



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

PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

**Análise e Implementação de um Algoritmo de
Busca Dispersa para o Planejamento da Expansão
de Sistemas de Transmissão**

ADRIANA APARECIDA DE LIMA

Orientador: Prof. Dr. Rubén Augusto Romero Lázaro

Ilha Solteira – SP
Outubro de 2012

ADRIANA APARECIDA DE LIMA

Análise e Implementação de um Algoritmo de Busca Dispersa para o Planejamento da Expansão de Sistemas de Transmissão

Dissertação apresentada à Faculdade de Engenharia – UNESP – Campus de Ilha Solteira, para obtenção do título de Mestre em Engenharia Elétrica.
Área de Conhecimento: Automação.

Prof. Dr. Rubén Augusto Romero Lázaro.
Orientador.

Ilha Solteira SP
Outubro de 2012

FICHA CATALOGRÁFICA

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

- L732a Lima, Adriana Aparecida de.
Análise e implantação de um algoritmo de busca dispersa para o planejamento da expansão de sistemas de transmissão / Adriana Aparecida de Lima. – Ilha Solteira : [s.n.], 2012
93 f. : il.
- Dissertação (mestrado) - Universidade Estadual Paulista. Faculdade de Engenharia de Ilha Solteira. Área de conhecimento: Automação, 2012
- Orientador: Rubén Augusto Romero Lázaro
Inclui bibliografia
1. Redes elétricas - Planejamento. 2. Energia elétrica - Planejamento. 3. Planejamento de expansão de redes. 4. Busca dispersa. 5. Metaheurísticas.


CERTIFICADO DE APROVAÇÃO


TÍTULO: Análise e Implementação de um Algoritmo de Busca Dispersa para o Planejamento da Expansão de Sistemas de Transmissão


AUTORA: ADRIANA APARECIDA DE LIMA

ORIENTADOR: Prof. Dr. RUBEN AUGUSTO ROMERO LAZARO

Aprovada como parte das exigências para obtenção do Título de Mestre em Engenharia Elétrica ,
Área: AUTOMAÇÃO, pela Comissão Examinadora:


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


Prof. Dr. JOSE ROBERTO SANCHES MANTOVANI
Departamento de Engenharia Elétrica / Faculdade de Engenharia de Ilha Solteira


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

Data da realização: 05 de outubro de 2012.

Dedicatória:

A Deus, aos meus pais Luzia e Jose, minha avó Jasmira (in memoriam) e meu namorado Luiz.

AGRADECIMENTOS

A Deus por iluminar meu caminho me amparando nos momentos difíceis, por me dar força interior para superar as dificuldades, mostrar os caminhos nas horas incertas e me suprir em todas as minhas necessidades. A minha grande intercessora infalível Nossa Senhora Aparecida a quem tenho imensa devoção.

Aos meus pais Luzia Marques de Lima e Jose de Lima pelo imenso apoio em qualquer que for a situação e pelo grande exemplo de vida que sempre me ensinam. A minha irmã Andreia Uchida e meu cunhado Sandro Uchida pela ajuda que sempre me forneceram quando precisei. A minha sobrinha e afilhada Yasmin, que embora bebê, conseguiu me inspirar nos dias mais difíceis através do seu sorriso angelical. Aos meus padrinhos Aurora Marques dos Santos e Hilário Costa dos Santos pelo carinho sempre presente.

Ao meu querido namorado Luiz Ravagnani Marçolla Neto pela imensa ajuda e força que sempre me atribuiu qualquer que fosse a hora do dia ou da noite, ajuda esta que não tem preço e eu serei grata por toda a vida... Obrigada pelo incentivo, paciência, força e às vezes acreditar mais em mim do que eu mesma!

A minha grande companheira de moradia em Ilha Solteira, Ana Claudia Barros, jamais me esquecerei tudo que passamos juntas, tudo que me ajudou e tudo que dividimos, foi um grande aprendizado.

Ao meu orientador e Professor Dr. Rubén Augusto Romero Lázaro pela imensa oportunidade que me deu pela escolha do tema e pela grande paciência.

Ao Mohsen Rahmani pelo imenso apoio que sempre me forneceu e jamais negou qualquer que fosse a ajuda para a construção deste trabalho. Tenho certeza que tudo que me ensinou e todas as vezes que me ajudou jamais serão esquecidas, sempre serão lembradas com grande gratidão.

A todos os professores do DEE e também às secretárias do DEE e PPGE.

A todos os colegas do Laboratório de Planejamento de Sistemas de Energia Elétrica (LaPSEE) pela grande convivência e solidariedade sempre

que precisei. Em especial aos meus colegas Joel Trujillo, Simone Frutuoso e Eliane Souza.

A minha amiga Ana Paula Sakai pela convivência que tive o prazer de continuar a ter desde a UFMS.

Aos meus amigos que me apoiaram em todas as dificuldades que passei durante a construção deste trabalho.

E ainda a todos aqueles que de uma forma ou de outra contribuíram para a conclusão deste trabalho.

À CNPq pelo suporte financeiro.

*Feliz o homem que suporta com paciência a
provação! Porque, uma vez provado,
receberá a coroa da vida, que o Senhor
prometeu àqueles que O amam (São Tiago
1, 12).*

*Por caminhos planos, ela guiou o justo, que
fugia da ira do irmão, mostrou-lhe o reino
de Deus e revelou-lhe as coisas santas.
Deu-lhe sucesso nas suas fadigas e
multiplicou os frutos do seu trabalho
(Sabedoria 10, 10).*

RESUMO

O Problema de Planejamento da Expansão do Sistemas de Transmissão de Energia Elétrica tem por objetivo escolher, entre um conjunto predefinido de circuitos candidatos, aqueles que devem ser incorporados ao sistema de forma a minimizar os custos de investimento e operação e atender a demanda de energia futura ao longo de um horizonte de planejamento com confiabilidade, assumindo como conhecido o plano de geração. É considerado um problema muito complexo e difícil de resolver por se tratar de um problema não linear inteiro misto, não convexo, multimodal e altamente combinatório. Este problema tem sido resolvido usando técnicas clássicas como *Decomposição de Benders* e *Branch and Bound*, assim como também algoritmos heurísticos e metaheurísticas obtendo diversos resultados, porém com uma série de problemas, por exemplo, alto tempo de processamento pelos computadores e problemas de convergência. Neste trabalho se apresenta a metaheurística Busca Dispersa que é um método que combina sistematicamente conjuntos de soluções para se obter soluções melhores. O algoritmo é apresentado sistematicamente, explicando sua estrutura básica e a forma como é adaptado para resolver o problema do planejamento da expansão de sistemas de transmissão, considerando a modelagem matemática conhecida como modelo de transporte e o modelo DC. São realizados testes com o sistema Garver de 6 barras, o sistema IEEE de 24 barras e o Sul Brasileiro de 46 barras e os resultados obtidos são comparados com os obtidos com outras metaheurísticas, mostrando um bom desempenho tanto em velocidade de processamento como em esforço computacional.

Palavras-chave: Planejamento da expansão de redes. Busca dispersa. Metaheurísticas.

ABSTRACT

In the Transmission Expansion Planning problem of power systems a predefined set of candidate circuits are selected, in order to minimize investment and operation costs and meet the future energy demand over a planning horizon while reliability is considered and the generations plans are known. It is considered a very complex problem and difficult to solve because it is a mixed integer nonlinear problem, not convex, multimodal and highly combinatorial. This problem has been solved using classical techniques such as Benders Decomposition and Branch and Bound, as well as heuristic and metaheuristics algorithms achieving different results, but with some difficulties, such as high demand for processing by computers and convergence problems. This paper presents the scatter search metaheuristic which is a method that combines systematically sets of solutions to obtain better solutions. The algorithm is presented systematically, explaining its basic structure and how it is adapted to solve the Transmission Expansion Planning problem, considering the mathematical model known as transportation model and DC model. Tests are performed with Garver 6 bus system, IEEE 24 bus system and the South Brazilian 46 bus system, and the results obtained are compared with those obtained with other metaheuristics, showing a good performance both in processing speed as in computational effort.

Keywords: Transmission expansion planning. Metaheuristics. Scatter search.

LISTA DE FIGURAS

Figura 1.	Topologia base	50
Figura 2.	Proposta de solução.....	52
Figura 3.	Codificação de uma proposta de solução.....	53
Figura 4.	Topologia ótima.....	55
Figura 5.	Algoritmo de Busca Dispersa.	60
Figura 6.	<i>Path Relinking</i>	61
Figura 7.	Codificação de uma proposta de solução para o PPEST	64
Figura 8.	Sistema de 6 barras com seis circuitos na configuração base e seis circuitos adicionados.....	65
Figura 9.	Algoritmo de Busca Dispersa - Diagrama de Fluxo.....	68
Figura 10.	Algoritmo de Busca Dispersa com <i>Path Relinking</i> no Meio (BD-PR-M).....	69
Figura 11.	Algoritmo de Busca Dispersa com <i>Path Relinking</i> no Final (BD-PR-F).....	70
Figura 12.	Processo da Distância Computacional	73
Figura 13.	Geração do Diagrama do Conjunto de Referência.....	74
Figura 14.	Sistema de 6 barras de Garver	77
Figura 15.	Sistema IEEE 24 barras	79
Figura 16.	Sistema sul brasileiro de 46 barras	82

LISTA DE TABELAS

Tabela 1.	Dados do sistema de 6 barras da topologia base.....	49
Tabela 2.	Uma amostra de soluções de teste inicial	73
Tabela 3.	Resultado do algoritmo proposto para quatro planos.....	78
Tabela 4.	Parâmetros do algoritmo BDM	81
Tabela 5.	Sistema Garver (com reprogramação de geradores e sem reprogramação de geradores).....	84
Tabela 6.	IEEE 24 Barras com busca dispersa e <i>path relinking</i> no final	84
Tabela 7.	IEEE 24 Barras com busca dispersa e <i>path relinking</i> no final	85
Tabela 8.	46 Barras com busca dispersa e <i>path relinking</i> no final	85

LISTA DE ABREVIATURAS E SIGLAS

AC	<i>Alternating Current</i>
AG	Algoritmo Genético
AGB	Algoritmo Genético Básico
AHC	Algoritmo Heurístico Construtivo
BD	Busca Dispersa
BDM	Busca Dispersa Modificada
BD-PR-M	Algoritmo de Busca Dispersa com Path Relinking no Meio
BD-PR-F	Algoritmo de Busca Dispersa com Path Relinking no Final
Circ.	Circuito
CRG	Com Reprogramação de Geradores
DC	<i>Direct Current</i>
G0	Gerador Zero
G1	Gerador Um
G2	Gerador Dois
G3	Gerador Três
G4	Gerador Quatro
IEEE	<i>Institute of Electrical and Electronics Engineers</i>
Inv.	Investimento
LKC	Primeira Lei de Kirchhoff
LKT	Segunda Lei de Kirchhoff
MHL	Modelo Híbrido Linear
PNLIM	Problema não Linear Inteiro Misto
MT	Modelo de Transporte
MW	Mega watt
NCR	Número de conjunto de referência

PL	Programação Linear
PR	<i>Path Relinking</i>
PNLIM	Problema de Programação Não-Linear Inteiro Misto
PPEX	Problema de Planejamento da Expansão
PSO	Probabilidade de Obter Solução Ótima
SA	<i>Simulated Annealing</i>
SDH	<i>Steepest Descent Heuristic</i>
Seg	Segundos
SRG	Sem Reprogramação de Geradores
Temp	Tempo
TS	<i>Tabu Search</i>
VGS	Villassana-Garver-Salon
VNS	<i>Variable Neighborhood Search</i>

SUMÁRIO

1	<i>Introdução</i>	15
1.1	<i>O Problema de Planejamento da Expansão do Sistema de Transmissão</i>	15
1.2	<i>Modelagem Matemática</i>	17
1.2.1	Descrição do Problema e Formulação	18
1.2.2	Modelo de Operação DC	20
1.2.3	Modelo Híbrido Linear	21
1.2.4	Modelo de Transportes	23
1.3	<i>AHC de Villasana-Garver-Salon</i>	24
1.4	<i>Uma Revisão sobre o Planejamento da Expansão de Sistemas de Transmissão</i>	26
2	<i>Introdução a Metaheurísticas Aplicadas a Sistemas Elétricos de Potência</i>	34
2.1	<i>Introdução sobre as Heurísticas</i>	34
2.1.1	O Algoritmo Heurístico Construtivo	35
2.1.2	O Algoritmo Heurístico de Busca Através de Vizinhança	37
2.2	<i>Introdução sobre as Metaheurísticas</i>	40
2.2.1	Simulated Annealing	40
2.2.2	Tabu Search - Busca Tabu	42
2.2.3	O Algoritmo Genético	44
2.3	<i>Aplicação das Metaheurísticas na Otimização de Sistemas Elétricos de Potência</i>	47
2.3.1	O Problema de Planejamento da Expansão de Sistemas de Transmissão	47

3	<i>A Metaheurística de Busca Dispersa</i>	57
3.1	<i>Uma Revisão sobre a Busca Dispersa.</i>	57
3.2	<i>Tipos de Algoritmos de Busca Dispersa</i>	59
3.3	<i>A Estratégia de Path Relinking</i>	61
4	<i>A Metaheurística de Busca Dispersa para o Problema do Planejamento da Expansão de Sistemas de Transmissão</i>	64
4.1	<i>A Proposta de Codificação de uma Proposta de Solução</i>	64
4.1.1	Algoritmo de Busca Dispersa.....	66
4.1.2	Algoritmo de Busca Dispersa Implementado no Problema de Planejamento da Expansão de Sistemas de Transmissão.....	70
5	<i>Testes e Resultados Encontrados</i>	75
5.1	<i>Sistemas para Teste</i>	75
5.2	<i>Sistema Garver</i>	75
5.3	<i>Sistema IEEE 24 Barras</i>	78
5.4	<i>Sistema Sul Brasileiro de 46 barras</i>	80
6	<i>Conclusões</i>	87
	<i>REFERÊNCIAS</i>	89

1 Introdução

Diante das recentes reestruturações impostas ao setor de energia elétrica e a necessidade de suprir a crescente demanda de energia elétrica que ocorre com o passar dos anos, surge a tendência dominante de competição de mercados. A nova concepção para o setor identifica, pelo menos, três etapas distintas nesta cadeia de produção e consumo: geração, transmissão e distribuição. Neste sentido, as atividades de planejamento da expansão do sistema assumem uma importância ainda maior, em função da necessidade de conciliar interesses comerciais dos diversos agentes envolvidos. Então surge o problema de planejamento da expansão do sistema de geração e transmissão, o qual precisa ser realizado de forma conjunta e em um horizonte de longo prazo, mesmo que os agentes responsáveis sejam muitos e distintos.

Neste trabalho se considera o planejamento da expansão do sistema de transmissão a longo prazo, um problema considerado clássico no setor de energia elétrica e cuja modelagem matemática ideal corresponde a um problema de programação não-linear inteira mista, e que, além disso, apresenta o fenômeno de explosão combinatória. As principais dificuldades na resolução deste problema estão relacionadas com a natureza combinatória do processo de planejamento que, via de regra, leva a uma explosão combinatorial de alternativas, inclusive no caso de sistemas de médio porte.

Adicionalmente a estas dificuldades, o problema de planejamento apresenta uma estrutura multimodal com um número muito elevado de ótimos locais, o que leva a maioria dos métodos aproximados a parar numa solução ótima local e às vezes pobre.

1.1 O Problema de Planejamento da Expansão do Sistema de Transmissão

No decorrer dos anos a evolução social impeliu uma demanda energética cada vez maior, e aliado a isto, os consumidores se tornaram cada vez mais conscientes e exigentes. Nesse sentido, o problema de planejamento da expansão de sistemas de transmissão é um tema de grande importância

para o setor elétrico, cuja solução propiciará o atendimento aos consumidores de forma confiável e econômica.

Nos últimos anos o sistema elétrico está passando por um processo de modificação normativa, mudando de uma estrutura centralizada para uma descentralizada, que tem como objetivo obter uma maior eficiência dos agentes participantes do setor (geração, transmissão, distribuição, entre outros) que decidirão onde e quando investir seus recursos para expandir o sistema. Este processo deverá sofrer a intermediação de um agente central e deverá funcionar como um plano de referência, de forma a garantir uma expansão ótima global do sistema, otimizando a utilização dos recursos disponíveis e os custos para os consumidores. Logo, novos parques geradores e novas linhas de transmissão devem ser construídos para atender esta nova carga do sistema.

É de suma importância a construção de novos circuitos de transmissão com a finalidade de transmitir a energia elétrica produzida nas usinas hidrelétricas a fim de aumentar a confiabilidade do sistema, otimizar recursos hídricos, etc, tendo em vista que estas usinas, enquanto principais centros geradores de energia elétrica do Brasil estão afastadas dos centros consumidores.

As decisões do processo de planejamento estão relacionadas à triagem das melhores unidades geradoras, das melhores rotas de transmissão e das melhores malhas para garantir um suprimento de energia de forma econômica. No processo de planejamento, a tomada de decisões dá origem a um problema de otimização complexo, pois é necessário o desenvolvimento de estratégias e técnicas de solução que assegurem que as decisões tomadas durante o processo de planejamento sejam as melhores possíveis.

Trata-se de um problema que não pode ser resolvido sem que sejam feitas simplificações. Normalmente, o problema de planejamento é separado com relação aos seus principais agentes, quais sejam: problema de planejamento da geração, que não leva em conta os custos da expansão da transmissão, o problema de planejamento da transmissão, que supõe conhecidas as estimativas de crescimento da demanda e programas alternativos de expansão da geração, até o ano horizonte de planejamento e o planejamento da distribuição. No que tange ao planejamento de sistemas de

transmissão ainda é possível separar o problema em dois tipos: planejamento estático e planejamento multiestágio.

No planejamento estático existe apenas um estágio de planejamento, onde o planejador procura conhecer o circuito ótimo para ser adicionado em um único ano no horizonte de planejamento, ou seja, o planejador não está interessado em saber quando o circuito deverá ser construído, mas encontrar a topologia final ótima para uma futura situação definida. Por outro lado, se múltiplos anos são considerados e a estratégia de expansão ótima abrange todo o horizonte, o planejamento é classificado como multiestágio. Neste caso, o modelo matemático deve conter restrições de tempo para considerar a expansão ao longo dos anos de tal forma que o valor presente dos custos ao longo do horizonte de planejamento seja minimizado enquanto que as restrições impostas sejam atendidas.

O planejamento multiestágio é muito complexo, pois deve levar em consideração não só as especificações técnicas e a alocação dos circuitos planejados, mas, também, considerações de tempo. Há escassos trabalhos sobre planejamento dinâmico para problemas reais de planejamento na literatura, no entanto, Latorre et al. (2003) apontam alguns destes trabalhos.

Esta pesquisa está focada no planejamento da expansão de sistemas de transmissão nos horizontes de médio e longo prazo (10 anos ou mais) que consiste em determinar onde e como os equipamentos de transmissão (como transformadores, linhas de transmissão, entre outros) devem ser instalados de forma a atender a demanda de forma confiável. Devido tanto às incertezas como também às dimensões inerentes a este tipo de problema, métodos rápidos e aproximados de análise são requeridos.

1.2 Modelagem Matemática

Como foi anteriormente mencionado, o problema de planejamento da expansão de sistemas de transmissão de energia elétrica consiste em se escolher, entre um conjunto predefinido de circuitos candidatos, aqueles que devem ser incorporados ao sistema de forma a minimizar os custos de investimento e operação e atender a demanda de energia futura ao longo de um horizonte de planejamento com confiabilidade, assumindo como conhecido

o plano de geração. Esse problema tem uma natureza dinâmica, isto é, requer a consideração de múltiplos períodos de tempo, determinando-se uma sequência (estágios) de planos de expansão do sistema. Quando o horizonte de planejamento se reduz a apenas um estágio, o problema multiestágio se transforma em um problema estático.

Os dados necessários para este problema são a previsão de carga futura, bem como o despacho dos geradores para atender ao mercado. Além disso, são necessários dados da rede existente, também chamada de rede básica e dados dos novos circuitos que podem ser adicionados à rede básica. Note que a rede básica não tem capacidade suficiente para o atendimento da demanda no mercado futuro.

Assim, o modelo matemático mais indicado para representar a operação adequada do sistema seria a representação do problema por meio de relações matemáticas de fluxo de carga AC (*Alternating Current*), tipicamente usada na análise da operação do sistema elétrico. Entretanto, o uso desta modelagem é muito recente e, portanto, sua aplicação ainda se encontra restrita e em fase de desenvolvimento. Para alguns detalhes sobre a aplicação do modelo AC no planejamento da expansão de sistemas de transmissão ver Rider et al. (2007). Portanto, considera-se que a modelagem matemática mais indicada em trabalhos de planejamento de sistemas de transmissão em longo prazo, é o chamado modelo DC (*Direct Current*) que leva em conta as duas leis de Kirchhoff apenas para o balanço e o fluxo de potência ativa. Nesse caso, o problema resultante é do tipo de programação não-linear inteiro misto de elevada complexidade para sistemas de grande porte.

1.2.1 Descrição do Problema e Formulação

Geralmente, a longo prazo o planejamento da expansão da rede de transmissão é modelado por uma formulação matemática que é chamado de modelo DC, um problema não-linear inteiro misto (PNLIM) que é difícil de ser resolvido especialmente para sistemas de grande porte. O modelo DC para o planejamento da expansão da rede de transmissão é formulado da seguinte forma:

$$\min \nu = \sum_{(i,j) \in \Omega} c_{ij} n_{ij} + \alpha \sum_{i \in B} r_i \quad (1)$$

s.a

$$f + g + r = d \quad (2)$$

$$f_{ij} - \gamma_{ij} (n_{ij}^0 + n_{ij}) (\theta_i - \theta_j) = 0 \quad (3)$$

$$|f_{ij}| \leq (n_{ij}^0 + n_{ij}) \overline{f_{ij}} \quad (4)$$

$$0 \leq g \leq \overline{g} \quad (5)$$

$$0 \leq n_{ij} \leq \overline{n_{ij}} \quad (6)$$

$$0 \leq r \leq d \quad (7)$$

$$n_{ij} \text{ inteiro}, f_{ij} \text{ e } \theta_i \text{ ilimitado } (i,j) \in \Omega$$

Em que B é o conjunto de todas as barras com demanda ou carga, Ω é o conjunto de todos os ramos definidos pelas linhas existentes e as alternativas de expansão, em que a ampliação ou duplicação de uma linha existente também é considerada uma alternativa de expansão. S é a matriz de incidência nó-ramo transposta, ν é o custo da expansão; c_{ij} , n_{ij} e f_{ij} representam, respectivamente, o custo de uma linha de transmissão, o número de linhas de transmissão que podem ser adicionados e o fluxo total pelas linhas de transmissão no caminho i - j ; n_{ij}^0 é o número de linhas existentes na topologia base no caminho i - j , $\overline{n_{ij}}$ é o número máximo de linhas que podem ser adicionadas no caminho i - j , $\overline{f_{ij}}$ é o fluxo máximo em cada linha de transmissão no caminho i - j , $\overline{g}$ é o vetor de gerações com valores máximos iguais a $\overline{g}$, d é o vetor de demandas, r é o vetor de geradores artificiais com elementos r_k (geração artificial na barra de demanda k), os θ_i são os ângulos das tensões de barra, γ_{ij} é a susceptância de uma linha de transmissão, e α um parâmetro de penalidade.

A equação (1) é a função objetivo do modelo DC contendo a soma dos custos de investimento das linhas de transmissão candidatas a adição, bem como o corte de carga com grande penalidade. Na equação (2), a lei de correntes de Kirchhoff (LKC) na rede DC equivalente é modelada, a equação (3) é uma expressão da lei de Ohm para a rede DC equivalente, e representa a

lei de voltagem de Kirchhoff (LKT). As equações (4), (5) e (6) são as relações que envolvem o limite de fluxo da linha de transmissão, são a capacidade do gerador e a limitação para os números de linhas que serão adicionadas, respectivamente. O algoritmo proposto para solução do modelo é o Algoritmo de Busca Dispersa modificado para resolver o modelo DC, que é um problema não-linear inteiro misto, no entanto, usamos alguns outros modelos relaxados, extraído a partir do modelo DC, no algoritmo de Busca Dispersa. Apesar da utilização de modelos relaxados em Busca Dispersa o algoritmo proposto tem a capacidade de encontrar solução ou topologias factíveis também para o modelo DC. Os modelos relaxados com relação ao modelo DC são conhecidos como modelo híbrido Linear e modelo de transporte.

1.2.2 Modelo de Operação DC

O modelo DC atualmente é considerado o modelo matemático mais indicado para representar o problema de planeamento da expansão de sistemas de transmissão a longo prazo. Os principais motivos para essa opção são os seguintes:

- (1) É a modelagem mais aceita por pesquisadores e especialistas em planeamento das empresas de energia elétrica;
- (2) Existem várias técnicas de solução (algoritmos) que resolvem de maneira adequada os problemas de planeamento que usam o modelo DC; e
- (3) Neste modelo, o tempo de processamento não é elevado.

Quando são usadas metaheurísticas se estabelece uma proposta de investimento. Neste contexto, para verificar se esta proposta é factível, determina-se o seguinte PL:

$$\begin{aligned}
 \min \quad & w = \sum_{i \in B} r_i \\
 \text{s.a.} \quad & sf + g + r = d \\
 & f_{ij} - \gamma_{ij} n_{ij}^1 (\theta_i - \theta_j) = 0 \\
 & |f_{ij}| \leq (n_{ij}^1) \bar{f}_{ij} \\
 & 0 \leq g \leq \bar{g} \\
 & f_{ij} \text{ e } \theta_j \text{ ilimitados } (i,j) \in \Omega
 \end{aligned} \tag{7}$$

Onde: n_{ij}^1 é dado e definido por:

$$n_{ij}^1 = n_{ij}^0 + n_{ij}^k \quad (8)$$

e n_{ij}^k é uma proposta de solução gerada pela metaheurística.

1.2.3 Modelo Híbrido Linear

O algoritmo proposto por Villasana et al. (1985) é um AHC (Algoritmo Heurístico Construtivo) que utiliza o modelo híbrido linear com a estratégia de resolver apenas um PL em cada passo do processo de otimização. A estratégia consiste em resolver um PL de tal forma que seja possível verificar se os circuitos já adicionados permitem que o sistema opere adequadamente para o modelo DC ou, caso contrário, identificar o circuito mais promissor que deve ser adicionado ao sistema. Esses objetivos são atingidos resolvendo um PL de um caso especial do modelo híbrido linear após relaxar a integralidade das variáveis de investimento n_{ij} . Assim, em cada passo, o algoritmo Villasana-Garver-Salon (VGS) resolve o PL (9)-(17).

$$\min v = \sum_{(i,j) \in \Omega} c_{ij} n_{ij} \quad (9)$$

s.a

$$Sf + S^0 f^0 + S^1 f^1 + g = d \quad (10)$$

$$f_{ij}^0 - \gamma_{ij} n_{ij}^0 (\theta_i - \theta_j) = 0, \forall (i, j) \in \Omega_0 \quad (11)$$

$$|f_{ij}^1| - \gamma_{ij} n_{ij}^1 (\theta_i - \theta_j) = 0, \forall (i, j) \in \Omega_1 \quad (12)$$

$$|f_{ij}^0| \leq n_{ij}^0 \bar{f}_{ij}, \forall (i, j) \in \Omega_0 \quad (13)$$

$$|f_{ij}^1| \leq n_{ij}^1 \bar{f}_{ij}, \forall (i, j) \in \Omega_1 \quad (14)$$

$$|f_{ij}| \leq n_{ij} \bar{f}_{ij}, \forall (i, j) \in \Omega \quad (15)$$

$$0 \leq g \leq \bar{g} \quad (16)$$

$$0 \leq n_{ij} \leq (\bar{n}_{ij} - n_{ij}^1) \quad (17)$$

$$f_{ij}^0 \quad f_{ij}^1 \quad f_{ij} \text{ irrestritos}$$

$$\theta_j \text{ irrestrito}$$

Em que:

S : Matriz de incidência nó-ramo transposta para os circuitos candidatos à adição.

S^0 : Matriz de incidência nó-ramo transposta para os circuitos da topologia base.

S^1 : Matriz de incidência nó-ramo transposta para os circuitos adicionados e dos nós conectados a esses caminhos no processo iterativo do algoritmo VGS.

f : Vetor de fluxos totais nos circuitos novos que devem ser adicionados na resolução, do PL com elementos f_{ij} .

f^0 : Vetor de fluxos totais através dos circuitos da topologia base, com elementos f_{ij} .

f^1 : Vetor de fluxos totais através dos caminhos adicionados no processo iterativo e com elementos f_{ij}

f_{ij} : fluxo nos circuitos candidatos à adição no caminho ij .

Ω : Conjunto de índices dos circuitos candidatos.

Ω_0 : Conjunto de índices dos circuitos presentes na topologia base.

Ω_1 : Conjunto de índices dos circuitos adicionados no processo de otimização pelo VGS.

Deve-se observar que no PL mostrado em (9)-(17) os fluxos em cada caminho estão separados em três grupos: fluxos em circuitos existentes na topologia base f_{ij}^0 , fluxos nos circuitos já adicionados no processo iterativo do algoritmo VGS f_{ij}^1 , e os fluxos nos circuitos adicionados na resolução do PL, f_{ij} . O mesmo acontece com os circuitos n_{ij}^0 , n_{ij}^1 e n_{ij} , representando, respectivamente, o número de circuitos presentes no caminho ij na configuração base, circuitos já adicionados no processo iterativo pelo algoritmo VGS e os circuitos adicionados na resolução do PL. Ω_0 representa o conjunto dos circuitos presentes na configuração base e Ω_1 representa o conjunto dos circuitos já adicionados pelo VGS.

Se na solução do PL (9)-(17) obter-se $v = 0$ e, portanto, $n_{ij} = 0, \forall (i, j) \in \Omega$ então, o sistema opera adequadamente apenas com os circuitos da topologia base e os já adicionados no processo iterativo. Como esses circuitos obedecem as duas leis de Kirchhoff, então a proposta de solução, isto é, os circuitos que foram adicionados, é uma proposta factível para o modelo DC.

Caso contrário, a solução encontrada nos permite identificar o circuito mais atrativo que deve ser adicionado ao sistema elétrico no próximo passo.

1.2.4 Modelo de Transportes

O modelo de transportes foi originalmente proposto por Garver (1970), onde se relaxa o modelo DC, eliminando-se a equação de restrição (3) dando origem a um modelo linear mais facilmente de ser trabalhado. O modelo pode determinar soluções viáveis, mas não necessariamente uma solução ideal, e entre essas, algumas podem não satisfazer ou ser factíveis para o modelo DC.

$$\begin{aligned}
 \min \quad & \nu = \sum_{(i,j) \in \Omega} c_{ij} n_{ij} \\
 \text{s.a.} \quad & Sf + g = d \\
 & |f_{ij}| \leq (n_{ij}^0 + n_{ij}) \overline{f_{ij}} \\
 & 0 \leq g \leq \overline{g} \\
 & 0 \leq n_{ij} \leq \overline{n_{ij}} \\
 & n_{ij} \text{ inteiro; } f_{ij} \text{ ilimitado } (i,j) \in \Omega
 \end{aligned} \tag{18}$$

No caso do modelo de transportes o problema resultante é do tipo linear inteiro misto, logo, é uma modelagem mais simplificada, que considera apenas a primeira lei de Kirchhoff (LKC).

Mesmo sendo linear, ainda não é possível encontrar a solução ótima para o modelo de transportes para sistemas de grande porte.

Tal modelo de transportes foi à primeira proposta sistemática de modelagem matemática usado com muito sucesso no problema de planejamento de sistemas de transmissão. O modelo foi proposto por Garver, (1970) e representou o início de uma pesquisa sistemática nos problemas de

planejamento de sistemas de transmissão, sugerindo o uso de modelos distintos para os problemas de operação e de planejamento.

Garver propõe que, devido aos grandes problemas de usar o modelo de fluxo de carga AC utilizado para operação, deve-se usar modelos mais relaxados que permitam encontrar topologias ou configurações atrativas do crescimento do sistema elétrico mesmo que estas propostas sejam aproximadas. Assim, sugere a utilização de um modelo matemático que deve satisfazer somente a primeira lei de Kirchhoff (LKC), isto é, a modelagem matemática proposta não leva em conta a segunda lei de Kirchhoff (LKT). Este modelo matemático é conhecido como modelo de transportes.

Do ponto de vista de modelagem matemática, por ser um modelo relaxado ou com restrições que são relaxadas quando comparado com o modelo DC, a solução encontrada pelo modelo de transportes pode ser menos precisa para o problema real representado pelo modelo DC. No modelo de transportes se deseja encontrar uma configuração que produza o menor investimento no plano de expansão do sistema elétrico e condições adequadas de operação desse sistema elétrico. Sendo que condições adequadas de operação significam que o sistema deve satisfazer a primeira lei de Kirchhoff e que os circuitos e as usinas de geração operem dentro de seus limites especificados.

A grande vantagem do modelo de transportes é que praticamente não existe diferença entre resolver problemas de sistemas conexos e altamente ilhados e a característica linear facilita o processo de resolução.

A desvantagem principal é que a solução apresentada pelo modelo de transportes pode estar distante da solução correspondente ao modelo DC, considerado como modelo mais indicado.

1.3 AHC de Villasana-Garver-Salon

O AHC proposto por Villasana et al. (1985) utiliza um indicador de sensibilidade definido a partir da solução ótima do modelo híbrido linear (MHL) correspondente à topologia corrente (circuitos da topologia base e os

adicionados no processo iterativo) com a integralidade das variáveis n_{ij} relaxadas na resolução do modelo (9)-(17).

Considerando-se que relaxando-se a integralidade das variáveis n_{ij} no problema de planejamento, como foi feito no problema (9)-(17), este torna-se um problema de programação linear (PL), com o índice de sensibilidade definido como sendo o fluxo de potência pelos circuitos com $n_{ij} \neq 0$ na solução do PL. Assim em cada passo do AHC, o circuito selecionado para adição é aquele identificado pelo seguinte índice de sensibilidade:

$$IS = \max \{ IS_{ij} = n_{ij} \overline{f_{ij}} : n_{ij} \neq 0 \} \quad (19)$$

em que n_{ij} é a solução do PL depois de relaxar a condição de integralidade no AHC. Em cada passo a solução corrente é, então, atualizada, e assim a topologia corrente é formada pela topologia base juntamente com os circuitos adicionados durante o processo iterativo.

A característica mais interessante apresentada no algoritmo VGS é que cada circuito adicionado durante o processo deve satisfazer as duas leis de Kirchhoff, simultaneamente, o que significa que a solução determinada pelo VGS é uma solução factível para o modelo DC.

O algoritmo VGS pode ser resumido nos passos a seguir.

Passo 1: Assumir a topologia base como solução corrente e usar o modelo híbrido linear modificado relaxado mostrado (9)-(17). Todos os circuitos presentes na solução corrente devem satisfazer as leis de Kirchhoff da corrente e da tensão.

Passo 2: Resolver o PL (9)-(17) 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 para o modelo DC foi encontrada.

Passo 3: Utilizar o índice de sensibilidade (19) para identificar o circuito mais atrativo que deve ser adicionado ao sistema. Atualizar a topologia com o circuito adicionado, acrescentando ij em Ω_1 e ir ao passo 2.

A vantagem de se utilizar esta estratégia é que em cada passo se resolve apenas um PL, mas no final do processo encontra-se uma solução para

o modelo DC. Outra possibilidade é resolver o próprio modelo DC após relaxar a integralidade das variáveis n_{ij} mas, nesse caso, deve-se resolver um problema de programação não-linear em cada passo do AHC.

Do ponto de vista de otimização matemática o VGS é um algoritmo heurístico construtivo que, na prática, encontra configurações de boa qualidade, mas do ponto de vista teórico não existe garantia de encontrar a solução ótima global.

Um significado importante no algoritmo VGS sobre o índice de sensibilidade é que a solução ótima do PL apresenta um conjunto de valores $n_{ij} \neq 0$ que identifica o melhor investimento proposto 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 pode não apresentar o desempenho desejado como o índice utilizado no modelo de transportes. Para outros índices, ver (ROMERO et al., 2003).

O algoritmo VGS é usado nesta dissertação para encontrar uma solução inicial de boa qualidade para a metaheurística busca dispersa.

1.4 Uma Revisão sobre o Planejamento da Expansão de Sistemas de Transmissão

Nesta seção se considerou como base para realizar a revisão os trabalhos de Latorre et al. (2003), Faria (2005), Tagliarenha (2008) e alguns trabalhos recentes.

Nas primeiras fases dos trabalhos em planejamento da expansão, as únicas ferramentas disponíveis para a síntese de redes de transmissão eram os softwares de análise como os utilizados no cálculo de fluxo de carga, estudos de estabilidade, curto-circuito, etc. O planejador do sistema de energia elétrica era o responsável por determinar onde instalar novos equipamentos para suprir as novas cargas do sistema, resultando em uma configuração que deveria ser analisada através dos métodos mencionados anteriormente. Com o crescimento das dimensões das redes de transmissão, este procedimento se torna inadequado.

Contudo, as pesquisas na área de planejamento de sistemas de transmissão experimentaram uma expansão e novos desenvolvimentos de modelos e técnicas de solução. Muitos artigos e relatos sobre novos modelos foram publicados na literatura especializada devido principalmente à melhoria das ferramentas tecnológicas disponíveis, novos algoritmos de otimização, e o maior nível de incerteza introduzida pela desverticalização do setor de energia.

A pesquisa pioneira de Knight (1960) teve o mérito de propor a distinção entre os métodos de análise e métodos matemáticos de projeto (síntese) de sistemas de transmissão de energia elétrica.

Uma das primeiras pesquisas propostas para a solução deste problema é de Garver (1970). O autor formulou o problema considerando apenas a Primeira Lei de Kirchhoff e resolveu este modelo matemático usando um Algoritmo Heurístico Construtivo (AHC) que em, cada passo, escolhia o circuito mais atrativo para ser incorporado ao sistema, que era identificado após se resolver um problema de programação linear.

Kaltenbath et al. (1970), também do ano de 1970, propuseram combinar programação linear com programação dinâmica. Programação linear era usada para encontrar o mínimo incremento da capacidade da rede para atender às variações de demanda e geração nas barras do sistema. Após essa etapa, era utilizada programação dinâmica para achar a melhor sequência de investimentos (contínuos) para o horizonte de planejamento. Este trabalho é pioneiro para problemas de planejamento de expansão de redes de transmissão considerando múltiplos estágios.

Monticelli et al. (1982) propuseram o uso de ferramentas interativas para o planejamento da transmissão. Para ordenar as possibilidades de adições era utilizado o índice de “Mínimo Esforço”, que consistia de uma análise de sensibilidade em relação às susceptâncias dos circuitos em um problema de otimização correlato cujo resultado era idêntico ao modelo de fluxo de carga linearizado. A proposta era essencialmente um algoritmo heurístico construtivo usando o modelo DC.

O uso de análise de sensibilidade no problema de Planejamento de Sistemas de Transmissão foi inicialmente proposto no trabalho de Champs et al. (1979) onde utilizaram a análise de sensibilidade em relação às susceptâncias a partir de um problema de programação linear, cujas restrições

eram as equações do modelo de fluxo de carga linearizado em conjunto com limites de transporte nos circuitos e de capacidade nos geradores. O objetivo do problema era obter o mínimo corte de carga necessário para eliminar todas as violações operacionais na rede elétrica. O uso de análise de sensibilidade também foi proposto por Pereira et al. (1987).

Villasana (1984 e 1985) apresentam duas diferentes metodologias para serem aplicadas ao planejamento da expansão de sistemas de transmissão. Estas propostas consistiam de um aperfeiçoamento do trabalho feito por Garver (1970), que propôs o modelo de transportes, representando uma técnica fundamental na pesquisa em planejamento da expansão de sistemas de transmissão, pois naquela época era a única forma disponível de otimizar este problema. Esse modelo relaxado, diferente dos usados em análise de operação, foi chamado de modelo de síntese de sistemas de transmissão. O modelo de transportes, assim como todo modelo de síntese, faz apenas o planejamento considerando o fluxo de potência ativa. Portanto, soluciona apenas o problema de capacidade de transmissão. O problema de planejamento de reativos era resolvido na fase seguinte. Na tentativa de aperfeiçoar estas propostas e diminuir a complexidade do problema, Villasana determinou soluções viáveis para o modelo DC resolvendo modelos híbridos lineares, em que apenas os circuitos existentes na configuração base deviam obrigatoriamente, satisfazer as duas leis de Kirchhoff.

Em contraste, o modelo híbrido não-linear é um problema de programação, não-linear inteiro misto (PNLIM) de complexidade muito parecida como o modelo DC. Esse modelo foi pouco usado por pesquisadores em planejamento de sistemas de transmissão porque devem ser utilizadas as mesmas técnicas utilizadas para o modelo DC e, portanto, pode ser preferível trabalhar diretamente com o modelo DC, considerado ideal. Mesmo assim, o modelo híbrido não linear deve ser de menor dificuldade de resolução que o modelo DC.

A utilização de esquemas de decomposição para este problema teve início com o trabalho de Pereira (1985). Naquele trabalho, um esquema de decomposição de *Benders* foi aplicado para decompor o problema global de planejamento de redes em dois subproblemas: um de investimento, que tinha por objetivo propor um plano de expansão; e outro de operação, que devia

analisar o plano proposto e expressar as restrições operacionais em termos das variáveis de investimento através de restrições lineares chamadas de cortes de *Benders*. Essa nova restrição devia ser adicionada ao subproblema de investimento e novas iterações de *Benders* eram repetidas até a obtenção da convergência. O modelo adotado para formular o problema de planejamento da expansão de redes de transmissão era não-linear e não-convexo, o que podia trazer sérias dificuldades para métodos de cortes como o algoritmo de decomposição de *Benders*.

Objetivando contornar esta deficiência do método de decomposição de *Benders*, em relação ao modelo não-linear e não-convexo, foi proposto na tese de doutorado de Romero (1993), aparecendo, também, no trabalho de Romero et al. (1994), uma metodologia de decomposição, hierárquica composta por três fases distintas. Assim na primeira fase o problema de planejamento deve ser resolvido por decomposição de *Benders* considerando somente o modelo de transporte para o subproblema de operação. Além disso, a integralidade das variáveis de investimento deveriam ser relaxadas. Já na segunda fase, o modelo do subproblema de operação devia ser trocado por um modelo híbrido que consistia do modelo de fluxo de potência linearizado para os circuitos existentes e um modelo de transporte para calcular o fluxo nos circuitos planejados. Enfim, na terceira fase deste trabalho, o modelo de fluxo de carga linearizado era utilizado para o cálculo do fluxo de carga em todos os circuitos da rede de transmissão. Desta maneira, no subproblema de investimento consideram-se as variáveis de investimento discretas e utiliza-se um algoritmo especializado de enumeração implícita (ROMERO, 1993). Pinto et al. (1990,) usaram o esquema de decomposição de *Benders* combinado com um algoritmo de enumeração implícita. Com o objetivo de reduzir o esforço computacional, que pode ser muito grande, eles empregaram duas técnicas para redução do espaço de busca do problema: redução por inviabilidade e por custo.

Latorre-Bayona et al. (1994) propuseram uma metodologia heurística que utilizava a vantagem da decomposição natural do problema em subproblemas de operação e investimento. O subproblema de investimento era resolvido utilizando-se um procedimento heurístico de busca em árvore iniciada a partir de uma solução viável obtida por outros modelos. As variáveis de

investimento (ramos da árvore de busca) poderiam ser classificadas de três maneiras: as variáveis questionáveis (circuitos incluídos na solução viável inicial, mas que o usuário pensa não pertencer ao plano ótimo), as variáveis atrativas (circuitos que o usuário pensa pertencer ao planejamento ótimo) e as variáveis congeladas (circuitos que não eram testados no processo de busca). Esta classificação das variáveis já consistia de um critério de truncamento utilizado por este trabalho com o objetivo de redução do tempo computacional. Os outros critérios utilizados eram limites na profundidade e na largura do processo de busca na árvore, limite no número de resoluções do subproblema de operação e limite no número de “passos errados” do processo de busca na árvore.

Já Binato et al. (1995) propuseram um método de busca, *backward/forward* para o problema de planejamento de expansão de redes de transmissão multiestágio. Neste método eram definidos passos para uma análise de planejamento a dois estágios: o passo *backward*, que consistia de um planejamento retornando no tempo, buscando antecipações de circuitos já definidos para os anos seguintes e o passo *forward*, que fazia uma análise no sentido correto do tempo. Utilizando-se de uma maneira organizada estes dois passos, o método explora a região de viabilidade do problema na busca de economias de escala quando são considerados vários estágios durante o horizonte de planejamento.

Ao contrário de Romero (1993), também Oliveira et al. (1995) utilizaram um esquema de decomposição hierárquica, mas composto por duas fases ao invés de três. A primeira fase, da mesma forma que no trabalho de Romero, considerava somente o modelo de transporte, porém não relaxava a integralidade das variáveis de investimento, enquanto que a segunda fase era igual à terceira do trabalho de Romero. A maior diferença entre estes dois trabalhos não vem da decomposição hierárquica utilizada e sim da maneira como o subproblema de investimento era resolvido. Enquanto que no trabalho de Romero (1993) resolvia-se o subproblema de investimento até obter a solução ótima utilizando um algoritmo de enumeração implícita especializado, no trabalho de Oliveira et al. (1995) utilizava-se um algoritmo de *branch and bound* com o objetivo de achar somente a primeira solução viável. Com isso, era possível obter considerável redução do demanda computacional.

Binato (2000), em seu trabalho, propôs uma aplicação computacional utilizando decomposição de *Benders* que assegurava que a solução ótima, obtida pelo método de decomposição, era o plano ótimo de expansão da rede de transmissão. Isso estava diretamente relacionado com a utilização do modelo linear (0-1) disjuntivo que pôde ser aplicado a problemas testes com sistemas reais devido à obtenção de valores mínimos para a constante disjuntiva. Uma nova heurística para determinar a convergência do problema mestre da decomposição de *Benders* resultou também em grandes economias em termos de tempo computacional gasto. Entretanto, muitas vezes, o número elevado de candidatos de um caso de planejamento da expansão impediu a aplicação com sucesso de técnicas de decomposição. Portanto, é necessário o desenvolvimento de técnicas heurísticas que sejam capazes de fornecer 'boas' soluções para o problema.

Entre os anos de 1990 e 2000 apareceram novos algoritmos heurísticos e metaheurísticos, diferentes dos algoritmos tradicionais, geralmente mais eficientes e com uma grande variedade de tempo de processamento que pode ser calibrado para cada tipo de aplicação. Pertence a esse tipo de algoritmos técnicas de otimização como algoritmos genéticos e evolutivos em geral, *tabu search*, *GRASP*, *particle swarm*, *ant colony*, etc.

Metaheurísticas proporcionam a grande vantagem de que a forma de resolver um problema varia muito pouco quando se muda a modelagem matemática do problema. Assim, por exemplo, em planejamento de sistemas de transmissão, a forma usada para resolver os modelos de transporte, híbridos e o modelo DC é praticamente a mesma. Em cada caso, deve-se resolver apenas um PL sob diferentes formas. Por esse motivo, todas as aplicações de metaheurísticas em planejamento de sistemas de transmissão foram aplicadas diretamente no modelo DC. As principais aplicações de metaheurísticas no problema de planejamento são apresentadas por Romero et al. (1996), Gallego et al. (1997, 1998a, 1998b) e Silva et al. (2000 e 2001).

O *Simulated Annealing* foi aplicado por Romero et al. (1996) e posteriormente foi paralelizado por Gallego et al. (1997). A qualidade dos resultados publicados nestes dois artigos mostraram que tais métodos têm um excelente potencial para a solução deste problema.

Pesquisas apresentadas, utilizando metaheurísticas, indicam que, no momento, esses tipos de algoritmos são os mais competitivos para obter soluções de excelente qualidade de sistemas complexos. As metaheurísticas apresentam a vantagem de que são relativamente fáceis de implementar e, geralmente, apresentam excelente desempenho para todos os tipos de sistemas elétricos. Apresentam a grande desvantagem de que geralmente requerem tempos de processamento elevados para encontrar soluções de excelente qualidade. No entanto, deve-se observar que o tempo de processamento não é um problema crucial em planejamento de sistemas de transmissão. Nos próximos anos deve continuar muito ativa a pesquisa em metaheurísticas aplicadas ao problema de planejamento de sistemas de transmissão.

Quase todas as propostas de metaheurísticas apresentadas na literatura especializadas foram aplicadas ao planejamento estático. Escobar et al. (2004) apresentaram a primeira metaheurística aplicada ao planejamento multiestágio de sistemas de transmissão.

Posteriormente, outras metaheurísticas também foram propostas. GRASP (*Greedy Randomized Adaptive Search Procedure*) foi utilizado em (BINATO et al., 2001). As melhores soluções já conhecidas para dois sistemas testes brasileiros reais utilizados no estudo foram obtidas pela metaheurística, assim como melhoramentos na solução do caso do planejamento da expansão do sistema sudeste brasileiro, revelando o potencial do método.

Os Algoritmos de Busca Tabu (*Tabu Search*) foram utilizados nos trabalhos de Gallego et al. (1998) e Areiza Ortiz (1997). Dois Algoritmos Genéticos foram propostos para resolver problemas de planejamento: *Extended Genetic Algorithms* por Gallego et al. (1998b) e *Improved Genetic Algorithms* por Silva et al. (2000). Silva et al. (2001) utilizaram Busca Tabu para resolver o problema de planejamento estático de redes de transmissão. Foram utilizados vários conceitos da Busca Tabu como memória de curto-prazo, lista tabu e critério de aspiração. Uma fase de intensificação, que explorava regiões do espaço de busca onde boas soluções deviam existir, foi implementada juntamente com uma fase de diversificação, que direcionava a busca para regiões não exploradas, utilizando-se conceitos de memória de médio e longo prazo.

Faria et al. (2005) desenvolveram uma metodologia híbrida combinando GRASP com *Path Relinking*. *Path Relinking* é uma técnica que surgiu como uma estratégia de intensificação para melhorar a qualidade da solução de outras metaheurísticas. Nos poucos trabalhos em que foi utilizado, obteve grande êxito. Neste trabalho foi aprimorada a qualidade da busca por novas soluções, ajudando a obter a solução ótima dos problemas propostos com um número menor de iterações.

O modelo de planejamento estático foi o único utilizado em praticamente todas as pesquisas apresentadas em planejamento da expansão de sistemas de transmissão. Existe pouca bibliografia de modelagem e otimização de modelos matemáticos de planejamento multiestágio. Assim, por exemplo, Haffner et al. (2000) apresenta uma discussão interessante de modelagem deste problema e Romero et al. (2003) apresenta um algoritmo heurístico construtivo para o planejamento multiestágio utilizando o modelo de transportes.

Os algoritmos heurísticos encontram, todos eles, apenas soluções de boa qualidade para sistemas de médio e grande porte, e a qualidade dessas soluções pode ficar muito distante das soluções ótimas ou sub ótimas como acontece, por exemplo, com o sistema norte-nordeste brasileiro. A vantagem dos algoritmos heurísticos é que são simples de entender, robustos e muito rápidos. No momento, os algoritmos heurísticos ainda representam um campo de pesquisa muito interessante e as soluções encontradas por esses algoritmos podem ser utilizadas como base para encontrar soluções melhores utilizando algoritmos mais demorados como as metaheurísticas.

Há ainda uma extensa bibliografia tratando de outros aspectos do problema de planejamento da expansão de sistemas de transmissão tais como o planejamento da expansão considerando contingências, o planejamento da expansão considerando incertezas na demanda, o planejamento da expansão considerando um ambiente de mercado competitivo, entre outros. Para ver detalhes de trabalhos desse tipo ver os trabalhos de Fang et al. (2003), Garcés et al. (2009) e Silva et al. (2005).

2 Introdução a Metaheurísticas Aplicadas a Sistemas Elétricos de Potência

2.1 Introdução sobre as Heurísticas

As heurísticas são técnicas de otimização que geralmente encontram soluções de boa qualidade de problemas complexos. Deve-se observar que entre as décadas de 1960 e 1970, as heurísticas foram as técnicas de otimização mais usadas e com maior sucesso para resolver problemas complexos do campo da otimização matemática, especialmente para aqueles problemas não lineares, discretos e não convexos.

A maioria das heurísticas encontra soluções de boa qualidade de problemas altamente complexos em tempos computacionais relativamente rápidos. Adicionalmente, a maioria das heurísticas são simples de entender e também de implementar computacionalmente. Entretanto, as técnicas heurísticas renunciam, pelo menos do ponto de vista teórico, a encontrar a solução ótima global de um problema complexo. Em problemas de grande porte e complexos, as técnicas heurísticas raramente encontram as soluções ótimas. Neste trabalho consideramos um problema como sendo complexo quando existe grande dificuldade para encontrar a solução ótima global devido, principalmente, a característica da explosão combinatória, quando o tamanho do problema cresce e/ou porque o problema apresenta uma modelagem matemática complexa (variáveis inteiras ou discretas, função objetivo não linear e não diferenciável, restrições não lineares, região factível não convexa, etc.).

Uma técnica heurística pode ser muito simples como, por exemplo, o uso de bom senso ou a experiência de um especialista ou pode ser muito sofisticada, geralmente, envolvendo a solução de modelos matemáticos relaxados em relação ao modelo original.

É interessante usar técnicas heurísticas de otimização nos seguintes casos:

1. Quando não existe um método exato de otimização para resolver o problema em análise.

2. Quando 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 próxima da solução ótima global.
3. Quando os dados usados apresentam incerteza elevada como acontece em muitos problemas relacionados com planejamento.
4. Quando existem limitações de tempo de processamento para encontrar a solução procurada e quando existem problemas de memória para armazenamento de dados. Problemas desse tipo podem aparecer em problemas de aplicação em tempo real.
5. Quando se pretende encontrar uma boa solução inicial para ser usada como ponto de partida na aplicação de uma técnica de otimização mais sofisticada como, por exemplo, quando se pretende usar um algoritmo *branch and bound*.

Não é uma tarefa simples classificar as técnicas heurísticas de otimização. Uma proposta de classificar as técnicas heurísticas é a seguinte : algoritmos heurísticos construtivos, algoritmos de decomposição, algoritmos de divisão, algoritmos de redução, algoritmos de manipulação do modelo matemático e algoritmos de busca através de vizinhança (steepest descent heuristic). Neste trabalho não se pretende realizar uma apresentação detalhada dos diferentes tipos de algoritmos ou técnicas heurísticas de otimização. Assim, é apresentado de forma mais detalhada apenas dois desses algoritmos ou técnicas heurísticas de otimização e que são muito importantes no desenvolvimento das propostas de otimização desenvolvidos neste trabalho, assim como na compreensão das metaheurísticas. Essas heurísticas são as seguintes: (1) o algoritmo heurístico construtivo e, (2) o algoritmo heurístico de busca através de vizinhança.

2.1.1 O Algoritmo Heurístico Construtivo

O algoritmo heurístico construtivo (AHC) é uma das técnicas heurísticas de otimização mais usadas para resolver problemas complexos e ainda é muito usado isoladamente ou integrado a metaheurísticas mais sofisticadas. O mais

popular dos algoritmos heurísticos construtivos é o tipo guloso (greedy). O AHC do tipo guloso é o único tipo de AHC que é analisado neste trabalho e chamaremos a esse algoritmo simplesmente de AHC.

O AHC é uma técnica de otimização que, em um processo passo a passo, gera uma solução geralmente de boa qualidade de um problema complexo. Em cada passo o AHC escolhe-se um elemento ou componente da solução que está sendo construída e no último passo termina de gerar uma solução factível. O elemento ou componente da solução que é escolhido em cada passo do AHC é identificado usando-se um indicador de sensibilidade que identifica o componente mais interessante a ser incorporado na solução em construção. Assim, a diferença fundamental entre os AHCs usados para resolver um mesmo problema está no indicador de sensibilidade usado.

Um AHC pode assumir a seguinte forma genérica:

1. Armazenar os dados do problema e escolher o indicador de sensibilidade a ser usado. Escolher os componentes que podem ser incorporados na solução em construção (geralmente o processo é iniciado sem componentes).
2. Verificar se a solução em construção já representa uma solução factível. Caso seja factível então pare o processo porque foi encontrada a solução factível procurada. Em caso contrário ir ao passo 3.
3. Usando a solução em construção, resolver o problema que permite identificar o indicador de sensibilidade de todos os componentes do problema que ainda não foram incorporadas na solução em construção.
4. Usando a informação dos indicadores de sensibilidade encontrados no passo anterior identificar o componente que deve ser incorporado na solução em construção. Adicionar o componente identificado na solução em construção e voltar ao passo 2.

Em resumo, os algoritmos heurísticos construtivos do tipo guloso apresentam as seguintes características:

- É um processo iterativo onde em cada passo escolhe-se uma componente da solução em construção. O indicador de sensibilidade pode ser muito simples ou muito sofisticado.

- Apenas no último passo se encontra uma solução factível. Antes disso não existe nada útil disponível em relação com o problema a ser resolvido. Esta característica nos lembra o algoritmo dual simplex em PL onde apenas na última iteração encontramos um ponto extremo que é adicionalmente ótimo e antes disso existe apenas uma sequência de pontos infactíveis.

2.1.2 O Algoritmo Heurístico de Busca Através de Vizinhança

O algoritmo heurístico de busca através de vizinhança (steepest descend heuristic) é significativamente diferente do algoritmo heurístico construtivo do tipo guloso. No AHC se gera apenas uma solução factível através de uma sequência de passos e usando um indicador de sensibilidade. No algoritmo heurístico de busca através de vizinhança, que será chamado neste trabalho apenas como algoritmo SDH (do inglês Steepest Descent Heuristic para o problema de minimização), o processo é geralmente iniciado a partir de uma solução factível e na sequência são encontradas novas soluções factíveis percorrendo o espaço de busca passando sempre para a melhor solução vizinha.

Assim, a forma genérica da heurística SDH assume a seguinte forma:

1. Passo preliminar: Montar dados do problema. Escolher uma forma de codificação de uma proposta de solução denominada de p . Identificar uma forma de avaliar a qualidade da função objetivo ou equivalente e denominada $f(p)$. Definir a estrutura de vizinhança a ser usada o que caracteriza o espaço de busca.
2. Encontrar uma solução inicial p_0 que se transforma na solução corrente p_c .
3. Identificar e avaliar todas as soluções vizinhas da solução corrente p_c e identificar a melhor solução vizinha p^{best} .

4. Se $f(p^{best}) < f(p)$ então a melhor solução vizinha é melhor que a solução corrente e, portanto, fazer $p_c = p^{best}$ e voltar ao passo 3. Em caso contrário pare o processo e a solução encontrada pela heurística SDH é p_c (geralmente em ótimo local).

Em relação com a heurística SDH, deve-se realizar as seguintes observações:

- O passo 1 é muito mais importante do que normalmente é considerado por muitos pesquisadores. Uma codificação eficiente é crucial, assim como a caracterização da estrutura de vizinhança. Neste passo também deve ser decidido como devem ser tratadas as propostas de solução vizinhas que são infactíveis. Assim, é de responsabilidade do pesquisador escolher ou definir a codificação a ser usada, o tipo de vizinhança escolhido e a forma de tratar as soluções vizinhas infactíveis.

- No passo 2 a heurística SDH exige apenas uma solução inicial. Assim, essa solução inicial pode ser encontrada de forma trivial escolhendo, por exemplo, uma solução gerada de forma aleatória ou pode ser gerada de forma sofisticada usando, por exemplo, um AHC conhecido e eficiente para o tipo de problema em análise (um ótimo local). A solução inicial p_0 pode ser factível ou infactível. Caso seja infactível então devemos mudar a estratégia de qualidade para avaliar as soluções vizinhas (a mais popular consiste em penalizar a função objetivo das propostas de soluções infactíveis). No passo 2 é exigido apenas uma solução inicial.

- No passo 3, a heurística SDH exige avaliar a qualidade de todas as soluções vizinhas e identificar a melhor solução vizinha. Esse passo pode exigir muito tempo de processamento, especialmente em determinados problemas em que avaliar a qualidade de uma solução vizinha pode exigir resolver um problema relativamente complexo como, por exemplo, um problema de programação linear ou não linear.

- No passo 4 a heurística SDH termina o processo se a melhor solução vizinha for de pior qualidade que a solução corrente. Assim, se a vizinhança for definida de forma inadequada então a heurística SDH pode terminar encontrando uma solução ótima local de pobre qualidade. Também, devemos observar que quando a heurística SDH converge então a solução corrente é também incumbente. Essa característica não acontece na maioria das metaheurísticas, exceto na metaheurística de busca de vizinhança variável (VNS, do inglês Variable Neighborhood Search).

O algoritmo heurístico construtivo e a heurística SDH foram analisados com certos detalhes porque a estrutura básica da maioria das metaheurísticas pode ser interpretada apenas como uma generalização de um AHC, uma generalização da heurística SDH ou uma generalização conjunta do AHC e da heurística SDH.

Termina-se fazendo uma diferenciação clara entre o AHC de tipo guloso e a heurística SDH. Assim, deve-se observar os seguintes aspectos:

Um AHC gera apenas uma solução factível através de uma sequência de passos guiado por um indicador de sensibilidade e apenas no último passo é encontrada uma solução factível. Como mencionado anteriormente, essa estratégia é muito parecida com o algoritmo dual simplex em programação linear onde apenas na última iteração é encontrada uma solução factível e ótima. Nas iterações prévias existem disponíveis apenas propostas de soluções infactíveis.

Uma heurística SDH gera um conjunto de soluções factíveis a partir de uma solução inicial (geralmente factível), realizando 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. Essa estratégia é muito parecida com a estratégia fundamental do algoritmo primal simplex em programação linear.

Uma heurística SDH geralmente é muito mais complexa, sofisticada e muito mais demorada que um AHC. Portanto, é esperado que a heurística SDH encontre soluções de melhor qualidade que o AHC na tentativa de resolver um problema complexo. Assim, quando é analisado publicações especializadas e é verificado que um AHC é superior a uma heurística SDH em termos de

qualidade de solução final encontrada na resolução do mesmo problema complexo, então este é considerado um caso anormal ou atípico e deveria ser analisado em detalhe os motivos desse comportamento.

2.2 Introdução sobre as Metaheurísticas

A definição de uma metaheurística apresentada por Fred Glover em 1986 é a seguinte : Metaheurísticas são técnicas de solução que gerenciam uma interação entre as estratégias de busca local e as estratégias de nível superior para criar um processo de otimização com capacidade de sair de soluções ótimas locais e realizar uma busca robusta através de espaço de busca. Alternativamente, podemos definir uma metaheurística como sendo um processo de otimização representado por uma generalização e/ou integração do algoritmo heurístico construtivo de tipo guloso e a heurística de busca através de vizinhança de forma que seja possível encontrar soluções de qualidade percorrendo de forma eficiente o espaço de busca. Em outras, palavras, uma metaheurística pode ser interpretada como uma generalização e/ou integração do AHC e da heurística SDH.

2.2.1 Simulated Annealing

Simulated Annealing (SA) é uma das primeiras metaheurísticas que foi usada com muito sucesso na otimização de problemas complexos na pesquisa operacional. S.A foi proposta após ser verificado que existiam muitas semelhanças entre a técnica de construção de cristais perfeitos usando a técnica de annealing e a otimização de um problema complexo no campo da pesquisa operacional.

Existem muitas técnicas usadas na construção de cristais perfeitos e uma delas é a técnica de annealing. A técnica de annealing consiste em esquentar um material até temperaturas elevadas na qual existe muita movimentação molecular do material esquentado e, portanto, um novo arranjo dos átomos do material. A partir desse estado, se o material for esfriado lentamente então a movimentação molecular também diminui. Se esse processo de diminuição for adequadamente controlado,

preservando o chamado quase equilíbrio termodinâmico no qual a temperatura deve ser diminuída lentamente, então existe grande possibilidade de que o material se transforme em um cristal perfeito. Se esse processo não é realizado de forma adequada então esse material pode ser transformado em um cristal imperfeito, isto é, em um vidro.

Resumindo, usando o paralelismo ou semelhanças que existem entre a técnica de annealing na construção de cristais perfeitos e na otimização de problemas complexos no campo da pesquisa operacional, foi desenvolvido o algoritmo de Simulated Annealing que na formulação básica assume a seguinte forma (problema de minimização):

1. Passo preliminar: Montar os dados do problema. Escolher uma forma de codificação de uma proposta de solução denominada de p . Identificar uma forma de avaliar a qualidade da função objetivo ou equivalente e denominada $f(p)$. Definir a estrutura de vizinhança a ser usada o que caracteriza o espaço de busca. Escolher os parâmetros de SA tais como o parâmetro chamado de temperatura inicial T_o , a temperatura final T_f ou um critério de parada, o número de tentativas de transição no primeiro nível de temperatura N_o , o parâmetro ρ que controla o número de tentativas de transição em cada nível de temperatura e o parâmetro β que controla a diminuição do parâmetro temperatura.

2. Encontrar uma solução inicial p_o que se transforma na solução corrente p_c e fazer $N_k = N_o, s = 0$.

3. Identificar e avaliar uma solução vizinha p_v escolhida aleatoriamente.

4. Se $f(p_v) < f(p_c)$ então a solução vizinha é melhor que a solução corrente e, deve-se realizar a transição, isto é, $p_c \leftarrow p_v$ e ir ao passo 5. Em caso contrário gere um número aleatório entre 0 e 1, $P(0, 1) = \text{random}[0, 1]$, e seja

$\Delta f(p) = f(p_v) - f(p_c)$. Assim, se $\exp\left[\frac{-\Delta f(p)}{T_k}\right] > P(0,1)$ então, deve-se realizar a

transição e $p_c = p_v$ e, em caso contrário, a solução corrente é preservada. Ir ao passo 5.

5. $s = s + 1$. Se $s < N_k$ então ir ao passo 3. Em caso contrário ir ao passo 6.

6. Se o critério de parada foi cumprido então pare. Em caso contrário, fazer $T_{k+1} = \beta T_k$ e $N_{k+1} = \rho N_k$. $k = k + 1$. Voltar ao passo 3.

Deve-se observar também que a técnica de annealing é uma técnica mais geral e não é usada apenas para a construção de cristais perfeitos. Essa técnica também é usada, por exemplo, na construção de condutores elétricos para tornar o condutor mais uniforme e maleável.

2.2.2 Tabu Search - Busca Tabu

Tabu Search (TS) é uma metaheurística inventada por Fred Glover na década de 80. Ao contrário da maioria das metaheurísticas que usaram comportamentos ou características existentes em ramos do conhecimento distantes da otimização matemática, Glover usou apenas conhecimento existente no campo da otimização matemática. Antes de inventar o TS, Glover já era um pesquisador destacado em otimização clássica, especialmente nas técnicas de otimização de problemas de programação inteira.

A ideia central de Glover foi mostrar que é possível propor uma estratégia de busca inteligente percorrendo o espaço de busca de forma eficiente e seletiva. Nesse processo é fundamental integrar o processo de busca e as estratégias de intensificação e de diversificação. Nesse contexto, intensificar significa realizar uma busca mais intensa em torno da solução corrente, por exemplo, aumentando-se o tamanho da vizinhança ou melhorando a qualidade da vizinhança. Por outro lado, diversificar significa sair de uma região do espaço de busca e, de forma proposital, atingir uma região distante para novamente realizar algum processo de intensificação.

A formulação básica de TS que está inspirada fundamentalmente no uso da estratégia de intensificação assume a seguinte forma:

1. Passo preliminar: Montar os dados do problema. Escolher uma forma de codificação de uma proposta de solução denominada de p . Identificar uma forma de avaliar a qualidade da função objetivo ou equivalente e denominada $f(p)$. Definir a estrutura de vizinhança a ser usado o que caracteriza o espaço de busca. Identificar os atributos que devem ser proibidos e o critério de aspiração. Escolher os parâmetros do algoritmo tais como a dimensão da lista tabu. Escolher o critério de parada.
2. Encontrar uma solução inicial p_0 que se transforma na solução corrente p_c .
3. Identificar e avaliar todas as soluções vizinhas da solução corrente p_c , ordenar essas soluções vizinhas por qualidade sendo que o primeiro da lista é a melhor solução vizinha p^{best} .
4. Realizar a transição para a solução vizinha melhor classificada que não tem o atributo proibido ou se tem o atributo proibido, então satisfaça o critério de aspiração. Seja p_e a melhor solução vizinha escolhida, então fazer $p_c = p_e$.
5. Atualizar a incumbente e a lista de atributos proibidos. Se o critério de parada for satisfeito então pare. Em caso contrário voltar ao passo 3.

O algoritmo TS anteriormente apresentado é chamado de algoritmo TS básico que fundamentalmente usa memória de curto prazo, uma lista de atributos proibidos e um critério de aspiração, isto é, é uma estratégia de otimização que prioriza a intensificação.

Técnicas de otimização tipo TS mais complexas podem ser implementadas onde o TS básico funciona como um módulo de otimização integrado em uma estrutura TS mais complexa. Essas estruturas mais complexas podem ser idealizadas usando outros operadores existentes em TS tais como a diversificação, a memória baseada em frequência, a lista de soluções de elite, o *path relinking*, entre outros.

2.2.3 O Algoritmo Genético

O algoritmo genético (AG) é uma metaheurística proposta por Holland na década de 70 sendo que apenas na década de 80 teve sua aplicação de forma intensa para resolver problemas complexos no campo da pesquisa operacional. Para inventar o AG, Holland encontrou semelhanças entre a forma de resolver um problema de otimização matemática e o processo de seleção natural e evolução das espécies. Na verdade, na natureza o processo de seleção natural e a evolução das espécies é a consequência de um processo de otimização estocástico que acontece em um determinado ambiente e em tempo real.

O processo de seleção natural e a evolução das espécies é um problema muito complexo para que seja imitado de forma adequada por um processo de otimização de um problema complexo do campo da pesquisa operacional. Assim, pode-se afirmar que o AG imita apenas uma parcela dos componentes que fazem parte do processo de seleção natural e de evolução das espécies.

Um algoritmo genético básico assume a seguinte forma:

1. Passo preliminar: Montar os dados do problema. Escolher uma forma de codificação de uma proposta de solução denominada de p . Identificar uma forma de avaliar a qualidade da função objetivo ou equivalente e denominada $f(p)$. Escolher os parâmetros do algoritmo tais como o tamanho da população n_p , a taxa de recombinação p_r , a taxa de mutação p_m e o tipo de seleção. Escolher um critério de parada.
2. Gerar a população inicial, isto é, gerar um conjunto de n_p propostas de solução que se transforma na população corrente.
3. Avaliar a qualidade $f(p)$ de todos os elementos da população e atualizar a incumbente, se possível.
4. Se o critério de parada for satisfeito, pare. Em caso contrário, ir ao passo 5.

5. Implementar o operador de seleção.
6. Implementar o operador de recombinação.
7. Implementar o operador de mutação, atualizar a população corrente e voltar ao passo 3.

Os primeiros algoritmos genéticos usavam a codificação binária. Entretanto, os algoritmos genéticos modernos seguem a proposta de Michalewicz que em 1994 sugeriu que a codificação deve ser realizada seguindo a natureza e as características do problema. Assim, por exemplo, no problema da mochila, a codificação pode ser a binária, no problema do caixeiro viajante a codificação mais popular é um vetor que mostra a sequência em que as cidades são visitadas. Geralmente, em problemas que apresentam uma modelagem matemática e a proposta consiste em usar essa modelagem matemática e codificar as variáveis de decisão desse modelo, então a proposta mais popular consiste em codificar as variáveis binárias de forma binária, as variáveis inteiras e discretas usando a codificação inteira e as variáveis contínuas usando uma codificação real. Entretanto, em problemas altamente restritos, geralmente se codifica apenas as variáveis binárias e inteiras, sendo que o valor exato das variáveis contínuas são encontradas de forma exata resolvendo-se um subproblema auxiliar (problema de programação linear, problema de programação não linear, sistema de equações algébricas lineares ou sistema de equações algébricas não lineares). Esse é o caso da maioria dos problemas de otimização relacionados com o planejamento e a operação de sistemas de energia elétrica.

Deve-se observar que o algoritmo genético básico (AGB) pode ser reformulado usando-se apenas os conceitos existentes na pesquisa operacional e sem a necessidade de procurar conceitos existentes na seleção natural e na evolução das espécies. Na verdade, o AGB pode ser interpretado como uma generalização da heurística SDH. Assim, uma generalização da heurística SDH usando a lógica do AGB seria a seguinte:

1. Passo preliminar: Montar os dados do problema. Escolher uma forma de codificação de uma proposta de solução denominada de p . Identificar uma forma de avaliar a qualidade da função objetivo ou equivalente e denominada $f(p)$. Definir a estrutura de vizinhança dinâmica definida pelos operadores de seleção, recombinação, mutação e os respectivos parâmetros.
2. Encontrar um conjunto n_p de soluções iniciais que se transformam no conjunto de soluções corrente (população corrente).
3. Avaliar a qualidade de todas as soluções existentes na população corrente, isto é, encontrar os valores de $f_i(p)$. Atualizar a incumbente, se possível.
4. Se for satisfeito um critério de parada então pare. Em caso contrário ir ao passo 5.
5. A partir do conjunto de soluções corrente gerar um novo conjunto de n_p^n propostas de solução usando as estratégias de seleção, recombinação e mutação. O novo conjunto de soluções passa a ser o conjunto de soluções corrente e voltar ao passo 3.

No algoritmo apresentado anteriormente, a estratégia de seleção pode ser a seleção usando torneio. A estratégia de recombinação é simplesmente a mistura da informação codificada em duas soluções previamente selecionadas para gerar duas novas soluções candidatas, isto é, a partir de duas soluções de boa qualidade (selecionadas) e que se encontram estrategicamente localizadas no espaço de busca (região em que podem existir outras soluções melhores) devem ser geradas outras duas soluções que devem estar localizadas na região do espaço de busca entre as duas soluções geradoras e, portanto, existindo assim uma grande probabilidade de que essas soluções novas sejam melhores de que as soluções geradoras. A estratégia de mutação seria apenas uma pequena perturbação na solução encontrada após a recombinação, isto é, uma

solução vizinha dessa solução no espaço de busca. Em outras palavras, a partir de n_p propostas de solução, gerar n_p novas propostas de solução priorizando-se as melhores soluções e descartando-se as piores, dentro de uma lógica estocástica e, portanto, encontrando-se soluções novas na vizinhança dessas soluções melhores no espaço de busca e, finalmente, incorporar um elemento de perturbação adicional chamado de mutação que consiste em escolher, de forma estocástica, uma solução vizinha.

2.3 Aplicação das Metaheurísticas na Otimização de Sistemas Elétricos de Potência

2.3.1 O Problema de Planejamento da Expansão de Sistemas de Transmissão

O problema de planejamento da expansão (PPEX) em longo prazo de sistemas de transmissão de energia elétrica é um problema muito complexo para ser resolvido por técnicas tradicionais de otimização porque apresenta muitos ótimos locais. Assim foi analisado o caso mais simples, o problema de planejamento estático.

A modelagem mais usada no planejamento estático da expansão de sistemas de transmissão é o modelo DC que assume a seguinte forma:

$$\begin{aligned}
 \min v &= \sum_{ij} c_{ij} n_{ij} + \alpha \sum_i r_i \\
 S f + g + r &= d \\
 f_{ij} - \gamma_{ij} (n_{ij}^o + n_{ij}) (\theta_i - \theta_j) &= 0 \\
 |f_{ij}| &\leq (n_{ij}^o + n_{ij}) \overline{f_{ij}} \\
 0 \leq g &\leq \overline{g} \\
 0 \leq r &\leq d \\
 0 \leq n_{ij} &\leq \overline{n_{ij}} \\
 f_{ij} \text{ e } \theta_j &\text{ irrestritos}
 \end{aligned}$$

onde v é o custo total de expansão do sistema elétrico, c_{ij} é o custo de expansão de uma linha no caminho $i - j$, n_{ij} é o número de linhas que podem ser adicionadas no caminho $i - j$ e representa a principal variável de decisão do problema de otimização, n_{ij} é o número máximo de linhas que podem ser adicionadas no caminho $i - j$, S é a matriz de incidência nó-ramo transposta do sistema elétrico, f_{ij} é o fluxo de potência total que passa pelas linhas no caminho $i - j$, $\overline{f_{ij}}$ é o fluxo de potência máximo que pode passar por uma linha no caminho $i - j$, θ_j é o ângulo de tensão na barra j , γ_{ij} é a susceptância de uma linha no caminho $i - j$, d é o vetor de demanda nas barras de demanda, g é o vetor de geração nas barras de geração, r é o vetor de geradores artificiais nas barras de demanda, sendo que r_i é a geração artificial na barra i . Assim, as variáveis r_i foram adicionadas no modelo de otimização apenas para facilitar o processo de resolução do problema PPEX quando usamos heurísticas e metaheurísticas.

O primeiro conjunto de restrições representa a lei de Kirchhoff das correntes e o segundo conjunto representa a lei de Kirchhoff das tensões. As outras restrições representam as restrições operacionais dos equipamentos de geração e de transmissão. Do ponto de vista de otimização matemática o problema PPEX mostrado anteriormente é um problema de programação não linear inteiro misto. Assim, neste trabalho é analisada a forma de resolver o problema PPEX quando são usadas as metaheurísticas.

O problema PPEX mostrado anteriormente corresponde ao tipo de problema em que não pode ser dispensada a modelagem matemática quando são utilizadas metaheurísticas. Esse tipo de comportamento acontece com a maioria de problemas de otimização relacionadas com a operação e o planejamento de sistemas de energia elétrica. Portanto, todas as metaheurísticas apresentadas na literatura especializada para resolver o problema PPEX codificam apenas as linhas de transmissão que correspondem a uma proposta de solução. Em outras palavras, escolhe-se os valores das variáveis n_{ij} no modelo matemático usando-se a lógica de


cada metaheurística. Após essa decisão, os valores das variáveis de operação (f_{ij}, θ_j, g_k) são encontradas de forma exata resolvendo-se um problema de programação linear (PL). A solução desse PL fornece também a informação da proposta de solução em termos de factibilidade. Para ilustrar a implementação de uma metaheurística utilizou-se os dados do sistema de 6 barras e 15 caminhos de Garver. Na Tabela 1 são apresentados os dados das linhas de transmissão e na Figura 1 é ilustrado a topologia base.

Tabela 1. Dados do sistema de 6 barras da topologia base

Circ.	Barra	Barra	n_{ij}^0	Circ.	Barra	Barra	n_{ij}^0
1	1	2	1	9	2	6	0
2	1	3	0	10	3	4	0
3	1	4	1	11	3	5	1
4	1	5	1	12	3	6	0
5	1	6	0	13	4	5	0
6	2	3	1	14	4	6	0
7	2	4	1	15	5	6	0
8	2	5	0				

Fonte: Elaboração da própria autora.

Figura 1. Topologia base



Fonte: Elaboração da própria autora.


Neste trabalho apresentou-se de forma resumida os tópicos relacionados com a implementação de uma metaheurística para resolver o problema PPEX. Assim, foi analisado a forma de codificação, a forma de encontrar o valor da função objetivo, a forma de encontrar as variáveis operacionais, a forma de verificar a factibilidade ou infactibilidade de uma proposta de solução e a forma de especificar as estruturas de vizinhança.

A codificação ou representação de uma proposta de solução do problema PPEX é realizado apenas escolhendo-se o valor das variáveis inteiras n_{ij} . Os valores dos n_{ij} , como foi mencionado anteriormente, são escolhidos usando-se a lógica de cada metaheurística. Assim, as primeiras soluções podem ser geradas de forma aleatória ou usando AHC's.

Posteriormente, novas propostas de solução são geradas usando os operadores das metaheurísticas (por exemplo, usando a seleção, recombinação e mutação no algoritmo genético e escolhendo-se uma solução vizinha, no caso de tabu search ou simulated annealing).

Supondo-se que foi gerada a proposta de solução mostrada na Figura 2 em que foram adicionadas duas linhas de transmissão no caminho 2 - 6 e outras duas linhas de transmissão no caminho 4 - 6.

Figura 2. Proposta de solução



Fonte: Elaboração da própria autora.

Para essa proposta de solução, a codificação assume a forma que pode ser observada na Figura 3 abaixo:

Figura 3. Codificação de uma proposta de solução

	barra															
	1-3	1-3	1-4	...				2-6						4-6	5-6	
$p_1 =$	0	0	0	0	0	0	0	2	0	0	0	0	0	2	0	

Fonte: a própria autora.

Para cada proposta de solução, como a mostrada na Figura 3, pode-se encontrar o valor da função objetivo (a qualidade da solução) e verificar a operação do sistema (se o sistema opera de forma adequada). O valor da função objetivo pode ser encontrada de forma trivial usando a seguinte relação:

$$v_1 = \sum_{ij} c_{ij} n_{ij}$$


onde v_1 representa o custo da expansão. Para a proposta da Figura 2, o custo da expansão é $v_1=120$ unidades monetárias.

Para verificação da qualidade da operação devemos resolver o problema de PL que aparece na modelagem matemática após fixar os valores das variáveis n_{ij} . Esse problema de PL, para uma proposta de solução n_{ij}^k conhecida, assume a seguinte forma:

$$\begin{aligned} \min w &= \sum_i r_i \\ S \quad f + g + r &= d \\ f_{ij} - \gamma_{ij}(n_{ij}^o + n_{ij}^k)(\theta_i - \theta_j) &= 0 \\ |f_{ij}| &\leq (n_{ij}^o + n_{ij}^k) \overline{f_{ij}} \\ 0 &\leq g \leq \overline{g} \\ 0 &\leq r \leq d \\ f_{ij} \text{ e } \theta_j &\text{ irrestritos} \end{aligned}$$

onde w representa o corte de carga relacionado com a proposta de solução. Obviamente, a proposta de solução relacionada com os n_{ij} devem estar dentro dos limites. Se $w = 0$ significa que a proposta de solução gerada pela metaheurística é factível. Por outro lado, se $w \neq 0$ então a proposta de solução é infactível e o valor de w representa o nível de infactibilidade da proposta de solução. A resolução do PL também permite encontrar os valores das variáveis de operação (f_{ij}, θ_j, g_k) . Para a proposta de solução mostrada na Figura 2, a resolução do PL mostra um valor de $w=158,2\text{MW}$ indicando que a proposta de expansão é infactível. Os valores das variáveis de operação são mostrados na Figura 2. A solução ótima do sistema de Garver é mostrada na Figura 4.

Figura 4. Topologia ótima



Fonte: Elaboração da própria autora.

Finalmente, a maioria das metaheurísticas usa a estrutura de vizinhança tradicional. Assim, para a codificação tradicional proposta, codificando-se somente as variáveis inteiras, pode-se definir várias formas

de vizinhança, isto é, várias formas de identificar soluções vizinhas da solução corrente. Para fins de ilustração, podem ser identificados vizinhos da configuração corrente, com todas as topologias obtidas da seguinte forma:

1. Adicionando-se um circuito na topologia corrente.
2. Trocando-se circuitos com a adição de um circuito e a retirada de outro circuito.
3. Retirando-se um circuito da topologia corrente.
4. Todas as propostas anteriores.

As propostas anteriores, muito parecidas às propostas de estrutura de vizinhança propostas para outros problemas combinatórios, geralmente são ineficientes para o PPEX porque identificam muitas propostas de solução vizinhas e geralmente a grande maioria delas são de baixa qualidade. Esse problema se torna mais crítico no caso do problema PPEX porque avaliar uma solução vizinha significa resolver um problema de PL. A estratégia mais eficiente é definir uma estrutura de vizinhança com troca de linhas de transmissão mas usando uma estratégia de redução de vizinhança que pode ser realizada conhecendo-se os fluxos nas linhas da solução corrente.

3 A Metaheurística de Busca Dispersa

3.1 Uma Revisão sobre a Busca Dispersa.

Scatter Search, ou em português, metaheurística Busca Dispersa (BD), foi introduzida em 1977 por Fred Glover, como uma heurística para programação inteira e foi baseada em estratégias apresentadas na *Management Science and Engineering Conference* em Austin, Texas, em Setembro de 1967 (LAGUNA et al., 2005). A BD opera em um conjunto de soluções, chamado conjunto de referência, combinando as soluções para gerar outras soluções novas, de modo que estas novas soluções sejam melhores que as soluções que as originaram. A combinação de estratégias foi criada com a crença de que melhores informações podem ser encontradas quando são tratadas de forma integrada, do que quando tratadas isoladamente. Em contraste com outros algoritmos evolutivos como os algoritmos genéticos, a BD é principalmente baseada em métodos sistemáticos com o propósito de criar novas soluções. A BD utiliza estratégias de intensificação e diversificação na busca. Sua estrutura é flexível, permitindo o desenvolvimento de implementações alternativas com vários graus de sofisticação.

Busca Dispersa é um método evolutivo que tem sido aplicado com sucesso na otimização de problemas. Os conceitos e princípios fundamentais do método foram propostos em 1970 sendo baseados em formulações, que remonta a 1960, para combinar regras de decisão e problemas de restrições. O método usa estratégia para diversificação e intensificação de busca que tem eficácia provada na variedade de problemas com restrições.

A Busca Dispersa (*Scatter Search* em inglês) é um método evolutivo (baseado em populações) que é muito efetivo na solução de diversos problemas de otimização discreta, por exemplo, na solução do problema de ordenação linear, ver Campos et al. (2001), na otimização global de funções multimodais, ver Laguna et al. (2000) e na solução de problemas de roteamento de veículos com janelas de tempo, ver Russel et al. (2006). Essa metaheurística combina soluções pertencentes a um conjunto denominado conjunto de referência (*RefSet*), com o intuito de capturar informação não

contida nas soluções originais. O *RefSet* guarda "boas" soluções encontradas durante o processo de busca. Cabe destacar que o significado de "boa" não se restringe apenas à qualidade da solução, mas também a sua diversidade em relação a outras soluções deste conjunto. A BD é composta basicamente por 5 etapas.

Em 1977 a metodologia da Busca Dispersa foi introduzida pela primeira vez como uma heurística para a programação inteira (GLOVER, 1977), com base em estratégias apresentadas em uma conferência de gestão realizada em Austin, Texas, em 1967. Dada a popularidade dos algoritmos chamados genéticos (AGs), também introduzida nos anos setenta e também com base na manutenção e evolução de um conjunto de soluções, vários trabalhos têm se dedicado a esclarecer suas diferentes origens, perspectivas e seus potenciais comuns.

Na proposta original de *Glover*, foi descrita a Busca Dispersa como um método que usa uma sucessão de inicializações coordenadas para gerar soluções. Ele introduziu estratégias de intensificação e diversificação na busca, assim a busca dispersa ocorre de forma sistemática com o propósito de criar novas soluções se opondo a outros algoritmos evolutivos (AG's, por exemplo).

Glover et al. (1995) descrevem a Busca Dispersa como um elo entre Busca Tabu e ideias de algoritmo genético. Eles exploram a natureza das conexões entre esses métodos e mostram uma variedade de oportunidades para a criação de abordagens híbridas. Em 1998 Glover publicou o modelo de Busca Dispersa (GLOVER, 1998). Este artigo apresenta uma descrição algorítmica do método e pode ser considerado um marco na literatura de Busca Dispersa, uma vez que muitas aplicações diferentes foram desenvolvidas depois. Em alguns aspectos esta versão é uma simplificação da anterior, mas incorpora muito da implementação e detalhes algorítmicos que despertou o interesse de pesquisadores e profissionais.

Esta versão do método gera um conjunto inicial de vetores de solução para garantir um nível crítico de diversidade e aplica processos heurísticos projetados para o problema considerado, como uma tentativa de melhorar essas soluções. Então, um subconjunto dos melhores soluções (em termos de qualidade e diversidade) é designado para serem soluções de referência. Novas soluções são criadas por meio de combinações estruturadas de

subconjuntos de soluções de referência atual e os processos heurísticos aplicados acima são utilizados novamente para melhorar as novas soluções. Finalmente, uma coleção das "melhores" soluções melhoradas são adicionadas ao conjunto de referência. Estes passos são repetidos até que o conjunto de referência não mude.

3.2 Tipos de Algoritmos de Busca Dispersa

Especificamente a Busca Dispersa, como mostra a Figura 5, emprega o conceito de cinco estratégias da seguinte forma:

- *Método de Geração Diversificada*: O método de geração diversificada cria um conjunto de soluções de teste inicial que tem uma diversidade de soluções de modo que a aleatoriedade como AG é evitada. As soluções são uniformemente avaliadas de uma forma que as mesmas soluções não são empregadas.


- *Método de Melhoria do Conjunto de Soluções*: O método de melhoria altera as soluções de teste para melhorar a qualidade da solução. Esta é empregada no caso em que soluções de alta qualidade são necessárias. Nesse sentido, este método é opcional na realização da Busca Dispersa.

- *Método de Atualização do Conjunto de Referência*: O método de atualização de referência cria e mantém certo número de boas soluções no conjunto de referência. De acordo com esta estratégia, tanto soluções de alta qualidade e as diversificadas precisam ser avaliadas para atualizar o conjunto de referência.

- *Método de Geração do Subconjunto de Soluções*: O método de geração de subconjunto cria subconjuntos de duas ou mais soluções para o método de combinação de solução. O subconjunto é gerado para não fornecer o mesmo subconjunto.

- *Método de Combinação de Soluções*: utiliza os subconjuntos de soluções gerados na etapa anterior, combinando as soluções em cada subconjunto com o objetivo de encontrar novas soluções. Este método de combinação é um mecanismo específico para cada problema, uma vez que está diretamente relacionado com a representação da solução.

Figura 5. Algoritmo de Busca Dispersa.




Fonte: Elaboração da própria autora.

3.3 A Estratégia de Path Relinking

Pelo método de combinação por *Path Relinking (PR)*, dadas duas soluções n^1 e n^2 , explora-se o caminho que conecta estas duas soluções, criando uma sucessão de soluções $n^1 = n(1), n(2), \dots, n(r) = n^2$. O ponto inicial n^1 deste caminho é chamado solução inicial, e o ponto final, n^2 , é chamado solução guia. A Figura 6 mostra a estratégia de Path Relinking.

Figura 6. *Path Relinking*



Fonte: Tagliaenha (2008).

Este caminho pode ser tomado de diversas formas e utilizando vários critérios. Por exemplo, num primeiro passo, comparam-se as soluções n^1 e n^2 obtendo-se dois vetores Δ_{ad} e Δ_{ret} , identificando, respectivamente, os circuitos

que devem ser adicionados e os que devem ser retirados em n^1 para alcançar n^2 . Seja $\hat{n} = n^1$ a solução obtida.

Em um segundo passo se implementa a escolha de um movimento, que é feito de forma gulosa em Δ_{ret} , ou seja, retira-se de $\hat{n}$ o circuito mais caro em Δ_{ret} e se verifica resolvendo o PL, se a solução é factível, ou seja, se $\omega = 0$. Neste caso, $\hat{n}$ é candidato a *Path Relinking*, e faz-se $n(2) = \hat{n}$. Se $\hat{n}$ não é factível, ou seja, se $\omega > 0$, deve-se acrescentar circuitos em $\hat{n}$ para retomar sua factibilidade e estes circuitos são escolhidos inicialmente em Δ_{ad} . Se os circuitos de Δ_{ad} não são suficientes para retomar esta factibilidade, deve-se escolher circuitos como no AHC do método gerador de soluções diversas. Feita a adição do circuito, verifica se há factibilidade novamente, e se ainda $\omega > 0$, deve se realizar um novo movimento de adição até que $\omega = 0$. Neste caso, $\hat{n}$ é candidato a PR. O processo PR se reinicia, agora em $\hat{n}$ como solução inicial, sendo necessário realizar uma nova comparação com a solução guia. Ao se alcançar a solução guia, toma-se $n' = \min \hat{n}$ a solução combinada por PR, ou seja, obtém-se apenas uma solução combinada para se armazenar em *Pool* (lista de armazenamento das soluções obtidas pelo método de combinação).

Uma outra forma de se fazer o *Path Relinking* é realizar os movimentos permitindo infactibilidades nas soluções obtidas durante a trajetória. Assim, por exemplo, num primeiro passo, compara-se a solução base com a solução guia, obtendo-se o vetor Δ_k formado pelos k atributos que devem ser modificados para que a solução base alcance a solução guia. Se $n(1) = n^1$ é a solução de trabalho, deve-se simular a cópia de cada um dos atributos de Δ_k , e verificar a factibilidade das k soluções candidatas. O movimento escolhido, ou seja a solução $n(2)$, será a melhor (menor custo) solução factível obtida, ou, caso não se obtenha soluções factíveis, será a solução com menor infactibilidade. Para se realizar o próximo movimento, novamente deve ser simulada a cópia dos $k - 1$ atributos restantes, e se escolher dentre as $k - 1$ opções, a melhor opção (a melhor factível ou a menos infactível). O processo deve ser repetido até que o último atributo de Δ_k tenha sido copiado, ou seja, $n(k) = n^2$. Aqui, todas as soluções factíveis distintas devem ser armazenadas em *Pool*, ou seja, se obtém várias soluções combinadas.

Caso não existam soluções factíveis, deve-se armazenar em uma lista auxiliar *Pool* as soluções infactíveis distintas, para que depois, parte destas


soluções possam ser factibilizadas e aproveitadas. O PR também pode ser realizado em trajetória dupla, ou seja, considerando-se ambas soluções como base e guia, respectivamente. O método de melhoria deve ser aplicado nas soluções armazenadas em *Pool*.

4 A Metaheurística de Busca Dispersa para o Problema do Planejamento da Expansão de Sistemas de Transmissão

4.1 A Proposta de Codificação de uma Proposta de Solução

Tome como base o sistema da Figura 8, em que existem seis circuitos na topologia base $n_{12}^0 = n_{14}^0 = n_{15}^0 = n_{23}^0 = n_{24}^0 = n_{35}^0 = 1$ e seis circuitos adicionados (representados pelos traços pontilhados na Figura 8) $n_{12}^1 = n_{23}^1 = n_{26}^1 = n_{35}^1 = 1$ e $n_{46} = 2$. Em todos os caminhos se podem adicionar circuitos.

Tal configuração pode ser representada através de um vetor $n = (n_{12}, n_{13}, \dots)$ de dimensão nl , em que nl indica o número de caminhos (ramos) em que é possível adicionar circuitos, com elementos n_{ij} que indicam a quantidade de circuitos adicionados no caminho ij , como pode ser observado na Figura 7.




Fonte: Martins (2009).

Assim, a configuração n da proposta de solução mostrada na Figura 8 demonstra que existe um circuito adicionado no caminho 1 (entre as barras 1 e 2), um circuito adicionado no caminho 6 (entre as barras 2 e 3), outro no caminho 9 (entre as barras 2 e 6), outro no caminho 11 (entre as barras 3 e 5) e outros dois no caminho 14 (entre as barras 4 e 6). Nos demais caminhos não existe nenhum circuito adicionado.

Essa proposta de solução pode ser codificada através de um vetor de codificação mostrado na Figura 7.

Figura 8. Sistema de 6 barras com seis circuitos na configuração base e seis circuitos adicionados.



Fonte: Martins (2009).

4.1.1 Algoritmo de Busca Dispersa

O Algoritmo de Busca Dispersa é uma das mais eficientes e flexíveis metaheurísticas, uma vez que cada um de seus elementos podem ser implementados com uma variedade de formas e graus de complexidade. A Busca Dispersa é uma metaheurística baseada em população que produz novas soluções através da combinação de soluções a partir do conjunto de referência. O conjunto de referência desempenha um papel fundamental para armazenar as melhores e diversificadas soluções para uma busca local, a fim de alcançar a solução ótima. Um projeto básico para implementar a Busca Dispersa é construído sobre o conhecido modelo de cinco estágios:

a) *estágio de geração diversificada*: Nesta etapa um conjunto de diversas soluções de teste inicial é gerado. Portanto, as mesmas soluções não estão incluídas.

b) *fase de melhoria*: a fase de melhoria irá melhorar a qualidade das soluções geradas no passo anterior.

c) *etapa de atualização do conjunto de referência*: esta etapa mantém o número de soluções com maior qualidade e maior diversificação, em que estas soluções vão estabelecer um conjunto de referência. Portanto, o conjunto de referência é composto de soluções diversas e de alta qualidade.

d) *estágio de geração de subconjuntos de soluções*: o estágio de geração de subconjuntos de soluções cria subconjuntos de duas ou mais soluções, enquanto nenhum dos subconjuntos gerados são semelhantes.

e) *estágio de combinação de soluções*: a fase de combinação de soluções cria uma ou mais soluções combinando os subconjuntos que são criados pela geração de subconjunto de soluções.

O diagrama de fluxo da Busca Dispersa é mostrado na Figura 9, em que após a etapa (a) as soluções são melhoradas e um conjunto de soluções com

dimensão P é selecionado com qualidades superiores. O número de soluções candidatas no conjunto inicial é P , que é geralmente calculado usando a equação (20).


$$P = \max\{5b, 100\} \quad (20)$$

Onde b denota a dimensão do conjunto de referência (*RefSet*). O laço que é mostrado na Figura 8 é repetido até que a condição de parada seja satisfeita. As cinco fases podem variar para diferentes aplicações, assim, algumas mudanças podem afetar a qualidade da solução final.

Através da introdução de algumas estratégias, a Busca Dispersa é melhor para encontrar uma solução ideal para sistemas médios e pode encontrar uma melhor solução para sistemas de grande porte que ainda não têm uma solução ótima global conhecida.


A Figura 10 e Figura 11 mostram o Algoritmo de Busca Dispersa com Path Relinking no Meio (BD-PR-M) e, Algoritmo de Busca Dispersa com Path Relinking no Final (BD-PR-F), respectivamente.

Figura 9. Algoritmo de Busca Dispersa - Diagrama de Fluxo




Fonte: Elaboração da própria autora.

Figura 10. Algoritmo de Busca Dispersa com *Path Relinking* no Meio (BD-PR-M).



Fonte: Elaboração da própria autora.

Figura 11. Algoritmo de Busca Dispersa com *Path Relinking* no Final (BD-PR-F)



Fonte: Elaboração da própria autora.

4.1.2 Algoritmo de Busca Dispersa Implementado no Problema de Planejamento da Expansão de Sistemas de Transmissão

Nesta subseção, considerando o Algoritmo Heurístico Construtivo para o planejamento de expansão do sistema de transmissão, são descritos os passos do Algoritmo de Busca Dispersa Modificada que são empregados em planejamento de expansão. São os seguintes:

Passo 1: Criar soluções iniciais usando AHC's

Usando a geração de diversificação e melhoria, um conjunto de soluções é gerado, onde nesta dissertação uma solução é um conjunto que representa os caminhos candidatos (i, j) . Qualquer parte de cada solução é limitada entre os números mínimo e máximo de linhas candidatas. Vários métodos podem ser tratados para gerar soluções de teste iniciais, mas podem não oferecer

soluções de alta qualidade e, portanto, estas soluções iniciais podem levar a um processo demorado. Afim de gerar as melhores soluções, a qualidade das soluções iniciais é muito importante. Neste trabalho, ao contrário do Algoritmo de Busca Dispersa comum que gera aleatoriamente as soluções iniciais, um modelo de transporte (18), com perturbação de custo é usado. A fim de criar diversas soluções de alta qualidade usando apenas um AHC então a função objetivo do MT, modelo (18), é alterado da seguinte forma:

$$\min \nu = \sum_{(i,j) \in \Omega} (w_1 c_r + w_2 c_{ij}) n_{ij} \quad (21)$$

Onde: c_r é um vetor de ruído aplicado aos custos de linhas candidatas; c_{ij} é o custo de linhas candidatas e w_1 , w_2 são coeficientes da função custo. Controlando esses coeficientes a diversificação de soluções geradas é obtida, ou seja, se w_1 é maior do que w_2 , a diversificação das soluções iniciais é alta e vice-versa. Para gerar cada solução inicial o modelo de transporte deve ser resolvido individualmente e este processo continua até que o conjunto inicial esteja completo. Cinco amostras das soluções de teste iniciais para o sistema Garver geradas pelo modelo de transporte são apresentadas na Tabela 2. O estágio de melhoria é aplicado a cada solução de teste inicial, em que as soluções viáveis são melhoradas e as soluções inviáveis são transformadas em viáveis eliminando-se o corte de carga. Em seguida, a topologia atualizada é avaliada calculando gerações artificiais. Como se pode verificar, as soluções são classificadas em dois grupos: soluções factíveis (geração artificial é igual a zero) e solução infactível (geração artificial é diferente de zero). Para melhorar as soluções factíveis, os seus custos de investimento devem ser diminuídos (através da remoção de circuitos desnecessários), enquanto a geração artificial deve ser mantida em zero e, portanto, para soluções factíveis os custos de circuitos adicionados são importantes. A fim de melhorar soluções infactíveis o algoritmo VGS é aplicado de forma que novas linhas são propostas para eliminar o corte de carga de soluções infactíveis. Uma vez que para soluções inviáveis, o valor da geração artificial é importante, o estágio de melhoria deve eliminar cortes de carga. Ao melhorar a solução inviável, a adição de novas

linhas elimina o corte de carga e, portanto, a solução inviável é transformada em viável.

Passo 2: Gere o conjunto de soluções de referência.

Nesta etapa um conjunto de soluções de referência é gerado usando as soluções de alta qualidade e as diversificadas. Vale a pena notar que as soluções de baixo custo são identificadas como soluções de alta qualidade. Metade do conjunto de referência é selecionado a partir das soluções com a mais alta qualidade e o resto de nossas soluções são classificadas usando a equação proposta (22) que é a combinação de qualidade e à distância.

$$\text{solução de melhor qualidade} = (1 - k)\text{qualidade} - k(\text{distância}), 0 \leq k \leq 1 \quad (22)$$

A distância é definida pela equação:

$$\text{Distância} = \max[\min(D(s_d, s_h))] \quad (23)$$

Onde Sh é a primeira metade do conjunto de referência (de soluções de alta qualidade), Sd é o conjunto de soluções de teste e D (sd, sh) é a distância entre qualquer solução de Sd e Sh que é mostrado na Figura 12. Portanto, a outra metade do conjunto de referência será produzido para selecionar essas soluções de teste ordenadas de cima para baixo. O processo de gerar o conjunto de referência é mostrado na Figura 13.

Passo 3: Gerar o subconjunto de soluções.

A partir do conjunto de referência um único grupo de subconjuntos, composto por duas soluções deve ser selecionado de forma aleatória.

Passo 4: Criar soluções por combinação.

Usando a combinação de soluções via operações de AG (recombinação e mutação) uma solução de teste é criada em uma combinação que é produzida a partir de subconjuntos organizados na etapa anterior.

Passo 5: Melhorar as soluções combinadas

Neste passo uma etapa de melhoria é aplicada às soluções de teste atual e, em seguida, o algoritmo retorna ao passo 2.


4.2 Estudos de simulação.

Tabela 2. Uma amostra de soluções de teste inicial

Caminhos	soluções				
	Amostra 1	Amostra 2	Amostra 3	Amostra 4	Amostra 5
1-2	0	0	0	1	0
1-3	1	0	0	1	1
1-4	0	2	1	0	1
1-5	2	0	0	1	0
1-6	0	0	0	1	0
2-3	1	1	2	1	2
2-4	0	0	0	0	0
2-5	1	0	0	1	0
2-6	2	2	3	3	1
3-4	0	0	0	1	0
3-5	2	1	2	2	2
3-6	0	0	0	1	1
4-5	0	0	0	1	0
4-6	2	2	3	2	2
5-6	0	0	0	1	1


Fonte: Elaboração da própria autora.

Figura 12. Processo da Distância Computacional



Fonte: Elaboração da própria autora.

Figura 13. Geração do Diagrama do Conjunto de Referência



B=tamanho do conjunto de referência

Fonte: da própria autora.

5 Testes e Resultados Encontrados

5.1 Sistemas para Teste

Alguns sistemas são utilizados com grande frequência por pesquisadores em planejamento da expansão de sistemas de transmissão. Esses sistemas apresentam dimensão e complexidade variada. Nesta dissertação são tratados os seguintes sistemas: sistema de Garver de 6 barras e 15 circuitos, (2) sistema IEEE 24 barras e 41 circuitos, (3) sistema sul brasileiro de 46 barras e 79 circuitos.

O algoritmo proposto foi implementado utilizando-se a linguagem de programação MATLAB Realese R2009a e o Linprog Revision 2 como uma sub-rotina de resolução de PL.

5.2 Sistema Garver

O sistema Garver inclui seis linhas de transmissão e seis barras com a demanda 760MW na topologia base, que é mostrado na Figura 14. O número de caminhos para adição é de 15 caminhos. O número máximo de linhas paralelas permitido é de quatro para cada ramo. Os dados do sistema podem ser encontrados nos trabalhos de Romero et al. (2002) e Garver (1970).

Ao aplicar o método proposto para o sistema Garver com a reprogramação de geração os resultados obtidos são:

O investimento total é $v=\$110M$ com circuitos adicionados são $n_{3-5}=1$, $n_{4-6}=3$.


Os resultados do método proposto para o sistema Garver sem reprogramação de geração são:

O investimento total é $v=\$200M$ com circuitos adicionados são $n_{2-6}=4$, $n_{3-5}=1$, $n_{4-6}=2$.

O número de PL's resolvido para obter a solução ótima para os dois casos do Sistema Garver, usando o algoritmo de busca dispersa modificado

desenvolvido neste trabalho é significativamente menor que o obtido por outras metaheurísticas apresentadas na literatura como, por exemplo, as propostas apresentadas por Gallego (1997). Para o caso em que existe reprogramação da geração o algoritmo de busca dispersa converge após resolver entre 50 e 140 problemas de PL e para o caso em que não existe reprogramação da geração, o algoritmo converge após resolver entre 60 a 90 problemas de PL.

Figura 14. Sistema de 6 barras de Garver



Fonte: Tagliarenha (2008).

5.3 Sistema IEEE 24 Barras

O sistema IEEE 24 barras é composto por 24 barras, 41 caminhos para a adição de novos circuitos, com 8.550 MW de demanda na topologia base, que é mostrado na Figura 15. Os dados estão disponíveis em Silva (2000). Ao aplicar o método proposto para o IEEE 24 barras, considerando reprogramação de geração, os resultados obtidos são:

O investimento total é de \$152M com o circuito adicionado:

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

A Tabela 3 mostra os resultados encontrados pelo algoritmo de busca dispersa desenvolvido neste trabalho para 4 casos diferentes sem reprogramação de geração, isto é, para os seguintes quatro planos G1, G2, G3 e G4. Com base na Tabela 3, a topologia obtida para o G1 apresenta plano de menor investimento usando o método proposto, em vez dos resultados obtidos por Romero et al. (2002).


Para o sistema IEEE 24 barras, com reprogramação da geração e sem reprogramação da geração, não há resultados com o número de PL's resolvidos na literatura:

Tabela 3. Resultado do algoritmo proposto para quatro planos

Plano	Linha adicionada ao sistema		Custo (M\$)	
	BDM	Resultado em [Romero <i>et al.</i> , 2002]	BDM	Resultado em [<i>Ibid.</i>]
G1	$n_{1-5}=1, n_{3-24}=1, n_{6-10}=1, n_{7-8}=2$ $n_{14-16}=1, n_{15-24}=1, n_{16-17}=2$ $n_{16-19}=1, n_{17-18}=1$	$n_{1-5}=1, n_{3-4}=1, n_{6-10}=1, n_{7-8}=2$ $n_{14-16}=1, n_{15-21}=1, n_{15-24}=1$ $n_{16-17}=2, n_{16-19}=1, n_{17-18}=1$	390	438
G2	$n_{1-5}=1, n_{3-24}=1, n_{6-10}=1, n_{7-8}=2$ $n_{10-12}=1, n_{14-16}=1, n_{15-24}=1$ $n_{16-17}=2, n_{17-18}=2$	-	392	-
G3	$n_{6-10}=1, n_{7-8}=2, n_{10-12}=1, n_{14-16}=1$ $n_{16-17}=1, n_{20-23}=1$	$n_{6-10}=1, n_{7-8}=2, n_{10-12}=1, n_{14-16}=2$ $n_{16-17}=1, n_{20-23}=1$	218	218
G4	$n_{3-24}=1, n_{6-10}=1, n_{7-8}=2, n_{9-11}=2$ $n_{10-12}=1, n_{14-16}=2, n_{16-17}=1$	-	342	-

Fonte: Elaboração da própria autora.

Figura 15. Sistema IEEE 24 barras



Fonte: Elaboração da própria autora.

5.4 Sistema Sul Brasileiro de 46 barras

Este sistema tem 46 barras, 79 caminhos para a adição de novos circuitos e 6.880 MW de demanda, onde os dados do sistema estão disponíveis nos trabalhos de Oliveira (1995) e Haffner (2000). A topologia base deste sistema é mostrado na Figura 16. O número máximo de adições de circuitos em cada caminho é igual a 4. Como no caso anterior, há duas opções, dependendo se a reprogramação de geração é considerada ou não.

A proposta do Algoritmo de Busca Dispersa Modificado encontra os seguintes resultados:

a) Com a reprogramação de geração:

O investimento total é de \$70,289M, com circuitos adicionados:

$$n_{2-5}=1, n_{5-6}=2, n_{13-20}=1, n_{20-21}=2, n_{20-23}=1, n_{42-43}=1, n_{46-6}=1.$$

Neste caso também o algoritmo BDM se mostrou mais eficiente que outras metaheurísticas para encontrar a solução ótima do sistema. Assim, o algoritmo de BDM converge encontrando a solução ótima do sistema e após resolver entre 500 e 1500 problemas de PL.

b) Sem reprogramação de geração:

O investimento total é de \$154,420M, com circuitos adicionados:

$$n_{20-21}=1, n_{42-43}=2, n_{46-6}=1, n_{19-25}=1, n_{31-32}=1, n_{28-30}=1, n_{26-29}=3, n_{24-25}=2, n_{29-30}=2, n_{5-6}=2.$$

Para o sistema sul brasileiro de 46 barras, sem reprogramação da geração, não existem quaisquer resultados com o número de PL's resolvidos na literatura.

Na Tabela 4 são apresentados os parâmetros do Algoritmo de Busca Dispersa Modificado (número de conjunto inicial, número de conjunto de referência e número de iterações para alcançar a solução ótima) para resolver o problema de planejamento da expansão da rede de transmissão.

Em resumo, o Algoritmo de Busca Dispersa Modificado proposto tem as seguintes características: (i) esforço reduzido já que reduz o número de PL's, (ii) extensível, já que pode ser estendido para vários estágios de planejamento mesmo considerando geração dispersa e (iii) encontra soluções iniciais de alta


qualidade; ele usa o modelo de transporte para gerar a população inicial de alta qualidade fazendo com que o planejamento da expansão da rede de transmissão consiga convergir mais rapidamente.

Tabela 4. Parâmetros do algoritmo BDM

	Com Reprogramação de Geração			Sem Reprogramação da Geração		
	N ° de soluções iniciais (P)	Nº. de Conjunto de Referência(b)	Nº. de iter	N ° de solução iniciais (P)	Nº. de Conjunto de Referência(b)	Nº. de iter
Sistema de Garver	20	6	3	20	6	4
IEEE 24 Barras	40	10	5	40	10	7
46-Barras	100	20	9	100	20	10

Fonte: Elaboração da própria autora.

Figura 16. Sistema sul brasileiro de 46 barras



Fonte: Elaboração da própria autora.

Finalmente, apresentam-se resultados com a incorporação de *path relinking* e também realizamos vários testes já que a Busca Dispersa tem componentes aleatórios.

Considerando-se:

BD: Busca Dispersa (de acordo com a Figura 8)

BD-PR-F: Busca Dispersa com Path Relinking no final (De acordo com a figura 10)

NCR: Número de conjunto de referência

PSO: Probabilidade de obter solução ótima

Já que o algoritmo tem parâmetros aleatórios a solução de um teste pode variar com outro. Então para avaliar o algoritmo de forma mais exata o programa é processado 10 vezes para cada teste (**BD**, **BD-PR-F**) e depois a probabilidade de encontrar a solução ótima é relatada. Por exemplo, no caso de teste com BD para sistema 46 barras com 5 iterações de programa a probabilidade de encontrar solução ótima é de 30%, isso significa que entre 10 resoluções de algoritmo a solução ótima foi encontrada 3 vezes.

Da mesma forma o número da média de PL's resolvidos e também o tempo médio para encontrar a solução será calculado usando estes 10 testes do programa.

Inv.: Investimento.

PL: Número de PL resolvido.

No algoritmo de Busca Dispersa o programa resolve vários tipos de PL's:

O modelo de transporte com perturbação de custo é usado para encontrar solução inicial. O modelo híbrido é utilizado para melhorar a solução na fase de melhoria de soluções usando algoritmo AHC. O modelo DC operacional é utilizado na fase de melhoria no algoritmo AHC quando foram retiradas as linhas redundantes. É utilizado o path relinking para avaliar a solução oferecida com este método.

Tabela 5. Sistema Garver (com reprogramação de geradores e sem reprogramação de geradores)

SISTEMA GARVER						
	<i>Iteração</i>	<i>NCR</i>	<i>Inv.</i>	<i>PL</i>	<i>Tempo (seg)</i>	<i>PSO(%)</i>
1) BD (CRG)	4	3	110	271(25+57+189)	1	100
2)BD (SRG)	4	3	200	326	2	100

Fonte: Elaboração da própria autora.

Tabela 6. IEEE 24 Barras com busca dispersa e *path relinking* no final

IEEE 24 Barras						
	<i>Iteração</i>	<i>NCR</i>	<i>Inv.</i>	<i>PL</i>	<i>Tempo (seg)</i>	<i>PSO(%)</i>
1) BD (GO)	3	4	152	421(25+185+211)	13	90
2) BD-PR-F (GO)	3	4	152	497(25+182+290)	14	100
	<i>Iteração</i>	<i>NCR</i>	<i>Inv.</i>	<i>PL</i>	<i>Tempo (seg)</i>	<i>PSO(%)</i>
1) BD (G1)	3	4	370	499	11	100
2) BD-PR-F (G1)	3	4	370	559	13	100
	<i>Iteração</i>	<i>NCR</i>	<i>Inv.</i>	<i>PL</i>	<i>Tempo (seg)</i>	<i>PSO(%)</i>
1) BD (G2)	3	4	372	571	13	60
2) BD-PR-F (G2)	3	4	372	565	14	50
	<i>Iteração</i>	<i>NCR</i>	<i>Inv.</i>	<i>PL</i>	<i>Tempo (seg)</i>	<i>PSO(%)</i>
1) BD (G3)	3	4	188	426	10	80
2) BD-PR-F (G3)	3	4	188	480	12	100
	<i>Iteração</i>	<i>NCR</i>	<i>Inv.</i>	<i>PL</i>	<i>Tempo (seg)</i>	<i>PSO(%)</i>
1)BD (G4)	3	4	288	459	11	0
2) BD-PR-F (G4)	3	4	288	473	12	0

Fonte: Elaboração da própria autora.

Tabela 7. IEEE 24 Barras com busca dispersa e *path relinking* no final

IEEE 24 Barras						
	<i>Iteração</i>	<i>NCR</i>	<i>Inv.</i>	<i>PL</i>	<i>Tempo (seg)</i>	<i>PSO(%)</i>
1) BD (G0)	5	10	152	2161	69	100
2) BD-PR-F (G0)	5	10	152	2716	80	100
	<i>Iteração</i>	<i>NCR</i>	<i>Inv.</i>	<i>PL</i>	<i>Tempo (seg)</i>	<i>PSO(%)</i>
1) BD (G1)	5	10	370	2064	45	100
2) BD-PR-F (G1)	5	10	370	2639	60	100
	<i>Iteração</i>	<i>NCR</i>	<i>Inv.</i>	<i>PL</i>	<i>Tempo (seg)</i>	<i>PSO(%)</i>
1) BD (G2)	5	10	372	1851	43	100
2) BD-PR-F (G2)	5	10	372	2399	57	100
	<i>Iteração</i>	<i>NCR</i>	<i>Inv.</i>	<i>PL</i>	<i>Tempo (seg)</i>	<i>PSO(%)</i>
1) BD (G3)	5	10	188	2108	52	100
2) BD-PR-F (G3)	5	10	188	2460	62	100
	<i>Iteração</i>	<i>NCR</i>	<i>Inv.</i>	<i>PL</i>	<i>Tempo (seg)</i>	<i>PSO(%)</i>
1)BD (G4)	5	10	288	1790	42	60
2) BD-PR-F (G4)	5	10	288	2349	56	70

Fonte: Elaboração da própria autora.

Tabela 8. 46 Barras com busca dispersa e *path relinking* no final

SISTEMA 46 BARRAS						
	<i>Iteração</i>	<i>NCR</i>	<i>Inv.</i>	<i>PL</i>	<i>Tempo</i>	<i>PSO (%)</i>
1) BD	5	10	72870	2123(25+630+1468)	109	40
	10	10	72870	3957	219	70
2) BD-PR-F	5	10	72870	3010	168	20
	10	10	72870	5025	285	70

Fonte: Elaboração da própria autora.

Um exemplo para calcular os valores no BD para o sistema Garver:

TESTE	1	2	3	4	5	6	7	8	9	10	Média
PL_Transporte	25	25	25	25	25	25	25	25	25	25	25
PL_Hibrido	98	121	92	100	101	115	120	108	103	134	109
PL_DC operacional	166	196	164	247	192	163	203	212	229	146	192
PL_Tempo	2	2	2	2	2	2	2	2	2	2	2
Solucao Ótima (200)	SIM	SIM	SIM	SIM	SIM	SIM	SIM	SIM	SIM	SIM	PSO: 100%

Um exemplo de calcular os valores no BD para o sistema IEEE 24 Barras (exemplo referente ao resultado da Busca Dispersa em GO, com 3 iterações e conjunto de referência igual a 4):

TESTE	1	2	3	4	5	6	7	8	9	10	Média
PL_Transporte	25	25	25	25	25	25	25	25	25	25	25
PL_Hibrido	209	193	178	195	148	189	190	198	180	174	185
PL_DC operacional	231	195	225	247	171	175	235	167	186	275	211
PL_Tempo	14	13	13	14	10	11	14	12	11	15	13
Solucao Ótima (152)	SIM	SIM	SIM	SIM	SIM	SIM	SIM	NÃO	SIM	SIM	PSO: 90%

Um exemplo de calcular os valores no BD para o sistema 46 barras:

TESTE	1	2	3	4	5	6	7	8	9	10	Média
PL_Transporte	25	25	25	25	25	25	25	25	25	25	25
PL_Hibrido	640	622	620	644	554	636	559	724	554	749	630
PL_DC operacional	1303	1444	1387	1418	1633	1407	1462	1643	1474	1513	1468
PL_Tempo	108	105	105	105	115	108	105	126	102	120	109
Solucao Ótima (72870)	SIM	SIM	NÃO	NÃO	SIM	NÃO	NÃO	NÃO	NÃO	SIM	PSO: 40%

6 Conclusões

Neste trabalho, foi estudado o problema de planejamento da expansão de sistemas de transmissão de energia elétrica e a metaheurística de Busca Dispersa (uma técnica de solução), que é uma abordagem combinatória que consiste dos métodos de Busca Dispersa e de Algoritmo Heurístico Construtivo que tem sido proposta para o planejamento de expansão da transmissão como um método eficiente para alcançar soluções ótimas. O algoritmo Villasana-Garver-Salon (VGS) também é implementado para auxiliar o Algoritmo de Busca Dispersa Modificado, a fim de melhorar a qualidade das soluções obtidas. O algoritmo proposto de Busca Dispersa Modificado foi aplicado em alguns casos, para resolver o planejamento estático da expansão do sistema de transmissão da rede. Os resultados obtidos para sistemas de médio e grande porte mostram um aumento significativo de desempenho em relação às técnicas anteriores recomendadas. Soluções ótimas de alguns sistemas testes podem ser obtidas através de implementação do algoritmo de Busca Dispersa modificado para os problemas de planejamento da expansão da rede de transmissão.

Realizou-se o detalhamento do problema de planejamento da expansão de sistemas de transmissão, um problema clássico na área de otimização e de grande importância para o setor elétrico, onde foram apontadas as principais dificuldades na resolução deste problema, as quais estão relacionadas com sua estrutura multimodal, que apresenta um número muito elevado de ótimos locais, o que leva a maioria dos métodos aproximados a parar numa solução ótima local, e a natureza combinatória do processo de planejamento que leva a um número muito grande de alternativas de solução.

Foi realizada neste trabalho uma apresentação da metaheurística Busca Dispersa, proposta na década de 70 e embora seja menos conhecida que os Algoritmos Genéticos, tem sido aplicada com êxito em numerosos problemas difíceis de otimização.

Foi realizada sua aplicação na solução do problema de planejamento da expansão de sistemas de transmissão, mostrando que os resultados obtidos foram bastante satisfatórios. Para todos os testes mostrados, o algoritmo

Busca Dispersa encontrou as melhores soluções conhecidas e mostradas na literatura especializada.

O fato de que o algoritmo de Busca Dispersa modificado exigido resolva menos problemas de PL para encontrar as soluções ótimas mostra que o algoritmo proposto de Busca Dispersa apresenta um melhor desempenho e maior eficiência do que as outras técnicas de metaheurística implementadas e relatadas na literatura para resolver problemas de planejamento da expansão da rede de transmissão estática.

O *Path Relinking* foi aplicado no conjunto de referência para encontrar uma solução melhor, e ele pode ser aplicado durante a Busca Dispersa após cada iteração no conjunto de referência.

REFERÊNCIAS

AREIZA ORTIZ, J. M. **Metodologia de expansão automática da transmissão utilizando um algoritmo de busca tabu**. 1997. 128 f. Dissertação (Mestrado) - Centro Tecnológico, Universidade Federal de Santa Catarina, Florianópolis, 1997.

BINATO, S. **Expansão ótima de sistemas de transmissão através de decomposição de Benders e técnicas de planos cortantes**. 2000. 203 f. Tese (Doutorado) – COPPE, Universidade Federal do Rio de Janeiro- UFRJ, Rio de Janeiro, 2000.

BINATO, S.; OLIVEIRA, C. A heuristic approach to cope with multi-year transmission expansion planning. In: STOCKHOLM POWER TECH CONFERENCE, 1995, Stockholm. **Proceedings...** Stockholm: [s.n.], 1995. n. S01-03-277.

BINATO, S.; PEREIRA, M. V. F.; GRANVILLE, S. A new benders decomposition approach to solve power transmission network design problems. **IEEE Transaction on Power Systems**, New York, v. 16, n. 2, p. 235–240, 2001.

CAMPOS, V.; GLOVER, F.; LAGUNA, M.; MARTÍ, R. An experimental evaluation of a scatter search for the linear ordering problem. **Journal of Global Optimization**, Dordrech, v. 21, n. 21, p. 397-414, 2001.

CHAMPS, D. C.; VANKELECOM, J.; AMOULLE, E. Tranex - an interactive computer program for transmission expansion. In: IEEE SUMMER POWER MEETING, Vancouver, 1979. **Proceedings...** New York: IEEE, 1979. n. A79-476-3, p. 10.

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.

ESCOBAR, A.; GALLEGO, R. A.; ROMERO, R. Multistage and coordinated planning of the expansion of transmission systems. **IEEE Transactions on Power Systems**, New York, v. 19, n. 2, p. 735–744, 2004.

FANG, R.; HILL, D. J. A new strategy for transmission expansion in competitive electricity markets. **IEEE Transaction on Power Systems**, New York, v. 18, n. 1, p. 474–380, 2003

FARIA JÚNIOR, H. **Uma nova metaheurística para problemas combinatórios aplicado ao planejamento da expansão de sistemas de transmissão de energia elétrica**. 2005. 154 f. Tese (Doutorado em Engenharia Elétrica) - Instituto Alberto Luiz Coimbra de Pós-Graduação e Pesquisa de Engenharia, Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2005.

FARIA, H. J.; BINATO, S.; RESENDE, M. G. C.; FALCÃO, D. M. Power transmission network design by greedy randomized adaptive path relinking. **IEEE Transactions on Power Systems**, New York, v. 20, n. 1, p. 43–49, 2005.

GALLEGO, R. **Long term transmission systems planning using combinatorial optimization**. 1997. Tese (Pós-doutorado) - Universidade de Campinas, Campinas, 1997.

GALLEGO, R. A.; ALVES, A. B.; MONTICELLI, A.; ROMERO, R. Parallel simulated annealing applied to long term transmission expansion planning. **IEEE Transaction on Power Systems**, New York, v. 12, n. 1, p. 181–187, 1997.

GALLEGO, R. A.; MONTICELLI, A.; ROMERO, R. Comparative studies on non-convex optimization methods for transmission network expansion planning. **IEEE Transaction on Power Systems**, New York, v. 13, n. 3, p. 822–828, 1998.

GALLEGO, R. A.; MONTICELLI, A.; ROMERO, R. Transmission system expansion planning by extended genetic algorithm. **IEE Proceeding Generation, Transmission and Distribution**, New York, v. 3, n. 145, p. 329–335, 1998.

GARCES, L. P.; CONEJO, A. J.; GARCIA-BERTRAND, R.; ROMERO, R. A bilevel approach to transmission expansion planning within a market environment. **IEEE Transaction on Power System**, New York, v. 24, n. 3, p. 1513-1522, 2009.

GARVER, L. L. Transmission network estimation using linear programming', **IEEE Transactions on Power Apparatus and Systems**, New York, v. 89, 7, p. 1688–1697, 1970.

GLOVER, F. A template for scatter search and path relinking. **Artificial Evolution: Lecture Notes in Computer Science**, Berlin, v. 1363, p. 13–54, 1998.

GLOVER, F. Heuristics for integer programming using surrogate constraints. **Decision Sciences**, Atlanta, v. 8, n. 2, p. 156–166, 1977.

GLOVER, F.; KELLY, J. P.; LAGUNA, M. Genetic algorithms and tabu search: hybrids for optimization. **Computers and Operations Research**, Kidlington, v. 22, n. 1, p. 111-134, 1995.

HAFFNER, S.; MONTICELLI, A.; GARCIA, A.; MANTOVANI, J.; ROMERO, R. Branch and bound algorithm for transmission system expansion planning using a transportation model. **IEEE Proceedings of Generation, Transmission and Distribution**, New York, v. 147, n. 3, p. 149-156, 2000.

HASHIMOTO, S. H. M.; ROMERO, R.; MANTOVANI, J. R. S. Efficient linear programming algorithm for the transmission network expansion planning problem. **IEEE Proceedings of Generation, Transmission and Distribution**, New York, v. 150, n. 5, p. 536-542, 2003.

KALTENBATCH, J. C.; PESHON, J.; GEHRIG, E. H. A mathematical optimization technique for the expansion of electrical power transmission systems. **IEEE Transaction on Power Apparatus and Systems**, New York, v. 1, n. PAS-89, p. 113–119, 1970.

KNIGHT, U. G. W. The logical design of electrical networks using linear programming methods. **Proceedings of IEE – Part A: Power Engineering**, New York, A, n. 107, p. 306–314, 1960.

LAGUNA, M.; ARMENTANO, V. A. **Lessons from applying and experimenting with scatter search**. Kluwer Academic: Springer, 2005. Disponível em: <<http://leeds-faculty.colorado.edu/laguna/articles/sslessons.pdf>>. Acesso em: 8 set. 2011.

LAGUNA, M.; MARTÍ, R. Experimental testing of advanced scatter search designs for global optimization of multimodal functions. **Journal of Global Optimization**, Massachusetts, v. 33, n. 2, p. 235-255, 2005.

LAGUNA, M.; MARTÍ, R.; MARTÍ, R. C. **Scatter search: methodology and implementations in C**. [S.l.]: Interfaces, 1999.

LATORRE, G.; CRUZ, R. D.; AREIZA, J. M.; VILLEGAS, A. Classification of publication and model on transmission expansion planning. **IEEE Transaction on Power Systems**, New York, v. 2, n. 18, p. 938–946, 2003.

LATORRE-BAYONA, G.; PÉRES, I. J. Chopin, a heuristic model for long term transmission expansion planning. **IEEE Transaction on Power Systems**, New York, v. 9, n. 4, p. 1886–1894, 1994.

MARTINS, W. A. **Busca em vizinhança variável aplicado na solução do problema de planejamento da expansão do sistema de transmissão de energia elétrica**. 2009. 85 f. Dissertação (Mestrado em Engenharia Elétrica) - Faculdade de Engenharia, Universidade Estadual Paulista, Ilha Solteira, 2009.

MONTICELLI, A.; SANTOS JUNIOR, R. A.; PEREIRA, M. V. F.; CUNHA, S. H.; PARKER B. J.; PRAÇA, J. C. G. Interactive transmission network planning using a leasteffort criterion. **IEEE Transactions on PAS**, New York, v. PAS-101, n. 10, p. 3919-3925, Oct. 1982.

MONTICELLI, A.; SANTOS, R. 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, v. 10, n. PAS-101, p.3319–3325, 1985.

OLIVEIRA, G. C.; COSTA, A. P.; BINATO, S. Large scale transmission network planning using optimization and heuristic techniques. **IEEE Transactions on Power Systems**, New York, v. 4, n. 10, p. 1828–1834, 1995.

OLIVEIRA, G. C.; COSTA, A. P. C.; BINATO, S. Large scale transmission network planning using optimization and heuristic techniques. **IEEE Transactions on Power Systems**, New York, v. 10, n. 4, p.1828-1834, Nov. 1995.

PEREIRA, M. V. F. **Análise de sensibilidade no planejamento de expansão dos sistemas de geração-transmissão**. 1985. Tese (Doutorado) - Instituto Alberto Luiz Coimbra de Pós-Graduação e Pesquisa de Engenharia, Universidade Federal do Rio de Janeiro, Rio de Janeiro, 1985.

PEREIRA, M. V. F.; PINTO, L. M. V. G.; OLIVEIRA, G. C.; CUNHA, S. H. F. **Composite generation-transmission expansion planning**. Rio de Janeiro: CEPEL, 1987. (Technical Report EPRI, RP 2473-9).

PINTO, L. M. V. G.; NUNES, A. A model for optimal transmission expansion planning. In: POWER SYSTEM COMPUTING CONFERENCE, 1., 1990, Graz. **Proceedings...** Graz: [s.n.], 1990. p. 13–23.

RIDER, M.; GARCIA, A.; ROMERO, R. Power systems network expansion planning using ac model. **IEEE Generation, Transmission and Distribution**, New York, v. 1, n. 5, p. 731–742, 2007.

ROMERO, R. **Um método de decomposição para o planejamento a longo prazo de sistemas de transmissão**. 1993. 169 f. Tese (Doutorado) – Faculdade de Engenharia Elétrica, Universidade Estadual de Campinas, Campinas, 1993.

ROMERO, R.; GALLEGU, R. A.; MONTICELLI, A. Transmission system expansion planning by simulated annealing. **IEEE Transaction on Power System**, New York, v. 11, n. 1, p. 364–369, 1996.

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.

ROMERO, R.; MONTICELLI, A.; GARCIA, A.; HAFFNER, S. Test systems and mathematical models for transmission network expansion planning. **IEEE Generation, Transmission and Distribution**, New York, v. 148, n. 5, p. 482–488, 2002.

ROMERO, R.; ROCHA, C.; MANTOVANI, J. R. S.; SANCHEZ, I. G. Constructive heuristic algorithm for the DC model in network transmission expansion planning. **IEEE Generation, Transmission and Distribution**, New York, v. 152, n. 2, p. 277-282, Mar 2005.

ROMERO, R.; ROCHA, R.; MANTOVANI, M.; MANTOVANI, J. R. S. Analysis of heuristics algorithms for the transportation model in static and multistage planning in network expansion systems. **IEEE Generation, Transmission and Distribution**, New York, v. 5, n. 150, p. 521–526, 2003.

RUSSELL, R.A.; CHIANG, W. Scatter search for the vehicle routing problem with time windows. **European Journal of Operational Research**, Aylesbury, v. 169, n. 2, p. 606-622, 2006.

SABEDORIA. In: A BÍBLIA: tradução pastoral da bíblia católica. São Paulo: Paulus, 2000.

SILVA, E. L.; AREIZA, J. M.; OLIVEIRA, G. C.; BINATO, S. Transmission network expansion planning under a tabu search approach. **IEEE Transaction on Power Systems**, New York, v. 16, n. 1, p. 62–68, 2001.

SILVA, E. L.; GIL, H. A.; AREIZA, A. M. Transmission network expansion planning under an improved genetic algorithm. **IEEE Transaction on Power Systems**, New York, v. 15, n. 3, p.1168–1175, 2000.

SILVA, I.; RIDER, M.; ROMERO, MURARI, C.A. Transmission network expansion planning with security constraints. **IEEE Proceedings, Generation, Transmission and Distribution**, New York, v. 152, n. 6, p. 828-836, 2005.

TAGLIALENHA, S. L. S. **Novas aplicações de metaheurísticas na solução do problema de planejamento da expansão do sistema de transmissão de energia elétrica**. 2008. 136 f. Tese (Doutorado em Engenharia Elétrica) – Faculdade de Engenharia, Universidade Estadual Paulista, Ilha Solteira, 2008.

SÃO TIAGO. In: A BÍBLIA: tradução pastoral da bíblia católica. São Paulo: Paulus, 2000.

VILLASANA, R. **Transmission network planning using linear and linear mixed integer programming**. 1984. Tese (Doutorado) - Ressenlaer Polytechnic Institute, Universidade Microfilms, New York, 1984.

VILLASANA, R.; GARVER, L. L.; SALON, S. J. Transmission network planning using linear programming. **IEEE Transaction on Power Apparatus and Systems**, New York, v. 2, n. PAS-104, p. 349-356, 1985.