 1, p. 181–188, 1997.
- [18] GALLEGO, L.A.; GARCÉS, L.P.; RAHMANI, M.; ROMERO, R.A. High-performance hybrid genetic algorithm to solve transmission network expansion planning. **IET Gener. Transm. Distrib.**, Stevenage, Inglaterra, v. 11, p 1111-1118, 2017.
- [19] GALLEGO, R.A.; MONTICELLI, A.; ROMERO, R. Transmission system expansion planning by extended genetic algorithm. **IEE Proceedings of Generation, Transmission and Distribution**, London, v. 145, n. 3, p. 329–335, 1998.
- [20] GALLEGO, R.A.; MONTICELLI, A.; ROMERO, R. Tabu search algorithm for network synthesis. **IEEE Transactions on Power Systems**, New York, v. 15, n. 2, p. 490–495, 2000.
- [21] GOLDBERG, D.E. **Genetic Algorithms in Search, Optimization and Machine Learning**. Reading: Addison Wesley, 1989.
- [22] GLOVER, F. Future paths for integer programming and links to artificial intelligence. **Computers & Operations Research**, New York, v. 13, n. 5, p. 533–549, 1986.
- [23] GLOVER, F. Tabu search – part I. **ORSA Journal of Computing**, Baltimore, v. 1, n. 3, p. 190 – 206, 1989. Disponível em: <http://www.cs.amherst.edu>. Acesso em: 17 out. 2019.
- [24] GLOVER, F. **Multipartida and strategic oscillation methods - Principles to exploit adaptive memory, Computing tools for modeling optimization and simulation**. [S. l.]: Kluwer Academic Publishers, 2000. p. 1-25,
- [25] HOLLAND. J.H. **Adaptation in natural and artificial systems: an introductory analysis with applications to biology, control, an artificial intelligence**. Michigan: The University of Michigan Pres, 1975.

- [26] JIRUTITIJAROEN, P.; SINGH, C. Reliability Constrained Multi-Area Adequacy Planning Using Stochastic Programming with Sample-Average Approximations. **IEEE Trans. Power Syst.**, New York, v. 23, p. 504-513, 2008.
- [27] LAN, G.; DEPUY, G.W. On the effectiveness of incorporating randomness and memory into a multi-start metaheuristic with application to the set covering problem. **Computers and Industrial Engineering**, New York, v. 51, p. 362-374, 2006.
- [28] LEVI, V.A.; CALOVIC, M.S. A new decomposition based method for optimal expansion planning of large transmission networks. **IEEE Transactions on Power System**, New York, v. 6, n. 3, p. 937-943, 1991.
- [29] LIMSAKUL, P.; POTHYA, S.; LEEPRECHANON, N. Application of Ant Colony Optimization to Transmission Network Expansion Planning with Security Constraint. *In*: INT. CONF. ON ADVANCES IN POWER SYSTEM CONTROL, OPERATION AND MANAGEMENT (APSCOM), 8th, 2009, Hong Kong. **Proceedings [...]** Hong Kong: [s. n.], 2009. p. 1-6.
- [30] MARTI, R.; RESENDE, M.G.C.; RIBEIRO, C. Multi-start methods for combinatorial optimization. **European Journal of Operational Research**, Amsterdam, v. 226, n.1, p. 1-18, 2013.
- [31] MONTICELLI, A.; SANTOS, A.; PEREIRA, M.V.F.; CUNHA, S.H.; PARKER, B.J.; PRAÇA, J.C.G. Interactive transmission network planning using a least-effort criterion. **IEEE Transactions on Power Apparatus and Systems**, New York, n. 10, p. 3919-3925, 1982.
- [32] MORI H.; SHIMOMUGI, K. Transmission network expansion planning with Scatter Search. *In*: IEEE Int. Conf. on Systems, Man and Cybernetics, p. 3749-3754, Montreal, Canada, 2007.
- [33] MORTAZ, E.; VALENZUELA, J. Evaluating the impact of renewable generation on transmission expansion planning. **Electric Power Systems Research**, Amsterdam, v. 169, p. 35-44, 2019.
- [34] PATTERSON, R.; PIRKUL, H.; ROLLAND, E. Adaptive reasoning techniques for the capacitated minimum spanning tree problem. **Journal of Heuristics**, Boston, v. 5, p. 159-180, 1999.
- [35] PEREIRA, M.V.F.; PINTO, L.M.V.G. Application of sensitivity analysis of load supplying capability to interactive transmission expansion planning. **IEEE Transactions on Power Apparatus and Systems**, New York, n. 2, p. 381-389, 1985.
- [36] REN, P.; GAO, L.Q.; LI, N.; LI, Y.; LIN, Z.L. Transmission network optimal planning using the particle swarm optimization method. *In*: MACHINE LEARNING AND CYBERNETICS, 7, 2005, Guangzhou. **Proceedings [...]** Guangzhou: [s. n.], 2005. p. 4006-4011
- [37] RENDÓN, R.A.G.; ZULUAGA, A.E.; OCAMPO, E.M.T. Técnicas Meta-heurísticas de Optimización. Pereira: [s.n.], 2008.

- [38] RIDER, M.J.; GARCIA, A.V.; ROMERO, R. Power system transmission network expansion planning using AC model. **IET Generation, Transmission Distribution**, Stevenage, Inglaterra, v. 1, n. 5, p. 731–742, 2007.
- [39] ROMERO, A., MANTOVANI, J.R.S. Introdução a Meta-heurísticas. Mini-curso do III Congresso Temático de Dinâmica e Controle da SBMAC, Ilha Solteira, SP, Junho, 2004.
- [40] ROMERO, R.; GALLEGOS, R.A.; MONTICELLI, A. Transmission system expansion planning by simulated annealing. **IEEE Transactions on Power Systems**, New York, v. 11, n. 1, p. 364–369, 1996.
- [41] ROMERO, R.; MONTICELLI, A. A hierarchical decomposition approach for transmission network expansion planning. **IEEE Transactions on Power Systems**, New York, v. 9, n. 1, p. 373–380, 1994.
- [42] ROMERO, R.; MONTICELLI, A.; GARCIA, A.; HAFFNER, S. Test systems and mathematical models for transmission network expansion planning. **IEE Proceedings of Generation, Transmission and Distribution**, London, v. 149, n. 1, p. 27–36, 2002.
- [43] ROMERO, R. A. **Planejamento a longo prazo da expansão de sistemas de transmissão de energia elétrica**: 1999. 138 f. Tese (Livre docência) – Faculdade de Engenharia, Universidade Estadual Paulista, Ilha Solteira, 1999.
- [44] ROMERO, R.; RIDER, M.J.; SILVA, I.J. A metaheuristic to solve the transmission expansion planning. **IEEE Transactions on Power Systems**, New York, v. 22, n. 4, p. 2289–2291, 2007.
- [45] SILVA, E.F. **Planejamento estocástico da expansão da rede de transmissão de energia elétrica multiestágio considerando restrições de segurança**. 2013. 183 f. Tese (Tese de Doutorado) - Faculdade de Engenharia, Universidade Estadual Paulista, Ilha Solteira, 2013.
- [46] SILVA, S.M.L.; FARIA, L.T.; ROMERO, R. Multi-Start for transmission system expansion planning using a transportation model. *In*: SIMPÓSIO BRASILEIRO DE SISTEMAS ELÉTRICOS (VII SBSE), 7., 2018, Rio de Janeiro. Proceedings [...], Rio de Janeiro: [s. n.], 2018.
- [47] SILVA, E.L.; GIL, H.A.; AREIZA, J.M. Transmission network expansion planning under an improved genetic algorithm. **IEEE Transactions on Power Systems**, New York, v. 15, n. 3, p. 1168–1175, 2000.
- [48] TAGLIALENHA, S.L.S. **Novas Aplicações de Meta-heurísticas na Solução do Problema de Planejamento da Expansão do Sistema de Transmissão de Energia Elétrica**. 2008. 138 f. Tese (Doutorado em Engenharia Elétrica) – Faculdade de Engenharia de Ilha Solteira (FEIS), Universidade Estadual Paulista (UNESP), Ilha Solteira, 2008.
- [49] VILLASANA, R.; GARVER, L.; SALON, S. Transmission network planning using linear programming. **IEEE Trans. on Power Apparatus and Syst.**, New York, n. 2, p. 349–356, 1985.

APÊNDICE A – DADOS ELÉTRICOS DOS SISTEMAS-TESTE

A.1 SISTEMA TESTE GARVER 6 BARRAS

Tabela 10 – Dados de barras do sistema teste de Garver 6 barras e 15 caminhos.

Barras	Geração Máxima (MW)	Demanda (MW)
1	150	80
2	0	240
3	360	40
4	0	160
5	0	240
6	600	0

Fonte: Elaboração da própria autora.

Tabela 11 – Dados de ramos do sistema teste de Garver 6 barras e 15 caminhos.

Ramos	Linhas Existentes	Reatância (<i>pu</i>)	Fluxo Máximo (MW)	Custo (10 ³ US\$)
1-2	1	0,40	100	40
1-3	0	0,38	100	38
1-4	1	0,60	80	60
1-5	1	0,20	100	20
1-6	0	0,68	70	68
2-3	1	0,20	100	20
2-4	1	0,40	100	40
2-5	0	0,31	100	31
2-6	0	0,30	100	30
3-4	0	0,59	82	59
3-5	1	0,20	100	20
3-6	0	0,48	100	48
4-5	0	0,63	75	63
4-6	0	0,30	100	30
5-6	0	0,61	78	61

Fonte: Elaboração da própria autora.

A.2 SISTEMA TESTE IEEE 24 BARRAS

Tabela 12 – Dados de barras do sistema teste IEEE com 24 barras e 41 caminhos.

Barras	Geração (MW) Cenário 1	Geração (MW) Cenário 2	Geração (MW) Cenário 3	Geração (MW) Cenário 4	Demanda (MW)
1	576	465	576	520	324
2	576	576	576	520	291
3	0	0	0	0	540
4	0	0	0	0	222
5	0	0	0	0	213
6	0	0	0	0	408
7	900	722	900	812	375
8	0	0	0	0	513
9	0	0	0	0	525
10	0	0	0	0	585
11	0	0	0	0	0
12	0	0	0	0	0
13	1773	1424	1457	1599	795
14	0	0	0	0	582
15	645	645	325	581	951
16	465	465	282	419	300
17	0	0	0	0	0
18	1200	1200	603	718	999
19	0	0	0	0	543
20	0	0	0	0	384
21	1200	1200	951	1077	0
22	900	900	900	900	0
23	315	953	1980	1404	0
24	0	0	0	0	0

Fonte: Elaboração da própria autora.

Tabela 13 – Dados de ramos do sistema teste IEEE com 24 barras e 41 caminhos.

Ramos	Linhas Existentes	Reatância (pu)	Fluxo Máximo (MW)	Custo (10 ⁶ US\$)
1-2	1	0,0139	175	3
1-3	1	0,2112	175	55
1-5	1	0,0845	175	22
2-4	1	0,1267	175	33
2-6	1	0,1920	175	50
3-9	1	0,1190	175	31
3-24	1	0,0839	400	50
4-9	1	0,1037	175	27
5-10	1	0,0883	175	23
6-10	1	0,0605	175	16
7-8	1	0,0614	175	16
8-9	1	0,1651	175	43
8-10	1	0,1651	175	43
9-11	1	0,0839	400	50
9-12	1	0,0839	400	50
10-11	1	0,0839	400	50
10-12	1	0,0839	400	50
11-13	1	0,0476	500	66
11-14	1	0,0418	500	58
12-13	1	0,0476	500	66
12-23	1	0,0966	500	134
13-23	1	0,0865	500	120
14-16	1	0,0389	500	54
15-16	1	0,0173	500	24
15-21	2	0,0490	500	68
15-24	1	0,0519	500	72
16-17	1	0,0259	500	36
16-19	1	0,0231	500	32
17-18	1	0,0144	500	20
17-22	1	0,1053	500	146
18-21	2	0,0259	500	36
19-20	2	0,0396	500	55
20-23	2	0,0216	500	30
21-22	1	0,0678	500	94
1-8	0	0,1344	500	35
2-8	0	0,1267	500	33
6-7	0	0,1920	500	50
13-14	0	0,0447	500	62
14-23	0	0,0620	500	86
16-23	0	0,0822	500	114
19-23	0	0,0606	500	84

Fonte: Elaboração da própria autora.

A.3 SISTEMA TESTE SUL-BRASILEIRO 46 BARRAS

Tabela 14 – Dados de barras do sistema teste Sul-Brasileiro de 46 Barras e 79 caminhos.

Barras	Geração Máxima (MW)	Demanda (MW)	Barras	Geração Máxima (MW)	Demanda (MW)
1	0	0	24	0	478,2
2	0	443,1	25	0	0
3	0	0	26	0	231,9
4	0	300,7	27	220	0
5	0	238,0	28	800	0
6	0	0	29	0	0
7	0	0	30	0	0
8	0	72,2	31	700	0
9	0	0	32	500	0
10	0	0	33	0	229,1
11	0	0	34	748	0
12	0	511,9	35	0	216,0
13	0	185,8	36	0	90,1
14	1257	0	37	300	0
15	0	0	38	0	216,0
16	2000	0	39	600	0
17	1050	0	40	0	262,0
18	0	0	41	0	0
19	1670	0	42	0	1607,9
20	0	1091,2	43	0	0
21	0	0	44	0	79,1
22	0	81,9	45	0	86,7
23	0	458,1	46	700	0

Fonte: Elaboração da própria autora.

Tabela 15 – Dados de ramos do sistema teste Sul-Brasileiro de 46 barrase 79 caminhos.

Ramos	Linhas Existentes	Reatância (pu)	Fluxo Máximo (MW)	Custo (10 ³ US\$)	Ramos	Linhas Existentes	Reatância (pu)	Fluxo Máximo (MW)	Custo (10 ³ US\$)
1-7	1	0,0616	270	4349	44-45	1	0,1864	200	11924
1-2	2	0,1065	270	7076	19-32	1	0,0195	1800	23423
4-9	1	0,0924	270	6217	46-19	1	0,0222	1800	26365
5-9	1	0,1173	270	7732	46-16	1	0,0203	1800	24319
5-8	1	0,1132	270	7480	18-19	1	0,0125	600	8178
7-8	1	0,1023	270	6823	20-21	1	0,0125	600	8178
4-5	2	0,0566	270	4046	42-43	1	0,0125	600	8178
2-5	2	0,0324	270	2581	2-4	0	0,0882	270	5965
8-13	1	0,1348	240	8793	14-15	0	0,0374	270	2884
9-14	2	0,1756	220	11267	46-10	0	0,0081	20	10889
12-14	2	0,0740	270	5106	4-11	0	0,2246	240	14247
14-18	2	0,1514	240	9803	5-11	0	0,0915	270	6167
13-18	1	0,1805	220	11570	46-6	0	0,0128	20	16005
13-20	1	0,1073	270	7126	46-3	0	0,0203	1800	24319
18-20	1	0,1997	200	12732	16-28	0	0,0222	1800	26365
19-21	1	0,0278	1500	32632	16-32	0	0,0311	1400	36213
16-17	1	0,0078	20	10505	17-32	0	0,0232	1700	27516
17-19	1	0,0061	20	8715	19-25	0	0,0325	1400	37748
14-26	1	0,1614	220	10409	21-25	0	0,0174	20	21121
14-22	1	0,0840	270	5712	25-32	0	0,0319	1400	37109
22-26	1	0,0790	270	5409	31-32	0	0,0046	20	7052
20-23	2	0,0932	270	6268	28-31	0	0,0053	20	7819
23-24	2	0,0774	270	5308	28-30	0	0,0058	20	8331
26-27	2	0,0832	270	5662	27-29	0	0,0998	270	6672
24-34	1	0,1647	220	10611	26-29	0	0,0541	270	3894
24-33	1	0,1448	240	9399	28-41	0	0,0339	1300	39283
33-34	1	0,1265	270	8288	28-43	0	0,0406	1200	46701
27-36	1	0,0915	270	6167	31-41	0	0,0278	1500	32632
27-38	2	0,2080	200	13237	32-41	0	0,0309	1400	35957
36-37	1	0,1057	270	7025	41-43	0	0,0139	20	17284
34-35	2	0,0491	270	3591	40-45	0	0,2205	180	13994
35-38	1	0,1980	200	12631	15-16	0	0,0125	600	8178
37-39	1	0,0283	270	2329	46-11	0	0,0125	600	8178
37-40	1	0,1281	270	8389	24-25	0	0,0125	600	8178
37-42	1	0,2105	200	13388	29-30	0	0,0125	600	8178
39-42	3	0,2030	200	12934	40-41	0	0,0125	600	8178
40-42	1	0,0932	270	6268	2-3	0	0,0125	600	8178
38-42	1	0,0907	270	6116	5-6	0	0,0125	600	8178
32-43	1	0,0309	1400	35957	9-10	0	0,0125	600	8178
42-44	1	0,1206	270	7934	-	-	-	-	-

Fonte: Elaboração da própria autora.

APÊNDICE B – ARTIGOS PUBLICADOS E SUBMETIDOS

Congresso Nacional:

(Artigo Publicado)

SILVA, S.M.L.; FARIA, L.T.; ROMERO, R. Multi-Start for transmission system expansion planning using a transportation model. **In:** VII Simpósio Brasileiro de Sistemas Elétricos (VII SBSE), 2018. Rio de Janeiro, Brasil, 2018.

Revista Internacional:

(Artigo Submetido)

SILVA, S.M.L.; FARIA, L.T.; ROMERO, R.; FRANCO, J.F. Efficient Multi-Start and Path Relinking Search Strategy for the Transmission System Expansion Planning. **Electric Power Systems Research**, 2020.