UNIVERSIDADE ESTADUAL PAULISTA
Faculdade de Engenharia
Campus de Bauru

ABORDAGENS DE SISTEMAS INTELIGENTES PARA A SOLUÇÃO DO PROBLEMA DE DESPACHO ECONÔMICO DE GERAÇÃO

LETICIA TAKAHASHI

Dissertação apresentada à Faculdade de Engenharia da UNESP - Campus de Bauru, para obtenção do título de Mestre em Engenharia Industrial.

BAURU - SP
Abril - 2004

UNIVERSIDADE ESTADUAL PAULISTA
Faculdade de Engenharia
Campus de Bauru

ABORDAGENS DE SISTEMAS INTELIGENTES PARA A SOLUÇÃO DO PROBLEMA DE DESPACHO ECONÔMICO DE GERAÇÃO

LETICIA TAKAHASHI

Orientador: Prof. Dr. Ivan Nunes da Silva
Co-orientador: Prof. Dr. Leonardo Nepomuceno

Dissertação apresentada à Faculdade de Engenharia da UNESP - Campus de Bauru, para obtenção do título de Mestre em Engenharia Industrial.

BAURU – SP
Abril – 2004

Ficha catalográfica elaborada por
DIVISÃO TÉCNICA DE BIBLIOTECA E DOCUMENTAÇÃO
UNESP - Bauru

Takahashi, Leticia
Abordagens de sistemas inteligentes para a solução do problema de despacho econômico de geração / Leticia Takahashi. - - Bauru : [s.n.], 2004.
143 f.

Orientador: Ivan Nunes da Silva.
Co-orientador: Leonardo Nepomuceno.

Dissertação (Mestrado) – Universidade Estadual Paulista. Faculdade de Engenharia de Bauru, 2004.

1.Despacho econômico. 2. Redes neurais artificiais. 3. Algoritmos genéticos. 4. Pontos de válvula. I – Universidade Estadual Paulista. Faculdade de Engenharia de Bauru. II - Título.

PÓS-GRADUAÇÃO
ENGENHARIA MECÂNICA

ATA Nº 056/2004

ATA DA DEFESA PÚBLICA DA DISSERTAÇÃO DE MESTRADO DE *LETICIA TAKAHASHI*, ALUNA DO PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA MECÂNICA, DA FACULDADE DE ENGENHARIA DA UNESP – CAMPUS DE BAURU.

No dia dezesseis de abril de dois mil e quatro , às 10 horas, no anfiteatro do prédio da Pós-graduação da Faculdade de Engenharia da UNESP, Campus de Bauru, reuniu-se a Comissão Examinadora da Defesa Pública, composta pelos Professores Doutores: Leonardo Nepomuceno do Departamento de Engenharia Elétrica da Faculdade de Engenharia - UNESP – Campus de Bauru, Presidente da Banca, Geraldo Roberto Martins da Costa do Departamento de Engenharia Elétrica – EESC – São Carlos e Takaaki Ohishi do Departamento de Engenharia de Sistemas – UNICAMP – Campinas, a fim de proceder a argüição pública da Dissertação de Mestrado da candidata ***LETICIA TAKAHASHI***, intitulada "ABORDAGENS DE SISTEMAS INTELIGENTES PARA A SOLUÇÃO DO PROBLEMA DE DESPACHO ECONÔMICO DE GERAÇÃO". O Professor Doutor Leonardo Nepomuceno, Presidente da Banca, apresentou a candidata, que dissertou sobre seu trabalho, em quarenta minutos, após, a candidata foi argüida oralmente pelos membros componentes da Comissão Examinadora no tempo regulamentar exigido. Logo após, reuniu-se a Comissão Examinadora, tendo apresentado o conceito final: **APROVADO.** Nada mais havendo, foi lavrada a presente ata, que após, lida e aprovada, será assinada pelos Senhores Membros da Comissão Examinadora. Bauru, 16 de abril de dois mil e quatro. / . / . / . /

Prof. Dr. Leonardo Nepomuceno - Presidente _____

Prof. Dr. Geraldo Roberto Martins da Costa - Membro _____

Prof. Dr. Takaaki Ohishi _____

unesp

UNIVERSIDADE ESTADUAL PAULISTA
Faculdade de Engenharia - Bauru
Av.Engº Luiz Edmundo Carrijo Coube s/nº • Caixa Postal 473 • CEP 17 033-360 • Bauru • SP • Fone: 14 3103 6000 e 14 3103 6108 • Fax: 14 3103 6104
E-mail: spg@feb.unesp.br • home page: www.feb.unesp.br/pos/fe.htm

Dedico este trabalho aos meus pais, Iassuo Takahashi e Tateishi Tokiko Takahashi, que me ensinaram os princípios e valores da vida e pelo constante amor, carinho e apoio.

AGRADECIMENTOS

A Deus por iluminar meu caminho e proporcionar saúde, confiança, decisão, coragem e sabedoria para realizar este trabalho.

Aos professores Ivan Nunes da Silva e Leonardo Nepomuceno, um agradecimento especial pela constante dedicação, incentivo, sugestões, ensinamentos transmitidos e confiança depositada no desenvolvimento deste trabalho. Meu reconhecimento e gratidão pela paciência, compreensão e orientação.

Agradecimento especial aos professores José Alfredo Covolan Ulson e Pedro da Costa Junior pelas sugestões.

Aos meus irmãos, Sueli, Laura, Gerson e Cassia, um quarteto de ternura, sempre alegres e incentivadores.

Aos amigos do Laboratório de Sistemas Inteligentes que fazem deste um ambiente próspero, amigável e cooperativo.

Aos professores, funcionários e amigos da UNESP – Bauru. Um agradecimento especial às supervisoras da seção de Pós-Graduação da Faculdade de Engenharia, Djanira Maria Amaral e Iara Lúcia Brito dos Santos, e às secretárias do Departamento de Engenharia Elétrica, Regina Célia Nogueira Lima Guerrero Mendes e Tatiane B. A. Luz, sempre muito prestativas em atender às solicitações.

À CAPES pela credibilidade e apoio financeiro.

Agradeço aos professores Takaaki Ohishi - UNICAMP e Geraldo Roberto Martins da Costa – USP – São Carlos por aceitar participar da banca examinadora, pelo cuidado e atenção que tiveram em ler esta dissertação e também pelos comentários sugeridos e contribuições.

À Faculdade de Engenharia – UNESP – Campus de Bauru, sou profundamente grata por todas as possibilidades que me proporcionou, entre elas, de cursar o Mestrado.

E, finalmente, a todos que direta ou indiretamente contribuíram para a realização deste trabalho.

SUMÁRIO

LISTA DE FIGURAS iv

LISTA DE TABELAS v

RESUMO 1

ABSTRACT 2

CAPÍTULO 1 – INTRODUÇÃO 3

1.1. Introdução 4
1.2. Objetivos 6
1.3. Estrutura da Dissertação 7
1.4. Divulgação Científica 8

CAPÍTULO 2 – O PROBLEMA DE DESPACHO ECONÔMICO 10

2.1. Introdução 11
2.2. Despacho Econômico 12
2.3. Problema de Despacho Econômico Clássico 15
2.3.1. Resolvendo o DEC para um Sistema com Duas Barras 18
2.3.2. DEC Considerando-se as Restrições de Desigualdade 22
2.3.3. DEC para um Sistema com *n* Barras 23
2.4. Problema de Despacho Econômico com Representação do Sistema de Transmissão 24
2.4.1. Equacionamento e Dados Iniciais do Problema 25
2.5. Despacho Econômico Multi-Objetivo 25
2.5.1. Equacionamento do Problema 26
2.6. Despacho para Sistemas Hidrotérmicos 27

CAPÍTULO 3 – REDES NEURAIS ARTIFICIAIS 30

3.1. Introdução 31
3.2. Histórico 32
3.3. Neurônio Biológico 33
3.4. Neurônio Artificial 34
3.5. A Rede de Hopfield 39
3.6. A Rede de Hopfield Modificada 41
3.7. Rede Neural de Hopfield Modificada Fuzzy (RHMF) 44
3.8. Controlador Lógico Nebuloso 47

CAPÍTULO 4 – ALGORITMOS GENÉTICOS 52

4.1 Introdução 53

4.2 Um Breve Histórico 54
4.3. Espaço de Busca 56
4.4. Algoritmos Genéticos e Métodos Tradicionais de Busca e Otimização 59
4.5. Conceitos Básicos da Genética 60
4.6. Esquemas 62
4.6.1. Esquemas: blocos de construção dos Algoritmos Genéticos 62
4.7. Algoritmo Genético Simples 64

CAPÍTULO 5 – APLICAÇÃO DA REDE DE HOPFIELD MODIFICADA 70

5.1. Introdução 71
5.2. Mapeamento do Problema de DE pela Rede de Hopfield Modificada 71
5.3. Exemplo de Aplicação da Rede de Hopfield Modificada 74

CAPÍTULO 6 – APLICAÇÃO DO ALGORITMO GENÉTICO 76

6.1. Introdução 77
6.2. Solução do Problema de Despacho Econômico Clássico 77
6.3. Solução do Problema de Despacho Econômico com Representação do Sistema de Transmissão 79
6.4. Solução do Problema de Despacho Multi-Objetivo 81
6.5. Solução do Problema de Despacho Econômico Hidrotérmico 81

CAPÍTULO 7 – RESULTADOS DA SIMULAÇÃO 83

7.1. Introdução 84
7.2. Problema de Despacho Econômico Clássico (DEC) 84
7.2.1. Exemplo 1 85
7.2.2. Exemplo 2 88
7.2.3. Conclusões 90
7.3. Definição de Parâmetros dos Algoritmos Genéticos 91
7.3.1. Variação do Tamanho da População 91
7.3.2. Variação das Probabilidades de *Crossover* 92
7.3.3. Variação das Probabilidades de Mutação 93
7.4. Problema de Despacho Econômico com Representação do Sistema de Transmissão 93
7.4.1. Sistema Teste IEEE de 14 Barras 94
7.4.2. Caso I 95
7.4.3. Caso II 97
7.4.4. Caso III 100
7.4.5. Conclusões 102
7.5. Problema de Despacho Multi-Objetivo 103
7.5.1. Caso 1 104
7.5.2. Caso 2 106
7.5.3. Caso 3 108
7.5.4. Caso 4 109

7.5.5. Conclusões..... 111
7.6. Problema de Despacho de Geração para Sistemas Hidrotérmicos..... 112
7.6.1. Sistema Teste IEEE de 30 Barras..... 112
7.6.2. Resultados da Simulação..... 113
7.6.3. Sistema Teste IEEE de 118 Barras..... 114

CAPÍTULO 8 – CONCLUSÕES E PROPOSTAS FUTURAS..... 118

8.1. Conclusões..... 119
8.2. Propostas Futuras 120

REFERÊNCIA BIBLIOGRÁFICA..... 122

APÊNDICE A 128

APÊNDICE B 131

APÊNDICE C 135

LISTA DE FIGURAS

FIGURA 2.1 - Funções típicas de custo de geração para unidades de geração térmica....17
FIGURA 2.2 - Funções típicas de custo de perdas para unidades de geração hidráulicas.18
FIGURA 2.3 - Sistema com duas barras 19
FIGURA 2.4 - Representação gráfica do problema.....19
FIGURA 2.5 - Curva de nível da função custo 20
FIGURA 2.6 - Representação gráfica do despacho ótimo para n barras 24
FIGURA 3.1 - Esquema de um neurônio natural 34
FIGURA 3.2 - Esquema da unidade de processamento 35
FIGURA 3.3 - Funções de transferência mais usadas 37
FIGURA 3.4 - Organização da rede em camadas.....38
FIGURA 3.5 - A rede Hopfield convencional.....40
FIGURA 3.6 - Rede de Hopfield Modificada (RHM).....43
FIGURA 3.7 - Rede de Hopfield Modificada Fuzzy (RHMF).....45
FIGURA 3.8 - Funções de pertinência do controlador nebuloso 51
FIGURA 5.1 - Evolução da função custo da RHM 75
FIGURA 6.1 - Estrutura geral de uma *string P* utilizada no AG. 77
FIGURA 6.2 - Estrutura geral de uma *string* utilizada no AG proposto. 81
FIGURA 7.1 - Evolução da função custo (RHM, AG e AGV) – Exemplo 1.....87
FIGURA 7.2 - Evolução da função custo (RHM, AG e AGV) – Exemplo 2.....89
FIGURA 7.3 - Evolução da função custo (RHM e RHMF) – Caso I.....96
FIGURA 7.4 - Evolução da função custo (AG e AGV) – Caso I.....97
FIGURA 7.5 - Evolução da função custo (RHM e RHMF) – Caso II 98
FIGURA 7.6 - Evolução da função custo (AG e AGV) – Caso II 99
FIGURA 7.7 - Evolução da função custo (RHM e RHMF) – Caso III 101
FIGURA 7.8 - Evolução da função custo (AG e AGV) – Caso III 102
FIGURA 7.9 - Evolução da função custo (Abordagens AG e AGV – Caso 1).....106
FIGURA 7.10 - Evolução da função custo (Abordagens AG e AGV – Caso 2).....107
FIGURA 7.11 - Evolução da função custo (Abordagens AG e AGV – Caso 3).....109
FIGURA 7.12 - Evolução da função custo (Abordagens AG e AGV – Caso 4).....111
FIGURA 7.13 - Evolução da função custo (AG e AGV) 114
FIGURA 7.14 - Evolução da função custo (AG e AGV) 117

LISTA DE TABELAS

Tabela 3.1 – Conjunto de Regras Nebulosas 50
Tabela 4.1 – Comparação da Terminologia Natural e do AG 61
Tabela 4.2 – Exemplo de Esquema 62
Tabela 4.3 – Tamanho do Esquema 63
Tabela 4.4 – Ordem de um Esquema 63
Tabela 5.1 – Parâmetros Iniciais 74
Tabela 7.1 – Parâmetros Iniciais da Função Custo – Sistema de 3 Barras 85
Tabela 7.2 – Resultados da Simulação – Sistema de 3 Barras. 86
Tabela 7.3 – Parâmetros Iniciais – Sistema de 14 Barras 88
Tabela 7.4 – Resultados da Simulação – Sistema de 14 Barras. 88
Tabela 7.5 – Resultados – Variação do Tamanho da População 92
Tabela 7.6 – Variação das Probabilidades de *Crossover* 93
Tabela 7.7 – Variação das Probabilidades de Mutação 93
Tabela 7.8 – Parâmetros Iniciais da Função Custo 95
Tabela 7.9 – Resultados da Simulação (Caso I) 95
Tabela 7.10 – Restringindo a Geração (Caso II) 98
Tabela 7.11 – Contingência Dupla de Linha (Caso III) 100
Tabela 7.12 – Fluxos nas Linhas 101
Tabela 7.13 – Parâmetros Iniciais 104
Tabela 7.14 – Resultados da Simulação – Caso 1. 105
Tabela 7.15 – Resultados da Simulação – Caso 2. 107
Tabela 7.16 – Resultados da Simulação – Caso 3. 108
Tabela 7.17 – Resultados da Simulação – Caso 4. 110
Tabela 7.18 – Parâmetros Iniciais 112
Tabela 7.19 – Resultados da Simulação 113
Tabela 7.20 – Parâmetros Iniciais 115
Tabela 7.21 – Resultados da Simulação em MW. 116

TAKAHASHI, L. *Abordagens de Sistemas Inteligentes para a Solução do Problema de Despacho Econômico de Geração.* Bauru, 2004. 143p. Dissertação (Mestrado em Engenharia Industrial) – Faculdade de Engenharia, Campus de Bauru, Universidade Estadual Paulista "Júlio de Mesquita Filho".

RESUMO

O presente trabalho desenvolve duas abordagens baseadas em sistemas inteligentes, redes neurais artificiais e algoritmos genéticos, para resolver problemas de Despacho Econômico (DE) com a incorporação das características não lineares e pontos de válvula na função custo das unidades geradoras em sistemas de geração. Os algoritmos de otimização convencionais têm apresentado problemas para resolver o DE nos casos em que as funções envolvidas apresentam características de não convexidade e/ou não diferenciabilidade. As abordagens neurais, mais especificamente a rede de Hopfield, mostram-se como ferramentas adequadas no estudo do DE quando funções objetivo não convexas são estudadas. Na Rede de Hopfield Modificada (RHM) aqui analisada, alguns problemas rotineiramente encontrados em outras abordagens neurais, tais como soluções infactíveis e a não convergência aos pontos de equilíbrio (que representam uma solução para o sistema), são tratados de forma eficiente e robusta. A RHM tem tido ainda um bom desempenho no que diz respeito à velocidade de convergência, se comparada com outras abordagens neurais, que em geral apresentam um número excessivo de iterações com um conseqüente aumento do esforço computacional. Já os Algoritmos Genéticos (AG) têm a facilidade de se adaptar a problemas com características não-lineares eliminando as dificuldades apresentadas pela aplicação de métodos clássicos relacionadas à descontinuidade da derivada da função custo e a existência de vários pontos de ótimos locais. Assim sendo, a abordagem de Algoritmo Genético proposta neste trabalho consegue tratar de forma eficiente modelos de DE mais precisos, nos quais a função custo das unidades geradoras leva em consideração características altamente não-lineares, tais como pontos de válvula (que tornam a função não diferenciável). Resultados da simulação e uma análise comparativa das duas abordagens para a solução do DE são apresentados utilizando sistemas teste do IEEE.

Palavras-chave: Despacho Econômico, Redes Neurais Artificiais, Algoritmos Genéticos, Pontos de Válvula.

TAKAHASHI, L. *Intelligence Systems Based Approaches from Solving the Economic Dispatch Problems.* Bauru, 2004. 143p. Dissertação (Mestrado em Engenharia Industrial) – Faculdade de Engenharia, Campus de Bauru, Universidade Estadual Paulista "Júlio de Mesquita Filho".

ABSTRACT

The present work develops two intelligent system approaches: artificial neural networks and genetic algorithms to solving economic dispatch (DE) problems in which the valve point loading is introduced in the cost function analysis. Conventional optimization algorithms have presented some drawbacks when solving certain DE problems presenting non-convexity or non-differentiability issues. The neural approaches, specially the Hopfield network, have proven its efficiency as good tools for solving the DE when such problem presents non-convex objective functions. In the Modified Hopfield network (RHM) studied in this work some problems being highlighted in the literature, such as infeasible solutions or bad convergence rates to the equilibrium points, have been effectively handled. The RHM has also presented a good convergence rate when compared to other neural approaches, which, in general, take thousands of iteration to reach the solution. The Genetic Algorithms (GA) have proven to be suitable for solving optimization problems presenting non-linear and non-differentiable cost functions. Thus, the genetic algorithm approach presented in this work is able to solve more accurate DE problems. The valve point introduces non-differentiability characteristics in the objective function. Simulation results and a comparative analysis of the intelligent approaches studied in this work are presented in the final sections.

Keywords: Economic Dispatch, Neural Networks, Genetics Algorithms, Valve Point Loading.

CAPÍTULO 1

Introdução

O capítulo 1 apresenta uma breve introdução do trabalho, os objetivos e as informações gerais desta dissertação.

1.1. Introdução

O problema de Despacho Econômico (DE) tem como objetivo principal o cálculo dos níveis de geração de cada unidade geradora, de modo a suprir inteiramente a demanda da maneira mais econômica possível e respeitando determinadas restrições físicas e operacionais preestabelecidas (SURVEY; CARPENTIER, 1962) e (HAPP, 1977).

Alguns modelos de DE são propostos e estudados neste trabalho. A diferenciação entre os modelos está basicamente relacionada ao detalhamento da representação dos sistemas de geração e transmissão. No modelo mais simplificado (STEINBERG; SMITH, 1934) e (HAPP, 1977), conhecido na literatura como Despacho Econômico Clássico (DEC), adota-se como função objetivo os custos de geração das unidades térmicas, sendo consideradas as restrições canalizadas nas gerações (limites de gerações). No DEC o sistema de transmissão é representado de forma muito simplificada, cuja restrição de igualdade estabelece que o somatório de toda a geração deve igualar a demanda total do sistema.

O segundo modelo aqui estudado também adota os custos de geração das unidades térmicas como função objetivo. Este modelo e os subseqüentes, além de considerar as restrições canalizadas nas gerações, incorpora a representação do sistema de transmissão por meio de equações de fluxo de carga linear e limites nos fluxos de potência ativa nas linhas.

Após a inclusão do sistema de transmissão na representação do sistema, um novo termo é incorporado na função objetivo do terceiro modelo estudado de maneira a otimizar as perdas relacionadas ao sistema de transmissão. A função objetivo total é separável em duas funções: uma representando as perdas no sistema de transmissão e outra associada às perdas de geração hidráulica (SOARES *et al.*, 1997) ou aos custos de geração térmica. Logo, trata-se de um problema de otimização multi-objetivo.

Por fim, estuda-se o problema de Despacho Hidrotérmico. A função objetivo é constituída pela função que representa os custos de geração das

unidades térmicas e pela função associada às perdas de geração hidráulica. No conjunto de restrições são consideradas também as faixas de cavitação nas quais as unidades de geração hidráulica não podem operar.

Problemas de Despacho Econômico têm sido resolvidos por uma variedade de técnicas de otimização, tais como: fluxo em rede (LUO *et al.*, 1984), programação quadrática (REID *et al.*, 1973), método dos pontos interiores (YAN *et al.*, 1997), dentre outros.

A metodologia utilizada nesta dissertação para a solução dos problemas de Despacho Econômico é baseada em técnicas de sistemas inteligentes. A Inteligência Computacional surgiu a partir das técnicas capazes de reproduzir sistemas computacionais inspirados na natureza. A analogia entre os dispositivos naturais e artificiais despertou o interesse humano pelo desenvolvimento de processos de imitação da natureza. Redes neurais artificiais, sistemas *fuzzy*, agentes autônomos e técnicas baseadas em computação evolutiva, tais como Algoritmos Genéticos estão dentro do contexto da Inteligência Computacional.

A Rede de Hopfield Modificada (RHM), como demonstrado em (SILVA *et al.*, 2001) apresenta grandes vantagens em relação à grande maioria das abordagens neurais. A RHM, por meio da técnica de projeção no subespaço-válido, separa os termos de confinamento, relacionadas ao conjunto factível do problema, e de otimização, relacionada à função objetivo, em duas funções de energia, de modo que não são mais necessários que constantes de ponderação sejam estimadas. Este procedimento tem contornado os problemas de convergência e infactibilidade das redes de Hopfield Convencionais. Este trabalho propõe um aprimoramento da RHM por meio da proposição e desenvolvimento de um controlador lógico nebuloso para acelerar a convergência ao ponto de equilíbrio da rede.

Embora eficiente em muitos aspectos numéricos, a RHM também é uma técnica baseada em cálculo (*Calculus-based*). Técnicas baseadas em cálculo buscam pelo ótimo local por meio da resolução de um conjunto de equações normalmente não-lineares. Esta técnica apresenta algumas deficiências quando é aplicada para resolver um problema de Despacho Econômico mais representativo,

como discutido a seguir.

Dependendo da formulação do problema de DE adotada funções objetivos e/ou restrições operacionais complexas podem apresentar características de não convexidade e não diferenciabilidade (CHOWDHURY *et al.*, 1990). Este é o caso em que o carregamento do ponto de válvula é considerado nos problemas de DE para as unidades de geração térmica. Outra importante deficiência dos algoritmos de otimização tradicionais é a incapacidade para explorar o espaço global de otimização. A maioria destes métodos fornece um ótimo local ao invés de explorar todo o espaço de busca. Tais questões são as motivações básicas para o uso dos Algoritmos Genéticos (AG) para resolver o problema de DE.

1.2. Objetivos

Este trabalho tem como objetivo principal apresentar comparações numéricas, conceituais e computacionais entre duas abordagens baseadas em sistemas inteligentes para a solução dos problemas de despacho econômico, quais sejam: a rede de Hopfield Modificada, descrita em (SILVA *et al.* 2001), e uma abordagem baseada em Algoritmos Genéticos, descrita neste trabalho.

Com o intuito de adequar o problema de Despacho Econômico mais representativo com a realidade, foram estudadas novas tendências nesta área, tais como sistemas baseados em regras nebulosas e a incorporação das características não lineares e não diferenciáveis na função custo das unidades geradoras em sistemas de geração térmica. Da forma como o problema foi equacionado, os Algoritmos Genéticos são um importante instrumento para aperfeiçoar a solução de problemas de Despacho Econômico.

Como objetivos específicos têm-se:

a) Aplicação da Rede de Hopfield Modificada para resolver os problemas de Despacho Econômico. Além disso, é desenvolvido um controlador lógico nebuloso para acelerar a taxa de convergência da rede. A vantagem desta abordagem está relacionada à convergência eficiente em direção aos pontos de equilíbrio factíveis.

b) Aplicação de Algoritmos Genéticos (considerado como técnica robusta uma vez que trabalham com um universo mais abrangente de problemas) no cálculo do despacho de geração, dado que quando são aplicados métodos matemáticos tradicionais de busca, a incorporação das características não lineares e pontos de válvula na função custo apresenta dificuldades (descontinuidade da derivada da função custo e existência de vários pontos de ótimos locais) (WONG; WONG, 1996) e (SHEBLE'; WALTERS, 1993).

1.3. Estrutura da Dissertação

Além deste capítulo introdutório, o presente trabalho se encontra estruturado em sete capítulos e três apêndices, conforme resumido abaixo.

O capítulo 2 tem como objetivos estabelecer princípios teóricos para o desenvolvimento do modelo matemático que se pretende realizar, apresenta conceitos básicos e definições da teoria geral dos problemas de Despacho Econômico.

No capítulo 3 é apresentada uma introdução teórica e um histórico sobre as redes neurais artificiais, mais especificamente a rede de Hopfield modificada, bem como seus tipos, arquiteturas e algoritmos de treinamento.

O capítulo 4 apresenta uma introdução teórica e um histórico dos Algoritmos Genéticos.

No capítulo 5 são realizadas as aplicações da Rede de Hopfield Modificada e de um controlador lógico nebuloso nos problemas de Despacho Econômico.

O capítulo 6 apresenta o algoritmo geral dos modelos de Despacho Econômico propostos no capítulo 2, utilizando os Algoritmos Genéticos.

O capítulo 7 apresenta os principais resultados da aplicação dos modelos, considerando os aspectos abordados nos capítulos anteriores.

Por último, no capítulo 8, são apresentadas as principais conclusões obtidas e sugerem-se temas para a continuidade da pesquisa em futuros trabalhos.

Os apêndices A, B e C apresentam, respectivamente, as informações e os diagramas dos sistemas teste IEEE de 14, 30 e 118 barras utilizados nas simulações.

1.4. Divulgação Científica

A seguir é apresentada uma relação de publicações dos estudos relacionados à divulgação desta dissertação:

1. TAKAHASHI, L.; NEPOMUCENO, L.; SILVA, I. N. Modelo de Despacho Econômico Resolvido por Redes Neurais Artificiais e Lógica Nebulosa. In: VI SBAI - SIMPÓSIO BRASILEIRO DE AUTOMAÇÃO INTELIGENTE, Bauru – SP, 2003. *http://www.visbai.feb.unesp.br*

2. TAKAHASHI, L.; NEPOMUCENO, L.; SILVA, I. N. Duas Abordagens de Sistemas Inteligentes para a Solução do Problema de Despacho Econômico. In: XXXV SBPO - SIMPÓSIO BRASILEIRO DE PESQUISA OPERACIONAL, Natal – RN, 2003.

3. TAKAHASHI, L.; NEPOMUCENO, L.; SILVA, I. N. Problemas de Despacho Econômico Multi-Área com Restrições da Capacidade de Transmissão Resolvido através de uma Rede de Hopfield Modificado. In: XXXV SBPO – SIMPÓSIO BRASILEIRO DE PESQUISA OPERACIONAL, Natal – RN, 2003.

4. TAKAHASHI, L.; NEPOMUCENO, L.; SILVA, I. N. Uma Abordagem Baseada em Redes Neurais Artificiais e Lógica Nebulosa para a Solução de Problemas de Despacho Econômico. In: XXXV SBPO – SIMPÓSIO BRASILEIRO DE PESQUISA OPERACIONAL, Natal – RN, 2003

5. TAKAHASHI, L.; NEPOMUCENO, L.; SILVA, I. N. Economic Dispatch Problem with Valve-Point Loading Based on Genetic Algorithm Approach. In: 5TH LATIN-AMERICAN CONGRESS: ELECTRICITY GENERATION AND TRANSMISSION, São Pedro – SP, 2003.

CAPÍTULO 2

O Problema de Despacho Econômico

Este capítulo apresenta os conceitos básicos e definições relacionadas aos problemas de Despacho Econômico.

2.1. Introdução

A função básica dos sistemas elétricos de potência é suprir os consumidores com energia elétrica da forma mais econômica e confiável possível. Sistemas economicamente adaptados permitem o equilíbrio entre a oferta e a demanda da eletricidade, procurando o custo mínimo e mantendo a qualidade de suprimento (ELGERD, 1970).

Devido às complexidades inerentes, o planejamento operacional dos sistemas de geração de energia elétrica é, em geral, decomposto nos horizontes de longo, médio e curto prazos.

O planejamento da operação de longo prazo considera, em geral, uma discretização mensal que abrange o horizonte de até alguns anos à frente. O objetivo é obter uma política de geração para o período, levando em consideração as restrições operativas do sistema e a estocasticidade das vazões, e estabelecer custos para o médio prazo.

O planejamento de médio prazo determina as metas semanais de operação de cada usina, de forma que o custo operacional do sistema ao longo do horizonte seja mínimo, respeitando as restrições operacionais e os requisitos do sistema e seja compatível com o planejamento de longo prazo.

O planejamento da operação de curto prazo em sistemas de energia elétrica é um problema que determina as gerações das unidades térmicas e hidráulicas para o dia seguinte com um horizonte de tempo semanal e discretização horária. Em seguida deve-se compatibilizar os resultados do curto prazo com a operação em tempo real.

A operação em tempo real (*online*) requer respostas rápidas para que possam ser tomadas as devidas ações de controle no sistema. A operação em tempo real é feita utilizando-se uma série de ferramentas, denominadas de funções avançadas, tais como o estimador de estado, fluxo de carga do operador, fluxo de potência ótimo, análise de segurança, etc.

Na medida em que se aproxima a operação em tempo real, a modelagem elétrica do sistema deve ser mais detalhada, representando de forma mais precisa

o sistema de transmissão e as unidades geradoras.

2.2. Despacho Econômico

De forma bastante geral, matematicamente, o problema do Despacho Econômico consiste em se otimizar uma função escalar de custo, ou critério de custo, da forma:

$$C = C(\boldsymbol{x},\boldsymbol{u},\boldsymbol{p}) \tag{2.1}$$

sendo que devem ser satisfeitas certas condições de igualdade e desigualdade do tipo:

$$\mathbf{h}(\boldsymbol{x},\boldsymbol{u},\boldsymbol{p}) = 0 \tag{2.2}$$

$$\mathbf{g}(\boldsymbol{x},\boldsymbol{u},\boldsymbol{p}) \leq 0 \tag{2.3}$$

O problema exposto acima é dependente das variáveis $\boldsymbol{x}$, $\boldsymbol{u}$ e $\boldsymbol{p}$ que são, respectivamente, as variáveis de estado, controle e perturbação do sistema em questão. As variáveis de controle, também denominadas variáveis independentes, podem ser escolhidas dentro de certos limites práticos pelo operador. Essa escolha determinará as variáveis dependentes ou de estado. Esse estado é caracterizado por uma certa freqüência, um certo perfil de tensão e uma estrutura de fluxo de carga. As variáveis não controladas ou de perturbação, estão fora da influência dos operadores do sistema.

O número de restrições, ou seja, as dimensões dos vetores **h** e **g**, não necessitam ser relacionadas com o número de variáveis de estado e de controle. Este problema será linear se as equações (2.1) e (2.2) e a inequação (2.3) forem lineares quanto às suas variáveis, porém algumas destas relações geralmente são não-lineares.

Muitos problemas de Despacho Econômico foram propostos na literatura apresentando diferentes níveis de representação para os sistemas de transmissão e geração. Uma revisão dos avanços desta área é discutida em (CHOWDHURY *et al.*, 1990).

Problemas de DE têm sido resolvidos por uma variedade de técnicas de otimização, tais como: fluxo em rede (LUO *et al.*, 1984), programação quadrática

(REID *et al.*, 1973), método de pontos interiores (YAN *et al.*,1997), etc.

Algumas aplicações efetivas de redes neurais artificiais em problemas de Despacho Econômico (DE) têm sido apresentadas na literatura.

Uma abordagem buscando unificar o problema de *unit commitment* e funções de despacho de geração é descrita em (WALSH *et al.*, 1997). Nesta abordagem é proposta uma rede de Hopfield híbrida, uma vez que a função de energia desta rede é capaz de lidar com termos discretos e contínuos.

Uma rede neural de Hopfield (PARK *et al.*, 1993) é proposta para resolver um problema de DEC com funções de custo não-convexas. O esforço computacional para resolver o problema é alto devido ao grande número de iterações para obter a precisão desejada.

Em (SU *et al.*, 1997a) é proposto um método analítico de Hopfield reduzindo consideravelmente este esforço computacional. Entretanto, o método não é aplicável a funções de custo não-convexas. Um modelo de Hopfield para problemas de DE considerando zonas proibidas é desenvolvido em (SU *et al.*, 1997b).

A maioria das aplicações neurais descritas apresenta problemas de convergência para os pontos de equilíbrio que representam soluções factíveis para o problema de despacho. Uma análise cuidadosa dos resultados apresentados em alguns destes artigos revela que soluções infactíveis são, algumas vezes, obtidas (SILVA *et al.*, 2001). Na abordagem de Hopfield modificada proposta em (SILVA *et al.*, 2001) para resolver o problema de Despacho Econômico Clássico, a função custo e as restrições envolvidas no mapeamento do problema são tratadas em diferentes estágios. A abordagem de Hopfield modificada tem tido melhores resultados na convergência da rede para soluções ótimas factíveis (SILVA *et al.*, 2000). Os problemas associados com velocidade de convergência, descritos em (WALSH *et al.*, 1997) e em (PARK *et al.*, 1993), são também satisfatoriamente tratados em (SILVA *et al.*, 2001). Como demonstrado em (SILVA *et al.*, 2000), a rede de Hopfield modificada é também aplicável se funções de custo não-convexas são utilizadas no problema de despacho.

As abordagens baseadas em Algoritmos Genéticos lidam de forma simples

com todos os tipos de problemas que geralmente representam obstáculos para a pesquisa operacional: variáveis inteiras, funções não-convexas, funções não-diferenciáveis, múltiplos ótimos locais, múltiplos objetivos, etc (MIRANDA *et al.*, 1998). Também, a habilidade dos Algoritmos Genéticos no tratamento de quaisquer tipos de restrições na forma de funções de penalidade ou por usar vários esquemas de codificação dos cromossomos de um problema específico (CHEN *et al.*, 1995) facilita sua utilização.

Atualmente, no setor elétrico, os Algoritmos Genéticos vêm sendo aplicados no planejamento ótimo de redes de distribuição (MIRANDA *et al.*, 1998), planejamento de sistemas de transmissão (RUDNICK, 1995), solução do problema de pré-despacho e despacho econômico de geração (BAKIRTZIS *et al.*, 1994), (BAKIRTZIS *et al.*, 1996) e (WONG *et al.*, 1996), despacho envolvendo pontos de válvula (BAKIRTZIS *et al.*, 1994) e (SHEBLE' *et al.*, 1993), *unit commitment* (KAZARLIS *et al.*, 1996), operação em zonas proibidas (ORERO *et al.*, 1996), planejamento hidrotérmico (MA *et al.*, 1996), planejamento de sistema de distribuição (LEVITIN *et al.*, 1995), etc.

Em (LAI *et al.*, 1997), o problema de Fluxo de Potência Ótimo (FPO) é resolvido utilizando um Algoritmo Genético Simples. As variáveis de controle são as potências ativas de geração e as tensões. Fluxos nos ramos, geração reativa e restrições das magnitudes das tensões são tratados como termos quadráticos de penalidade na função de aptidão do Algoritmo Genético.

Um Algoritmo Genético Melhorado para solucionar o FPO é apresentado em (LI *et al.*, 1997) com variáveis de controle discretas e contínuas. As variáveis de controle contínuas incluem as potências e ativas tensões das unidades geradoras, enquanto as variáveis de controle discretas são representadas pelo conjunto de *taps* de transformadores e dispositivos de chaveamento. Várias restrições operacionais funcionais, tais como limites de fluxo nos ramos, limites de magnitude de tensão das barras de carga e capacidades reativas do gerador são incluídos como penalidade na função de aptidão do Algoritmo Genético.

A formulação dos modelos de DE adotados é apresentada em ordem de complexidade, começando com o problema mais simples até os mais

representativos.

O primeiro estudo considera o problema de Despacho Econômico Clássico (DEC). O DEC se preocupa com a minimização dos custos operacionais totais enquanto supre integralmente a demanda do sistema e impõe limites aos níveis de geração. Modelos de DEC são limitados para problemas de otimização puramente ativos, levando em consideração as perdas, mas desprezando todos os aspectos relacionados à representação da rede de transmissão. Nos estudos subseqüentes, o problema de Despacho Econômico é formulado como um problema de Fluxo de Potência Ótimo DC, onde o sistema de transmissão é representado por equações de fluxo de carga lineares e limites nos fluxos de potência ativa. A seguir são introduzidas as perdas na transmissão e finalmente estuda-se um despacho de geração para sistemas hidrotérmicos.

2.3. Problema de Despacho Econômico Clássico

Nesta categoria, a primeira formulação adotada refere-se ao Despacho Econômico Clássico (DEC). O problema de DEC é formulado da seguinte forma:

$$\text{DEC} \begin{cases} \text{Min} & C_T = \sum_{i=1}^{n} C_i\left(P_{Gi}\right) & (a) \\ \text{s. a. :} & & \\ & P_{Gi}^{\min} \le P_{Gi} \le P_{Gi}^{\max} & (b) \\ & \sum_{i=1}^{n} P_{Gi} = P_D + P_L & (c) \end{cases} \tag{2.4}$$

onde:

P_{Gi}: potência ativa gerada pela unidade geradora *i*;

C_T: é o custo total de produção;

n: é o número de unidades geradoras;

$C_i\,(P_{Gi})$: é a função custo total de geração da unidade i;

$P_{Gi}^{\min}$: é a mínima geração de saída do gerador *i*;

$P_{Gi}^{\max}$: é a máxima geração de saída do gerador *i*;

P_D: é a demanda total do sistema;

P_L: é a perda total do sistema.

A equação (2.4b) representa os limites de geração do gerador *i*. As restrições de igualdade representadas pela equação (2.4c) são obtidas a partir do balanço estático de potência total do sistema.

A função custo $C_i(P_{Gi})$do problema pode assumir várias formas, dependendo do tipo do gerador e do nível de representatividade que se deseja adotar. Para geradores térmicos, o custo de geração de cada unidade é descrito como uma função do tipo $C1 = C_i(P_{Gi}) = a_i + b_i P_{Gi} + c_i P_{Gi}^2 + \left| e_i sen\left(f_i \left(P_{Gi}^{\min} - P_{Gi} \right) \right) \right|$; onde: a_i, b_i e c_i são constantes de custo para a unidade *i* e e_i e f_i são as constantes relativas aos pontos de válvula.

Na prática, a função custo de cada unidade de geração térmica é obtida através dos estudos de exigências de calor e potência elétrica, denominados testes de calor (NOYOLA *et al.*, 1990). Quando se estuda, detalhadamente as curvas de custo obtidas através dos testes de calor, é possível verificar que os efeitos de operação da válvula de admissão de vapor das turbinas produzem ondulações sobre a curva de custo de cada unidade de geração. Estes efeitos são denominados pontos de válvula e são considerados a partir do valor absoluto de uma função senoidal (conforme equação *C1*). Como a função *C1* apresenta características de não diferenciabilidade, em muitas abordagens o que se faz é simplesmente desprezar o ponto de válvula através da expressão de custo $C2 = C_i(P_i) = a_i + b_i P_i + c_i P_i^2$. As funções de custos *C1* e *C2*, para uma das unidades térmicas da seção de resultados, são mostradas na Figura 2.1 a seguir.

A consideração das características não-lineares e pontos de válvula apresentam dificuldades tais como as descontinuidades da derivada da função custo e vários pontos de ótimos locais. Neste caso, o problema pode ser solucionado utilizando Programação Dinâmica (PD), que trabalha diretamente por enumeração de todas as possíveis soluções e avalia o problema em estágios (que correspondem às estratégias de operação), escolhendo o estado ótimo (que corresponde ao despacho com custo mínimo) de forma recursiva. As dimensões

deste problema podem se tornar extremamente grandes e cada estágio pode exigir avaliações excessivas das relações recursivas (SHOULTS *et al.*, 1986). Os algoritmos genéticos não apresentam dificuldades em lidar com tais funções. Assim, a motivação básica para a aplicação de AG para a solução de problemas de DE reside basicamente no comportamento da função objetivo descrito na Figura 2.1. Os AG têm facilidade de se adaptar a problemas com características não-lineares e que não precisam que a derivada da função objetivo seja estritamente contínua no espaço $\Re^n$ considerado. Outro ponto que também motiva a aplicação de AG para a solução do problema está relacionado a um melhor mapeamento do espaço de otimização.

O problema de DEC é descrito para um sistema de energia predominantemente térmico. O Brasil tem grande parte da sua matriz energética constituída de geração hidráulica, o que torna o sistema hidrelétrico brasileiro bastante diferente dos sistemas americano e europeu.

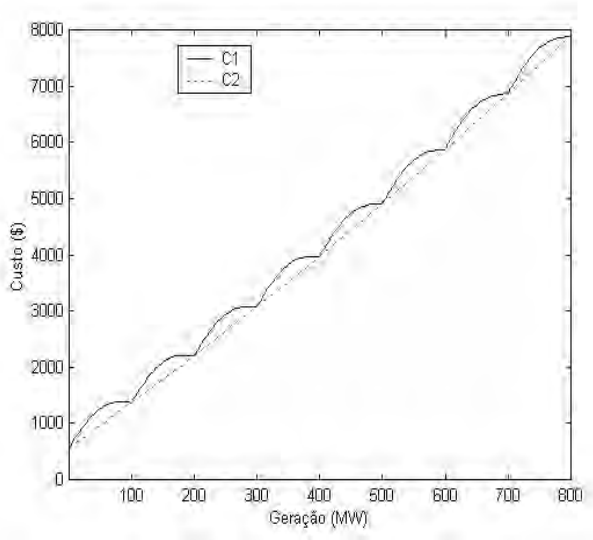

FIGURA 2.1 - Funções típicas de custo de geração para unidades de geração térmica.

Para as unidades hidráulicas a função que melhor tem representado o problema de despacho é a função de perdas na geração proposta em (SOARES *et al.*, 1997). Esta função é calculada de forma a representar as perdas no sistema de geração relacionadas com: o rendimento da máquina, a altura de queda de jusante

e as perdas nas tubulações. Estão mostradas no gráfico da Figura 2.2 várias situações de perdas para uma usina, a qual pode operar com 1, 2, 3 ou 4 unidades de geração. Por simplicidade, as quatro situações de perdas são mostradas ao mesmo tempo no gráfico. As faixas de cavitação também são mostradas.

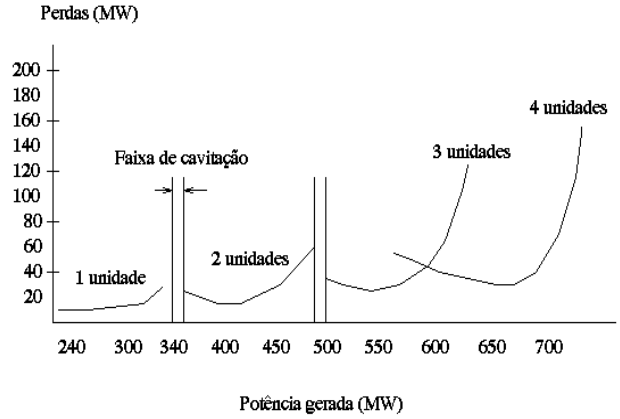

FIGURA 2.2 - Funções típicas de custo de perdas para unidades de geração hidráulicas.

2.3.1. Resolvendo o DEC para um Sistema com Duas Barras

Com o objetivo de explicar didaticamente as características gerais do DEC e explorar os conceitos fundamentais a ele relacionados, o problema é solucionado a seguir, para um sistema com apenas duas barras sem considerar os pontos de válvula.

Escolhemos trabalhar inicialmente com apenas duas barras pelo fato de sua interpretação geométrica ser de simples compreensão (Figura 2.3). Na seqüência, o estudo de um sistema de *n* barras será compreendido com maior facilidade.

Como existem apenas duas barras, *n*=2 e desprezando as perdas, as equações (2.4a) e (2.4c) resumem-se a:

$$C_T = C_1(P_{G1}) + C_2(P_{G2}) \tag{2.5}$$

$$h(P_{G1}, P_{G2}) = P_{G1} + P_{G2} - P_D = 0 \tag{2.6}$$

Considerando:

$$C_1 = a_1 + b_1 P_{G1} + c_1 P_{G1}^2 \tag{2.7}$$

$$C_2 = a_2 + b_2 P_{G2} + c_2 P_{G2}^2 \tag{2.8}$$

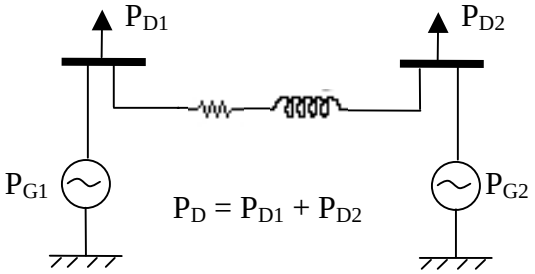

FIGURA 2.3 - Sistema com duas barras

O custo mínimo de geração será em $P_{G1} = P_{G2} = 0$. Esta, porém, é a solução trivial que não nos interessa, pois o sistema não pode funcionar neste ponto. O sistema deve satisfazer a equação de restrição (2.6) que representa a "superfície de restrição" (neste caso, um plano). Procura-se o ponto de mínimo dessa função, que estará na intersecção entre a curva e o plano que é definido pelas restrições do problema. Esse ponto é chamado de *mínimo restrito*.

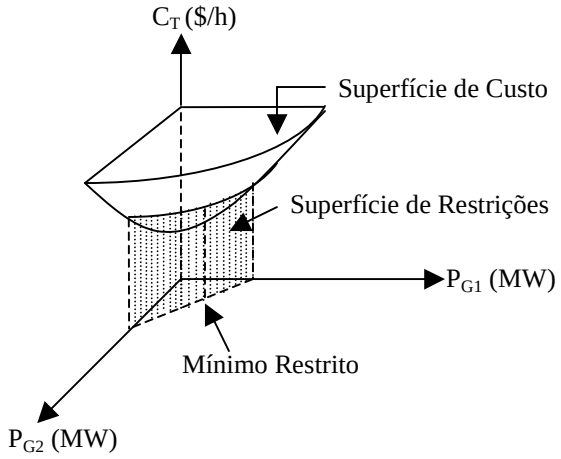

FIGURA 2.4 - Representação gráfica do problema.

O problema, neste momento, está limitado a encontrar este ponto mínimo restrito. A Figura 2.5, extraída do livro de ELGERD (1970), nos mostra uma nova visão da figura anterior, onde a superfície da Figura 2.4 é cortada por um plano horizontal. As intersecções obtidas são os contornos *eqüi-custos*, ao longo dos quais o custo C_T é constante.

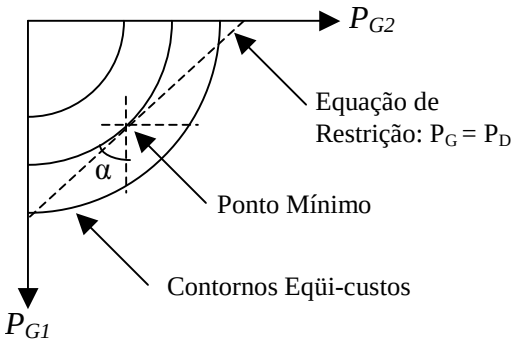

FIGURA 2.5 - Curva de nível da função custo

Observando a figura, nota-se um importante dado: a linha de restrição tangencia o ponto que se está procurando. Esta informação será utilizada mais adiante.

Inicialmente, a inclinação do contorno de custo é encontrada pela diferenciação da própria função custo, que será:

$$dC_T = \frac{\partial C_T}{\partial P_{G1}} dP_{G1} + \frac{\partial C_T}{\partial P_{G2}} dP_{G2} = 0 \tag{2.9}$$

A equação anterior é igual a zero por estar sendo diferenciada a função C_T em uma de suas curvas de nível.

Para a inclinação, tem-se:

$$\frac{dP_{G2}}{dP_{G1}} = \frac{\dfrac{\partial C_T}{\partial P_{G1}}}{\dfrac{\partial C_T}{\partial P_{G2}}} \tag{2.10}$$

A diferenciação da restrição de igualdade, definida em (2.6) fornece também:

$$\frac{dP_{G2}}{dP_{G1}} = -\frac{\dfrac{\partial h}{\partial P_{G1}}}{\dfrac{\partial h}{\partial P_{G2}}} \tag{2.11}$$

Utilizando-se da observação gráfica que foi feita no início deste equacionamento, que nos prova a exigência de tangência, resulta:

$$\frac{\dfrac{\partial C_T}{\partial P_{G2}}}{\dfrac{\partial C_T}{\partial P_{G1}}} = \frac{\dfrac{\partial h}{\partial P_{G2}}}{\dfrac{\partial h}{\partial P_{G1}}} = -\tan(\alpha) \tag{2.12}$$

A equação anterior pode ser escrita na forma:

$$\frac{\dfrac{\partial C_T}{\partial P_{G2}}}{\dfrac{\partial h}{\partial P_{G2}}} = \frac{\dfrac{\partial C_T}{\partial P_{G1}}}{\dfrac{\partial h}{\partial P_{G1}}} = const \triangleq \lambda \tag{2.13}$$

A constante λ é chamada de *multiplicador de Lagrange*.

As equações (2.13) podem ser separadas em duas, de modo que:

$$\frac{\partial C_T}{\partial P_{G1}} - \lambda \frac{\partial h}{\partial P_{G1}} = 0 \tag{2.14}$$

$$\frac{\partial C_T}{\partial P_{G2}} - \lambda \frac{\partial h}{\partial P_{G2}} = 0 \tag{2.15}$$

Se for definida uma função de custo restrito do tipo:

$$C_T^* \triangleq C_T - \lambda h = C_1 + C_2 - \lambda\left(P_{G1} + P_{G2} - P_D\right) \tag{2.16}$$

Então, pode-se concluir que o mínimo restrito é caracterizado por:

$$\frac{\partial C_T^*}{\partial P_{G1}} = 0 \tag{2.17}$$

$$\frac{\partial C_T^*}{\partial P_{G2}} = 0 \tag{2.18}$$

Com as definições acima, pode-se dizer que o problema do despacho está resolvido matematicamente. Para que o problema se torne aplicável, é necessário que algumas considerações físicas sejam ponderadas neste momento. Então, antes de trabalhar com as equações (2.10) e (2.11), encontra-se as derivadas parciais de (2.5) e (2.6):

$$\frac{\partial h}{\partial P_{G1}} = \frac{\partial h}{\partial P_{G2}} = 1$$

$$\frac{\partial C_T}{\partial P_{G1}} = \frac{\partial C_1}{\partial P_{G1}}$$

$$\frac{\partial C_T}{\partial P_{G2}} = \frac{\partial C_2}{\partial P_{G2}}$$

Substituindo, então, estes dados obtidos nas equações (2.10) e (2.11):

$$\frac{\partial C_1}{\partial P_{G1}} = \frac{\partial C_2}{\partial P_{G2}} = \lambda \tag{2.19}$$

Este último resultado mostra como o sistema deve funcionar a fim de satisfazer as condições de despacho ótimo. Estas duas equações e a equação $\frac{\partial C_T^*}{\partial \lambda} = 0$ são suficientes para a determinação das três incógnitas P_{G1}, P_{G2} e λ. Isto porque estamos trabalhando com o chamado *custo incremental (IC)* de geração, que é definido como:

$$IC = \frac{\partial Ci}{\partial P_{Gi}} \tag{2.20}$$

Desta forma, a equação (2.19) diz que os custos incrementais de cada unidade geradora deverão ser os mesmos em todo o sistema. Com isso, o problema do despacho econômico, sem serem consideradas as restrições de desigualdade, está resolvido.

2.3.2. DEC Considerando-se as Restrições de Desigualdade

Quando se definiu o problema do DEC, foi observado que a geração ótima de cada unidade deve permanecer dentro dos limites operacionais factíveis, isto é, as restrições de desigualdade devem ser observadas. Caso um desses geradores excedesse esse valor, os outros deveriam ser equacionados de modo a suprir a carga deficiente desse gerador em questão.

No caso de existirem apenas dois geradores, fica evidente que um dos geradores gera o restante da potência ativa de modo a suprir toda a demanda, eliminando maiores problemas no equacionamento. Esta conclusão não ficará tão óbvia quando forem consideradas *n* unidades geradoras, que é o caso que será visto a seguir.

2.3.3. DEC para um Sistema com *n* Barras

De maneira totalmente análoga se desenvolve o equacionamento para este novo sistema de *n* barras. O único inconveniente, neste caso, é que não existe mais uma interpretação gráfica para o problema como um todo.

Neste caso existirão *n* equações, ao invés de duas, a serem satisfeitas:

$$\frac{\partial C_T^*}{\partial P_{Gi}} = 0 \text{ , } i = 1, 2, ..., n \tag{2.21}$$

Define-se, agora, como equação de custo restrito:

$$C_T^* \triangleq C_1 + C_2 + ... + C_n - \lambda\left(\sum_{i=1}^{n} P_{Gi} - P_D\right) \tag{2.22}$$

A fim de se obter uma estratégia ótima de despacho para o caso de *n* barras, substitui-se a equação (2.22) em (2.21), resultando:

$$\frac{\partial C_i}{\partial P_{Gi}} = (IC)_i = \lambda^* \tag{2.23}$$

Nota-se que para as *n* equações definidas em (2.23), em conjunto com a equação do balanço estático do sistema, são suficientes para se determinar as *n+1* variáveis do sistema (potências ativas ótimas e o multiplicador de Lagrange).

A Figura 2.6 apresenta uma interpretação geométrica bastante interessante do problema em questão. O valor λ^* representa o ponto ótimo do sistema. Os pontos onde esta linha intercepta as linhas verticais de cada unidade geradora indicam o valor de geração de cada unidade quando em configuração ótima. Esta figura nos faz imaginar o que aconteceria caso a linha horizontal excedesse o valor máximo de um gerador. Fisicamente, isto representaria que a potência ótima para esta unidade geradora em questão estaria acima da sua própria capacidade máxima de geração.

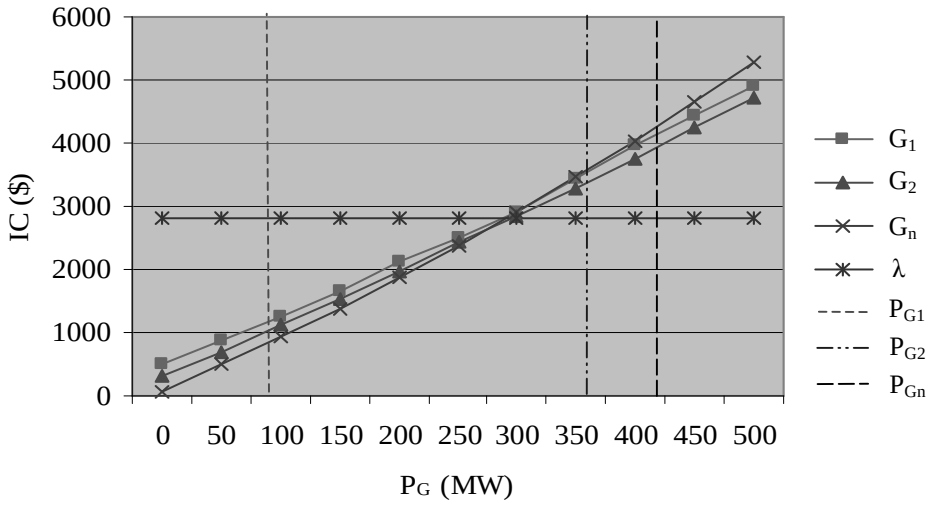

FIGURA 2.6 - Representação gráfica do despacho ótimo para n barras

O multiplicador de Lagrange é igual para todas as unidades quando operam dentro de seus limites de geração. As restrições de desigualdade ou de geração das unidades são consideradas da seguinte forma:

$$\frac{\partial C_i}{\partial P_{Gi}} = \lambda \text{ ; para } P_{Gi}^{\min} \le P_{Gi} \le P_{Gi}^{\max} \quad \text{(a)}$$

$$\frac{\partial C_i}{\partial P_{Gi}} \le \lambda \text{ ; para } P_{Gi} = P_{Gi}^{\max} \quad \text{(b)} \qquad (2.24)$$

$$\frac{\partial C_i}{\partial P_{Gi}} \ge \lambda \text{ ; para } P_{Gi} = P_{Gi}^{\min} \quad \text{(c)}$$

2.4. Problema de Despacho Econômico com Representação do Sistema de Transmissão

O problema de DEC despreza todos os aspectos relacionados à representação da rede de transmissão. Com o intuito de obter uma melhor representação do sistema, e conseqüentemente encontrar uma solução para o problema do DE que seja mais fiel à realidade, apresenta-se a seguir uma nova modelagem. Nesta modelagem o sistema de transmissão é representado por meio de equações de fluxo de carga linear, bem como restrições nos fluxos de potência ativa nas linhas.

2.4.1. Equacionamento e Dados Iniciais do Problema

Para o problema da representação do sistema, novas equações serão incluídas na modelagem matemática, as chamadas Equações de Fluxo de Carga Linear. Além destas, considera-se também as restrições de fluxo em cada linha. Este equacionamento é apresentado neste trabalho pelas equações (2.25a)-(2.25d):

$$\text{DE\_ST} \begin{cases} \text{Min} & C_T = \sum_{i=1}^{n} C_i(P_{Gi}) & (a) \\ \text{s. a. :} & \mathbf{P} = \mathbf{B}.\boldsymbol{\theta} & (b) \\ & P_{Gi}^{\min} \le P_{Gi} \le P_{Gi}^{\max} & (c) \\ & F_i^{\min} \le F_i(\boldsymbol{\theta}) \le F_i^{\max} & (d) \end{cases} \tag{2.25}$$

Analisando estas equações, pode-se notar que as equações (2.25a) e (2.25c) são as mesmas anteriormente definidas em (2.4a) e (2.4b), sendo a função custo uma equação quadrática. Como dito anteriormente, duas novas equações surgem no problema 2.25. As equações em (2.25b), que representam um conjunto de equações chamadas equações de fluxo de carga linear, fazem o balanço de potência ativa em cada barra. O vetor **P** é o vetor das injeções de potência em cada barra; **B** é uma matriz quadrada das susceptâncias de linha e **θ** é o vetor dos ângulos de tensão. As novas restrições de desigualdade, mostradas em (2.25d), representam os limites de transmissão em cada linha e são definidos da seguinte forma:

$$F_i(\boldsymbol{\theta}) = \frac{\boldsymbol{\theta}_k - \boldsymbol{\theta}_m}{\mathbf{x}_{km}} \tag{2.26}$$

sendo que F_i é o fluxo na linha i conectando as barras k e m, $\boldsymbol{\theta}_k$ é o ângulo de tensão na barra k e x_{km} é a reatância do ramo i conectando as barras k e m. A equação 2.26 representa os fluxos nas linhas também de forma linearizada.

2.5. Despacho Econômico Multi-Objetivo

Após a inclusão do sistema de transmissão na representação do sistema,

um novo termo é incorporado nesta seção à função custo de maneira a otimizar as perdas relacionadas ao sistema de transmissão.

O problema proposto nesta seção busca uma formulação para o DE que representa uma relação de compromisso entre os custos de geração e as perdas na transmissão.

Uma vez que se deseja ponderar a influência das perdas na geração e transmissão de energia elétrica, o problema será reformulado. Um novo termo será introduzido na função objetivo de modo a quantificar as perdas inerentes a determinada configuração do sistema. Este novo termo dado inicialmente em MW, deverá ser convertido em valores monetários com a utilização de um parâmetro β, conforme mostra a função custo (2.27a). Tal procedimento tem o intuito de estimar o custo de se gerar as perdas. A idéia inicial de modelagem aqui comentada foi proposta em (OLIVEIRA *et al*., 2003), onde as técnicas de fluxo de redes e pontos interiores são combinadas de modo a resolver o problema.

Desde que a função de custo total de geração, como poderá ser visto mais adiante, é separável em duas parcelas, trata-se agora de uma otimização conhecida como *multi-objetivo*.

2.5.1. Equacionamento do Problema

O modelo matemático para o problema, chamado na literatura de Despacho de Geração Ativa (DGA), é formulado conforme (2.27) a seguir (OLIVEIRA *et al.*, 2003):

$$\text{DGA}\begin{cases} \text{Minimizar} \quad C = \alpha\,\phi_l(\mathbf{F}) + \beta\,\phi_g(\mathbf{P}) & (a) \\ \text{sujeito a :} & \\ \mathbf{P} = \mathbf{B}.\boldsymbol{\theta} & (b) \\ P_{Gi}^{\min} \le P_{Gi} \le P_{Gi}^{\max} & (c) \\ F_i^{\min} \le F_i(\boldsymbol{\theta}) \le F_i^{\max} & (d) \end{cases} \tag{2.27}$$

Analisando estas equações, pode-se notar que as equações (2.27b), (2.27c) e (2.27d) são as mesmas anteriormente definidas em (2.25b), (2.25c) e (2.25d),

sendo que:

$\phi_l(\mathbf{F})$ é uma função quadrática representando as perdas no sistema de transmissão.

$\phi_g(\mathbf{P})$ é uma função quadrática associada às perdas de geração hidráulica (SOARES *et al.*, 1997) ou aos custos de geração térmica.

As funções, definidas em (2.27a), são escritas da seguinte forma:

$$\phi_l(\mathbf{F}) = \frac{1}{2}\mathbf{F}^T\mathbf{R}\mathbf{F} \tag{2.28}$$

$$\phi_g(\mathbf{P}) = \frac{1}{2}\mathbf{P}^T\mathbf{Q}\mathbf{P} + \mathbf{c}_p^T\mathbf{P} \tag{2.29}$$

onde **R** é uma matriz diagonal de resistências, **F** é o vetor de fluxos de potência ativa no sistema, **Q** é a matriz diagonal dos coeficientes associados aos termos quadráticos e $\mathbf{c_p}$ é o vetor de coeficientes associado aos termos lineares. A obtenção da matriz **Q** e de $\mathbf{c_p}$ para unidades hidráulicas é discutida em (SOARES, 1997). A obtenção de **Q** e $\mathbf{c_p}$ para unidades térmicas é feita conforme descrito na seção 2.3 (ver *C2*).

O Despacho Econômico Multi-Objetivo calcula o despacho ponderando os custos na geração e as perdas na transmissão respeitando as restrições de potência ativa em (2.27b), os limites de geração definidos em (2.27c) e os limites de fluxo nas linhas descritos em (2.27d). Sua solução visará à minimização de duas funções objetivo multiplicadas por constantes, α e β, que ponderam a influência de cada termo na solução final do problema.

2.6. Despacho para Sistemas Hidrotérmicos

O sistema elétrico brasileiro é formado basicamente de energia hidrelétrica e termoelétrica. Nesta seção descreve-se o modelo hidrotérmico.

As hidrelétricas são construídas onde há condições adequadas de vazão e desnível e utilizam um combustível que, embora renovável, tem sua oferta

dependente de onde, quando e quanto chove. Dentre as várias restrições existentes na produção de energia hidrelétrica, este problema trata o fenômeno de cavitação.

O fenômeno de cavitação ocorre em instalações hidráulicas quando bolhas de vapor se formam em regiões de baixa pressão. Este fenômeno normalmente produz resultados agressivos, tais como diminuição da eficiência de turbinas hidráulicas com queda de potência, vibrações, ruídos excessivos, etc. Assim, as faixas de cavitação são faixas nas quais unidades de geração hidráulica não podem operar.

O problema de Despacho Hidrotérmico é formulado conforme (2.30) a seguir:

$$
\begin{aligned}
&\textit{Min.} \quad C_T = \sum_{i=1}^{NT} CT_i(PT_{Gi}) + \sum_{j=1}^{NH} CH_j(PH_{Gj}) && (a)\\
&\textit{s.a.}: \qquad \mathbf{P} = \mathbf{B}.\boldsymbol{\theta} && (b)\\
&\qquad PT_{Gi}^{\min} \le PT_{Gi} \le PT_{Gi}^{\max} && (c)\\
&\qquad PH_{Gj}^{\min} \le PH_{Gj} \le PH_{Gj}^{\max} && (d)\\
&\qquad F_l^{\min} \le F_l(\boldsymbol{\theta}) \le F_l^{\max} && (e)\\
&\qquad PH_{Gj} < Cav_j^{\min} && (f)\\
&\qquad PH_{Gj} > Cav_j^{\max} && (g)
\end{aligned}
\tag{2.30}
$$

onde

C_T: é o custo total de produção;

CT_i (PT_{Gi}): é o custo total de geração térmica da unidade *i*;

NT: é o número de unidades geradoras térmicas;

PT_{Gi}: potência ativa gerada pela unidade geradora térmica *i*;

CH_j (PH_{Gj}): é o custo total de geração hidráulica da unidade *j*;

NH: é o número de unidades geradoras hidráulicas;

PH_{Gj}: potência ativa gerada pela unidade geradora hidráulica *j*;

$PT_{Gi}^{\min}$: é a mínima geração de saída da unidade geradora térmica *i*;

$PT_{Gi}^{\max}$: é a máxima geração de saída da unidade geradora térmica *i*;

$PH_{Gj}^{\min}$: é a mínima geração de saída da unidade geradora hidráulica *j*;

$PH_{Gj}^{\max}$: é a máxima geração de saída da unidade geradora hidráulica *j*;

F_l : é o fluxo na linha *l* conectando as barras *k* e *m* que representam os limites de transmissão em cada linha e são definidos da seguinte forma:

$$F_l(\boldsymbol{\theta}) = \frac{\boldsymbol{\theta}_k - \boldsymbol{\theta}_m}{\mathbf{x}_{km}} \tag{2.31}$$

$\boldsymbol{\theta}_k$: é o ângulo de tensão na barra *k*;

$\mathbf{x}_{km}$: é a reatância do ramo *i* conectando as barras *k* e *m*;

$F_l^{\min}$: é o limite mínimo de transmissão na linha *l*;

$F_l^{\max}$: é o limite máximo de transmissão na linha *l*;

$Cav_j^{\min}$: é o limite mínimo da faixa de cavitação da unidade geradora hidráulica *j*

$Cav_j^{\max}$: é o limite máximo da faixa de cavitação da unidade geradora hidráulica *j*

A função custo $CT_i(PT_{Gi})$ de cada unidade térmica é descrita como uma função do tipo:

$$C1 = CT_i(PT_{Gi}) = a_{Ti} + b_{Ti}PT_{Gi} + c_{Ti}PT_{Gi}^2 + \left|e_i sen\left(f_i\left(PT_{Gi}^{\min} - PT_{Gi}\right)\right)\right| \tag{2.32}$$

onde: a_{Ti}, b_{Ti} e c_{Ti} são constantes de custo para a unidade térmica *i* e e_i e f_i são as constantes relativas aos pontos de válvula.

No próximo capítulo será apresentada a técnica de otimização baseada em redes neurais artificiais para tratar os modelos de Despacho Econômico adotados neste trabalho.

CAPÍTULO 3

Redes Neurais Artificiais

Este capítulo apresenta uma introdução teórica e um histórico sobre as redes neurais artificiais, incluindo seus tipos básicos, arquiteturas e algoritmos de treinamento.

3.1. Introdução

Redes Neurais Artificiais (RNA) são modelos computacionais inspirados no cérebro humano com a capacidade de aprender a partir da experiência e generalizar o conhecimento. Em outras palavras, RNA podem ser definidas como um conjunto de unidades de processamento (neurônios) que são interligadas por um grande número de interconexões.

Os elementos computacionais ou unidades processadoras correspondem aos nós da rede e são modelos simplificados dos neurônios biológicos. Estes modelos foram obtidos a partir da análise da geração e propagação de impulsos elétricos pela membrana celular dos neurônios (HODGKIN *et al.*, 1952). Os neurônios utilizados nos modelos de redes neurais artificiais são não lineares, tipicamente analógicos, e realizam funções simples, como coletar os sinais existentes em suas entradas, agregá-los de acordo com sua função de ativação (saída) inerente. O modelo de neurônio mais simples e que engloba as principais características de uma rede neural biológica, paralelismo e alta conectividade, foi proposto por McCulloch e Pitts (McCULLOCH *et al.*, 1943).

Sistemas baseados em RNA possuem elevadas taxas de computação por utilizarem um número massivo de elementos processadores simples com alta taxa de conectividade entre si.

As Redes Neurais Artificiais podem ser utilizadas em uma vasta classe de problemas encontrados em várias áreas de aplicação: classificação, identificação, diagnóstico, análise de sinais e de imagens, otimização, controle, etc.

Desde alguns anos atrás, com as novas descobertas na área, as redes neurais têm se mostrado de fácil implementação, robustas no tratamento de dados com ruído, e eficientes, especialmente nos problemas em que não temos formulação analítica ou não temos um conhecimento explícito acessível. A utilização de uma rede neural em um determinado problema dependerá da adaptabilidade dessa rede ao problema em estudo, visando sempre o aumento da eficiência.

A primeira abordagem baseada em sistemas inteligentes estudada neste trabalho está intrinsecamente relacionada com a aplicação de RNA na área de

otimização e identificação de sistemas. Mais especificamente, uma Rede de Hopfield Modificada é desenvolvida com a finalidade de resolver o problema do Despacho Econômico.

3.2. Histórico

As RNA foram inicialmente desenvolvidas no decorrer da década de 40 por Warren McCulloch, um neurofisiologista do MIT, e por Walter Pitts, um matemático da universidade de Illinois. Eles simularam uma rede por meio de potenciômetros (resistores variáveis) e amplificadores representando as conexões sinápticas de um neurônio. Sua origem também é atribuída ao psicólogo Donald Hebb, em seu livro *Organization of Behavior*, de 1949, onde descreveu pela primeira vez o funcionamento sináptico e o processo de treinamento das capacidades humanas. Segundo Hebb, se um neurônio A é repetidamente estimulado por um neurônio B, ele ficará mais sensível aos estímulos de B e a conexão de B para A será mais eficiente.

Em 1956 foi realizada a 1ª Conferência Internacional de Inteligência Artificial. Na oportunidade, o pesquisador Nathaniel Rochester, da IBM, apresentou um modelo de rede neural artificial. Seu sistema consistia de centenas de neurônios interconectados a fim de verificar como a rede responderia aos estímulos ambientais.

Em 1959, Rosemblatt reunindo as idéias de Hebb, McCulloch e Pitts, descreveu o primeiro modelo de rede neural, o Perceptron. Arranjando os neurônios em uma topologia particular e modificando as conexões entre as sinapses, o Perceptron poderia aprender funções lógicas.

Em 1962, Widrow e Hoff desenvolveram uma rede neural que utiliza um algoritmo supervisionado para minimizar o erro entre as entradas e as saídas, denominados ADALINE (Adaptive Linear Element).

Mas foi em 1969 que uma publicação realmente freou os estudos em RNA's. Mavin Minsky e Seymour Papert, dois cientistas renomados da época, publicaram o livro homônimo (MINSKY; PAPERT, 1969) ao de Rosemblatt no qual criticavam veementemente as pesquisas em redes neurais, alegando que

utilizavam métodos empíricos e contradiziam algumas operações booleanas. O impacto desta publicação foi devastadora. Grandes partes dos investimentos foram retraídas, encerrando a primeira onda de estudos em RNA.

O período de estagnação, conhecido como segunda onda, iniciou-se em 1969 e perdurou até 1982 quando John Hopfield, físico e biólogo do instituto de Tecnologia da Califórnia, contestou (com sucesso) as críticas feitas em 69 por Minsky e Papert. Com isso, ressurgiu o interesse nessa área e aumentaram os investimentos em projetos (início da terceira onda). Seus estudos propuseram um modelo onde a memória do sistema era armazenada nas interconexões entre as unidades neurais (HOPFIELD, 1982) Após a publicação de Hopfield, uma avalanche de trabalhos desenvolvidos na segunda onda foram apresentados para a comunidade científica. Neste mesmo ano, foi realizado em Kioto (Japão) a 1ª Conferência Conjunta Estados Unidos – Japão sobre redes neurais artificiais.

Já em 1986, o professor de psicologia de Standford University, David E. Rumelhart, e seu colega, James L. McClelland, professor de psicologia da Carnegie-Mellon University, publicaram o famoso livro *Parallel Distributed Processing: Explorations in the Microstructure of Cognition* (RUMELHART; MCCLLELLAND, 1986). Nele, é apresentado pela primeira vez um modelo matemático e computacional que propicia o treinamento supervisionado dos neurônios artificiais, o algoritmo *back-propagation*, o qual é um algoritmo de otimização global sem restrições. Seu descobrimento foi de grande valia para os avanços em RNA.

3.3. Neurônio Biológico

O processamento de informações no cérebro é altamente complexo, não-linear e paralelo.

A célula nervosa, ou simplesmente neurônio, representada pela Figura 3.1 (TAFNER *et al.*, 1995), é a principal componente do sistema nervoso. Existem diversos tipos de neurônios, mas basicamente eles constituem-se dos mesmos componentes básicos:

- *corpo do neurônio:* também chamado de *soma*, constituído de núcleo e pericário, que dá suporte metabólico à toda célula;
- *axônio:* conhecido também como *fibra nervosa*, é um prolongamento único e extenso que aparece no soma. É o responsável pela condução do impulso nervoso para o próximo neurônio, podendo ser ou não revestida por mielina (bainha axonial);
- *dendritos:* são prolongamentos na forma de ramificações encontrados no soma e no final do axônio, sendo responsáveis pela maioria das comunicações entre neurônios através de sinapses. Basicamente cada neurônio possui uma região receptiva e outra efetora.

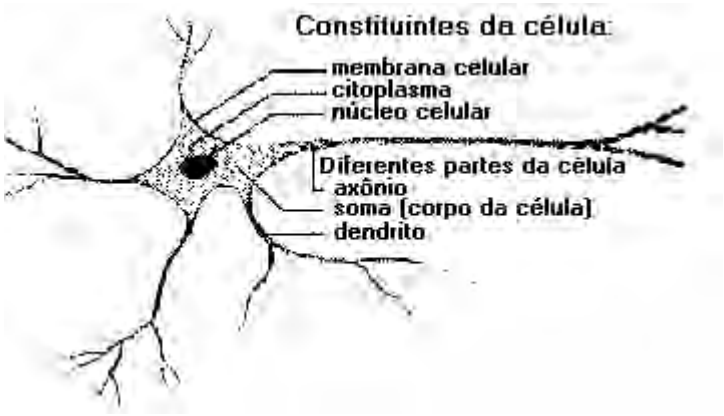

FIGURA 3.1 - Esquema de um neurônio natural

3.4. Neurônio Artificial

O neurônio artificial é a menor unidade de uma rede neural. Na literatura mundial também é chamado de unidade de processamento, elemento de processamento ou, simplesmente, nodo. O nome foi dado justamente por ter a intenção de simular o trabalho de um neurônio biológico.

Uma rede neural constitui-se de *N* unidades de processamento (Figura 3.2), cujo funcionamento é simples.

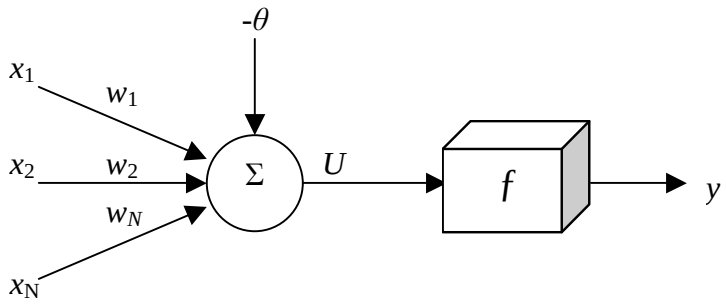

FIGURA 3.2 - Esquema da unidade de processamento

Segundo a proposição feita na década de 40, por McCullouch e Pitts, uma unidade de processamento de uma rede se comporta da seguinte maneira:

- Sinais (x_1, x_2, ..., x_N) são apresentados na entrada. Cada unidade de processamento trabalha sobre as entradas (x_1, x_2, ..., x_N), que substituem os dendritos. As entradas de um neurônio artificial são os estímulos que este neurônio recebe. Esses estímulos são trazidos para o neurônio simultaneamente. Isto significa dizer que o processamento do neurônio é do tipo paralelo, sendo também possível a simulação de um ambiente paralelo por meio de processamentos seqüenciais (computadores convencionais).
- Cada sinal é multiplicado por um número (w_1, w_2, ..., w_N), que indica sua influência na saída. Ou seja, as ligações das entradas com o corpo celular artificial são realizados através de elementos chamados pesos sinápticos (w_1, w_2, ..., w_N), simulando as sinapses naturais. Pesos sinápticos são vistos matematicamente como um vetor de valores (w_1, w_2, ..., w_N). Estes vetores possuem valores que variam entre 0 e 1, inclusive, que indicam a importância daquela entrada na resposta de saída. Um valor 0 indica total exclusão e 1, completa pertinência. Havendo mais de um neurônio, podemos ter uma coleção de vetores, constituindo uma matriz de pesos, onde cada vetor corresponde a um neurônio.

- Os estímulos captados pelas entradas são processados pela função soma que realiza as somas ponderadas dos sinais, produzindo assim um nível de atividade. As funções de ativação *g(.)* (HAYKIN, 1994) e de transferência *f* fazem parte da composição do neurônio artificial. A função de ativação, que antecede a de transferência, impõe um nível de ativação dentro do próprio neurônio. Ou seja, é uma função interna que tem por objetivo decidir se o valor resultante *U* do somatório das entradas ponderadas é suficiente para ativar a saída *y* do neurônio. Em termos matemáticos, tem-se:

$$U = \sum_{i=1}^{N} w_i x_i - \theta \text{ e } y = g(U) \tag{3.1}$$

onde θ é o limiar de ativação.

Em muitos casos, essa função é a própria função de soma das entradas ponderadas. Já a função de transferência *f* (limiar lógico ou *threshold*) trabalha para que ocorra a sinapse, isto é, a transferência de informação de um neurônio a outro. Em alguns modelos de redes, o nível de saída produzido por esta função é igual ao nível de ativação. Muitas vezes essa função possui características sigmas ou bipolares (Figura 3.3). Assim, o neurônio pode não produzir efeito no neurônio seguinte se o valor de ativação estiver abaixo de um valor mínimo para que ocorra esta ativação. As funções rampa e degrau possuem decisões ríspidas, principalmente para valores extremos. Essas funções refletem a saída dentro de uma faixa. Isto quer dizer que, ultrapassando certo limite, a função dispara o valor 0, 1 ou –1. As funções sigmas são utilizadas normalmente para decisões onde as saídas limites são disparadas quando existe uma saturação muito mais alta que o valor de ativação. Isto significa dizer que para obtermos um 0 de saída em uma função sigma do tipo $y = 1/(1+e^{-x})$ precisaríamos de um valor passado da função de ativação muito alto e negativo. Seguindo o mesmo raciocínio, para obtermos um valor de saída 1, o valor passado da função de ativação deveria ser muito alto e positivo. Esta função

realiza a transição entre os extremos de maneira suave. Transmitido a informação ou não, este resultado apresentado na saída do neurônio é muito significativo à rede como um todo. A lógica neural expõe que a intensidade dos sinais de entrada dispara, ou não, o sinal do neurônio, fazendo com que este estimule o neurônio seguinte.

Função Degrau
(Bipolar)

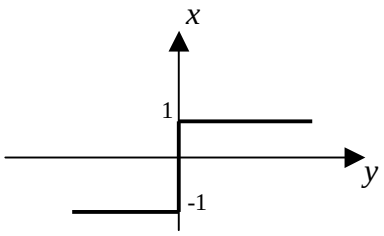

$$y = \begin{cases} -1, & se \quad x < 0 \\ 1, & se \quad x \geq 0 \end{cases}$$

Função Rampa

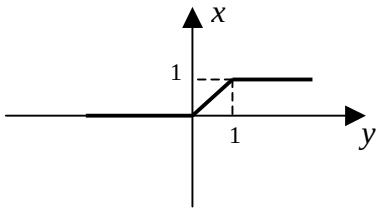

$$y = \begin{cases} 0, & se \quad x < 0 \\ x, & se \quad 0 \leq x \leq 1 \\ 1, & se \quad x > 1 \end{cases}$$

Função Sigmóide
(sigma)

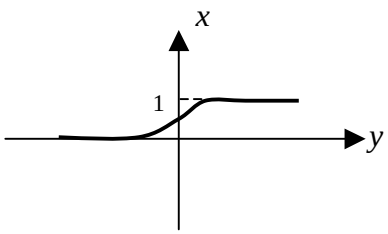

$$y = \frac{1}{\left(1 + e^{-x}\right)}$$

Função Sigmóide
(tangente-sigma)

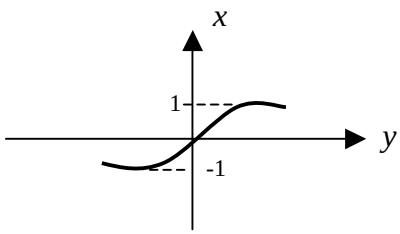

$$y = \begin{cases} 1 - \dfrac{1}{(1+x)}, & se \quad x \geq 0 \\ -1 + \dfrac{1}{(1-x)}, & se \quad x < 0 \end{cases}$$

FIGURA 3.3 - Funções de transferência mais usadas

Uma rede neural qualquer pode possuir quantas unidades de processamento forem necessárias. Geralmente elas são organizadas em camadas (Figura 3.4), que são classificadas em 3 grupos:

- *Camada de Entrada*: onde os padrões são apresentados à rede.

- *Camadas Intermediárias ou Escondidas*: onde é feita a maioria dos processamentos, através de conexões ponderadas.
- *Camada de saída*: onde o resultado final é apresentado.

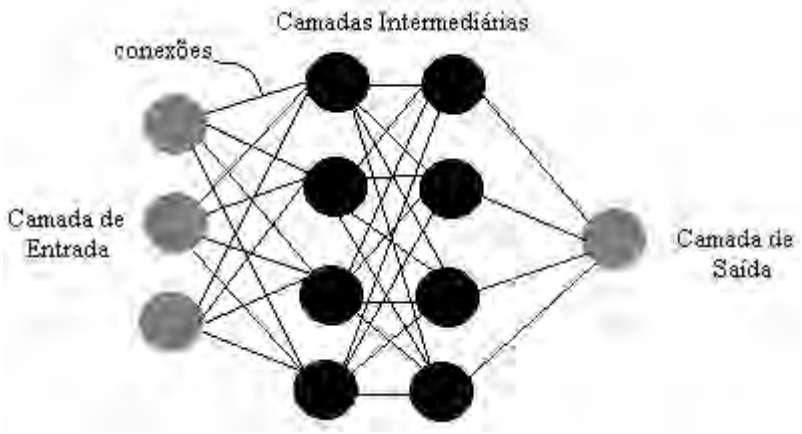

FIGURA 3.4 - Organização da rede em camadas

Uma rede neural é definida pela função do neurônio presente, por sua topologia e pelo algoritmo de aprendizagem utilizado.

- **Quanto à função do neurônio**

Uma rede pode ser:

  - **Homogênea:** todos os neurônios têm o mesmo comportamento.
  - **Heterogênea:** os neurônios têm comportamentos diferentes.

- **Quanto à topologia da rede**

A rede pode ser dividida em duas topologias principais:

  - ***Feed-Forward* (Alimentação para Frente):** os neurônios são organizados em camadas, e a informação desloca-se em um único sentido, entre camadas adjacentes.
  - **Recorrente** ou **Dinâmica:** não existe direção privilegiada para a propagação da informação, podendo haver retro-alimentação.

- **Quanto ao algoritmo de aprendizagem**

O algoritmo deve especificar as condições iniciais da rede e a metodologia de ajuste de seus parâmetros internos para se obter o desempenho desejado.

O treinamento ou processo de aprendizado de uma RNA consiste em ajustar os pesos sinápticos (matriz de pesos **w**) de forma que a aplicação de um conjunto de entradas produza um conjunto de saídas desejadas.

O treinamento da RNA pode ser classificado em dois tipos principais:

- **Supervisionado:** a rede é treinada para fornecer a saída desejada em relação a um estímulo de entrada específico.
- **Não Supervisionado:** não há uma saída específica em relação aos estímulos de entradas. A rede se auto-organiza em relação a um subconjunto de entradas cujos elementos possuem características similares.

3.5. A Rede de Hopfield

Neste trabalho, faz-se uso da rede conhecida como Hopfield (Figura 3.5). É uma rede denominada recorrente, pois trabalha com retro-alimentação e a informação não percorre um caminho idêntico em todos os casos. Por ser uma rede recorrente e, portanto um sistema dinâmico, sua estrutura pode ser representada por um conjunto de equações diferenciais, possibilitando o uso das técnicas clássicas de análise de sistemas dinâmicos no estudo da convergência e estabilidade desta rede.

Como sendo um dos melhores exemplos de redes recorrentes, a rede de Hopfield se apresenta normalmente com uma única camada de neurônios totalmente conectados. Define-se, para esta rede, a equação nodal para um modelo contínuo no tempo composto de *N*-neurônios:

$$\dot{u}_i(t) = -\eta \dot{u}_i(t) + \sum_{j=1}^{N} \mathbf{T}_{ij}(t)\mathbf{v}_j(t) + \mathbf{i}_i^b \tag{3.2}$$

$$\mathbf{v}_i(t) = g_i(u_i(t)) \tag{3.3}$$

onde: $u_i(t)$ é o estado corrente do *i*-ésimo neurônio.

$\mathbf{v}_i(t)$ é a saída do *i*-ésimo neurônio.

$\mathbf{T}_{ij}$ é o peso conectando o *i*-ésimo neurônio ao *j*-ésimo neurônio.

$\mathbf{i}_i^b$ é a entrada do *i*-ésimo neurônio (*input bias*).

$\eta.u_i(t)$ é um termo de decaimento passivo.

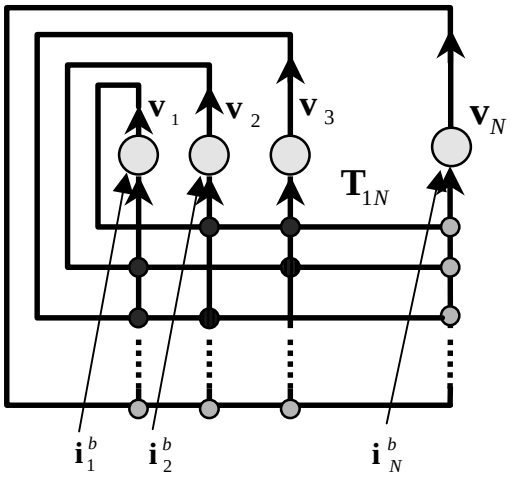

FIGURA 3.5 - A rede Hopfield convencional

A Equação (3.3) é uma função de ativação, monótona crescente, onde cada neurônio tem sua saída limitada a um intervalo pré-definido. Esta função será uma daquelas apresentadas na Figura 3.3. Uma versão discreta da rede Hopfield é obtida quando $\eta = 0$ e $\mathbf{T}_{ij} = \mathbf{T}_{ji}$. Neste caso, os pontos de equilíbrio da rede correspondem aos valores de $\mathbf{v}(t)$ que minimizam uma função de energia da rede. Se os neurônios forem alterados de forma assíncrona, a função de energia associada à rede de Hopfield é definida por:

$$E(t) = -\frac{1}{2}\mathbf{v}(t)^T \mathbf{T}\mathbf{v}(t) - \mathbf{v}(t)^T \mathbf{i}^b \tag{3.4}$$

Os problemas de otimização utilizando rede de Hopfield consistem em se determinar a matriz de pesos **T**, que é simétrica, e o vetor de entradas $\mathbf{i}^b$ associados à função de energia da rede. Esta função deverá, por conseguinte, estar

associada à função objetivo e às restrições descritivas do problema a ser resolvido. Este fato é o que dificulta o mapeamento de problemas de otimização, uma vez que caso uma das restrições seja violada, a solução da rede será considerada inválida (GEE et al., 1991).

Nos primeiros estudos da rede (SILVA, 1995), notava-se que, quando existiam multiplicidades de termos de restrições, os resultados obtidos eram consideravelmente afetados, gerando soluções infactíveis. Após algumas análises dos auto-vetores da rede durante sua convergência, pôde-se verificar como E^{ot} e os termos de restrições podem ser efetivamente separados dentro de subespaços diferentes, contornando o problema acima. Neste caso, a função de energia é definida como sendo:

$$E(t) = E^{ot}(t) + c_0 E^{conf} \tag{3.5}$$

onde o termo E^{conf} satisfaz todas as restrições impostas inicialmente ao problema de otimização. Desta forma, definem-se os termos da equação (3.5) como:

$$E^{ot}(t) = -\frac{1}{2}\mathbf{v}(t)^T \mathbf{T}^{ot}\mathbf{v}(t) - \mathbf{v}(t)^T \mathbf{i}^{ot} \tag{3.6}$$

$$E^{conf}(t) = -\frac{1}{2}\mathbf{v}(t)^T \mathbf{T}^{conf}\mathbf{v}(t) - \mathbf{v}(t)^T \mathbf{i}^{conf} \tag{3.7}$$

Devido à necessidade de E^{conf} ser dominante, deve-se atribuir um valor elevado para a constante c_0. Esta obrigatoriedade implica em um grande dispêndio de tempo para o confinamento da solução no subespaço válido, tornando a simulação da rede ineficiente. No intuito de contornarmos mais este problema, propõe-se, na próxima seção, uma Rede de Hopfield Modificada (RHM), que dispensa a utilização da constante de ponderação c_0.

3.6. A Rede de Hopfield Modificada

Para descrever o funcionamento da Rede de Hopfield Modificada, inicialmente faz-se um comentário a respeito da abordagem do subespaço válido.

Pode-se notar que, para uma vasta variedade de problemas cujas restrições se enquadram no modelo de Hopfield convencional, suas soluções se encontram

sempre num mesmo subespaço comum (AIYER *et al.*, 1990). Este subespaço comum, denominado subespaço válido de soluções, possui equação definida por:

$$\mathbf{v}(t+1) = \mathbf{T}^{val}\mathbf{v}(t) + \mathbf{s} \tag{3.8}$$

onde:

- $\mathbf{T}^{val}$ é uma matriz projeção ($\mathbf{T}^{val}\mathbf{T}^{val} = \mathbf{T}^{val}$) que projeta o vetor **v** dentro do subespaço válido ($\mathbf{v}^{val} = \mathbf{T}^{val}\mathbf{v}$, componente de **v** projetada sobre o subespaço válido);
- **s** é um vetor que está relacionado com as restrições do problema a ser resolvido. Este vetor é ortogonal ao subespaço válido ($\mathbf{T}^{val}\mathbf{s} = 0$).

Podemos definir, a partir da abordagem do subespaço válido, a operação da Rede de Hopfield em:

(i) A rede é inicializada em um estado aleatório tal que **v** seja limitado pela função de ativação dos neurônios;

(ii) A minimização de E^{conf}, por intermédio da projeção de **v** no subespaço válido, move **v** em direção a um dos pontos de equilíbrio da rede que satisfaz todas as restrições impostas pelo problema;

(iii) A minimização de E^{ot} garante que no ponto de equilíbrio encontrado no passo (ii) corresponde à solução de custo ótimo para o problema.

Portanto, a grande vantagem de primeiramente projetar o vetor **v** no subespaço válido é garantirmos que, caso este vetor seja o ponto de mínimo da função *E(t)*, ela já terá satisfeito todas as restrições do problema e, com isso, corresponderá à solução final encontrada pela rede.

Da mesma forma que para a Hopfield convencional, definem-se, agora, os passos principais da RHM (SILVA, 1995), que é ilustrada pela Figura 3.6:

Passo I) Minimização de E^{conf}: corresponde à projeção de **v** sobre o subespaço válido gerado por todas as restrições impostas pelo problema (Equação (3.8)). Dado que $\mathbf{T}^{val}$ é uma matriz projeção, qualquer componente de **v** que seja ortogonal a $\mathbf{T}^{val}\mathbf{v}$ é desprezada. Esta operação realiza uma minimização indireta de E^{conf}.

Passo II) Aplicação de uma função do tipo 'rampa-simétrica', restringindo **v** dentro de um hipercubo inicial:

$$g_i^r(\mathbf{v}_i) = \begin{cases} \mathbf{v}_i^{\min}, & se \quad \mathbf{v}_i^{\min} > \mathbf{v}_i \\ \mathbf{v}_i, & se \quad \mathbf{v}_i^{\min} \le \mathbf{v}_i \le \mathbf{v}_i^{\max} \\ \mathbf{v}_i^{\max}, & se \quad \mathbf{v}_i > \mathbf{v}_i^{\max} \end{cases} \tag{3.9}$$

onde $\mathbf{v}_i \in [\mathbf{v}_i^{\min}, \mathbf{v}_i^{\max}]$.

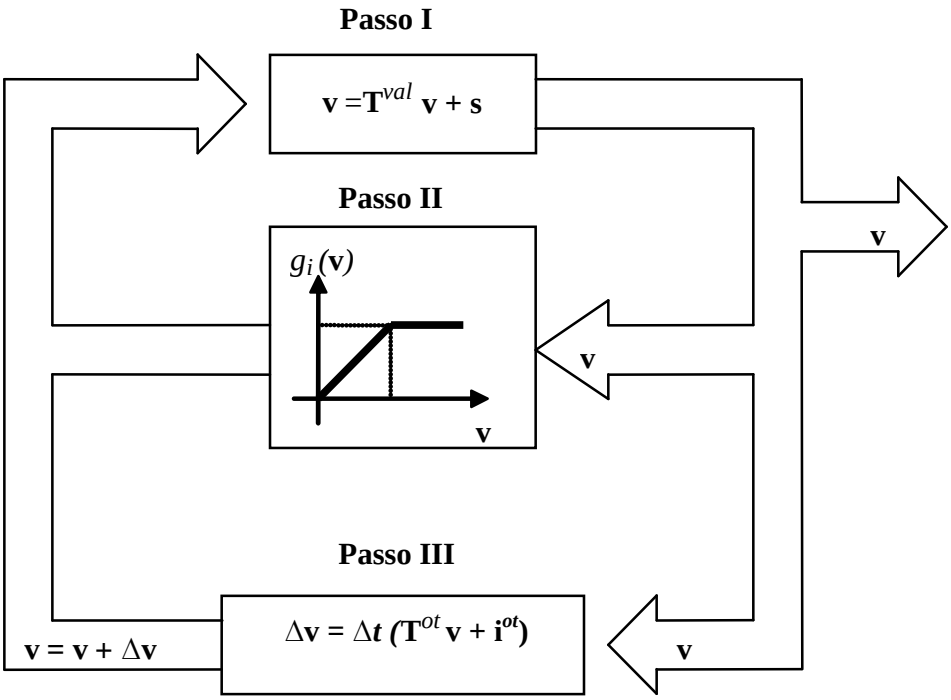

FIGURA 3.6 - Rede de Hopfield Modificada (RHM)

Passo III) Minimização de E^{ot}: consiste na alteração de **v** em direção a uma solução e custo ótimo (definida por $\mathbf{T}^{ot}$ e $\mathbf{i}^{ot}$) correspondendo aos pontos de equilíbrio da rede, que são as soluções para o problema de otimização considerado.

A minimização da função E^{ot}, descrita no passo anterior, consiste na alteração de **v** na direção oposta ao gradiente dessa função em relação ao próprio **v**. Este procedimento é descrito pela seguinte equação:

$$\Delta \mathbf{v} = \Delta t\left(\mathbf{T}^{ot}\mathbf{v} + \mathbf{i}^{ot}\right) \tag{3.10}$$

A grande vantagem de usarmos a RHM é a sua capacidade de resolver vários tipos de problemas diferentes, utilizando uma arquitetura de rede única e uma mesma metodologia de mapeamento. Podemos definir esta metodologia, de uma maneira objetiva, da seguinte forma:

(i) A função objetivo do problema deve ser escrita na forma mostrada em (3.11):

$$E^{ot}(t) = -\frac{1}{2}\mathbf{v}(t)^T\mathbf{T}^{ot}\mathbf{v}(t) - \mathbf{v}(t)^T\mathbf{i}^{ot} \tag{3.11}$$

(ii) As restrições devem ser expressas por intermédio da equação do subespaço válido definida em (3.8).

(iii) O domínio de variação de cada variável do problema deve ser definido através dos limites da função de ativação 'rampa simétrica', definida em (3.9).

3.7. Rede Neural de Hopfield Modificada Fuzzy (RHMF)

A rede de Hopfield convencional tem um tempo de processamento elevado devido à necessidade de um esforço computacional adicional para forçar o confinamento de **v** no subespaço-válido. Já, tanto a rede neural de Hopfield Modificada quanto a Convencional afetam o desempenho da rede devido ao passo de iteração ser fixo. Para contornar estes problemas propõe-se a implementação da rede de Hopfield Modificada Fuzzy com taxa de convergência (passo de iteração) calculada por um controlador lógico nebuloso.

Uma função de energia modificada $E^m(t)$ é usada neste processo. Esta função é definida como segue:

$$E^m(t) = E^{conf}(t) + E^{ot}(t) \tag{3.12}$$

onde $E^{conf}(t)$ é um termo de confinamento que agrupa as restrições dadas por (2.27b), (2.27c) e (2.27d); e $E^{ot}(t)$ é um termo de otimização que conduz a saída da rede aos pontos de equilíbrio. Este método é contrastante com a maioria das

abordagens neurais usadas em problemas de DE, o que as tornam ineficientes pelo fato de tratarem estes termos em uma única função de energia.

A Figura 3.6 mostra a rede de Hopfield Modificada sem a implementação de um controlador lógico nebuloso (Rede de Hopfield Modificada - RHM).

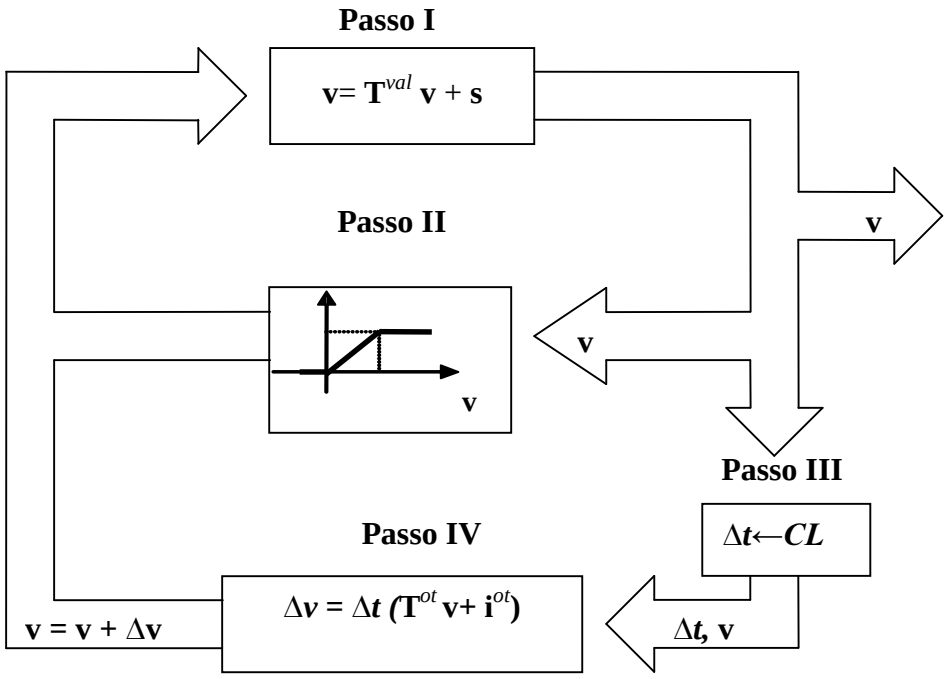

FIGURA 3.7 - Rede de Hopfield Modificada Fuzzy (RHMF)

A operação da rede de Hopfield Modificada consiste de três passos enquanto a rede de Hopfield Modificada Fuzzy consiste de quatro passos principais, conforme mostra a Figura 3.7. Estes passos podem ser explicados como segue:

Passo I) Minimização de E^{conf}, correspondendo à projeção de **v** no subespaço-válido definido por:

$$\mathbf{v} = \mathbf{T}^{val}\,\mathbf{v} + \mathbf{s} \tag{3.13}$$

onde: $\mathbf{T}^{val}$ é uma matriz projeção. Assim, qualquer componente de v que seja ortogonal a $\mathbf{T}^{val}\mathbf{v}$ é desprezada. Esta operação realiza uma minimização indireta de E^{conf}.

Passo II) Aplicação de uma função de ativação do tipo rampa simétrica não-linear restringindo **v** em um hipercubo:

$$g_i^r(\mathbf{v}_i) = \begin{cases} \mathbf{v}_i^{\min}, & se \quad \mathbf{v}_i^{\min} > \mathbf{v}_i \\ \mathbf{v}_i, & se \quad \mathbf{v}_i^{\min} \le \mathbf{v}_i \le \mathbf{v}_i^{\max} \\ \mathbf{v}_i^{\max}, & se \quad \mathbf{v}_i > \mathbf{v}_i^{\max} \end{cases} \tag{3.14}$$

onde $\mathbf{v}_i \in [\mathbf{v}_i^{\min}, \mathbf{v}_i^{\max}]$.

Passo (III): Determinação da taxa de convergência Δt (tamanho do passo de iteração) da rede através do controlador lógico nebuloso.

Passo (IV): Minimização de E^{ot}, o que envolve a atualização de v na direção da solução ótima (definida por $\mathbf{T}^{ot}$ e $\mathbf{i}^{ot}$) correspondendo aos pontos de equilíbrio da rede. Estes pontos são também as soluções para o problema do despacho econômico, desde que o gradiente em relação ao termo de energia E^{ot} seja aplicado. Utilizando a função de ativação rampa-simétrica e dado que η=0, a equação (3.3) torna-se (LI *et al.*, 1989):

$$\mathbf{v}(t) = g_i^r(u(t)) = u(t)$$

e comparando (3.2) e (3.11)

$$\frac{d\mathbf{v}(t)}{dt} = \dot{\mathbf{v}} = -\frac{\partial E^{ot}(t)}{\partial \mathbf{v}}$$

$$\Delta\mathbf{v} = -\Delta t \nabla \mathrm{E}^{ot}(\mathbf{v}) = \Delta t(\mathbf{T}^{ot}\mathbf{v} + \mathbf{i}^{ot}) \tag{3.15}$$

Desta forma, a minimização do termo E^{ot} consiste em atualizar **v** na direção oposta ao gradiente de E^{ot} em relação a **v**. Estes resultados também são válidos quando uma função de ativação do tipo tangente hiperbólica for utilizada (ABE, 1993).

As principais diferenças existentes entre a rede de Hopfield Modificada Fuzzy, desenvolvida neste projeto, e a rede de Hopfield convencional são:

- A taxa de convergência da rede de Hopfield Modificada, calculada por um controlador lógico nebuloso, reduz o tempo de convergência da rede.
- A inexistência das constantes de ponderação, escolhidas arbitrariamente, faz com que os pontos de equilíbrio da rede (solução final) sejam menos sensíveis à escolha do estado inicial.
- O termo de energia E^{ot} não interfere, durante o processamento, na minimização do termo de energia E^{conf}.
- Nenhum parâmetro de inicialização (controle) da rede é requerido para a execução da simulação.

Como visto na Figura 3.7, cada iteração possui 2 estágios diferentes. Primeiro, como descrito no Passo (IV), **v** é atualizado usando o gradiente do termo E^{ot} separadamente. Em seguida, após cada atualização, **v** é diretamente projetado no subespaço-válido. Este é um processo iterativo, no qual **v** é primeiramente projetado ortogonalmente no subespaço-válido definido em (3.13). Em seguida, os seus elementos são limitados pela função de ativação rampa-simétrica (3.14) dentro do intervalo $\mathbf{v}_i \in [\mathbf{v}_i^{\min}\ ,\ \mathbf{v}_i^{\max}]$.

3.8. Controlador Lógico Nebuloso

Em sistemas baseados em conhecimento, a utilização mais significativa da teoria dos conjuntos nebulosos são os controladores lógicos nebulosos.

Sistemas lógicos nebulosos, introduzidos por (ZADEH, 1979), permitem a manipulação de informações incertas. Em lógica nebulosa, um sistema pode representar conceitos imprecisos, não apenas por intermédio de variáveis lingüísticas (tais como rápido, lento e pequeno), mas também através de princípios matemáticos bem estabelecidos; além disso, pode-se utilizar estes conceitos para realizar deduções sobre um sistema (COX, 1992).

Em um controlador baseado em regras, as variáveis de entrada são normalizadas e convertidas em representações nebulosas. As bases de regras são executadas em paralelo, produzindo conseqüentemente uma região nebulosa para cada variável. Em seguida, as regiões são convertidas em valores *crisp* (não-

nebulosos) com o objetivo de determinar uma ação de controle (não nebulosa) que melhor represente a decisão nebulosa.

Na teoria clássica dos conjuntos, os conjuntos são ditos *crisp*, de tal forma que um dado elemento do universo de discurso (domínio) pertence ou não pertence ao referido conjunto. Na teoria dos conjuntos nebulosos, considera-se inicialmente um universo de discurso *U*, onde '*u*' é um elemento genérico. Um conjunto nebuloso F, definido neste universo, é caracterizado por uma função de pertinência $\mu_F(.)$ sobre o intervalo [0,1]. O grau de pertinência do elemento '*u*' ao conjunto F é dado pelo valor $\mu_F(u)$.

Considerando dois conjuntos nebulosos A e B em *U*, as três operações básicas (união, intersecção e complemento) podem ser definidas através de suas funções de pertinência (μ_A e μ_B) por:

$$\textbf{União: } \mu_{A\cup B} = \max\{\mu_A(u), \mu_B(u)\} \tag{3.16}$$

$$\textbf{Intersecção: } \mu_{A\cap B} = \min\{\mu_A(u), \mu_B(u)\} \tag{3.17}$$

$$\textbf{Complemento: } \mu_{\bar{A}} = 1 - \mu_A(u) \tag{3.18}$$

Um sistema de decisão nebuloso ou controlador nebuloso é então formado por um conjunto de regras de controle, às quais se associam implicações nebulosas utilizando as operações precedentes. Uma regra nebulosa típica "Se (x é A_i e y é B_i) então (z é C_i)" é implementada com uma implicação (relação) nebulosa R_i, cuja função de pertinência μ_{R_i} pode ser definida por:

$$\mu_{R_i} = \mu_{(A_i \text{ e } B_i \rightarrow C_i)}(u, v, w) = [\mu_{A_i(u)} \text{ e } \mu_{B_i(v)}] \rightarrow \mu_{C_i(w)} \tag{3.19}$$

onde A_i e B_i é um conjunto nebuloso A_i x B_i em *UxR;* $R_i = (A_i \text{ e } B_i) \rightarrow C_i)$ é uma relação nebulosa em *UxVxW;* e o operador $(\rightarrow)$ indica a função de implicação nebulosa.

Utilizando a regra de inferência composicional de (Zadeh, 1973), dada a relação *R*, de *U* a *V*, e um conjunto nebuloso de *U* denotado por *A'*; o conjunto nebuloso *B'* de *V*, inferido a partir de *A'*, tem função de pertinência definida pelo procedimento max-min por:

$$\mu_{B'}(v) = \max\{\min(\mu_{A'}(u), \mu_R(u,v))\}; u \in U, v \in V \tag{3.20}$$

Um controlador lógico nebuloso é associado à rede de Hopfield Modificada com o objetivo de manter o compromisso entre a eficiência da rede e a precisão dos valores do ponto de equilíbrio da rede. As variáveis lingüísticas de entrada do controlador são o erro quadrático médio (EQM) da saída entre dois instantes consecutivos e a variação de energia do termo E^{ot} (3.6), os quais são dados pelas equações (3.21) e (3.22):

$$EQM = \frac{1}{2}\sum_{i=1}^{N}\left[v_i(t) - v_i(t-1)\right]^2 \tag{3.21}$$

$$\Delta E^{ot}(t) = \left|E^{ot}(t) - E^{ot}(t-1)\right| \tag{3.22}$$

A saída do controlador lógico nebuloso é dada pela variável lingüística Δt, que determina o passo de iteração da rede.

À medida que a rede aproxima da solução ótima, o passo de iteração deve diminuir. Assim, quanto menor o erro quadrático médio, mais próximo da solução ótima. E, quanto menor for a variação de energia do termo de otimização, menor o custo obtido. Desta forma, à medida que a rede aproxima para a solução de custo mínimo, o passo de iteração também deve diminuir para que a rede não escape da região de menor custo.

O universo de discurso associado a cada variável lingüística de entrada tem valores no seguinte conjunto de termos: muito pequeno (MP), pequeno (PE), médio (ME), grande (GR) e muito grande (MG). Para a variável de saída Δt, os valores são: pequeno (PE), médio (ME) e grande (GR). Os valores de Δt são obtidos pela aplicação de regra de inferência composicional de Zadeh em regras do tipo "Se (EQM é grande) e (ΔE é pequeno) então (Δt é médio)", como apresenta a Tabela 3.1.

Tabela 3.1 – Conjunto de Regras Nebulosas

$\Delta E^{ot}(t)$ / EQM(t)	MP	PE	ME	GR	MG
MP	PE	PE	ME	ME	ME
PE	PE	PE	ME	ME	GR
ME	ME	ME	ME	GR	GR
GR	ME	ME	GR	GR	GR
MG	ME	GR	GR	GR	GR

Para cada regra, dada na Tabela 3.1, o grau de ativação da ação de controle é calculado de acordo com o resultado da combinação de seus antecedentes e conseqüentes. Todas as regras, com elementos tendo valores verdade não-nulos, são ativadas. As funções de pertinência para as variáveis lingüísticas do controlador são dadas na Figura 3.8. Os parâmetros ΔE_0 e EQ_0, diferentes em cada tipo de problema a ser resolvido pela rede, são obtidos após as primeiras iterações executadas pela rede. Após a aplicação do procedimento de inferência, a ação de controle final consiste da agregação (união) de todas as contribuições proporcionadas por cada regra ativada (LEE, 1990). O valor *crisp* (não nebuloso) de Δt é calculado pelo método do centro de área (CDA), dado por:

$$CDA = \frac{\sum_{k=1}^{n} \mu_{B'}(v_k).v_k}{\sum_{k=1}^{n} \mu_{B'}(v_k)} \tag{3.23}$$

onde n é o número de níveis de quantização da saída, ou seja, o número de segmentos gerados pela discretização dos universos de discursos.

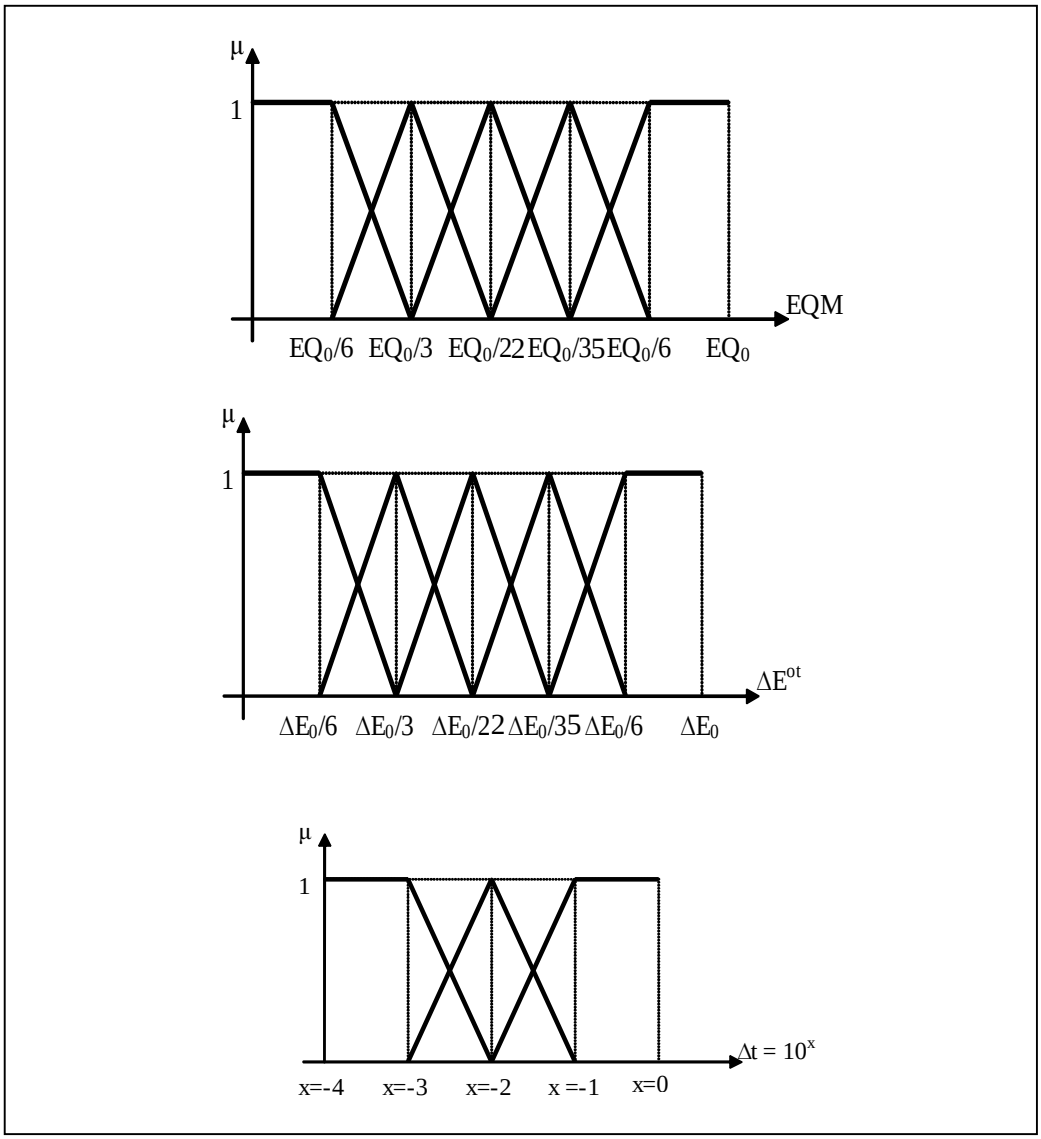

FIGURA 3.8 - Funções de pertinência do controlador nebuloso

O Capítulo 4 apresenta, de uma forma geral, os principais aspectos de um algoritmo genético.

CAPÍTULO 4

Algoritmos Genéticos

Este capítulo apresenta uma introdução teórica e um histórico sobre os algoritmos genéticos.

4.1 Introdução

Algoritmos Genéticos (AGs) são algoritmos de busca baseados nos mecanismos de seleção e genética natural. Os AGs combinam "sobrevivência dos mais aptos" com uma troca de informações, ao mesmo tempo, estruturada e aleatória. Uma população de *strings* (indivíduos), representando soluções de um problema específico, é mantida pelo algoritmo genético. O algoritmo genético cria iterativamente novas populações, a partir da população inicial, selecionando *strings* e cruzando as mais aptas para gerar novas *strings* que, espera-se, estejam mais próximas da solução ótima do problema dado. Em cada geração, criam-se novas *strings* a partir de bits e pedaços de *strings* anteriores, adicionando novos dados para evitar a estagnação da população. Após uma série de gerações, pode-se encontrar a solução ótima (ou indivíduo ótimo).

Apesar de usar oportunamente a idéia de aleatoriedade para realizarem uma pesquisa, é preciso ficar bem claro que os AGs não são simples algoritmos aleatórios de pesquisa. Algoritmos aleatórios de pesquisa podem ser inerentemente ineficientes devido à falta de direcionamento natural de suas pesquisas. Os AGs não são desprovidos de direção de pesquisa. Eles utilizam o conhecimento adquirido de gerações anteriores de *strings* para construir uma nova geração que irá se aproximar da solução ótima. Em outras palavras, eles usam o conhecimento passado para direcionar sua pesquisa.

Algoritmos Genéticos são muito eficientes para busca de soluções ótimas, ou aproximadamente ótimas, em nível global em uma grande variedade de problemas, pois não impõem muitas das limitações encontradas nos métodos de busca tradicionais, tais como a necessidade de diferenciabilidade ou convexidade das funções que descrevem o problema de otimização.

Normalmente, os AGs visam resolver problemas de otimização, embora a quantidade de problemas aos quais os AGs se aplicam seja bastante abrangente. Assim, o Algoritmo Genético é uma ferramenta potencialmente eficiente para resolver o problema de Despacho Econômico.

4.2 Um Breve Histórico

Até meados do século XIX, os naturalistas acreditavam que cada espécie havia sido criada separadamente por um ser supremo ou através de geração espontânea. Em 1735, o trabalho do naturalista Carolus Linnaeus, *Systema Naturae*, sobre a classificação biológica de organismos despertou o interesse pela similaridade entre certas espécies, levando a acreditar na existência de uma certa relação entre elas. Outros trabalhos influenciaram os naturalistas em direção à teoria da seleção natural, tais como os de Jean Baptiste Lamark, que publicou o livro *Zoological Philosophy* em 1809 e que sugeriu uma teoria evolucionária no "uso e desuso" de órgãos; e de Thomas Robert Malthus, 1798, com a obra *Essay on the Principle of Population* que propôs que fatores ambientais tais como doenças e carência de alimentos, limitavam o crescimento de uma população.

Depois de mais de 20 anos de observações e experimentos, Charles Darwin apresentou em 1858 sua teoria de evolução por meio de seleção natural, simultaneamente com outro naturalista inglês Alfred Russel Wallace. No ano seguinte, Darwin publica *On the Origin of Species by Means of Natural Selection* com a sua teoria completa, sustentada por muitas evidências colhidas durante suas viagens a bordo do *Beagle*. Esta publicação contém duas teses separadas: que todos os organismos com modificações descendem de ancestrais comuns, e que o principal agente de modificação é a ação da seleção natural sobre a variação individual.

Este trabalho influenciou muito o futuro não apenas da Biologia, Botânica e Zoologia, mas também teve grande influência sobre o pensamento religioso, filosófico, político e econômico da época. Darwin estendeu o conceito de um universo em constante mudança aos seres vivos, bem como introduziu o conceito de mutabilidade ao acaso, sem nenhum propósito divino ou filosófico que o norteasse. Desta maneira, não só os objetos inanimados, mas também tudo estava sujeito às leis físicas, que Newton, Descartes, entre outros, haviam delineado. Desta forma, os antigos paradigmas de existir um propósito (divino ou não) para tudo, foram substituídos por uma visão mais simples e mecanicista. A teoria da evolução e a computação nasceram praticamente na mesma época: Charles

Babbage, um dos fundadores da computação moderna e amigo pessoal de Darwin, desenvolveu sua máquina analítica em 1833. Ambos provavelmente estariam surpresos e orgulhosos com a ligação entre estas duas áreas.

Por volta de 1900, o trabalho de Gregor Mendel, *Experiments in Plant Hybridization*, desenvolvido em 1865 sobre os princípios básicos de herança genética, foi redescoberto pelos cientistas e teve grande influência sobre os futuros trabalhos relacionados à evolução. A moderna teoria da evolução combina a genética e as idéias de Darwin e Wallace sobre a seleção natural, criando o princípio básico de Genética Populacional: a variabilidade entre indivíduos em uma população de organismos que se reproduzem sexualmente é produzida pela mutação e pela recombinação genética.

Este princípio foi desenvolvido durante os anos 30 e 40, por biólogos e matemáticos de importantes centros de pesquisa. Nos anos 50 e 60, muitos biólogos começaram a desenvolver simulações computacionais de sistemas genéticos. Entretanto, foi John Holland quem começou, seriamente, a desenvolver as primeiras pesquisas no tema. Holland foi gradualmente refinando suas idéias e em 1975 publicou o seu livro *Adaptation in Natural and Artificial Systems*, hoje considerado a base de Algoritmos Genéticos. Desde então, estes algoritmos vêm sendo aplicados com sucesso nos mais diversos problemas de otimização e aprendizado de máquina. Os objetivos fundamentais de sua pesquisa eram:

- Explicar os processos adaptativos dos sistemas naturais;
- Desenvolver programas de computadores de sistemas artificiais que reproduzissem o importante mecanismo de solução de problemas empregados pelos sistemas naturais.

Os algoritmos genéticos fornecem robustez, eficiência e flexibilidade quando pesquisam espaços de problemas em busca da solução ótima.

A partir da publicação do trabalho de (HOLLAND, 1975), a área de Algoritmos Genéticos tem evoluído constantemente e, atualmente, usam-se algoritmos genéticos na solução de uma diversidade enorme de problemas de engenharia. Notam-se, também, esforços contínuos visando aprofundar os aspectos teóricos relativos a estes algoritmos.

4.3. Espaço de Busca

Toda tarefa de busca e otimização possui vários componentes, entre eles, o espaço de busca. O espaço de busca é o espaço de todas as soluções possíveis para um problema de otimização. Cada ponto no espaço de busca é uma solução possível. Cada solução possível pode ser associada a um valor de adequação ao problema. Estamos procurando nossa solução que é um ponto (ou mais) entre as soluções possíveis. A procura por uma solução é equivalente a procurar por algum ponto extremo (mínimo ou máximo) no espaço de busca. Este pode ser todo conhecido conforme o desenvolvimento da solução do problema, mas geralmente conhecemos apenas alguns pontos e geramos os outros como um processo contínuo para encontrarmos a solução.

Matematicamente, o espaço de busca é representado por um conjunto de equações e inequações que restringem o domínio de soluções de um problema de otimização, que em geral é escrito da forma:

$$\begin{array}{lll} \textit{Minimizar} & f(\mathbf{x}) & (a) \\ \textit{sujeito a}: & \mathbf{g}(\mathbf{x}) = 0 & (b) \\ & \mathbf{h}(\mathbf{x}) \leq 0 & (c) \\ & \mathbf{x} \in \mathbf{X} & (d) \end{array} \qquad (4.1)$$

O problema de otimização acima busca encontrar um ponto $\mathbf{x}^*$ que pertença ao espaço de busca descrito pelas equações (4.1b) e inequações (4.1c), além de (4.1d) e que minimize um determinado objetivo representado pela função objetivo (4.1a).

Resumidamente, as técnicas de busca são classificadas em:

- **Técnicas Baseadas em Cálculo:** usam um conjunto de condições necessárias e suficientes que devem ser satisfeitas pelas soluções de um problema de otimização (GOLDBERG, 1989):
    - **Métodos Indiretos:** procuram por um extremo local por meio da resolução de um conjunto de equações, normalmente não-lineares, que resultam quando se iguala o gradiente da função objetivo a zero. É uma extensão do cálculo elementar para funções irrestritas para o espaço n-dimensional.

- **Métodos Diretos:** utilizam informações da função como derivadas de primeira e/ou segunda ordem. Ou seja, estes métodos procuram pelo ótimo local por trabalhar sobre a função e mover na direção do gradiente local. Esta é simplesmente a noção de *Hill Climbing*. Pontos sucessivos são gerados baseados somente nos resultados anteriores. Há várias desvantagens no método *Hill Climbing*. Primeiramente, ele assume que o espaço de busca que está sendo pesquisado é contínuo. Em outras palavras, as derivadas da função que representam o espaço de busca existem. Isto não é verdadeiro para muitos problemas do mundo real em que o espaço de busca possui ruídos e descontinuidades. Uma outra grande desvantagem do algoritmo é que ele encontra somente a solução ótima local à vizinhança do ponto corrente. Ele não tem condições de analisar todo o espaço de busca. Entretanto, métodos *Hill Climbing* paralelos podem ser usados para pesquisarem múltiplos pontos no espaço de busca. Ainda assim não há garantia de se encontrar o valor ótimo, especialmente em espaços com muitos ruídos onde há um grande número de picos.

- **Técnicas Enumerativas**

  A base da técnica enumerativa é simples. Busca-se encontrar o valor ótimo (solução) em um espaço de um problema de otimização pesquisando seqüencialmente cada ponto do espaço de busca (finito e discreto). Este método é extremamente ineficiente. Para problemas com espaços de pesquisas muito grandes, a tarefa computacional é muitas vezes inviável.

- **Técnicas Dirigidas por Pesquisa Aleatória:** baseadas em técnicas enumerativas, mas usam informações adicionais para dirigir a busca.

Mas estes não realizam "andanças" aleatórias simplesmente. Esta técnica não é desprovida de direção para desenvolver a busca como os algoritmos de pesquisa aleatória. Elas utilizam na busca os conhecimentos obtidos de resultados anteriores combinando-os. O resultado conseguido é uma poderosa técnica de pesquisa que pode tratar ruídos, espaços de pesquisas multimodais com relativa eficiência. Os dois tipos de algoritmos de pesquisa aleatória mais populares são:

- ***Simulated Annealing:*** técnica baseada no processo de evolução termodinâmica para dirigir a busca para o estado de mínima energia.
- **Algoritmos Evolutivos:** baseados nos princípios de seleção natural:
  - **Algoritmos Genéticos**
  - **Estratégias Evolutivas**
  - **Programação Evolutiva**

Os Algoritmos Evolutivos são as formas de implementação dos modelos computacionais de processos evolutivos na área de computação evolutiva.

Estes três algoritmos são representados por uma população de indivíduos que sofrem uma série de transformações aleatórias para atualizar a busca e depois, por um processo de seleção que favorece os melhores indivíduos. Apesar disso, as técnicas de codificação, a maneira pela qual os cromossomos são selecionados para reprodução e os tipos de alterações usados para criar novas soluções podem variar.

Em 1975, John Holland publicou nos Estados Unidos o primeiro trabalho sobre Algoritmos Genéticos. Algoritmo Genético é uma técnica de busca baseada na teoria de evolução de Darwin, enfatizando os modelos de operadores genéticos.

As Estratégias Evolutivas foram introduzidas na Alemanha inicialmente por (RECHEMBERG, 1973), nos anos 60 e, mais tarde, desenvolvidas por (SCHWEFEL, 1995) com a finalidade de solucionar

problemas de otimização. As estratégias evolutivas priorizam as transformações realizadas pela mutação.

Já, a Programação Evolutiva foi desenvolvida por (FOGEL *et al.*, 1966) e consistia na evolução de populações com máquinas de estados finitos. A programação evolutiva foi aplicada a vários problemas de otimização de forma análoga às estratégias evolutivas (BÄCK, 1996).

Algoritmos genéticos e estratégias evolucionárias são métodos que simulam, através de algoritmos, os processos da evolução natural (biológica) visando, principalmente, resolver problemas de otimização.

Nesta dissertação, a aplicação de Algoritmos Genéticos na resolução do problema de Despacho Econômico está relacionada a uma maior capacidade de exploração do espaço de otimização e por tratar problemas que envolvem funções custos e/ou restrições não diferenciáveis.

4.4. Algoritmos Genéticos e Métodos Tradicionais de Busca e Otimização

Os Algoritmos Genéticos diferem dos métodos tradicionais de busca e otimização, principalmente em quatro aspectos (GOLDBERG, 1989):

1. AGs trabalham com uma codificação do conjunto de parâmetros e não com os próprios parâmetros.

2. AGs trabalham com uma população e não com um único ponto. Isto dá aos AGs a capacidade de pesquisar em espaços ruidosos com vários pontos ótimos locais. Os AGs observam diferentes áreas do espaço do problema de uma só vez e usam todas estas informações para se guiarem.

3. AGs utilizam informações de custo (função objetivo), e não derivadas ou outro conhecimento auxiliar. Muitas outras técnicas necessitam de uma grande variedade de informações para guiarem-se. O método *hill-climbing* requer derivadas, por exemplo. A única informação utilizada pelos AGs é uma medida de adaptabilidade de cada ponto no espaço (as vezes conhecida como valor da função objetivo). Uma vez conhecido este valor

sobre um ponto, os AGs podem usá-lo para continuar a pesquisa pelo valor ótimo.

4. AGs utilizam regras de transição probabilísticas e não determinísticas. Isto é resultado direto das técnicas randômicas usadas pelos AGs.

4.5. Conceitos Básicos da Genética

Os algoritmos genéticos emprestaram termos da Biologia para sua concepção. Alguns destes termos serão descritos a seguir. O *genótipo* é o projeto de um organismo, ou seja, o conjunto de instruções recebidas dos pais. O *fenótipo* é a manifestação, numa série de etapas de desenvolvimento, da interação dessas instruções com fatores físicos e químicos.

Devem-se ressaltar dois dos princípios da hereditariedade: o de que o fluxo de informação do genótipo para o fenótipo é unidirecional, e o de que as unidades hereditárias transmissíveis mantêm sua identidade, de geração em geração. O estudo da evolução, portanto, sempre esteve ligado, desde o seu início, ao estudo da transmissão de características de um indivíduo a outro: hereditariedade (FUTUYAMA, 1992).

Todos os seres vivos conhecidos são formados a partir de um conjunto de instruções que estão contidas no núcleo de todas as suas células. As estruturas que armazenam estas informações, de como será o indivíduo, recebem o nome de *cromossomos*. A quantidade, o tamanho e o formato destes cromossomos mudam de espécie para espécie. Ao conjunto de cromossomos, dá-se o nome de *genoma.*

O cromossomo, por sua vez, é constituído por uma cadeia de ácido desoxirribonucléico (ADN ou DNA), em forma de dupla hélice, que ele traz em seu interior. Essa molécula helicoidal que se encontra em forma contínua por toda extensão do cromossomo, por sua vez, é formada por uma série de pares de base. Cada par de bases (ou *nucleotídeo*) é constituído por uma purina (adenina (A) ou guanina (G)), acoplada a uma primidina específica (timina (T) ou citosina (C)), pareando-se A com T e C com G. Percebe-se, desta maneira, que os seres vivos são descritos por um alfabeto de quatro letras: G, C, A e T. Vale lembrar que embora estes nucleotídeos sejam os mesmos, em todos os animais e plantas, sua

seqüência no cromossomo não é, em geral, a mesma para todos os indivíduos (DAWKINS, 1979).

O cromossomo pode ser dividido, para efeito de estudos, em segmentos longitudinais chamados genes. Genes funcionam como unidade genética. Para efeitos práticos, são considerados como a unidade básica do cromossomo e juntos, carregam todas as características que o organismo pode ter.

Os cromossomos, em geral, ficam agrupados em pares. São denominados *cromossomos homólogos* os membros de cada par que compartilham os mesmos tipos de genes.

Define-se como *lócus* ou *loco* o lugar ocupado por um gene dentro de um cromossomo. O mesmo loco pode estar ocupado em diferentes cromossomos homólogos, por formas gênicas diferentes.

São chamados de *alelos* a essas variantes de um mesmo gene. Todos estão, naturalmente, relacionados à mesma função geral, mas podem atuar diversamente. Assim, por exemplo, no caso humano, num determinado lócus do cromossomo X existe um alelo que condiciona visão normal das cores e, no mesmo lócus do cromossomo homólogo, poderá haver um alelo que impossibilite o seu portador de distinguir o vermelho do verde.

A correspondência entre terminologia natural e artificial é resumida na Tabela 4.1.

Tabela 4.1 – Comparação da Terminologia Natural e do AG

NATURAL	**ALGORITMO GENÉTICO**
Cromossomo	*String*, Indivíduo
Gene	Característica, Caracter ou detector.
Alelo	Valor Característico
Lócus	Posição da *String*
Genótipo	Estrutura
Fenótipo	Conjunto de Parâmetros, Solução Alternativa, Estrutura Decodificada.

4.6. Esquemas

4.6.1. Esquemas: blocos de construção dos Algoritmos Genéticos

O que será visto agora é apenas uma simples introdução aos fundamentos da matemática envolvida no conceito de AGs. Uma visão mais detalhada pode ser encontrada nos livros (HOLLAND, 1992) e (GOLDBERG, 1989).

A fim de fornecer o fundamento teórico dos algoritmos genéticos, a idéia de blocos de construção precisa ser introduzida. A idéia principal dos blocos de construção é que indivíduos com um grau de adaptação elevado em uma população passem para seus filhos a noção de alta execução. Estas noções possuem a forma de *substrings*. Isto se deve ao fato de que *strings* com um alto valor de adaptação devem conter *substrings* que são a causa principal para apresentarem tais valores de adaptação. Assim, mesmo que as operações de *crossover* dividirem as *strings* em duas partes, haverá boas chances de se transmitir *substrings* adaptadas para os filhos gerados. Estas *substrings* altamente adaptadas são conhecidas como blocos de construção.

Esquemas são padrões de *strings* que descrevem semelhanças de conjuntos de *strings*. Em um esquema, além do alfabeto binário, adiciona-se um símbolo especial * ao alfabeto. Assim, o alfabeto {0,1,*} pode ser usado para representar qualquer padrão de *substring* binária que se desejar. Por exemplo:

Tabela 4.2 – Exemplo de Esquema

Esquema	***Strings* que Atendem ao Esquema**
*1111	01111
	11111
*010*0	101010
	001010
	101000
	001000
**1*0	00100
	.....

É extremamente válido observar como o conjunto de operações básicas do Algoritmo Genético afeta o processamento do esquema. Na reprodução, o efeito é óbvio. As melhores *strings* têm maiores chances de serem selecionadas para o grupo das *strings* reprodutoras do que as *strings* fracas e, portanto, melhores esquemas têm maiores chances de serem envolvidos na criação de novas populações do que os piores esquemas.

A operação de *crossover* possui um forte impacto nos blocos de construção dos AGs. A cada ocorrência de um *crossover,* há a possibilidade de um esquema ser destruído. Esta é uma das principais razões pela qual o *crossover* não deve ser executado 100% do tempo. Observe estes dois esquemas abaixo. Definiu-se o tamanho do esquema como sendo a distância entre a primeira e a última posição especificada na *string*.

Tabela 4.3 – Tamanho do Esquema

Esquema	**Tamanho**
0*	0
1**1**	2
*0*1*1	3

Lembre-se do modo de atuação da operação *crossover*. Percebe-se intuitivamente que esquemas cujos tamanhos são grandes são mais fáceis de se romperem do que esquemas menores.

Define-se ordem de um esquema como sendo o número de posições fixas em um esquema.

Tabela 4.4 – Ordem de um Esquema

Esquema	**Tamanho**
0	1
10*0**	3
111**0	4

Quanto maior for a ordem de um esquema mais específico ele se tornará. Obviamente, 100*1 é bem mais específico do que **0**. Novamente, com a operação de *crossover*, é óbvio que esquemas com pequenas ordens têm menos chances de serem rompidos do que esquemas com altas ordens.

O efeito da mutação nos esquemas não é difícil de se determinar. Uma alta taxa de mutação irá destruir o esquema, esta é a razão pela qual aconselha-se baixas taxas de mutação para a maioria dos AGs.

Desta forma, tem-se duas conclusões importantes a se ressaltar sobre a teoria de construção de bloco. *Strings* com esquemas altamente adaptativos e com pequenos tamanhos terão uma alta probabilidade de serem selecionados para a próxima população e, portanto, passar o esquema para as *strings* da nova população. Esquemas que atendem a estes requisitos aumentam de forma exponencial de uma geração para a próxima. Estes esquemas fornecem aos AGs o poder de pesquisar pelo espaço de um problema eficientemente.

4.7. Algoritmo Genético Simples

O algoritmo proposto por Holland, é conhecido na literatura como *Simple Genetic Algorithm* ou *Standard Genetic Algorithm* ou simplesmente pela sigla SGA**.** Pode-se descrever o algoritmo, sucintamente em seis passos (DAVIS, 1991):

(1) Inicie uma população de tamanho *N*, com cromossomos gerados aleatoriamente;

(2) Aplique a função de adequação em cada cromossomo desta população;

(3) Crie novos cromossomos através de cruzamentos de cromossomos selecionados desta população. Aplique seleção, *crossover* e mutação nestes cromossomos.

(4) Elimine membros da antiga população, de modo a ter espaço para inserir estes novos cromossomos, mantendo a população com o mesmo número *N* de cromossomos;

(5) Aplique a função de adequação nestes cromossomos e insira-os na população;

(6) Se a solução ideal for encontrada ou, se o tempo (ou número de gerações) se esgotou, apresente o cromossomo com a melhor adequação. Caso contrário, volte ao passo (3).

Esta simulação do processo evolutivo irá produzir, à medida que as gerações forem se sucedendo, cromossomos cada vez mais bem adaptados, isto é, com melhor valor da função de adequação, de maneira que, no final, obtém-se uma solução (cromossomo) com alto grau de adequação ao problema proposto.

Observa-se que cada iteração de um SGA é composta por operações básicas, tais como Reprodução, *Crossover* e Mutação. Tais operações básicas serão detalhadas a seguir:

- **INICIALIZAÇÃO**

  Inicialmente, uma população de *N* indivíduos é gerada aleatoriamente. Cada um dos indivíduos da população representa uma possível solução para o problema, ou seja, um ponto no espaço de soluções. A técnica de codificar soluções pode variar de problema para problema e de algoritmo genético para algoritmo genético. No trabalho original de (HOLLAND, 1975), a codificação é feita usando cadeias de bits. Segundo (GOLDBERG, 1989) esta é a técnica que funciona melhor, pois a base binária apresenta maior número de esquemas por bit de informação. Entretanto, outras técnicas podem ser usadas como, por exemplo, a utilização direta de números reais (BASKAR *et al.*, 2002; DAMOUSIS *et al.*, 2003).

  Segundo (GOLDBERG, 1989), o melhor método para trabalhar com o Algoritmo Genético é codificar os parâmetros de uma possível solução do problema em cadeia de bits de 0´s e 1´s. Isto permite uma manipulação fácil e eficiente dos operadores genéticos sobre estes cromossomos.

- **CÁLCULO DA FUNÇÃO DE ADEQUAÇÃO**

  A função de adequação tem o papel de ligar o algoritmo genético ao problema a ser resolvido. Ela é usada para avaliar o cromossomo para

posterior uso pelos operadores de reprodução. A função de adequação possui como entrada uma cadeia de bits e como saída um valor real que representa a possível solução do problema.

Geralmente a função de adequação do indivíduo é determinada através do cálculo da função objetivo, que depende das especificações de projeto. Neste trabalho, cada indivíduo é uma entrada para uma ferramenta de análise de desempenho, cuja saída fornece medidas que permitem ao algoritmo genético o cálculo da função de adequação do indivíduo. Ainda nesta fase os indivíduos são ordenados conforme a sua aptidão.

- **REPRODUÇÃO**

Reprodução é um processo em que *strings* individuais são copiadas de acordo com os seus valores da função de adequação *f* (biólogos chamam esta função de função *fitness*). Intuitivamente, podemos pensar na função *f* como alguma medida de lucro, utilidade ou qualidade que desejamos otimizar. Neste trabalho, a função *f* é uma medida de custo de geração que desejamos minimizar.

A reprodução permite que *strings* sejam copiadas para as próximas gerações. A possibilidade de uma *string* ser copiada é baseada em seu **valor de adaptação**, calculado através da função de adequação (*fitness*). Para cada geração, a operação de reprodução seleciona algumas *strings* que serão utilizadas para realizarem cruzamentos.

Há muitas formas de implementar o operador reprodução. O processo de seleção proposto por (HOLLAND, 1989), em seu SGA, é conhecido como o **método da seleção por roleta (*Roulette Wheel*)** onde cada *string* corrente na população tem uma proporção na roleta em relação ao valor de aptidão.

- **Roulette Wheel - "Roleta Giradora"**

O método da seleção por roleta, *Roulette Wheel*, simplesmente escolhe uma *string* de acordo com a porção ocupada por esta em uma roleta, isto é,

de acordo com um valor de adaptação relativo a esta roleta (em porcentagem).

Este algoritmo pode ser descrito da seguinte maneira:

1. **[Soma]** Calcular a soma dos valores de adaptação de todos os cromossomos - soma **S**.
2. **[Seleção]** Gerar um número aleatório **r** dentro do intervalo [0,S].
3. **[*Loop*]** Começar a somar os valores de adaptação dos cromossomos até atingir ou ultrapassar o valor **r**. Retornar o último cromossomo utilizado na soma.

Este processo é semelhante a uma roda de roleta, na qual os setores vão se sucedendo, sob um pino marcador, até que a roda pare com o pino sobre um setor qualquer. É claro que quanto maior a largura do setor, maior a probabilidade deste setor se encontrar sob o pino marcador.

- ***CROSSOVER***

Após a reprodução, que definiu o conjunto das *strings* reprodutoras, um simples *crossover* pode ser implementado em dois passos.

Em termos biológicos, *crossover* significa misturar os cromossomos dos indivíduos progenitores para gerar um novo cromossomo do indivíduo filho. A mesma idéia aplica-se ao *crossover* dos algoritmos genéticos.

No primeiro passo, o AG seleciona duas *strings* aleatoriamente do grupo das progenitoras. As *strings* selecionadas podem ser diferentes ou idênticas. O AG calcula se deve aplicar o *crossover* usando um parâmetro chamado probabilidade de *crossover* (p_c). Este é simplesmente um valor de probabilidade definido pelo usuário. Um valor sugerido é p_c=0,95, embora este valor possa ser dependente do domínio. Se o AG decide não realizar *crossover*, as duas *strings* selecionadas são simplesmente copiadas para a nova população (elas não são retiradas do grupo das reprodutoras. Elas podem ser usadas várias vezes durante o processo de *crossover*). Se o *crossover* é aplicado, uma posição inteira *k* pertencente a *string* é

selecionada uniformemente de forma aleatória entre 1 e o comprimento da string menos um [1, *l*-1]. Duas novas *strings* são criadas trocando-se todos os caracteres entre as posições *k+1* e *l* inclusive. Por exemplo, considere as *strings* A_1 e A_2 pertencentes à população inicial:

$$A_1 = 0\ 1\ 1\ 0 \mid 1$$

$$A_2 = 1\ 1\ 0\ 0 \mid 0$$

Supondo que na escolha de um número aleatório entre 1 e 4, obtivemos um $k = 4$ (como indicado pelo símbolo de separação |). Realiza-se o *crossover* entre as *strings* A_1 e A_2, gerando duas novas *strings*, A_1' e A_2':

$$A_1' = 0\ 1\ 1\ 0\ \mathbf{0}$$

$$A_2' = 1\ 1\ 0\ 0\ \mathbf{1}$$

O *crossover* é realizado até que a nova população seja criada. E então o ciclo inicia-se novamente com a seleção. Este processo continua iterativamente até que algum critério específico seja atendido (por exemplo, geração de 100 populações, ou até que uma string possua um valor de adaptação superior a um limite pré-estabelecido).

- **MUTAÇÃO**

Dependendo da escolha da população inicial, pode não haver uma variedade de *strings* suficientes para assegurar que os AGs verifiquem o espaço do problema inteiramente. Ou os AGs podem convergir para soluções que não são próximas da ótima devido a uma má escolha da população inicial.

Alguns destes problemas são minimizados pela introdução da operação de mutação. Os AGs possuem uma *probabilidade de mutação* p_m, que determina a freqüência de ocorrência da mutação. Por outro lado, as mutações podem ocorrer durante a seleção ou o *crossover* (no *crossover* é mais freqüente). Para cada elemento dentro de cada *string* do grupo das *strings* reprodutoras o AG verifica se há a necessidade de se realizar mutação. Se a mutação for necessária, ele aleatoriamente altera o valor do elemento em análise. Em *strings* binárias, *1*s são mudados para *0*s e *0*s

para *1*s. Por exemplo, o AG decide alterar o valor do bit da posição 2 na *string* 11000:

1**1**000 → 1**0**000

O resultado é a *string 10000* com o segundo elemento alterado. A probabilidade de mutação deve ser mantida baixa (aproximadamente 1%). Uma taxa de mutação alta irá destruir as *strings* mais adaptadas e tornar o AG desprovido de direção em sua pesquisa pelo espaço do problema. As mutações ajudam a prevenir a estagnação das populações, injetando "sangue novo". Lembre-se de que grande parte da capacidade dos AGs provém do fato de existir um conjunto de *strings* muito diverso. Mutações ajudam a preservar esta diversidade através das iterações.

No próximo capítulo será aplicada a Rede de Hopfield Modificada para a solução dos modelos de Despacho Econômico estudados neste trabalho.

CAPÍTULO 5

Aplicação da Rede de Hopfield Modificada

Este capítulo descreve a aplicação da rede de Hopfield Modificada Proposta para a solução do problema de Despacho Econômico.

5.1. Introdução

A resolução de um problema de otimização normalmente precisa passar por duas fases: a primeira consiste em transformar o problema em um modelo e, posteriormente, um algoritmo deve ser implementado para resolver o modelo.

Uma vez que foram definidas todas as considerações relacionadas ao modelo de Despacho Econômico (DE) no capítulo 2, passaremos agora a recuperar as equações obtidas anteriormente que serão utilizadas para o mapeamento do problema.

O mapeamento do problema de Despacho Econômico usando uma rede de Hopfield consiste em se determinar a matriz de pesos **T** e o vetor de entradas $\mathbf{i}^b$, descritos na seção 3.6, para obter os pontos de equilíbrio da função de energia associada ao problema.

O modelo tratado a seguir é o Despacho Econômico com Representação do Sistema de Transmissão descrito na seção 2.4.

5.2. Mapeamento do Problema de DE pela Rede de Hopfield Modificada

Como observado na seção 2.3, o DE consiste em minimizar uma função custo na presença de restrições lineares de igualdade e/ou desigualdade. Uma vez que restrições de igualdade podem ser facilmente convertidas em restrições de desigualdade assume-se, por simplicidade, apenas restrições de desigualdade. Considere o seguinte problema de otimização restrita:

$$\text{DE}\begin{cases} \text{Min} & C_T = \sum_{i=1}^{NG} C_i(P_{Gi}) & (a) \\ \text{s. a. :} & \mathbf{P} = \mathbf{B}\boldsymbol{\theta} & (b) \\ & P_{Gi}^{\min} \le P_{Gi} \le P_{Gi}^{\max} & (c) \\ & F_i^{\min} \le F_i(\boldsymbol{\theta}) \le F_i^{\max} & (d) \end{cases} \tag{5.1}$$

onde:

C_T : é o custo total de combustível.

NG: é o número de geradores disponíveis.

$C_i(P_{Gi}) = a_i + b_i P_{Gi} + c_i P_{Gi}^2$: é o custo total de geração da unidade *i*.

P_{Gi}: é a potência ativa de saída da unidade *i*.

a_i, b_i e c_i : são os coeficientes de custo para *i*.

P : é o vetor das injeções de potência ativa.

B: é a matriz de susceptâncias da rede.

θ: é o vetor dos ângulos de tensão.

$P_{Gi}^{\min}$: é a mínima geração de saída da unidade *i*.

$P_{Gi}^{\max}$:é a máxima geração de saída da unidade *i*.

$F_i(\boldsymbol{\theta})=(\boldsymbol{\theta}_k - \boldsymbol{\theta}_l) / x_{kl}$: é o fluxo de potência ativa no ramo (linha ou transformador) *i* conectando as barras *k* e *l*.

$\boldsymbol{\theta}_k$: é o ângulo de tensão na barra *k*.

x_{kl}: é a reatância no ramo *i* conectando as barras *k* e *l*.

onde $\mathbf{B} \in \Re^{nb-1 \; x \; nb-1}$, **P**, **θ**, $P_G^{\min}$, $P_G^{\max} \in \Re^{nb-1}$; F^{min}, $F^{max} \in \Re^{nr}$; *nb* corresponde ao número de barras e *nr* corresponde ao número de ramos. As condições em (5.1b), (5.1c) e (5.1d) definem as fronteiras de um poliedro convexo. Neste caso, os vetores **P** e $F(\boldsymbol{\theta})$, que correspondem às variáveis P_{Gi} e $F_i(\boldsymbol{\theta})$, no problema de DE devem permanecer dentro deste poliedro caso os mesmos representem uma solução válida para o problema de otimização definido em (5.1a). Uma solução desse problema pode ser obtida através de uma rede de Hopfield modificada, na qual a técnica do subespaço-válido garante que as condições (5.1b), (5.1c) e (5.1d) sejam satisfeitas. Além disso, o hipercubo inicial representado pela restrição em (5.1c) é mapeado diretamente pela função rampa-simétrica (3.9) usada como uma função de ativação da rede.

Os termos $\mathbf{T}^{conf}$ e $\mathbf{i}^{conf}$ são calculados pela transformação das desigualdades em (5.1c) e (5.1d) em igualdades, introduzindo-se variáveis de folga, $w \in \Re^n$, (BAZARAA; SHETTY, 1979), conforme a seguir.

$$P_{Gi} - P_{Gi}^{\max} + \mathbf{w} = 0 \tag{5.2}$$

$$-P_{Gi} + P_{Gi}^{\min} + \mathbf{w} = 0 \tag{5.3}$$

$$F_i(\boldsymbol{\theta}) - F_i^{\max} + \sum_{j=1}^{q} \delta_{ij} w_j = 0 \tag{5.4}$$

$$-F_i(\boldsymbol{\theta}) - F_i^{\min} + \sum_{j=1}^{q} \delta_{ij} w_j = 0 \tag{5.5}$$

sendo que δ_{ij} é definido pela função impulso de Kronecker:

$$\delta_{ij} = \begin{cases} 1 \text{ , se } i = j \\ 0 \text{ , se } i \neq j \end{cases} \tag{5.6}$$

Após esta transformação, o problema definido em (5.1a), (5.1b), (5.1c) e (5.1d) pode ser rescrito como:

$$\begin{aligned}
&\textit{Min} && C_T = \sum_{i=1}^{NG} C_i(P_i) && (a) \\
&\textit{s.a.}: && \mathbf{P} = \mathbf{B}\boldsymbol{\theta} && (b) \\
& && P_{Gi} - P_{Gi}^{\max} + \mathbf{w} = 0 && (c) \\
& && -P_{Gi} + P_{Gi}^{\min} + \mathbf{w} = 0 && (d) \\
& && F_i(\boldsymbol{\theta}) - F_i^{\max} + \sum_{j=1}^{q} \delta_{ij} w_j = 0 && (e) \\
& && -F_i(\boldsymbol{\theta}) + F_i^{\min} + \sum_{j=1}^{q} \delta_{ij} w_j = 0 && (f)
\end{aligned} \tag{5.7}$$

As equações (5.7b) a (5.7f) podem ser resolvidas em um sistema do tipo $\mathbf{Ax} = \mathbf{b}$.

A solução para a restrição de igualdade de (5.7b) será dada por:

$$\mathbf{x} = \mathbf{A}(\mathbf{A}^T\mathbf{A})^{-1}\mathbf{b} \tag{5.8}$$

e a expressão do subespaço-válido em (3.8) deve levar em consideração esta solução, i.e.:

$$\mathbf{i}^{conf} = \mathbf{A}(\mathbf{A}^T\mathbf{A})^{-1}\mathbf{b} \tag{5.9}$$

A partir de (3.8) e (5.9) parâmetro $\mathbf{T}^{conf}$ é deduzido como segue:

$$\mathbf{x} = \mathbf{T}^{conf}\mathbf{x} + \mathbf{i}^{conf} \tag{5.10}$$

$$\mathbf{x} = \mathbf{T}^{conf}\mathbf{x}^* + \mathbf{A}(\mathbf{A}^T\mathbf{A})^{-1}\mathbf{b} \tag{5.11}$$

Inserindo o valor de (5.7b) e (5.11), a expressão para $\mathbf{T}^{conf}$ é dada por:

$$\mathbf{T}^{conf} = \mathbf{I} - \mathbf{A}(\mathbf{A}^T\mathbf{A})^{-1}\mathbf{A}^T \tag{5.12}$$

onde **I** é a matriz identidade.

Os parâmetros $\mathbf{T}^{ot}$ e $\mathbf{i}^{ot}$ neste caso são tais que o vetor **x** e **b** é atualizado na direção oposta ao gradiente da função de energia E^{ot}. Uma vez que as condições dadas no problema por (5.7b), (5.7c) e (5.7d), (5.7e) e (5.7f) definem um poliedro convexo fechado, então a função objetivo (5.7a) possui um único mínimo global ($|\mathbf{T}^{ot}=\mathbf{0}|$). Assim, usando (3.4) e (3.8), os pontos de equilíbrio da rede podem ser calculados assumindo-se os seguintes valores para $\mathbf{T}^{ot}$ e $\mathbf{i}^{ot}$:

$$\mathbf{i}^{ot} = -\left[\frac{\partial f(P)}{\partial P_{G1}} \; \frac{\partial f(P)}{\partial P_{G2}} \cdots \frac{\partial f(P)}{\partial P_{GNG}}\right]^{T} \tag{5.13}$$

$$\mathbf{T}^{ot} = 0 \tag{5.14}$$

5.3. Exemplo de Aplicação da Rede de Hopfield Modificada

A fim de demonstrar a aplicabilidade da Rede de Hopfield Modificada no problema de Despacho Econômico com Representação do Sistema de Transmissão, o sistema teste padrão IEEE de 14 barras foi simulado. Neste sistema, uma demanda de 259 MW deve ser atendida através do arranjo de cinco geradores. A tabela 5.1 apresenta os parâmetros iniciais relativos à função custo, onde a_i, b_i e c_i são os coeficientes da função custo e $P_i^{\min}$ e $P_i^{\max}$ são os limites mínimos e máximos de geração.

Tabela 5.1 – Parâmetros Iniciais

Unidade	a_i ***($/h)***	b_i ***($/MW)***	c_i ***($/MW^2)***	$P_i^{\min}$ ***(MW)***	$P_i^{\max}$ ***(MW)***
1	550	8,10	0,00028	0	680
2	126	8,60	0,00284	0	120
3	240	7,74	0,00324	0	180
4	309	8,10	0,00056	0	360
5	240	7,74	0,00324	0	20

A evolução da função custo para este caso é apresentada na Figura 5.1. A rede neural atingiu a solução em aproximadamente 50 iterações para a rede de Hopfield Modificada.

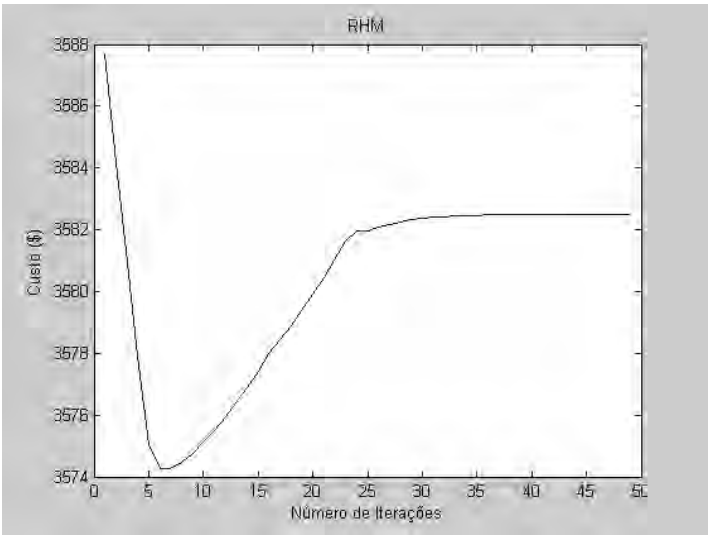

FIGURA 5.1 - Evolução da função custo da RHM

Quanto ao surgimento de uma espécie de vale na Figura 5.1 demonstra que a rede encontrou soluções mais econômicas que a solução final, mas não foi capaz de interromper sua evolução neste momento. Isto ocorre devido à não-linearidade da função objetivo que obriga um controle preciso e simultâneo do passo de convergência da rede. Uma vez que esta abordagem neural utiliza um passo constante (único parâmetro definido inicialmente pelo usuário), a rede acaba por escapar destas regiões de custo menor. Desta forma, com os objetivos de tornar o passo de iteração independente do problema, acelerar a velocidade de convergência da rede e garantir a precisão foi desenvolvido um controlador lógico nebuloso, o qual é discutido a seguir. O mesmo problema será resolvido utilizando o controlador lógico nebuloso na seção 7.4.

A aplicação do Algoritmo Genético proposto para a solução dos modelos de Despacho Econômico aqui estudada será apresentada no capítulo a seguir.

CAPÍTULO 6

Aplicação do Algoritmo Genético

Com este capítulo é apresentada a abordagem proposta baseada em Algoritmos Genéticos empregada na solução dos problemas de Despacho Econômico.

6.1. Introdução

Uma vez que foram definidos os modelos que descrevem o problema de DE no capítulo 2, passaremos agora a recuperar as equações obtidas anteriormente e discutir os algoritmos de AG especificamente propostos para a solução dos modelos já descritos.

6.2. Solução do Problema de Despacho Econômico Clássico

Para a solução do problema de Despacho Econômico Clássico (DEC), definida na seção 2.2.1, cada *string* está representada conforme mostrado na Figura 6.1, onde as gerações P_{Gi} das *n* unidades geradoras são mostradas.

O AG proposto relaciona-se com o problema do despacho a ser solucionado, principalmente através da codificação do problema e da função de adequação (expressa pela equação (2.4a), que avalia o custo do combustível). A estrutura de codificação permite representar soluções do problema (geração das unidades) como cromossomos e a função de adequação tem o papel de ligar o algoritmo genético ao problema a ser resolvido. Ela é usada para avaliar o cromossomo ou solução (custo total do combustível) para posterior uso pelos operadores de reprodução. Geralmente a função de adequação do indivíduo é determinada através do cálculo da função objetivo, que depende das especificações de projeto. Neste trabalho, a codificação utilizada é a binária e a função de adequação possui como entrada uma cadeia de bits e como saída um valor real. Cada indivíduo é uma entrada para uma ferramenta de análise de desempenho, cuja saída fornece medidas que permitem ao algoritmo genético o cálculo da função de adequação do indivíduo. Ainda nesta fase os indivíduos são ordenados conforme a sua aptidão.

P_{G1}	P_{G2}	P_{G3}	…	P_{Gn}

FIGURA 6.1 - Estrutura geral de uma *string P* utilizada no AG.

Cada uma das P_{Gi} gerações mostradas na Figura 6.2 está codificada em

binário. Muitas são as formas de codificar soluções, variando de problema para problema e de um algoritmo genético para outro. Os algoritmos de codificação/decodificação (binário - decimal e vice-versa) utilizados neste trabalho estão descritos em (GOLDBERG, 1989). Dada a estrutura geral das *strings* utilizadas, a descrição do AG proposto é ilustrada pelos seguintes passos:

***1. Início*:** Geração aleatória de uma população de *strings*, conforme a Figura 6.1. Cada uma das *n*-1 gerações de cada *string* é aleatoriamente gerada dentro dos limites mínimos e máximos de geração. Assim as restrições correspondentes a (2.4b) são automaticamente tratadas. A *n*-ésima unidade geradora é conhecida em análise de fluxo de potência como barra referência. Assim, a geração P_{ref} do gerador de referência é restringida pela equação 6.1 do balanço de potência do problema de DEC, conforme a seguir:

$$P_{ref} = D - \sum_{i=1}^{n-1} P_{Gi} + Loss \tag{6.1}$$

onde *D* é a demanda total do sistema e *Loss* são as perdas do sistema. Deste modo, a equação (2.4c) do problema fica também satisfeita.

2. Cálculo da Aptidão: Avaliação do grau de adaptação *f(P)* de cada string *P* de uma população.

3. Nova População: Criação de uma nova população através da repetição dos passos a seguir até que a população esteja formada.

3.1. Seleção: Selecionar dois cromossomos pais da população de acordo com seus valores de adaptação (os mais adaptados têm maior chance de serem selecionados).

3.2. Crossover: Com a probabilidade de *crossover*, cruzar os cromossomos selecionados no item anterior para formar as novas *strings* filhas. Se nenhum c*rossover* foi executado, as *strings* filhas serão cópias exatas das progenitoras.

3.3. Mutação: Com a probabilidade de mutação, realizar mutações em cada lócus (posição em um cromossomo) das novas *strings* produzidas.

3.4. Inserir as novas *strings* na nova população.

4. Substituição: Substituição da antiga população pela nova população gerada.

5. Condição de Parada: Verificar se as condições de parada são satisfeitas:

Se sim, parar a execução e apresentar a melhor solução da população atual (despacho de geração com custo total mínimo do combustível).

Se não, voltar ao Passo 2.

6.3. Solução do Problema de Despacho Econômico com Representação do Sistema de Transmissão

O AG proposto nesta seção também se relaciona com o problema de despacho a ser solucionado, principalmente por meio da codificação do problema e da função de adequação (expressa pela equação (2.25a), que avalia o custo do combustível).

Para cada indivíduo (*string*) as *n-1* gerações são calculadas pelo AG e a *n-ésima* unidade geradora refere-se à barra referência. Os valores θ_j são calculadas por meio do procedimento do fluxo de carga solucionando as equações (2.25b). As restrições funcionais (2.25d), representando os limites do fluxo de potência ativa no sistema de transmissão são introduzidas por meio de funções de penalidade na abordagem proposta. Esta abordagem consiste em introduzir na função objetivo de cada indivíduo infactível um termo quadrático de penalidade que adiciona um custo elevado aos indivíduos que violarem o limite do fluxo de potência ativa. A abordagem de penalidade é discutida em detalhe em (GOLDBERG, 1989). A função de penalidade aqui adotada é apresentada a seguir:

$$Pen_i = \frac{1}{2} w_p (F_i(\boldsymbol{\theta}) - F_i^{\lim})^2 \tag{6.2}$$

onde w_p é um parâmetro de penalidade e $F_i^{\lim}$ é o limite mínimo ou máximo violado no ramo *i*.

Dada a estrutura geral das *strings* utilizadas, a descrição do AG proposto para este problema segue os passos semelhantes ao do DEC:

1. ***Início:*** Geração aleatória das *n*-1 gerações P_{Gi} como mostradas na Figura 6.1 codificadas em binário. As *n*-1 gerações de cada string são geradas de forma aleatória dentro dos limites mínimos e máximo de geração.
2. ***Procedimento de Fluxo de Carga*:** Dadas as gerações, um procedimento de fluxo de potência DC é desenvolvido para cada *string*. Como resultado de tal procedimento, os valores dos ângulos de tensão e também os fluxos de potência ativa são obtidos para cada *string*. A geração da barra de referência de cada *string* é obtida pela equação (6.3):

$$P_{ref} = D - \sum_{i=1}^{n-1} P_{Gi} + Loss \tag{6.3}$$

   onde *D* é a demanda total do sistema e *Loss* são as perdas do sistema.
3. ***Cálculo da Aptidão***: Avaliação do grau de adaptação de cada *string* da população. Isto é realizado por avaliar o valor da função objetivo de cada *string*. O termo de penalidade, apresentado pela equação (6.2), é também adicionado à função objetivo de cada *string* que apresentar violação no limite do fluxo de potência ativa.
4. ***Nova População***: Criação de uma nova população de *strings*. Os passos seguintes são repetidos até a população esteja formada:
   - ***4.1. Seleção:*** Selecionar dois cromossomos pais da população de acordo com seus valores de adaptação (os mais adaptados têm maior chance de serem selecionados).
   - ***4.2. Crossover:*** Com a probabilidade de *crossover*, cruzar os cromossomos selecionados no item anterior para formar as novas *strings* filhas. Se nenhum *crossover* foi executado, as *strings* filhas serão cópias exatas das progenitoras.
   - ***4.3. Mutação:*** Com a probabilidade de mutação, realizar mutações em cada lócus (posição em um cromossomo) das novas *strings* produzidas.
   - ***4.4.*** Inserir as novas *strings* na nova população.

5. ***Substituição:*** Substituição da antiga população pela nova população gerada.
6. ***Condição de Parada:*** Verificar se as condições de parada são satisfeitas:

   6.1. Se sim, parar a execução e apresentar a melhor solução da população atual (geração das unidades com custo total mínimo do combustível).

   6.2. Se não, voltar ao Passo 2.

6.4. Solução do Problema de Despacho Multi-Objetivo

Para a solução do problema de Despacho Multi-Objetivo, definida na seção 2.5, cada *string* está representada conforme mostrado na Figura 6.1.

O AG utilizado neste problema é semelhante ao da seção 6.3. Novamente, para cada indivíduo que violar o limite de fluxo de potência ativa, é introduzido na função objetivo um termo quadrático de penalidade que adiciona um custo elevado.

6.5. Solução do Problema de Despacho Econômico Hidrotérmico

Para a solução do problema de despacho hidrotérmico, definida na seção 2.6, cada *string* está representada conforme mostrado na Figura 6.2, composta por nT gerações PT_{Gi} das unidades térmicas, as nH gerações PH_{Gj} das unidades hidráulicas.

PT_{G1}	PT_{G2}	...	PT_{GnT}	PH_{G1}	PH_{G2}	...	PH_{GnH}

FIGURA 6.2 - Estrutura geral de uma *string* utilizada no AG proposto.

Os valores dos ângulos de tensão são calculados através do procedimento do fluxo de carga. As equações funcionais (2.28e) e (2.28f), representando os limites do fluxo de potência ativa no sistema de transmissão são calculadas pelas funções de penalidade descrita em (6.2).

As restrições (2.28g) e (2.28h) do problema que representam os limites da

faixa de cavitação adicionam um custo elevado aos indivíduos (geração hidráulica) que resultar em valores de potência ativa pertencentes a essa faixa.

Os resultados obtidos com as aplicações das metodologias desenvolvidas para a solução dos problemas de despacho econômico adotados neste trabalho serão apresentados no próximo capítulo.

CAPÍTULO 7

Resultados da Simulação

Neste capítulo, resultados de simulações e uma análise de sensibilidade envolvendo sistemas testes são apresentados a fim de comparar e ilustrar a eficiência das abordagens propostas.

7.1. Introdução

Este capítulo apresenta a análise dos resultados obtidos com a aplicação da Rede de Hopfield Modificada e dos Algoritmos Genéticos propostos para a solução dos modelos de Despacho Econômico (DE) apresentados no capítulo 2. O primeiro estudo considera o problema de Despacho Econômico Clássico. O segundo estudo trata-se do problema de Despacho Econômico com representação do sistema de transmissão. O estudo seguinte considera o problema de Despacho Econômico incluindo as perdas na transmissão. Por fim, estuda-se o problema de Despacho Hidrotérmico.

A implementação computacional da Rede de Hopfield Modificada e do Algoritmo Genético, propostos para resolver os problemas de DE, foram realizadas utilizando o Matlab versão 6.5 e fabricado pela *MathWorks*.

Em todos os exemplos, as execuções dos métodos foram realizadas utilizando um PC com processador Intel 1000 MHz, Pentium III.

7.2. Problema de Despacho Econômico Clássico (DEC)

Nesta seção, resultados de simulação e análises comparativas são apresentados a fim de avaliar os métodos desenvolvidos. As abordagens propostas são aplicadas à solução do problema de DEC já descrito. Em alguns estudos os pontos de válvula são também considerados.

Foram desenvolvidas quatro abordagens para resolver o problema de DEC como descritas a seguir:

i) **(RHM)** A abordagem de Hopfield Modificada foi aplicada para uma formulação de DEC conforme descrito anteriormente. A abordagem RHM não é aplicável para resolver um problema de DEC que leva em consideração os pontos de válvula de unidades térmicas.

ii) **(Multiplicadores de Lagrange)** Com o objetivo de explicar didaticamente as características gerais do custo das unidades geradoras o problema de DEC é solucionado sem considerar os pontos de válvula como descrito na seção 2.3.1. Desta forma, o custo de produção é

determinado por meio da otimização irrestrita da função Lagrangeana, que incorpora as restrições de igualdade pré-multiplicadas pelos multiplicadores de Lagrange.

iii) **(AG)** Para efeito de validação e comparação com os itens (i) e (ii), o Algoritmo Genético proposto no item 6.2 também é aplicado no problema de DEC, ignorando os pontos de válvula.

iv) **(AGV)** O Algoritmo Genético proposto no item 6.2 é aplicado ao problema de DEC considerando o efeito de pontos de válvula.

Em todos os testes realizados para este sistema, na execução do método utilizando o Algoritmo Genético, foram consideradas as seguintes informações:

Número de gerações: 100
Número de indivíduos por geração: 30
Quantidade de bits de representação por unidade: 11
Percentagem de ocorrência de crossover: 0,95
Percentagem de ocorrência de mutação: 0,01

7.2.1. Exemplo 1

O sistema teste assumido neste exemplo é composto por três unidades geradoras que alimentam uma demanda total de 850 MW. Os parâmetros relativos à função custo são apresentados na Tabela 7.1.

Tabela 7.1 – Parâmetros Iniciais da Função Custo – Sistema de 3 Barras

Unidade	a_i	b_i	c_i	e_i	f_i	$P_i^{\min}$ ***(MW)***	$P_i^{\max}$ ***(MW)***
1	561	7,92	0,001562	900	0,0315	100	600
2	310	7,85	0,001940	600	0,0420	100	400
3	78	7,97	0,004820	450	0,0630	50	250

A Tabela 7.2 apresenta os resultados obtidos pela execução da rede de Hopfield Modificada (RHM), do método dos Multiplicadores de Lagrange e do Algoritmo Genético proposto. Na tabela são mostrados os despachos de geração P_1, P_2 *e* P_3 dados em MW e o custo dado em unidades monetárias ($). Os coeficientes a_i, b_i e c_i da função custo são dados, respectivamente, por $/h, $/MW

e $/MW^2.

Para a abordagem AG mostrada na tabela, assim como para a RHM considerou-se a função de custo aproximada: sem a representação dos pontos de válvula. Para isso foram adotados $e_i = 0$ e $f_i = 0$. Para AGV o problema de DEC foi formulado considerando os pontos de válvula com valores de e_i *e* f_i dados na Tabela 7.1.

A Figura 7.1. mostra a evolução da função custo das abordagens RHM, AG e AGV, respectivamente. A coluna "Custo Real" apresentada na última coluna da Tabela 7.2 refere-se ao custo obtido pelos métodos se os despachos de geração calculados são diretamente substituídos na função custo "real" dada pela equação em que os pontos de válvula são considerados.

Tabela 7.2 – Resultados da Simulação – Sistema de 3 Barras

Método	***P1 (MW)***	***P2 (MW)***	***P3 (MW)***	***Custo ($)***	***Custo Real ($)***
RHM	389,27	337,23	123,50	8194,40	9227,72
Lagrange	393,17	334,60	122,22	8194,40	9057,50
AG	393,06	334,70	122,24	8194,40	9063,00
AGV	403,60	287,39	159,00	8776,60	8776,60

O custo total obtido pelo método da RHM, Lagrange e AG é de $ 8194,40. De fato, o problema de DEC estudado é convexo. Neste caso, a solução obtida pelo método é o ótimo global para o problema. Pode -se verificar que tanto a RHM quanto o Algoritmo Genético são capazes de lidar com funções de custo não-lineares, encontrando para estes casos sempre uma solução factível. A RHM encontrou a solução em aproximadamente 50 iterações.

Ao tratarmos os pontos de válvula utilizando o algoritmo genético proposto, o custo total obtido foi de $ 8776,60. Neste sentido, observou-se, inicialmente, um aumento do custo do sistema de geração que consideram pontos de válvula em relação ao problema anterior que não os consideram. Este é um resultado esperado, já que o custo real (considerando os pontos de válvula nas unidades térmicas) é sempre superior ao custo aproximado (conforme mostrado na Figura 2.1).

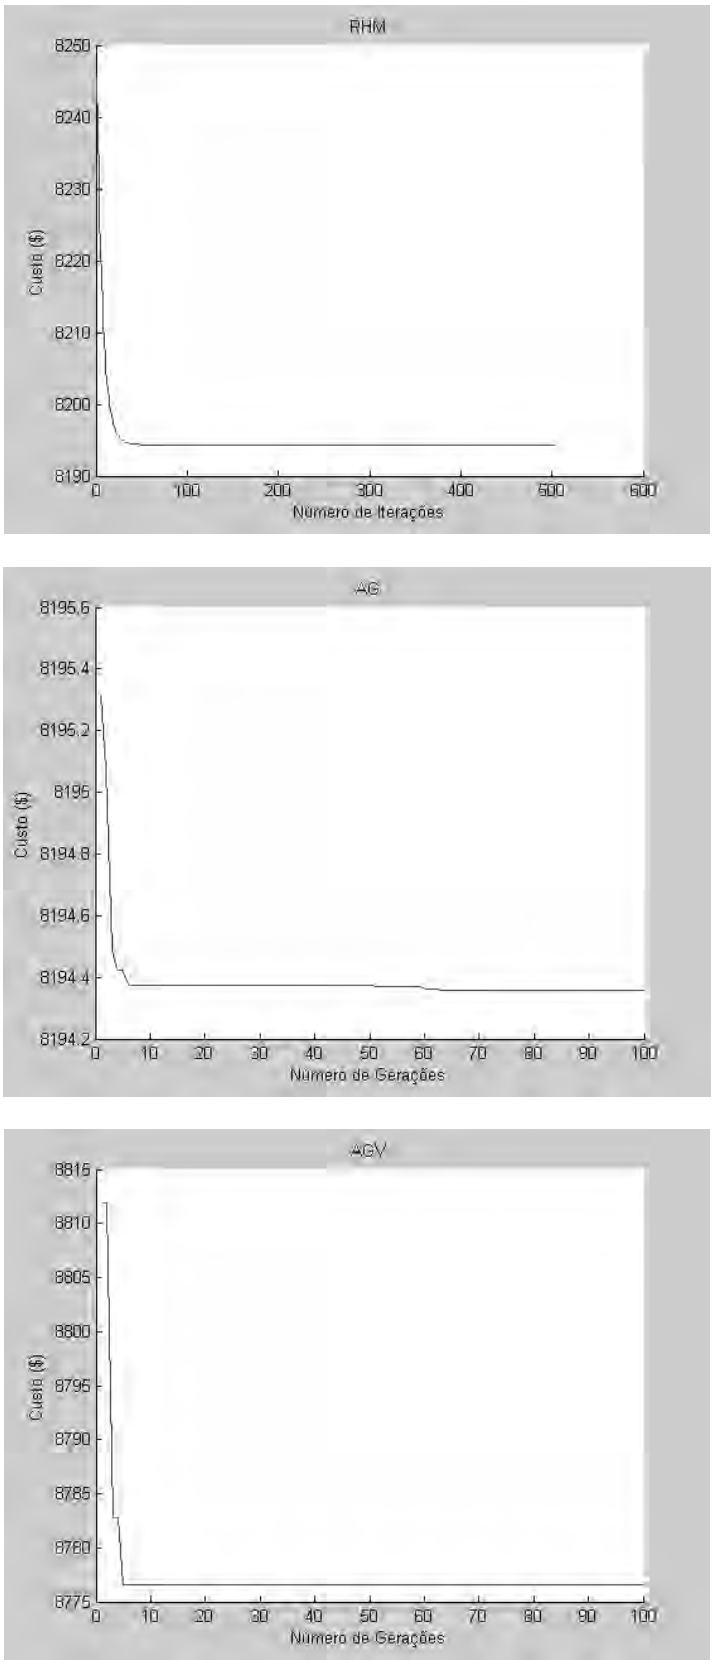

FIGURA 7.1 - Evolução da função custo (RHM, AG e AGV) – Exemplo 1

O método que utiliza Algoritmos Genéticos converge para soluções ótimas ou aproximadamente ótimas em níveis globais, encontrando a solução em aproximadamente 12 segundos.

7.2.2. Exemplo 2

O sistema teste assumido neste exemplo é composto por cinco unidades geradoras que suportam uma demanda total de 860 MW. Os parâmetros relativos à função custo são apresentados na Tabela 7.3.

A Figura 7.2. mostra a evolução da função custo das abordagens RHM, AG e AGV, respectivamente.

Tabela 7.3 – Parâmetros Iniciais – Sistema de 14 Barras

Unidade	a_i	b_i	c_i	e_i	f_i	P_i^{min} **(MW)**	P_i^{max} **(MW)**
1	550	8,10	0,00028	870	0,02094	0	680
2	126	8,60	0,00284	30	0,06283	0	120
3	240	7,74	0,00324	120	0,05712	0	180
4	309	8,10	0,00056	390	0,03927	0	360
5	240	7,74	0,00324	120	0,05236	0	180

A descrição da Tabela 7.4 é análoga à da Tabela 7.2 anterior.

Tabela 7.4 – Resultados da Simulação – Sistema de 14 Barras.

Método	P_1 ***(MW)***	P_2 ***(MW)***	P_3 ***(MW)***	P_4 ***(MW)***	P_5 ***(MW)***	***Custo ($)***	***Custo Real ($)***
RHM	287,02	37,83	180,00	175,10	180,00	8574,16	9138,14
Lagrange	430,00	1,00	96,85	236,23	96,39	8505,33	9119,11
AG	450,87	0	94,00	225,22	89,91	8504,94	8948,12
AGV	200,00	80,24	125,28	360,00	94,49	8691,45	8691,45

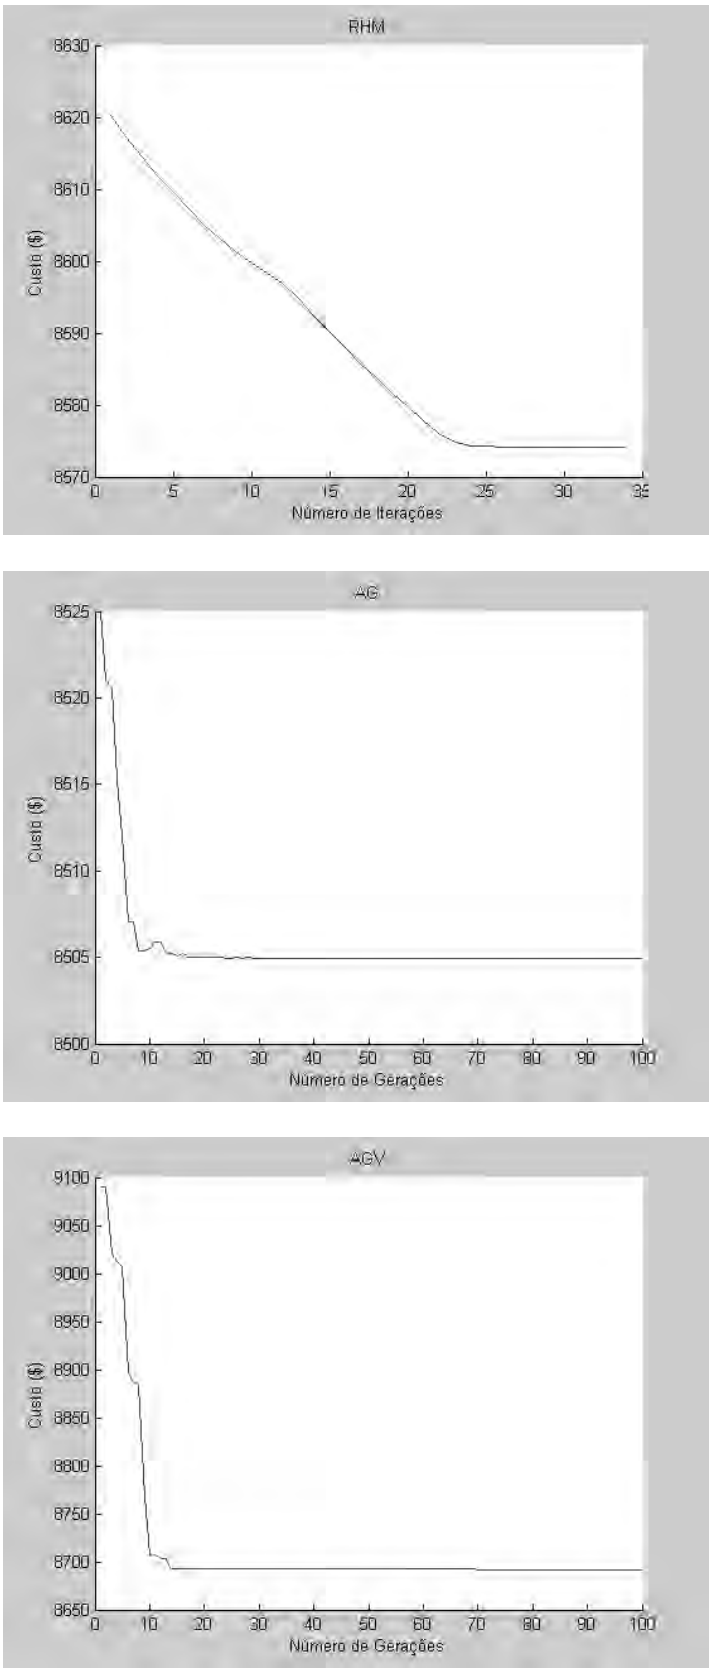

FIGURA 7.2 - Evolução da função custo (RHM, AG e AGV) – Exemplo 2

A RHM atingiu a solução de custo mínimo em aproximadamente 35 iterações. A maioria das redes neurais pode levar milhares de iterações para atingir os pontos de equilíbrio (PARK *et al.*, 1993). Na RHM aqui estudada tais problemas relacionados à velocidade de convergência são efetivamente contornados. Entretanto, percebe-se que a RHM apresenta valores subótimos, escapando do ponto de otimalidade do problema. Este é um problema freqüente encontrado na literatura e que carece de melhor tratamento por parte dos modelos baseados em redes neurais. Uma alternativa para a solução deste problema é a utilização de um mecanismo de controle do passo de otimização, conforme descrito na seção 3.7.

O método AG proposto é mais robusto e consegue aproximadamente o mesmo despacho de geração calculado por Lagrange. O AG obteve a solução de custo mínimo em aproximadamente 15 segundos.

7.2.3. Conclusões

Esta seção aplicou duas abordagens de sistemas inteligentes para resolver problemas de DEC.

Na Rede de Hopfield Modificada avaliada, os pontos de equilíbrio são obtidos eficientemente e a viabilidade da solução do DEC é garantida pela técnica de subespaço válido adotada. Entretanto, verifica-se que a RHM escapa do ponto ótimo do problema apresentando valores subótimos.

Os resultados focalizam as discrepâncias entre o modelo de RHM e AG. A RHM é eficiente nos casos em que funções não convexas são utilizadas, entretanto não podem resolver problemas de DEC envolvendo funções objetivo não diferenciáveis. Por outro lado os AGs obtiveram soluções para todos os tipos de DEC estudados.

Se a política de despacho calculada pela RHM e por Lagrange for usada para calcular o custo “real” (considerando os pontos de válvula), a economia fornecida pela solução proposta de AGV está na faixa de 4 a 5% dos custos da geração.

7.3. Definição de Parâmetros dos Algoritmos Genéticos

Além da forma como a *string* é codificada, existem vários parâmetros do Algoritmo Genético que podem ser escolhidos para melhorar o seu desempenho, adaptando-o às características particulares de determinadas classes de problemas. Dentre eles, os mais importantes são: o tamanho da população, a probabilidade de *crossover* e a probabilidade de mutação. Nesta seção, estudaremos estes parâmetros na solução do problema de DEC.

7.3.1. Variação do Tamanho da População

Utilizando o sistema teste descrito na seção 7.2.2, foram consideradas as seguintes informações:

Número de gerações: 100
Quantidade de bits de representação por unidade: 11
Percentagem de ocorrência de crossover: 0,95
Percentagem de ocorrência de mutação: 0,01

O tamanho da população é um fator muito importante no desempenho dos Algoritmos Genéticos. Uma população inicial muito pequena pode ocasionar ciclos e, por outro lado, populações muito grandes irão exigir um maior número de avaliações, comprometendo a eficiência do método.

Dependendo da escolha da população inicial, pode não haver uma variedade de *strings* suficiente para assegurar que os AGs verifiquem o espaço do problema inteiramente; ou os AGs podem convergir para soluções que não são próximas da ótima devido a uma má escolha da população inicial.

A Tabela 7.5 apresenta os resultados obtidos pela execução do Algoritmo Genético proposto. Na tabela são mostrados os despachos de geração, o custo mínimo e o tempo de execução obtido ao variar o número de indivíduos da população.

Tabela 7.5 – Resultados – Variação do Tamanho da População

Tamanho da População	***P_1 (MW)***	***P_2 (MW)***	***P_3 (MW)***	***P_4 (MW)***	***P_5 (MW)***	***Custo ($)***	***Tempo (s)***
4	414,65	15,36	101,65	227,04	101,30	8510,02	1
5	452,66	7,50	88,55	218,60	92,68	8507,04	1
10	449,35	0	89,96	225,64	95,06	8504,94	3
20	447,47	0	94,44	224,00	94,09	8504,87	6
30	446,62	0	94,18	225,11	94,09	8504,87	15
50	448,21	0	94,27	223,35	94,18	8504,87	40

Analisando a Tabela 7.5 verifica-se que populações grandes não melhoram o desempenho do AG, isto é, não melhoram a velocidade de determinação de uma solução. Por meio de estudos exaustivos para este problema específico, chegou-se a conclusão de que um bom tamanho para uma população inicial é de cerca de 20 a 30 indivíduos.

7.3.2. Variação das Probabilidades de *Crossover*

Utilizando o sistema teste descrito na seção 7.2.2, foram consideradas as seguintes informações:

Número de gerações: 100

Quantidade de bits de representação por unidade: 11

Número de indivíduos por geração: 30

A Tabela 7.6 apresenta os resultados obtidos pela execução do Algoritmo Genético proposto. Na tabela são mostrados os despachos de geração e o custo mínimo obtido ao variar a probabilidade de *crossover* p_c e fixando a probabilidade de mutação p_m em 0,01.

Quanto maior for a taxa de *crossover*, mais rapidamente novas estruturas serão introduzidas na população. Mas, se esta taxa for muito alta, estruturas com boas aptidões poderão ser retiradas mais rápido, ou seja, a maior parte da população será substituída. Com um valor baixo, o algoritmo pode tornar-se muito lento.

A taxa de *crossover* deve ser alta, aproximadamente 80% a 95% para que haja diversidade da população.

Tabela 7.6 – Variação das Probabilidades de *Crossover*

p_c	p_m	P_1 (MW)	P_2 (MW)	P_3 (MW)	P_4 (MW)	P_5 (MW)	Custo($)
0,30	0,01	441,24	7,09	93,56	225,11	93,00	8506,80
0,40	0,01	500,53	0	89,60	179,91	89,96	8506,64
0,50	0,01	456,83	0	89,78	223,53	89,87	8505,02
0,60	0,01	446,36	0	94,27	225,11	94,27	8504,87
0,70	0,01	446,80	0	94,00	223,53	95,67	8504,87
0,80	0,01	446,80	0	94,18	223,35	95,67	8504,87
0,90	0,01	448,12	0	94,18	223,70	94,00	8504,87

7.3.3. Variação das Probabilidades de Mutação

Nesta seção, as informações do sistema teste utilizado foram as mesmas da seção 7.3.2.

A Tabela 7.7 apresenta os despachos de geração e o custo mínimo obtido ao variar as probabilidades de mutação p_m e mantendo fixa a probabilidade de *crossover* p_c em 0,90.

Tabela 7.7 – Variação das Probabilidades de Mutação

p_c	p_m	P_1 (MW)	P_2 (MW)	P_3 (MW)	P_4 (MW)	P_5 (MW)	Custo($)
0,90	0,008	447,68	0	94,27	224,06	94,00	8504,87
0,90	0,01	448,12	0	94,18	223,70	94,00	8504,87
0,90	0,02	445,39	0	91,45	227,92	95,23	8504,91
0,90	0,03	467,41	0	89,52	214,00	89,08	8505,19
0,90	0,04	448,79	8,73	86,26	224,76	91,45	8507,50
0,90	0,05	453,89	8,91	89,96	227,57	79,67	8508,09
0,90	0,10	470,37	7,74	126,27	171,12	84,50	8512,30
0,90	0,80	380,00	11,14	137,70	223,00	108,16	8516,03

Dentre os custos obtidos, o pior ocorreu quando p_m=0,80, pois uma taxa de mutação alta destrói as *strings* mais adaptadas e torna a busca essencialmente aleatória. Assim, a taxa de mutação deve ser baixa para prevenir que uma dada posição fique estagnada em um valor, além de possibilitar que se chegue em qualquer ponto do espaço de busca.

7.4. Problema de Despacho Econômico com Representação do Sistema de Transmissão

Nos procedimentos de DEC, a representação do sistema de transmissão é totalmente desprezada. Desta forma, o intuito desta seção é adotar uma melhor

representação do sistema de transmissão, utilizando os métodos baseados em sistemas inteligentes propostos neste trabalho.

Para validar a proposta e demonstrar a eficiência das abordagens aplicadas à solução do problema de Despacho Econômico com representação do sistema de transmissão (DE_ST), descrito na seção 2.4, são realizadas simulações utilizando o sistema teste do IEEE de 14 barras. A descrição do sistema teste utilizado é dada no apêndice A.

7.4.1. Sistema Teste IEEE de 14 Barras

Foram desenvolvidas quatro abordagens para resolver o problema de DE_ST como descrito a seguir:

i) **(RHM)** A abordagem de Hopfield Modificada foi aplicada para uma formulação de DE_ST onde os pontos de válvula são ignorados.

ii) **(RHMF)** Com a finalidade de acelerar a taxa de convergência da rede e evitar escape nos pontos de ótimo, um controlador lógico nebuloso é introduzido na RHM conforme descrito na seção 3.7.

iii) **(AG)** Para efeito de validação e comparação com os itens (i) e (ii), o Algoritmo Genético proposto na seção 6.3 também é aplicado no problema de DE_ST, ignorando os pontos de válvula. O tratamento das restrições funcionais, representando os limites do fluxo de potência ativa no sistema de transmissão, é implementado por funções de penalidade na abordagem proposta conforme descrito na seção 6.3.

iv) **(AGV)** O Algoritmo Genético Proposto na seção 6.3 é aplicado ao problema de DE_ST considerando os pontos de válvula. O tratamento das restrições funcionais também é realizado por funções de penalidade.

Em todos os testes realizados para este sistema, na execução do método utilizando o Algoritmo Genético, foram consideradas as seguintes informações:

Número de gerações: 100
Número de indivíduos por geração: 14

Quantidade de bits de representação por unidade: 11

Percentagem de ocorrência de crossover: 0,95

Percentagem de ocorrência de mutação: 0,01

Esta seção mostra alguns resultados de simulação envolvendo o sistema teste de 14 barras do IEEE, no qual cinco unidades geradoras alimentam toda a demanda, que é de 259 MW. De posse dos dados fornecidos pela Tabela 7.8, alguns casos são analisados a fim de avaliar a sensibilidade das abordagens propostas com relação a algumas características de modelagem específicas (restrições, função objetivo, etc.).

Tabela 7.8 – Parâmetros Iniciais da Função Custo

Unidade	a_i	b_i	c_i	e_i	f_i	P_i^{min} **(MW)**	P_i^{max} **(MW)**
1	550	8,10	0,00028	870	0,0157	0	680
2	126	8,60	0,00284	30	0,0449	0	120
3	240	7,74	0,00324	120	0,0314	0	180
6	309	8,10	0,00056	390	0,0262	0	360
8	240	7,74	0,00324	120	0,0349	0	180

7.4.2. Caso I

Este caso representa uma situação básica do problema na qual nenhuma restrição está ativa na solução ótima (caso relaxado). Os despachos de geração computados, respectivamente, pela rede de Hopfield Modificada (RHM), rede de Hopfield Modificada Fuzzy (RHMF), AG e AGV são apresentados na Tabela 7.9.

Tabela 7.9 – Resultados da Simulação (Caso I)

Método	P_1 ***(MW)***	P_2 ***(MW)***	P_3 ***(MW)***	P_6 ***(MW)***	P_8 ***(MW)***	***Custo ($)***	***Custo Real ($)***
RHM	21,60	26,60	32,43	103,52	74,86	3567,28	4210,60
RHMF	21,59	26,59	32,42	103,51	74,84	3566,86	4210,10
AG	79,25	0	64,34	53,65	61,76	3546,60	4963,40
AGV	5,19	33,37	99,39	36,49	84,56	4016,60	4016,60

A Figura 7.3 mostra, respectivamente, a evolução da função custo das

redes de Hopfield Modificada (RHM) e de Hopfield Modificada Fuzzy (RHMF). Já, a Figura 7.4 apresenta, respectivamente, a evolução da função custo do AG e do AGV proposto.

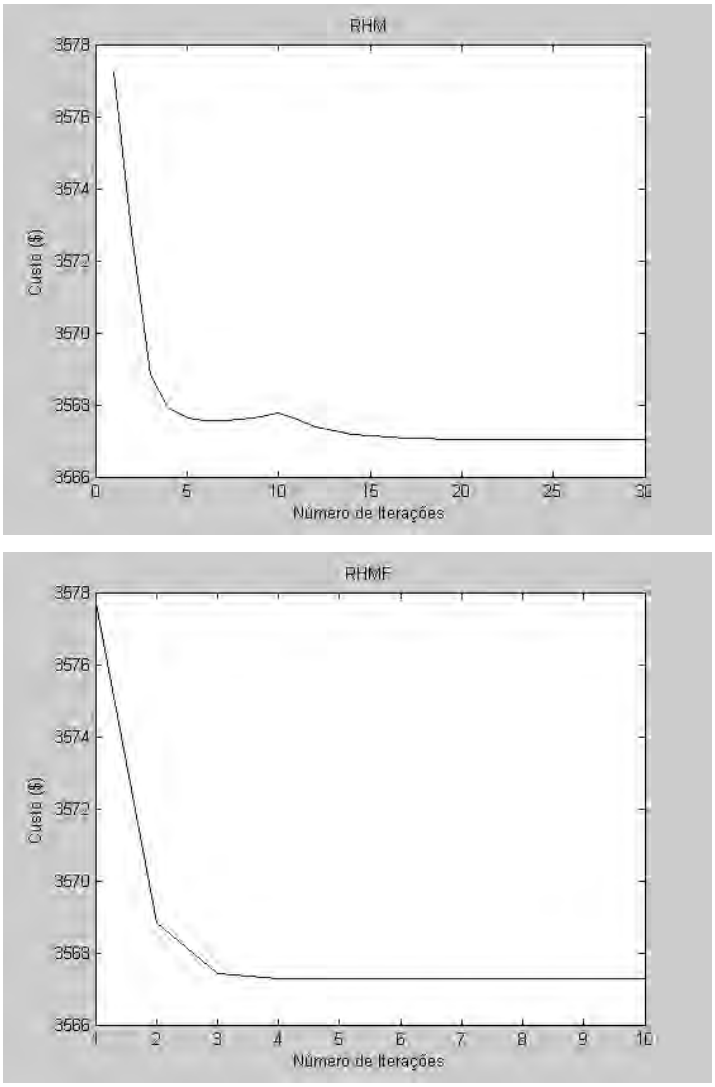

FIGURA 7.3 - Evolução da função custo (RHM e RHMF) – Caso I

A rede atingiu a solução de custo mínimo em aproximadamente 30 iterações para RHM e 10 iterações para RHMF. Desta forma, problemas relacionados ao passo de iteração são contornados na RHMF, onde a velocidade de convergência foi acelerada.

Entretanto, conforme se percebe pelos valores de custo finais mostrados na Tabela 7.9 para RHM e RHMF, mesmo com a introdução do controlador lógico nebuloso a solução permanece com um certo grau de subotimalidade, se comparada à solução obtida pelo Algoritmo Genético. Os despachos calculados

pelas abordagens neurais também se mostram bastante diferente daqueles calculados pelo Algoritmo Genético.

O AG obteve a solução de custo mínimo em aproximadamente 25 segundos.

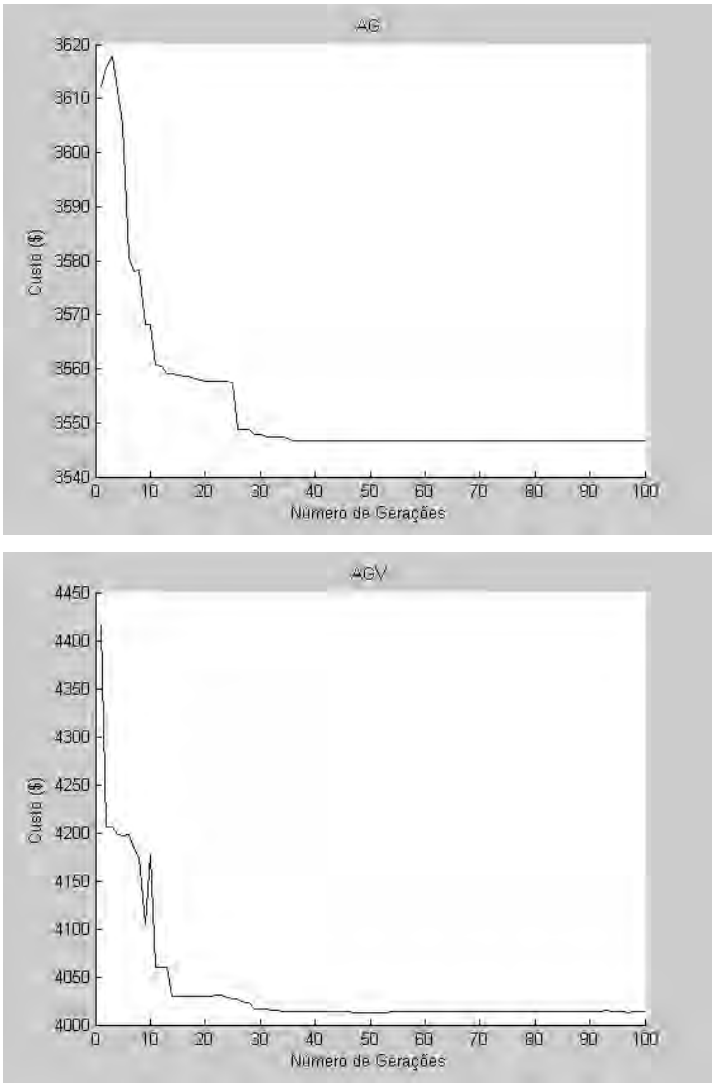

FIGURA 7.4 - Evolução da função custo (AG e AGV) – Caso I

7.4.3. Caso II

No Caso II, o limite máximo de geração para a unidade 8 foi modificado para 20 MW de modo a verificar o comportamento da rede nos casos em que limites na geração devam ser forçados. Os despachos calculados pelos modelos propostos são mostrados na Tabela 7.10. Como pode ser visto nesta tabela, a

geração de saída para a unidade 8 foi convenientemente fixada em seu valor máximo (20MW).

Tabela 7.10 – Restringindo a Geração (Caso II)

Método	P_1 *(MW)*	P_2 *(MW)*	P_3 *(MW)*	P_6 *(MW)*	P_8 *(MW)*	*Custo ($)*	*Custo Real ($)*
RHM	30,03	34,31	120,72	53,87	20,00	3582,50	4542,50
RHMF	34,55	32,80	57,71	113,94	20,00	3574,10	4308,30
AG	110,07	0	64,93	64,00	20,00	3553,00	4984,30
AGV	3,09	38,60	79,09	118,25	19,97	3820,10	3820,10

A evolução da função custo para este caso é apresentada na Figura 7.5 para a RHM e a RHMF e na Figura 7.6 para o AG e o AGV.

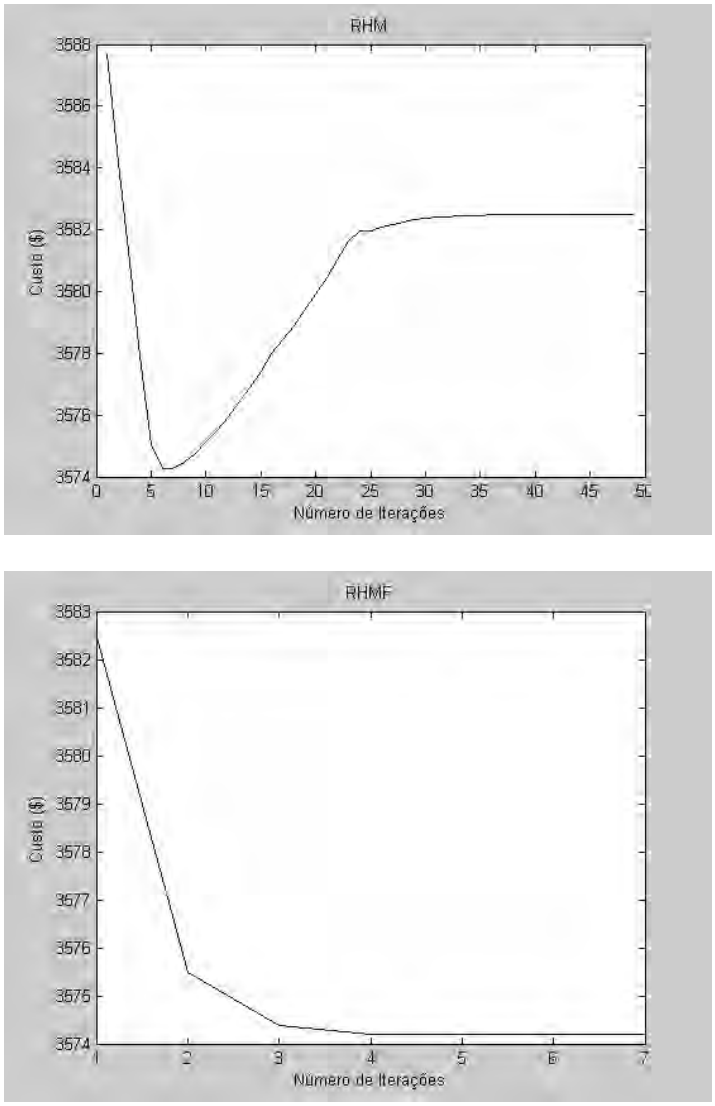

FIGURA 7.5 - Evolução da função custo (RHM e RHMF) – Caso II

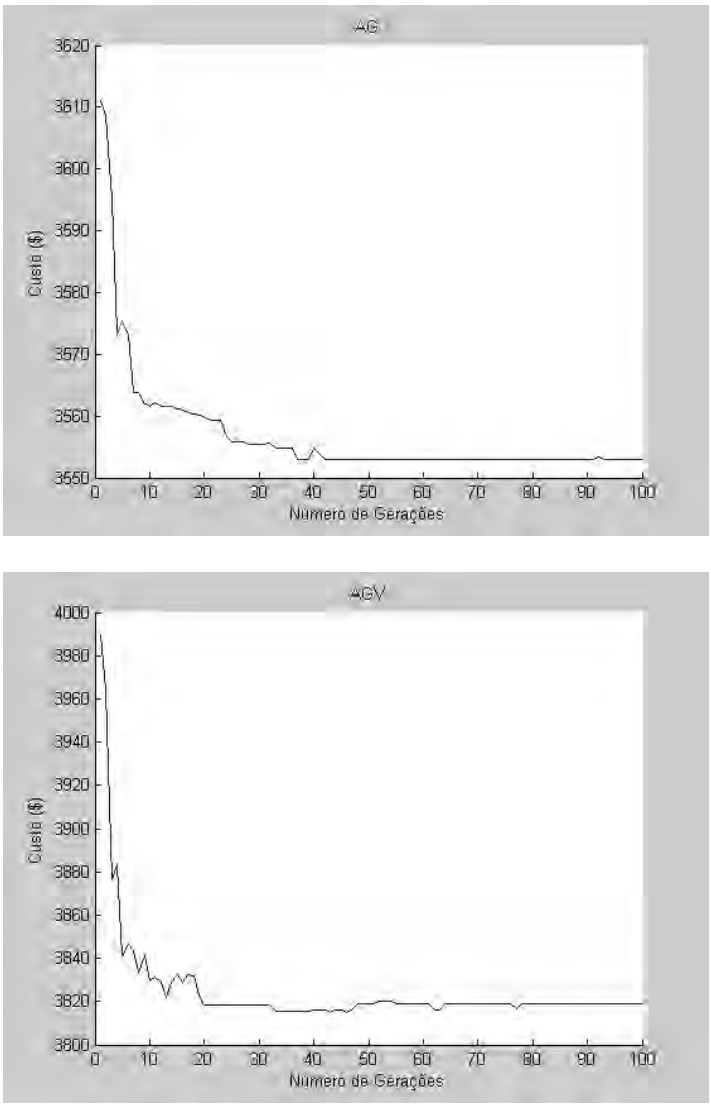

FIGURA 7.6 - Evolução da função custo (AG e AGV) – Caso II

A rede neural atingiu a solução em aproximadamente 40 iterações para a rede de Hopfield sem a implementação de um controlador lógico nebuloso. No gráfico obtido com a execução desta rede, observa-se o surgimento de uma espécie de vale. Isso demonstra que a rede encontrou soluções mais econômicas que a solução final, mas não foi capaz de interromper sua evolução neste momento devido à utilização de um passo de otimização de tamanho constante. Já, com a implementação de um controlador lógico nebuloso, a rede neural atingiu a solução em aproximadamente 7 iterações.

As abordagens baseadas no Algoritmo Genético proposto mostraram-se robustas e eficientes para encontrarem a solução em aproximadamente 27 segundos. Como ambas as soluções obtidas pelo algoritmo genético são estritamente factíveis, verifica-se que o tratamento da restrição de geração ativa foi convenientemente respeitado.

7.4.4. Caso III

Para o Caso III analisa-se o comportamento da rede de Hopfield quando limites no fluxo de potência ativa são forçados. Neste caso, os limites em duas linhas do sistema (conectando as barras 1-5 e 7-9), selecionadas aleatoriamente, são fixados em zero, simulando uma contingência de linhas dupla. O novo despacho calculado pela rede é totalmente rearranjado de modo a suprir a demanda do sistema. O novo despacho calculado pelos métodos propostos para este caso é apresentado na Tabela 7.11.

Tabela 7.11 – Contingência Dupla de Linha (Caso III)

Método	P_1 *(MW)*	P_2 *(MW)*	P_3 *(MW)*	P_6 *(MW)*	P_8 *(MW)*	*Custo ($)*	*Custo Real ($)*
RHM	20,13	30,20	35,42	153,54	19,63	3578,74	4362,11
RHMF	20,49	29,35	35,43	153,69	19,96	3578,12	4367,96
AG	84,42	0	59,00	54,00	61,58	3546,68	4991,51
AGV	0	47,37	36,49	89,58	85,56	4014,00	4014,00

As Figuras 7.7 e 7.8 mostram a evolução da função custo para este caso.

Pela Figura 7.7 pode ser notado que o número de iterações foi realmente pequeno (foram necessárias 10 iterações para RHM e 6 iterações para RHMF).

A Figura 7.8 apresenta evolução da função custo para as abordagens baseadas no Algoritmo Genético proposto que obtiveram a solução de custo mínimo em aproximadamente 27 segundos. O tratamento de restrições em fluxos do problema de DE foi bastante satisfatório. A Tabela 7.12 apresenta os fluxos nas linhas ao encontrar a solução ótima do problema.

Tabela 7.12 – Fluxos nas Linhas

Linha	*RHM*	*RHMF*	*AG*	*AGV*
1-5	0,0008	0,0014	0	0
7-9	0,0337	0,0321	0	0

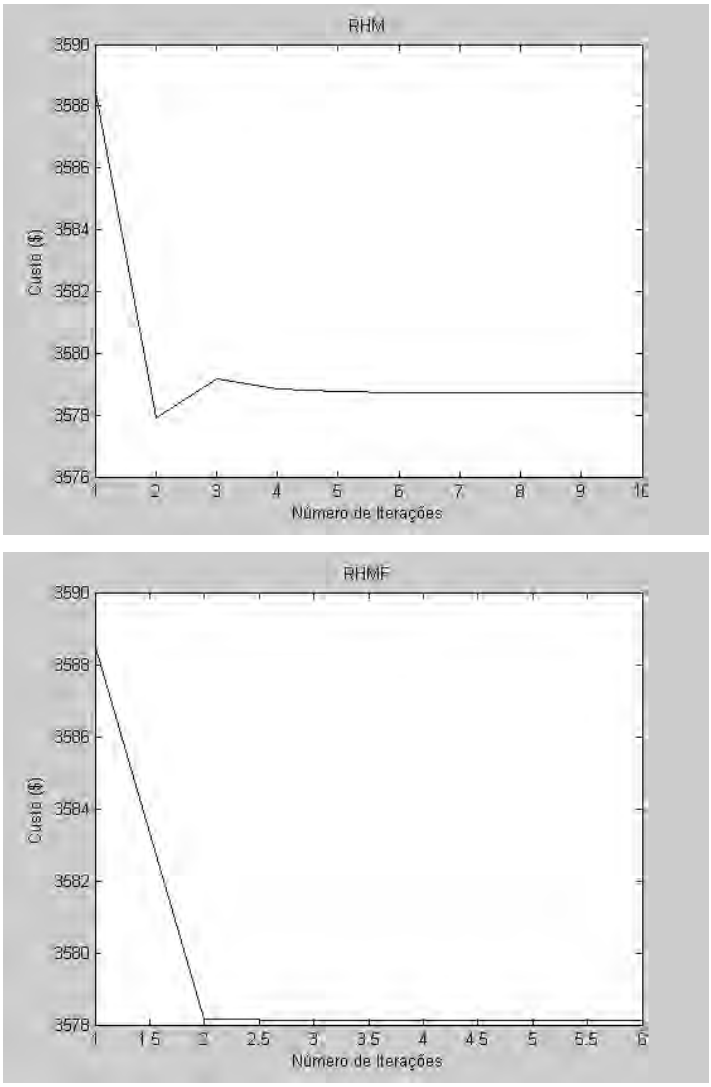

FIGURA 7.7 - Evolução da função custo (RHM e RHMF) – Caso III

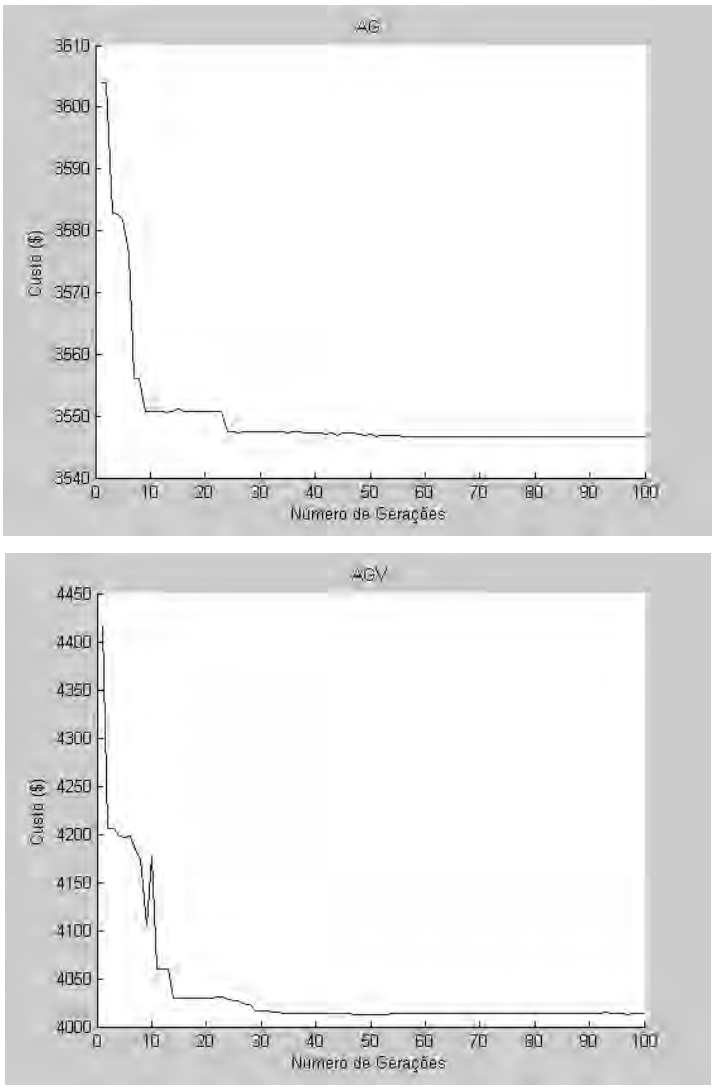

FIGURA 7.8 - Evolução da função custo (AG e AGV) – Caso III

7.4.5. Conclusões

Esta seção aplicou-se as abordagens de sistemas inteligentes para resolver problemas de DE com representação do sistema de transmissão.

O desempenho da rede neural de Hopfield sem a implementação do controlador lógico nebuloso (RHM) é afetado pelo uso de um passo de iteração (Δt) fixo. Em geral, para um Δt pequeno, a convergência para os pontos de equilíbrio é lenta, enquanto que para um Δt grande, a precisão destes pontos de equilíbrio pode ser prejudicada. Com a finalidade de contornar estes problemas, um controlador lógico nebuloso foi implementado.

Em todos os casos a velocidade de convergência da rede foi maior no

método em que o controlador lógico nebuloso foi implementado. Esse fato vem confirmar que a abordagem proposta é robusta e possui boas características de convergência quando aplicada no tratamento do despacho de potência. Entretanto, alguns problemas de subotimalidade acontecem mesmo com a implementação do controlador lógico nebuloso.

Por outro lado os Algoritmos Genéticos obtiveram soluções para todos os tipos de DE estudados.

A representação do sistema de transmissão pôde ser implementada com sucesso nas abordagens inteligentes propostas. Todos os processos de otimização analisados obtiveram soluções factíveis, mesmo quando restrições bastante fortes, como aquelas em que os fluxos em duas linhas foram anulados, foram introduzidas.

7.5. Problema de Despacho Multi-Objetivo

O Problema de Despacho Multi-Objetivo ou Problema de Despacho Geração Ativa (DGA) consiste em ponderar a influência das perdas na geração e transmissão de energia elétrica. A solução deste problema consiste em minimizar duas funções objetivo ponderadas por constantes, como descrito na seção 2.5.

A fim de demonstrar a aplicabilidade das abordagens em problemas de DGA, algumas simulações envolvendo o sistema teste padrão IEEE de 14 barras são desenvolvidas. Neste sistema, uma demanda de 700 MW deve ser atendida por meio do arranjo de cinco geradores.

O principal objetivo desta seção é explorar a estrutura de problemas multi-objetivo e analisar a eficiência e robustez do método proposto para a solução destes tipos de problemas. São apresentados quatro estudos:

Caso 1 – Somente as perdas no sistema de transmissão são consideradas para o cálculo do despacho (α=1 e β=0).

Caso 2 – Somente os custos de geração são considerados (α=0 e β=1).

Caso 3 – Uma combinação de custos de geração e perdas no sistema de transmissão é adotada (α=0,6 e β=0,4).

Caso 4 – Caso 3 é reestudado, limitando os fluxos de potência ativa de duas linhas específicas do sistema em zero (simulando dupla contingência na

linha).

Foram desenvolvidas três abordagens para resolver o problema de DGA, como descritas a seguir:

i) (**RHM**) Uma abordagem de Hopfield Modificada foi aplicada para uma formulação de DGA onde os pontos de válvula são ignorados.

ii) (**AG**) Para efeito de validação e comparação com o item (i), o Algoritmo Genético Proposto na seção 6.3 também é aplicado no problema de DGA, ignorando os pontos de válvula.

iii) (**AGV**) O Algoritmo Genético Proposto na seção 6.3 é aplicado ao problema de DGA considerando os pontos de válvula.

A partir deste problema, daremos um enfoque maior à abordagem baseada no Algoritmo Genético proposto devido aos problemas de subotimalidade ocorridos na rede de Hopfield Modificada.

Tabela 7.13 – Parâmetros Iniciais

Unidade	a_i	b_i	c_i	e_i	f_i	$P_i^{\min}$ **(MW)**	$P_i^{\max}$ **(MW)**
1	550	8,10	0,00028	300	0,03142	0	680
2	126	8,60	0,00284	30	0,31416	0	120
3	240	7,74	0,00324	120	0,07854	0	180
4	309	8,10	0,00056	190	0,05236	0	360
5	240	7,74	0,00324	120	0,07854	0	180

Em todos os testes realizados para este sistema, na execução do método utilizando o Algoritmo Genético, foram consideradas as seguintes informações:

Número de gerações: 100

Número de indivíduos por geração: 14

Quantidade de bits de representação por unidade: 11

Percentagem de ocorrência de crossover: 0,95

Percentagem de ocorrência de mutação: 0,01

7.5.1. Caso 1

Em uma primeira simulação, as constantes de ponderação são fixadas em $\alpha=1$ e $\beta=0$. Isto implica em anular a influência do custo de geração na solução do

problema, de modo que apenas as perdas no sistema de transmissão serão consideradas para o cálculo do despacho.

Os resultados encontrados pela rede neural de Hopfield Modificada (RHM) e pelo Algoritmo Genético proposto são mostrados na Tabela 7.14. Nas tabelas seguintes as perdas de transmissão $\phi_l(\mathbf{F})$ são apresentadas em MW e os custos de geração em unidade monetária ($). Como β=0, os custos de gerações não são considerados neste problema de otimização, então o custo total é exatamente o custo de gerar as perdas de transmissão.

Tabela 7.14 – Resultados da Simulação – Caso 1.

Método	***P_1 (MW)***	***P_2 (MW)***	***P_3 (MW)***	***P_6 (MW)***	***P_8 (MW)***	***$\phi_l(F)$ (MW)***	***$\phi_g(P)$ ($)***	***Custo (MW)***	***Custo Real ($)***
RHM	440,32	21,32	94,89	31,13	111,27	46,91	7196,19	46,91	7870,07
AG	440,21	24,52	89,91	47,00	98,36	46,17	7194,22	46,17	7832,80
AGV	442,15	25,81	94,13	48,00	89,91	46,76	7818,00	46,76	7818,00

A rede de Hopfield Modificada (RHM) converge para o ponto de equilíbrio em aproximadamente 1400 iterações. Muitos mínimos locais e não-linearidades tornam a evolução da RHM complicada. Devido a tais não-linearidades a abordagem neural leva um grande número de iterações para atingir o equilíbrio. O custo total obtido pelas abordagens RHM e AG é, respectivamente, $ 46,91 e $ 46,17. Quando o ponto de válvula é considerado no algoritmo genético (AGV), o custo obtido foi de $ 46,76.

O algoritmo AG proposto mostrou-se robusto e eficiente para encontrar a solução, e as soluções AG foram obtidas em aproximadamente 30 segundos. A Figura 7.9 apresenta, respectivamente, a evolução da função custo das abordagens AG e AGV.

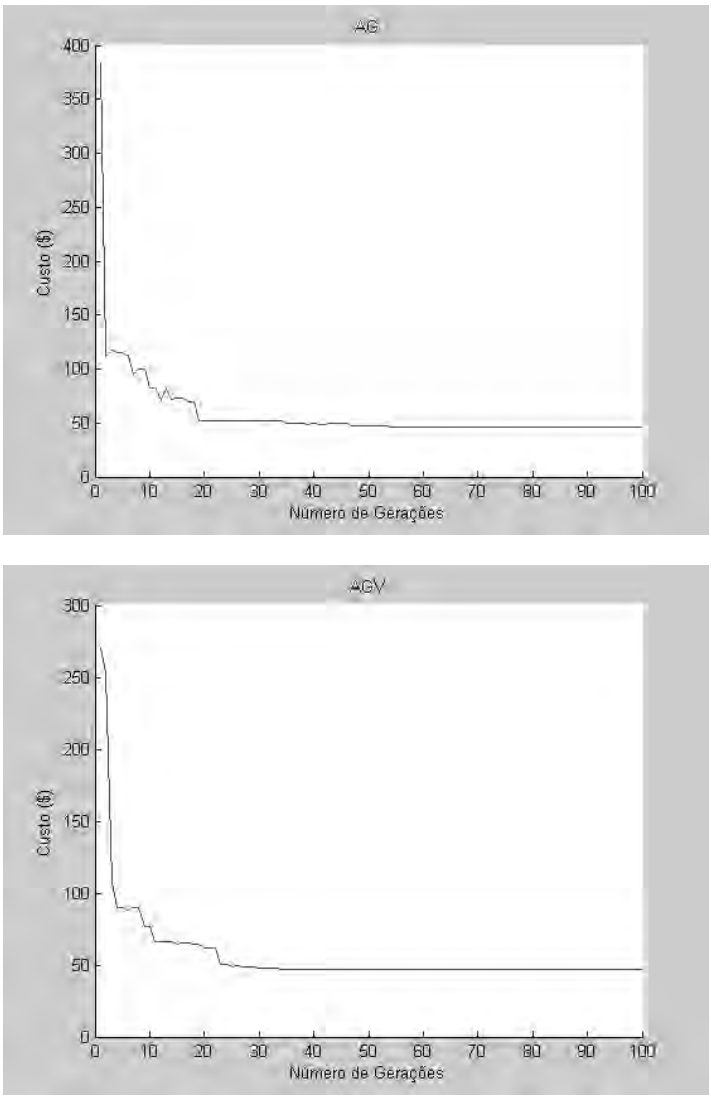

FIGURA 7.9 - Evolução da função custo (Abordagens AG e AGV – Caso 1)

7.5.2. Caso 2

Neste estudo, somente os custos de geração são considerados (α=0 e β=1). A Tabela 7.15 é análoga à Tabela 7.11. A evolução da função custo das abordagens AG e AGV, respectivamente, são apresentadas na Figura 7.10. Neste caso, o custo total é expresso em unidades monetárias ($).

Tabela 7.15 – Resultados da Simulação – Caso 2.

Método	P_1 *(MW)*	P_2 *(MW)*	P_3 *(MW)*	P_6 *(MW)*	P_8 *(MW)*	$\phi_l(F)$ *(MW)*	$\phi_g(P)$ *($)*	*Custo ($)*	*Custo Real ($)*
RHM	191,92	37,83	180,00	110,16	180,00	922,88	7254,71	7254,71	7682,30
AG	349,22	0	85,69	175,00	90,09	604,27	7173,10	7173,10	7659,50
AGV	199,82	30,03	151,85	239,65	78,65	1936,80	7297,25	7297,25	7297,25

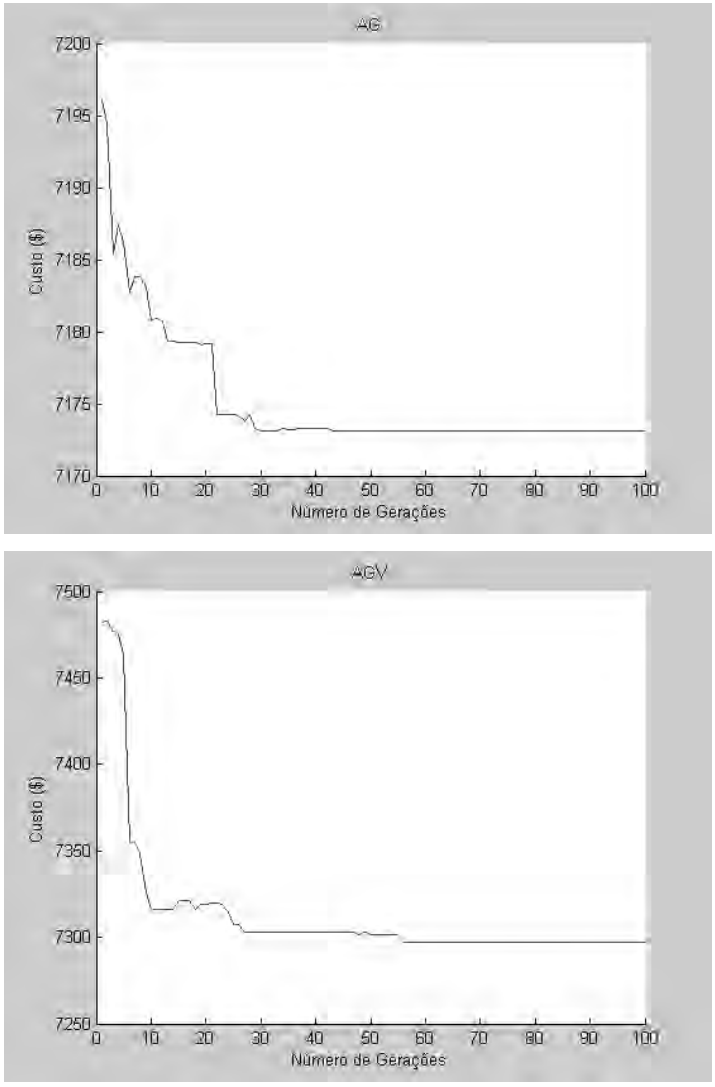

FIGURA 7.10 - Evolução da função custo (Abordagens AG e AGV – Caso 2)

A comparação entre as Tabelas 7.14 e 7.15 revela como as políticas de despacho calculadas são absolutamente diferentes. É visível que as perdas do sistema aumentaram consideravelmente neste caso, desde que não é mais

considerada na função objetivo. Por outro lado, os custos da geração introduzidos agora na função objetivo diminuíram consistentemente.

Se a política de despacho calculada pela RHM for usada para calcular o custo "real" (considerando o carregamento do ponto de válvula), teremos $\phi_g(\mathbf{P})$ = Custo Real = \$ 7682,30. A economia obtida pela solução proposta de AGV é de aproximadamente \$ 385,05 (que corresponde a uma redução de 5,28%). As abordagens baseadas em Algoritmos Genéticos obtiveram a solução de custo mínimo em aproximadamente 26 segundos.

7.5.3. Caso 3

Neste estudo é adotada uma combinação de custos de geração e perdas de transmissão de potência (α=0,6 e β=0,4), respectivamente. Perdas de potência ativa $\phi_l(\mathbf{F})$ são expressas em MW e os custos de gerações $\phi_g(\mathbf{P})$ são expressos em unidades monetárias (\$). Para tal razão foi adotada uma estratégia que converte perdas na transmissão (MW) em unidades monetárias (\$). Despachos calculados pelas abordagens são apresentados na Tabela 7.16. A abordagem RHM encontrou a solução ótima em aproximadamente 350 iterações e as abordagens baseadas nos Algoritmos Genéticos Propostos obtiveram a solução de custo mínimo em aproximadamente 26 segundos. A evolução das funções custo de AG e AGV são mostradas na Figura 7.11.

Tabela 7.16 – Resultados da Simulação – Caso 3.

Método	P_1 *(MW)*	P_2 *(MW)*	P_3 *(MW)*	P_6 *(MW)*	P_8 *(MW)*	$\phi_l(F)$ *(MW)*	$\phi_g(P)$ *(\$)*	*Custo (\$)*	*Custo Real (\$)*
RHM	432,03	14,62	96,00	42,35	115,00	91,19	7192,90	2931,90	7788,10
AG	445,74	12,00	89,91	51,00	101,35	47,91	7189,12	2904,39	7794,00
AGV	399,70	48,56	120,35	64,00	67,39	109,49	7365,71	3011,98	7365,71

Se o despacho calculado pela abordagem baseada na RHM for usado para calcular os custos de gerações "reais", ou seja, considerando os pontos de válvula, o custo de geração corresponderia a $\phi_g(\mathbf{P})$ = \$ 7788,10. Assim, a solução

fornecida pelo AGV proposto proporcionaria uma economia de $ 422,39 (5,73 % de economia nos custos de geração).

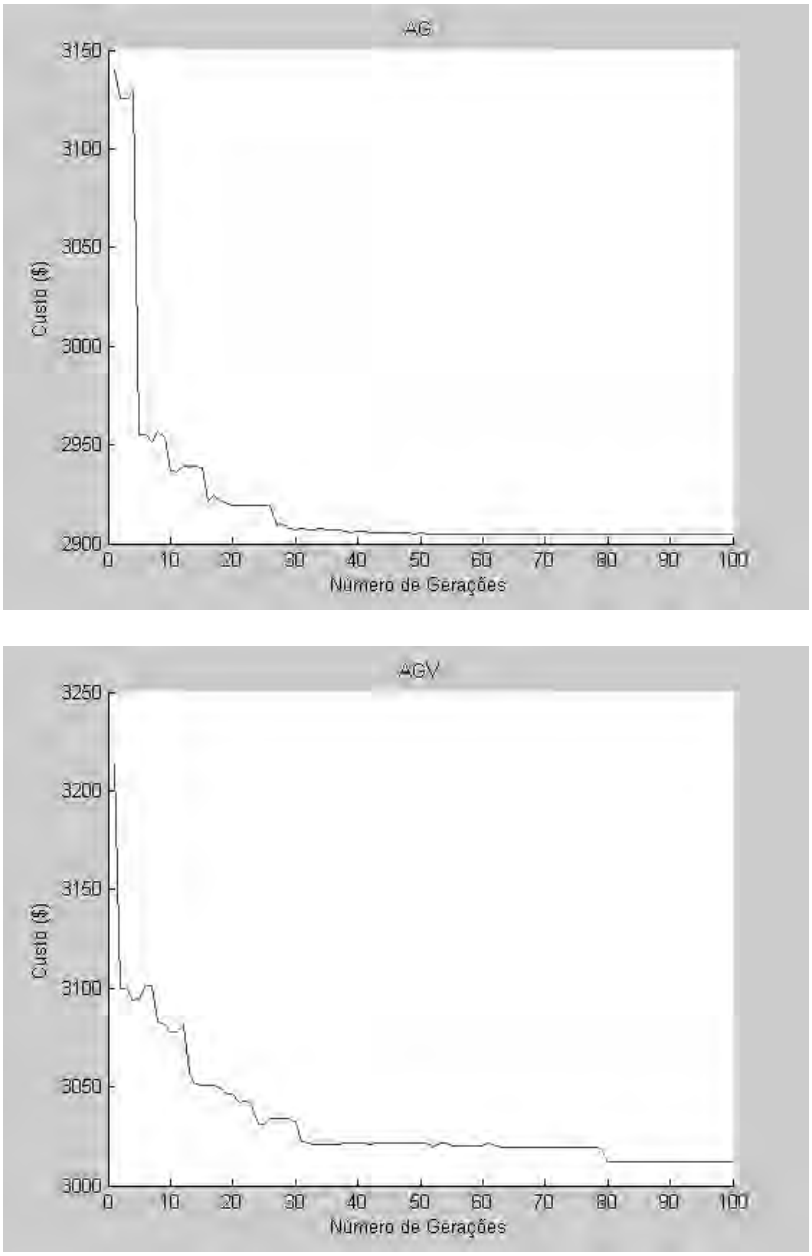

FIGURA 7.11 - Evolução da função custo (Abordagens AG e AGV – Caso 3)

7.5.4. Caso 4

Neste estudo é mantida a mesma configuração descrita na simulação anterior (Caso 3) com exceção dos limites em fluxos de potência ativa. Neste caso, os limites em duas linhas do sistema (conectando as barras 1-5 e 7-9),

escolhidas aleatoriamente, são fixados em zero, simulando uma dupla contingência na linha. Este procedimento representa a inclusão de uma restrição física muito procurada nos problemas reais e busca demonstrar que o método proposto é bastante robusto para tratar as restrições de fluxos de potência ativa.

Em todos os resultados os fluxos de potência ativa em tais linhas foram convenientemente zerados e o despacho de potência ativa foi completamente rearranjado para atender a demanda total requerida, como mostra a Tabela 7.17. A abordagem baseada na RHM convergiu para o ponto de equilíbrio em aproximadamente 200 iterações e as abordagens baseadas em Algoritmos Genéticos obtiveram a solução de custo mínimo em aproximadamente 29 segundos. A evolução da função custo das abordagens baseadas em AG e AGV, respectivamente, é mostrada na Figura 7.12.

Tabela 7.17 – Resultados da Simulação – Caso 4.

Método	P_1 ***(MW)***	P_2 ***(MW)***	P_3 ***(MW)***	P_6 ***(MW)***	P_8 ***(MW)***	$\phi_l(F)$ ***(MW)***	$\phi_g(P)$ ***($)***	***Custo ($)***	***Custo Real ($)***
RHM	441,69	54,15	47,35	70,05	87,77	57,67	7219,43	2914,70	7768,10
AG	432,18	24,00	88,68	64,00	91,14	56,03	7190,89	2909,53	7681,10
AGV	399,82	49,62	40,82	60,00	149,74	177,81	7322,10	3028,89	7322,10

Novamente, se o despacho calculado pela abordagem baseada na RHM for usado para calcular os custos de gerações “reais” e os resultados forem comparados ao AGV, a redução nos custos de geração seria de $ 446,00 (6,09 % de economia nos custos de geração).

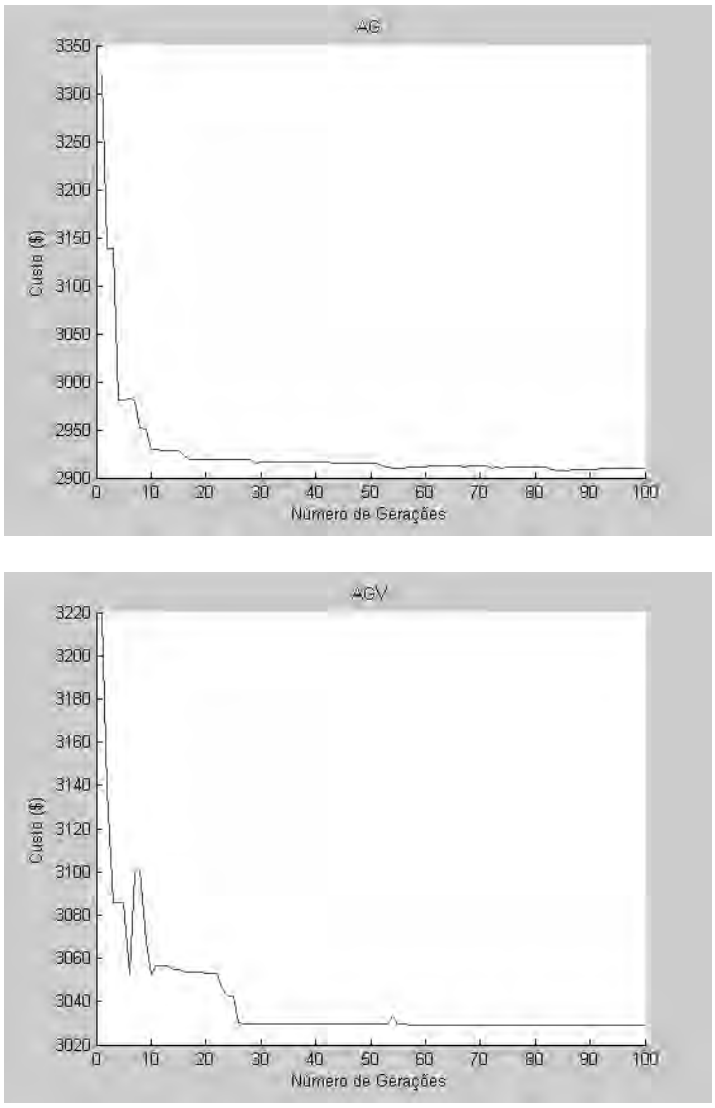

FIGURA 7.12 - Evolução da função custo (Abordagens AG e AGV – Caso 4)

7.5.5. Conclusões

Um novo problema de Despacho Econômico foi analisado nesta seção. A finalidade básica de tal problema é calcular uma política de despacho que destaque a relação de compromisso entre as perdas na transmissão e os custos de geração. A formulação desse problema de Despacho Econômico envolve a representação do sistema de transmissão por meio de equações do fluxo de carga e limites em fluxos de potência ativa. O Algoritmo Genético proposto forneceu a redução de custo substancial da geração quando comparado à aproximação da RHM. A economia fornecida pela abordagem baseada em Algoritmos Genéticos

está na faixa de 5 a 6 % dos custos da geração nos testes executados. O AG proposto pode também resolver eficientemente todos os problemas do DE testados. Testes adicionais com as abordagens propostas foram realizados para analisar o esforço computacional necessário para resolver sistemas de maior porte, os quais serão descritos a seguir.

7.6. Problema de Despacho de Geração para Sistemas Hidrotérmicos

7.6.1. Sistema Teste IEEE de 30 Barras

Esta seção o resultado de simulação envolvendo o sistema teste de 30 barras IEEE. A descrição do sistema teste utilizado é dada no apêndice B.

A Tabela 7.18 apresenta os parâmetros relativos à função custo. O sistema assumido suporta uma demanda de 1500 MW e é composto por seis unidades geradoras (duas térmicas e quatro hidráulicas). Para a simulação utilizam-se coeficientes comuns para todas as unidades térmicas e outros, comuns para todas as unidades hidráulicas. Além disso, todos os geradores possuem capacidade máxima fixa em 300 MW. A Tabela 7.18 apresenta ainda os parâmetros relativos aos pontos de válvula das unidades geradoras térmicas e os limites da faixa de cavitação considerados para as unidades geradoras hidráulicas. De posse destas informações, simulamos o problema de despacho hidrotérmico utilizando o Algoritmo Genético.

Tabela 7.18 – Parâmetros Iniciais

Unidade	***Tipo***	a_i	b_i	c_i	e_i	f_i	$P_i^{\min}$ ***(MW)***	$P_i^{\max}$ ***(MW)***	$Cav_i^{\min}$ ***(MW)***	$Cav_i^{\max}$ ***(MW)***
1	Térmica	720	24,3	0,00972	300	0,03142	0	300	---	---
2	Térmica	720	24,3	0,00972	30	0,31416	0	300	---	---
3	Hidráulica	240	8,10	0,00324	---	---	0	300	220	240
4	Hidráulica	240	8,10	0,00324	---	---	0	300	220	240
5	Hidráulica	240	8,10	0,00324	---	---	0	300	220	240
6	Hidráulica	240	8,10	0,00324	---	---	0	300	220	240

Na execução do método utilizando o Algoritmo Genético, foram consideradas as seguintes informações:

Número de gerações: 100

Número de indivíduos por geração: 30

Quantidade de bits de representação por unidade: 11

Percentagem de ocorrência de crossover: 0,95

Percentagem de ocorrência de mutação: 0,01

7.6.2. Resultados da Simulação

Os resultados computados pelo Algoritmo Genético ignorando o ponto de válvula (AG) e considerando o ponto de válvula (AGV) são apresentados na Tabela 7.19. A Figura 7.13 apresenta, respectivamente, a evolução da função custo das abordagens AG e AGV. No modelo em que os pontos de válvula não são considerados os despachos calculados para os geradores 3, 4, 5 e 6 são aproximadamente iguais (já que os custos são iguais e as perdas foram desprezadas no sistema). A barra *slack*, que neste caso corresponde ao gerador 1, gera o restante da potência ativa a fim de fechar o balanço de potência do sistema.

As soluções foram obtidas em aproximadamente 1minuto e 30 segundos.

Tabela 7.19 – Resultados da Simulação

Método	***P_1 (MW)***	***P_2 (MW)***	***P_3 (MW)***	***P_4 (MW)***	***P_5 (MW)***	***P_6 (MW)***	***Custo ($)***	***Custo Real ($)***
AG	154,84	145,16	300,00	300,00	300,00	300,00	21017,73	21341,00
AGV	199,51	113,78	287,00	300,00	300,00	299,71	21178,67	21178,67

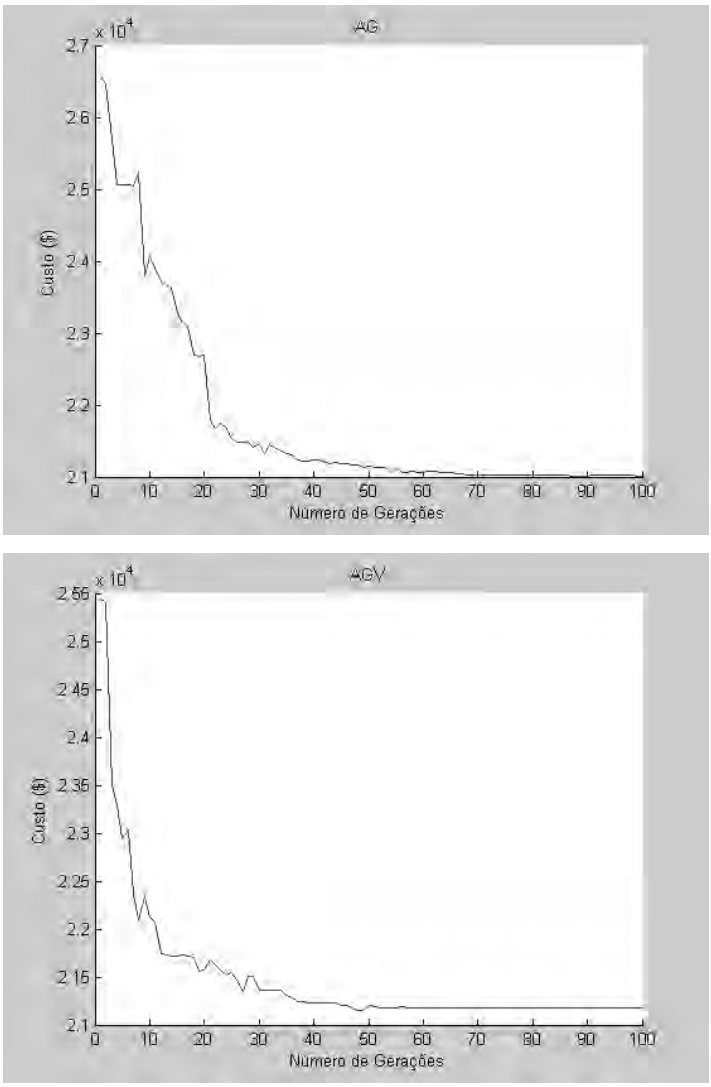

FIGURA 7.13 - Evolução da função custo (AG e AGV)

7.6.3. Sistema Teste IEEE de 118 Barras

Esta seção tem como objetivo o estudo do problema de Despacho Econômico Hidrotérmico com representação do sistema de transmissão para sistemas de maiores dimensões. O problema é resolvido utilizando a abordagem baseada nos Algoritmos Genéticos propostos. Busca-se avaliar o impacto do aumento nas dimensões do problema nas abordagens baseadas em algoritmos genéticos, e são propostas alterações futuras no modelo de solução a fim de diminuir estes impactos. Para as simulações, são fixados os mesmos coeficientes a_i, b_i e c_i da função custo para todas as unidades geradoras térmicas. Os coeficientes da função custo de todas as unidades geradoras hidráulicas também

são fixados com valores iguais. Todos os geradores possuem capacidade máxima fixa em 300 MW. As 53 unidades geradoras (13 térmicas e 40 hidráulicas) que compõem o sistema alimentam uma demanda total de 12000 MW. Os limites mínimos e máximos de faixa de cavitação para todas as unidades de geração hidráulica e as informações referentes aos pontos de válvula das unidades de geração térmica também são apresentados na Tabela 7.20. O diagrama do sistema teste IEEE de 118 barras utilizado é dado no apêndice C.

Tabela 7.20 – Parâmetros Iniciais

Unidades	a_i	b_i	c_i	e_i	f_i	P_i^{min} ***(MW)***	P_i^{max} ***(MW)***	Cav_i^{min} ***(MW)***	Cav_i^{max} ***(MW)***
Térmicas	240	8,10	0,00324	120	0,05236	0	300	---	---
Hidráulicas	240	8,10	0,00324	---	---	0	300	220	240

Na execução do método utilizando o Algoritmo Genético, foram consideradas as seguintes informações:

Número de gerações: 300

Número de indivíduos por geração: 80

Quantidade de bits de representação por unidade: 11

Percentagem de ocorrência de crossover: 0,95

Percentagem de ocorrência de mutação: 0,01

Os resultados computados pelo Algoritmo Genético com e sem a representação dos pontos de válvula, respectivamente, AG e AGV, são apresentados na Tabela 7.21. A Figura 7.14 apresenta a evolução da função custo das abordagens AG e AGV.

As soluções foram obtidas em aproximadamente 40 minutos.

Tabela 7.21 – Resultados da Simulação em MW.

Método	**AG**	**AGV**
P_1	231,55	161,23
P_2	271,57	270,54
P_3	207,08	235,00
P_4	273,47	231,85
P_5	268,05	210,00
P_6	258,67	289,45
P_7	276,70	202,10
P_8	287,98	229,07
P_9	288,72	136,44
P_{10}	204,59	231,27
P_{11}	266,00	125,16
P_{12}	171,76	291,35
P_{13}	250,90	258,96
P_{14}	244,02	218,37
P_{15}	298,10	257,50
P_{16}	211,77	282,27
P_{17}	296,92	245,77
P_{18}	250,32	287,69
P_{19}	116,66	186,27
P_{20}	187,01	276,99
P_{21}	259,84	174,69
P_{22}	156,08	186,00
P_{23}	251,78	138,64
P_{24}	147,00	141,28
P_{25}	281,83	276,84
P_{26}	105,96	158,28
P_{27}	247,83	170,44
P_{28}	290,47	277,43
P_{29}	144,80	290,91
P_{30}	213,97	131,46
P_{31}	299,27	217,64
P_{32}	299,71	181,44
P_{33}	112,99	198,58
P_{34}	251,05	299,85
P_{35}	263,21	287,10
P_{36}	276,70	196,97
P_{37}	280,36	282,56
P_{38}	131,46	181,44
P_{39}	296,92	281,83
P_{40}	292,53	258,38
P_{41}	97,02	191,84
P_{42}	261,46	200,93
P_{43}	175,00	262,04
P_{44}	247,83	279,92
P_{45}	192,87	161,21
P_{46}	214,12	268,49
P_{47}	213,97	270,98
P_{48}	195,65	270,25
P_{49}	216,61	124,13
P_{50}	298,68	264,00
P_{51}	134,25	248,27
P_{52}	91,45	245,04
P_{53}	195,51	253,83
Custo ($)	119.357,32	120.177,12
Custo Real ($)	120.349,22	120.177,12

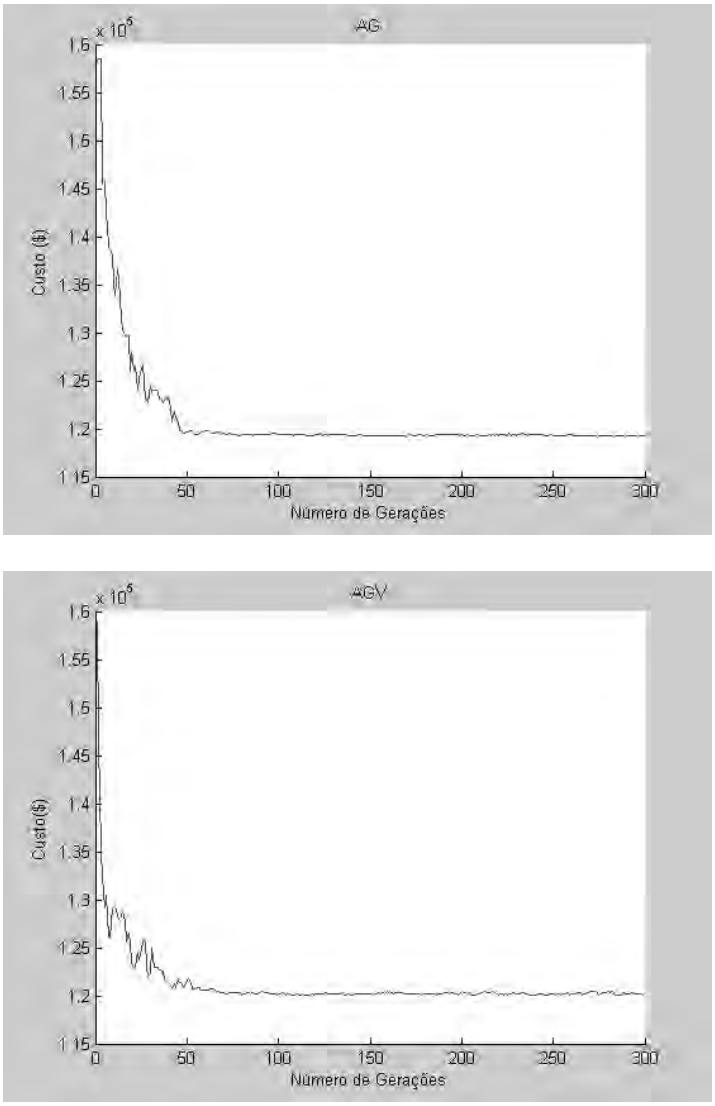

FIGURA 7.14 - Evolução da função custo (AG e AGV)

Nota-se que o tempo computacional foi bastante superior àquele obtido nos casos em que os sistemas de menor porte foram utilizados. Isto se deve ao aumento do "tamanho" dos indivíduos que representam possíveis soluções, e também ao aumento do número de indivíduos por geração. Além disso, para cada indivíduo da geração, aplica-se um procedimento de fluxo de carga linear - DC (descrito na seção 6.3) para obter os valores dos ângulos de tensão e dos fluxos de potência ativa.

Desta forma, são apresentadas a seguir algumas propostas futuras no sentido de reduzir este tempo computacional.

CAPÍTULO 8

Conclusões e Propostas Futuras

Este capítulo apresenta as conclusões gerais e as propostas de trabalhos futuros.

8.1. Conclusões

Este trabalho tem como objetivos básicos o desenvolvimento e avaliação de abordagens baseadas em sistemas inteligentes para a solução do problema de despacho econômico. Abordagens convencionais de solução para tais problemas têm apresentado deficiências, tais como: i) Dificuldade para encontrar a solução nos casos em que a função objetivo e/ou as restrições possuem características de não-linearidade ou não convexidade; ii) Dificuldade de explorar vários cenários dentro do espaço de busca; iii) Incapacidade para o tratamento de funções objetivo não diferenciáveis; iv) Em alguns métodos, soluções infactíveis são encontradas, apesar do tratamento das restrições estar implementado.

Tais deficiências motivaram o estudo de técnicas de inteligência computacional para a solução do DE. Devido aos resultados preliminares relatados na literatura, optou-se neste trabalho pela investigação de duas abordagens inteligentes potencialmente promissoras: as redes neurais artificiais e os algoritmos genéticos.

As redes neurais têm facilidade para lidar com problemas que apresentam não linearidades ou não convexidades. Dos modelos propostos na literatura a rede de Hopfield tem se destacado para a solução de problemas de DE. Entretanto, os modelos descritos comumente apresentam soluções infactíveis para o problema. Buscando contornar esta deficiência o presente trabalho propõe a aplicação da Rede de Hopfield Modificada, que utiliza o conceito de subespaço válido para tratar de modo mais robusto o conjunto factível do problema de otimização. Nesta rede a função objetivo e as restrições são tratadas separadamente por duas redes que se interagem para a obtenção da solução ótima. A Rede de Hopfield Modificada proposta é bastante robusta e obteve em todos os testes realizados sempre soluções factíveis. Entretanto, constatou-se alguns problemas relacionados à subotimalidade de algumas soluções obtidas pela RHM e verificou-se que tal subotimalidade estava diretamente relacionada ao tamanho do passo de otimização, que era mantido fixo na RHM. A fim de contornar tal problema foi proposto um controle mais eficaz do tamanho do passo de otimização por meio da

introdução de um controlador lógico nebuloso. A introdução do controlador melhorou consideravelmente o desempenho da rede, além de acelerar o processo de convergência para os pontos de equilíbrio, entretanto, em alguns casos ainda persistia a subotimalidade da solução. Além disso, a RHM e a RHMF não são capazes de lidar com a função objetivo não diferenciável enfocada neste trabalho, dadas as suas características intrínsecas (necessidade de formação da matriz de sensibilidade). Outra deficiência das abordagens neurais está relacionada à dificuldade para explorar de modo eficiente o espaço de busca do problema.

Os Algoritmos Genéticos lidam de forma bastante natural com os problemas relacionados à não-linearidades e/ou não convexidades e também com a não diferenciabilidade das funções relacionadas aos problemas de otimização, já que utilizam em sua direção de busca apenas informações da função de adequação do problema. Além disso, os algoritmos genéticos exploram de modo mais conveniente o espaço de busca do problema, já que operam sobre uma população de indivíduos e não apenas sobre um ponto.

Em todas as simulações envolvendo os AGs as soluções obtidas foram sempre consistentes com a região factível do problema, mesmo quando foram introduzidas restrições bastante fortes, como aquelas em que os fluxos em duas linhas foram anulados. Nos casos mais simples, em que os AGs foram comparados ao método exato (Lagrange), não se constatou também problemas de subotimalidade na solução dos AGs.

Por todas as características citadas neste trabalho, os AGs se mostraram uma ferramenta bastante promissora para a solução do DE. Entretanto, há que se aperfeiçoar o modelo de solução de AG proposto de modo que as soluções possam ser obtidas com um menor esforço computacional, já que se constatou que o tempo computacional pode ser grande nos casos em que sistemas de dimensões reais são estudados. São discutidas a seguir algumas propostas futuras no sentido de que este tempo computacional possa ser reduzido.

8.2. Propostas Futuras

Uma série de contribuições tem sido observada na literatura recente no

tocante às aplicações de Algoritmos Genéticos aos problemas de otimização em sistemas de potência, no sentido de diminuir o tempo computacional dos Algoritmos Genéticos e das redes neurais artificiais. Dentre elas destacam-se:

- Utilização de modelos híbridos, em que algoritmos de busca convencionais são utilizados para acelerar a busca dos AGs (LEITE, 2003).
- Representação real, ao invés da codificação binária, dos indivíduos, o que diminui os tempos relacionados à codificação/decodificação de cada indivíduo (DAMOUSIS *et al.*, 2003).
- Proposição de outros operadores genéticos que se adaptem às características específicas do problema estudado, melhorando a busca dos AGs (LEITE, 2003).
- Uma implementação de fluxo de carga desacoplado rápido.
- Avaliar de forma mais detalhada a robustez dos Algoritmos Genéticos frente a diferentes situações é importante estudar e incorporar um conjunto de restrições ao problema de Fluxo de Potência Ótimo AC.
- Com o objetivo de aprimorar o modelo proposto, recomenda-se, também, incorporar um modelo de pré-despacho ou *unit commitment*, que representa uma etapa fundamental na programação da operação das unidades geradoras. Isto consiste basicamente em selecionar um conjunto de unidades geradoras, entre aquelas disponíveis, para operar num intervalo de tempo garantindo a demanda prevista, cumprindo as restrições existentes e minimizando os custos totais de produção.
- Implementação de Redes Neurais Artificiais e Algoritmos Genéticos em computadores massivamente paralelos para sistemas de grande porte.
- Para dar um sentido prático e atual ao modelo, sugere-se estudar os problemas de despacho econômico e mercado de energia.

Estas questões não foram abordadas no presente trabalho e devem ser avaliadas de modo mais detalhado em estudos futuros com o modelo de Algoritmo Genético proposto.

REFERÊNCIA BIBLIOGRÁFICA

ABE, S. Global convergence and suppression of spurious states of the Hopfield neural networks. **IEEE Trans. On Circuits Syst. I**, vol. CAS-40, n.4, pp. 246-257, 1993.

AIYER, S. V. B.; NIRANJA, M.; FALLSIDE, F. A theoretical investigation into the performance of the Hopfield model. **IEEE Transaction on Neural Networks**, vol. 1, n.2, pp. 204-215, 1990.

BÄCK, T. **Evolutionary algorithms in theory and practice**. New York: Oxford University Press, 1996.

BAKIRTZIS, A.; PETRIDIS, V.; KAZARLIS, S. Genetic algorithm solution to the economic dispatch problem. **IEE**, vol. 141, pp. 377-382, July, 1994.

BAKIRTZIS, A. G.; KAZARLIS, S.; PETRIDIS, V. A genetic algorithm solution to the unit commitment problem. **IEEE Trans. on PS.**, vol. 11, n.1, pp. 83-91, February 1996.

BASKAR, S., SUBBARAJ, P.; RAO, M.V.C. Hybrid real coded genetic algorithm solution to economic dispatch problem, ..., 2002

BAZARAA, M. S.; SHETTY, C. M. Nonlinear Programming, John Wiley & Sons, New York, 1979.

CARPENTIER, J. L. Contribution à l'étude du dispatching économique, **Bulletin de la Société Française des Electriciens**, ser. 8, vol. 3, pp. 431-447, 1962

CHEN, P. H.; CHANG, H. –C. Large-scale economic dispatch by genetic algorithm, **IEEE Trans. Power Syst.**, vol. 10, pp.1919-1926, November 1995.

CHOWDHURY, B. H.; RAHMAN, S. A review of recent advances in economic dispatch. **IEEE Trans. Power Systems**, vol. 5, n. 4, pp. 1248-1257, 1990.

COX, E. Fuzzy Fundamentals. **IEEE Spectrum**, vol. 5, pp. 58-61, 1992.

DAMOUSIS, I.G.; BAKIRTZIZ, A.G.; DOKOPOULOS, P.S. Network-constrained economic dispatch using real-coded genetic algorithm. **IEEE Transactions on Power Systems**, vol. 18, n.1, 2003.

DAWKINS, R.. **O gene egoísta.** Belo Horizonte: Ed. Itatiaia/Edusp, 1979.

DAVIS, L. **Handbook of genetic algorithms.** New York: Van Nostrand Reinhold, 1991.

ELGERD, O. I. **Introdução à Teoria de Sistemas de Energia Elétrica**, Flórida, 1970.

FOGEL, L. J.; OWENS, A. J.; WALSH, M. J. **Artificial Intelligence Through Simulated Evolution.** New York: John Wiley & Sons, Inc., 1966.

FUTUYAMA, D. J. **Biologia Evolutiva.** Tradução: Fábio de Melo Sene, Ribeirão Preto: Sociedade Brasileira de Genética, 1992.

GEE, A. H.; PRAGER, R.W. **Alternative energy functions for optimizating neural networks**. Technical Report cued/F-Infeng/TR95, Cambridge University Department of Engineering, 1991.

GOLDBERG, D.E. **Genetic Algorithms in Search Optimization & Machine Learning.** Addison-Wesley, Reading, MA, 1989.

HAPP, H. H. Optimal Power Dispatch - A Comprehensive Survey. **IEEE Trans. Power Apparatus and Syst.**, vol. PAS-96, pp. 841-854, 1977.

HAYKIN, S. **Neural Networks – A Compreensive Foundation**. McMillan Inc., Englewood Cliffs, NJ, 1994.

HAYKIN, S. **Redes Neurais: Princípios e Prática.** Porto Alegre: Bookman, 2001.

HODGKIN, A. L.; HUXLEY, L. F. A Quantitative Description of Membrane Current and its Applications to Conduction and Excitation in Nerve. **Journal of Psysiology**, vol. 117, pp. 500-544, 1952.

HOLLAND, J.H. **Adaptation in Natural and Artificial Systems.** Ann Arbor, MI:Michigan Univ. Press, 1975.

HOPFIELD, J. J. Neural networks and physical systems wiyh emergent collective computational abilities. **Proceedings of the National Academy of Sciences.** USA, vol. 79, pp. 2554-2558.

KIM, J. –H.; MYUNG, H. Evolutionary programming techniques for constrained optimization problems. **IEEE Trans. Evolution Comput.,** Vol.1, N.2, pp. 129-140, 1997.

LAI, L. L.; MA, J. T.; YOKOYAMA, R.; ZHAO, M. Improved genetic algorithms for optimal power flow under both normal and contingent operation states. **Elec. Power Energy Syst.**, vol.19, n.5, pp. 287-292, 1997.

LEITE, P. T. **Aplicação de Técnicas de Inteligência Artificial no Planejamento da Operação de Sistemas Hidrotérmicos de Potência**. Tese de Doutorado, SEL/EESC/USP, São Carlos – SP, dezembro de 2003.

LEE, C. C. Fuzzy Logic in Control Systems: Fuzzy Logic Controller, Part I and II. **IEEE Transaction on Systems, Man and Cybernetics,** vol. 20, pp. 405-435, 1990.

LEVITIN, G.; MAZAL-TOV, S.; ELMAKIS, D. Genetic algorithm for open-loop distribution system design. **Electric Power Syst. Res.**, vol. 32, pp. 81-87, 1995.

LI, F.; MORGAN, R.; WILLIAMS, D. Hybrid genetic approaches to ramping rate constrained dynamic economic dispatch. **Electric Power Syst. Res.**, vol. 43, pp. 97-103, 1997.

LI, J. –H; MICHEL, A. N.; POROD, W. Analysis and synthesis of a class of neural networks. **IEEE Trans. On Circuits Syst.**, vol. 36, pp.1405-1422, 1989.

LUENBERGER, D.G. **Linear and Nonlinear Programming.** 2ª. Edição, Addison-Wesley, 1989.

LUO, J. S.; HILL, E.F.; LEE, T. H. Power system economic dispatch via network approach. **IEEE Trans. Power App. and Systems**, vol. PAS 103, pp. 1242-1248, 1984.

MA, T.; LAI, L. L. Evolutionary programming approach to reactive power planning. **IEE Proc. Gen. Trans. Distr.**, vol. 143, n. 4, pp. 365-370, 1996.

MCCULLOCH, W. S.; PITTS, W. A Logical Calculus of the Ideas Immanent in Nervous Activity. **Bulletin of Mathematical Biophysics**, vol. 5, pp. 115-133, 1943.

MINSKY, M. L.; PAPERT, S. A. **Perceptrons**, Cambridge, MA: MIT Press, 1969.

MIRANDA, V. et al. Evolutionary computation applications in power systems. **Electric Power System Res. 202**, pp. 89-98, 1998.

NOYOLA, A. H.; GRADY, W. M.; VIVIANE, G. L. An optimized procedure for determining incremental heat rate characteristics. **IEEE Trans. Power Systems**, vol. 5, n. 3, pp. 376-383, 1990.

OLIVEIRA, A. R. L.; SOARES, S.; NEPOMUCENO, L. Optimal active power dispatch combining network flow and interior point approaches. **IEEE Trans. Power Systems**, vol. 18, n.4, pp. 1235-1240, 2003.

ORERO, S.O. et al. Economical dispatch of generators with prohibited operating zones: a genetic algorithm approach. **Proc. Inst. Elect. Eng.**, vol. 143, n.6, pp. 507-513, 1996.

PARK, J. H.; KIN, Y. S.; EOM, I. K.; LEE, K. Y. Economic load dispatch for piecewise quadratic cost function using Hopfield neural network. **IEEE Trans. Power Systems**, vol. 8, pp. 1030-1038, 1993.

RECHENBERG, I. **Evolution strategie: Optimierung Techischer Systeme nach Prinzipien der Biologischen Evolution**, Frommann-Holzboog, 1973.

REID, G. F.; HASDORFF, L. Economic dispatch using quadratic programming. **IEEE Trans. Power App. and Systems**, vol. PAS 92, pp. 2015-2023, 1973.

RIBEIRO, F.J.L.; TRELEAVEN, P.C.; ALIPI, C. Genetic-Algorithm Programming Environments. **Computer**, June,1994.

RUDNICK, H. Aspectos técnico económicos de la desregulación del sector eléctrico. **Pontificia Universidad Católica de Chile**, pp. 205, 1995.

RUMELHART, D. E.; MCCLELLAND, J.L. **Parallel Distributed Processing: Explorations in the Microstructure of Cognition**, vol. 1, Cambridge, MA: MIT Press, 1986.

SCHWEFEL, H. –P. **Evolution and Optimum Seeking**, Sixty-Generation Computer Technology Series, Wiley, 1995.

SHEBLE', G. B.; WALTERS, D. C. Genetic algorithm solution of economic dispatch with valve point loading. **IEEE Trans. on PS.**, vol. 8, n. 3, pp. 1325-1332, August 1993.

SHOULTS, R. R.; VENKANTESH, S. V.; HELMICH. D.; WARD, G. L.; LOLLAR, M. J. A dynamic programming based method for developing dispatch curves when incremental heat rate curves are non-monotonically increasing. **IEEE Trans.**, vol. 1, pp. 10-16, 1986.

SILVA, I. N. **Estimação Paramétrica Robusta através de Redes Neurais Artificiais**. Tese de Mestrado, DCA/FEE/UNICAMP, Campinas – SP, janeiro de 1995.

SILVA, I. N.; ARRUDA, L. V. R.; AMARAL, W. C. A modified Hopfield architecture for solving nonlinear programming problems with bounded variables. **Neural Network World**, 10, 713-722, 2000.

SILVA, I. N.; NEPOMUCENO, L. An efficient neural approach to economic load dispatch in power systems. **IEEE PES Summer Meeting**, Vancouver, CD-ROM, 2001.

SILVA, I. N.; NEPOMUCENO, L.; BASTOS, T. M. Solving an economic dispatch problem with transmission system representation by a modified Hopfield network". **IFAC**, Barcelona, Espanha, 2002.

SOARES, S.; SALMAZO, C. T. Minimum loss predispatch model for hydroelectric systems. **IEEE Trans. Power Systems**, vol. 12, n. 3, pp. 1220-1228, 1997.

STEINBERG, M. J.; SMITH, T. H. The theory of incremental rates. **Electr. Eng.,** vol. I, March 1934.

SU, C.-T.; CHIOU, G.-J. A fast-computation Hopfield method to economic dispatch of power systems. **IEEE Trans. Power Systems**, 12, 1759-1764, 1997a.

SU, C.-T.; CHIOU, G.-J. An enhanced Hopfield model for economic dispatch considering prohibited zones. **Electric Power Systems Research**, 42, 71-76 1997b.

WALSH, M. J.; O'MALLEY, M. J. Augmented Hopfield network for unit commitment and economic dispatch. **IEEE Trans. Power Systems**, vol. 12, pp. 1765-1774, 1997.

WONG, K. P.; WONG, Y. Combined genetic algorithm/simulated annealing/ fuzzy set approach to short-term generation scheduling with take-or-pay fuel contract. **IEEE Trans. on PS.**, vol. 11, n. 11, pp. 128-136, February 1996.

YAN, X.; QUINTANA, V. H. An efficient predictor-corrector interior point algorithm for security-constrained economic dispatch, **IEEE Trans on Power Syst.,** vol 12, n. 2, pp 803-810, 1997.

ZADEH, L. A. Fuzzy Sets, **Information and Control**, vol. 8, pp. 338-353, 1965.

ZADEH, L. A. Outline of a new approach to the analysis of complex system and decision processes. **IEEE Transaction on Systems, Man and Cybernetics**, vol. SMC-3, pp. 28-44, 1973.

APÊNDICE A

Sistema 14 Barras

O apêndice A apresenta os dados das barras, os dados das linhas e o diagrama do sistema IEEE de 14 barras.

Dados de Barras em *p.u.*

Barra	*Tipo de Barra*	*Potência de Carga*
1	2	0
2	0	0,2170
3	0	0,9420
4	1	0,4780
5	1	0,0760
6	0	0,1120
7	1	0
8	0	0
9	1	0,2950
10	1	0,0900
11	1	0,0350
12	1	0,0610
13	1	0,1350
14	1	0,1490

Tipo de Barra = 0 → Barra *PV*
Tipo de Barra = 1 → Barra de Carga
Tipo de Barra = 2 → Barra de Referência (*Slack)*

Dados de Linhas em *p.u.*

Linha	*Origem*	*Destino*	*Resistência R*	*Reatância X*
1	1	2	0,01938	0,05917
2	1	5	0,05403	0,22304
3	2	3	0,04699	0,19797
4	2	4	0,05811	0,17632
5	2	5	0,05695	0,17388
6	3	4	0,06701	0,17103
7	5	4	0,01335	0,04211
8	4	7	0	0,20912
9	4	9	0	0,55618
10	5	6	0	0,25202
11	6	11	0,09498	0,19890
12	6	12	0,12291	0,25581
13	6	13	0,06615	0,13027
14	7	8	0	0,17615
15	7	9	0	0,11001
16	9	10	0,03181	0,08450
17	9	14	0,12711	0,27038
18	10	11	0,08205	0,19207
19	12	13	0,22092	0,19988
20	13	14	0,17093	0,34802

Diagrama do Sistema Teste IEEE de 14 Barras

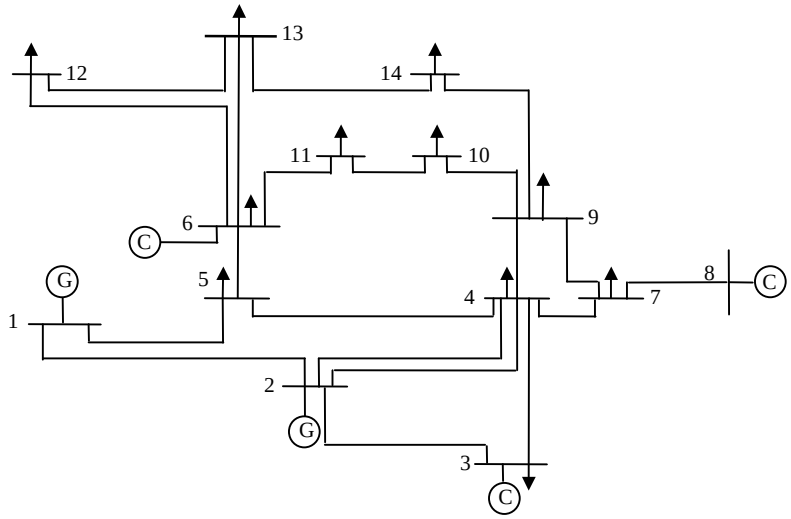

APÊNDICE B

Sistema 30 Barras

O apêndice B apresenta os dados das barras, os dados das linhas e o diagrama do sistema IEEE de 30 barras.

Dados de Barras em *p.u.*

Barra	*Tipo de Barra*	*Potência de Carga*
1	2	0
2	1	0,2170
3	0	0,0240
4	0	0,0760
5	1	0,9420
6	0	0
7	0	0,2280
8	1	0,3000
9	0	0
10	0	0,0580
11	1	0
12	0	0,1120
13	1	0
14	0	0,0620
15	0	0,0820
16	0	0,0350
17	0	0,0900
18	0	0,0320
19	0	0,0950
20	0	0,0220
21	0	0,1750
22	0	0
23	0	0,0320
24	0	0,0870
25	0	0
26	0	0,0350
27	0	0
28	0	0
29	0	0,0240
30	0	0,1060

Tipo de Barra = 0 → Barra *PV*
Tipo de Barra = 1 → Barra de Carga
Tipo de Barra = 2 → Barra de Referência (*Slack)*

Dados de Linhas em *p.u.*

Linha	*Origem*	*Destino*	*Resistência R*	*Reatância X*
1	1	2	0,0192	0,0575
2	1	3	0,0452	0,1852
3	2	4	0,0570	0,1737
4	3	4	0,0132	0,0379
5	2	5	0,0472	0,1983
6	2	6	0,0581	0,1763
7	4	6	0,0119	0,0414
8	5	7	0,0460	0,1160
9	6	7	0,0267	0,0820
10	6	8	0,0120	0,0420
11	6	9	0,0	0,2080
12	6	10	0,0	0,5560
13	9	11	0,0	0,2080
14	9	10	0,0	0,1100
15	4	12	0,0	0,2560
16	12	13	0,0	0,1400
17	12	14	0,1231	0,2559
18	12	15	0,0662	0,1304
19	12	16	0,0945	0,1987
20	14	15	0,2210	0,1997
21	16	17	0,0524	0,1923
22	15	18	0,1073	0,2185
23	18	19	0,0639	0,1292
24	19	20	0,0340	0,0680
25	10	20	0,0936	0,2090
26	10	17	0,0324	0,0845
27	10	21	0,0348	0,0749
28	10	22	0,0727	0,1499
29	21	22	0,0116	0,0236
30	15	23	0,1000	0,2020
31	22	24	0,1150	0,1790
32	23	24	0,1320	0,2700
33	24	25	0,1885	0,3292
34	25	26	0,2544	0,3800
35	25	27	0,1093	0,2087
36	28	27	0,0	0,3960
37	27	29	0,2198	0,4153
38	27	30	0,3202	0,6027
39	29	30	0,2399	0,4533
40	8	28	0,0636	0,2000
41	6	8	0,0169	0,0599

Diagrama do Sistema Teste IEEE de 30 Barras

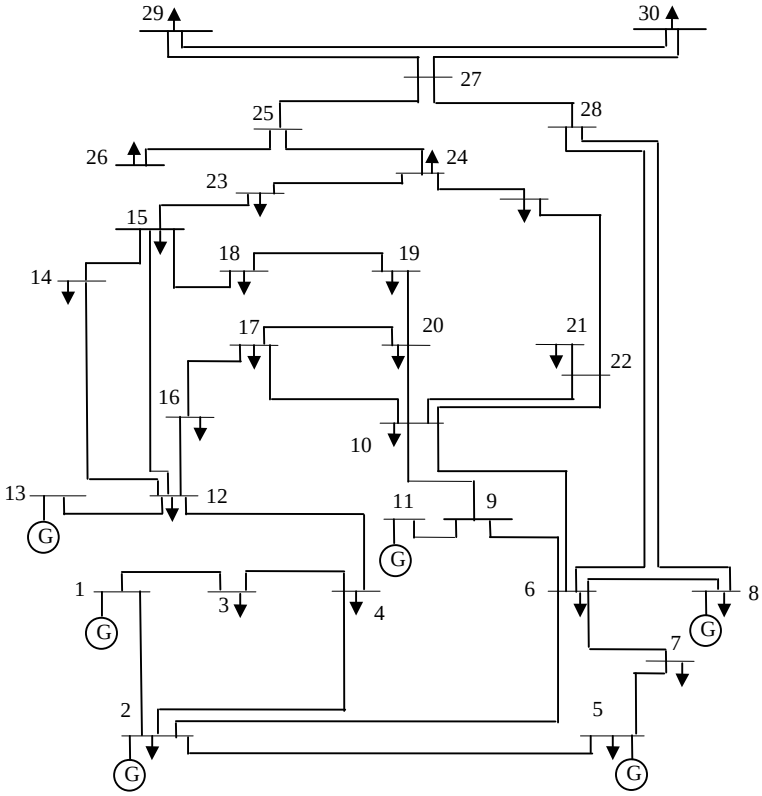

APÊNDICE C

Sistema 118 Barras

O apêndice C apresenta os dados das barras, os dados das linhas e o diagrama do sistema IEEE de 118 barras.

Dados de Barras em *p.u.*

Barra	*Tipo da Barra*	*Potência de Carga*
1	1	0,51
2	0	0,20
3	0	0,39
4	1	0,39
5	0	0
6	1	0,52
7	0	0,19
8	1	0,28
9	0	0
10	1	0
11	0	0,70
12	1	0,47
13	0	0,34
14	0	0,14
15	1	0,90
16	0	0,25
17	0	0,11
18	1	0,60
19	1	0,45
20	0	0,18
21	0	0,14
22	0	0,10
23	0	0,07
24	1	0,13
25	1	0
26	1	0
27	1	0,71
28	0	0,17
29	0	0,24
30	0	0
31	1	0,43
32	1	0,59
33	0	0,23
34	1	0,59
35	0	0,33
36	1	0,31
37	0	0
38	0	0
39	0	0,27
40	1	0,66
41	0	0,37
42	1	0,96
43	0	0,18
44	0	0,16
45	0	0,53
46	1	0,28

Continuação

Barra	***Tipo da Barra***	***Potência de Carga***
47	0	0,34
48	0	0,20
49	1	0,87
50	0	0,17
51	0	0,17
52	0	0,18
53	0	0,23
54	1	1,13
55	1	0,63
56	1	0,84
57	0	0,12
58	0	0,12
59	1	2,77
60	0	0,78
61	1	0
62	1	0,77
63	0	0
64	0	0
65	1	0
66	1	0,39
67	0	0,28
68	0	0
69	2	0
70	1	0,66
71	0	0
72	1	0,12
73	1	0,06
74	1	0,68
75	0	0,47
76	1	0,68
77	1	0,61
78	0	0,71
79	0	0,39
80	0	1,30
81	0	0
82	0	0,54
83	0	0,20
84	0	0,11
85	1	0,24
86	0	0,21
87	1	0
88	0	0,48
89	1	0
90	1	1,63
91	1	0,10
92	1	0,65
93	0	0,12

Continuação

Barra	***Tipo da Barra***	***Potência de Carga***
94	0	0,30
95	0	0,42
96	0	0,38
97	0	0,15
98	0	0,34
99	1	0,42
100	1	0,37
101	0	0,22
102	0	0,05
103	1	0,23
104	1	0,38
105	1	0,31
106	0	0,43
107	1	0,50
108	0	0,02
109	0	0,08
110	1	0,39
111	1	0
112	1	0,68
113	1	0,06
114	0	0,08
115	0	0,22
116	1	1,84
117	0	0,20
118	0	0,33

Tipo de Barra = 0 → Barra *PV*
Tipo de Barra = 1 → Barra de Carga
Tipo de Barra = 2 → Barra de Referência (*Slack)*

Dados de Linhas em *p.u.*

Linha	*Origem*	*Destino*	*Resistência R*	*Reatância X*
1	1	2	0,03030	0,0999
2	1	3	0,01290	0,0424
3	2	12	0,00176	0,0660
4	3	5	0,02410	0,1080
5	3	12	0,04840	0,1600
6	4	5	0,00176	0,0080
7	4	11	0,02090	0,0688
8	5	6	0,01190	0,0540
9	8	5	0,00000	0,0267
10	5	11	0,02030	0,0682
11	6	7	0,00459	0,0208
12	7	12	0,00862	0,0340
13	8	9	0,00244	0,0305
14	8	30	0,00431	0,0504
15	9	10	0,02580	0,0322
16	11	12	0,00595	0,0196
17	11	13	0,02225	0,0731
18	12	14	0,02150	0,0707
19	12	16	0,02120	0,0834
20	12	117	0,03290	0,1400
21	13	15	0,07440	0,2444
22	14	15	0,05950	0,1950
23	15	17	0,01320	0,0437
24	15	19	0,01200	0,0394
25	15	33	0,03800	0,1244
26	16	17	0,04540	0,1801
27	17	18	0,01230	0,5050
28	30	17	0,00000	0,3880
29	17	31	0,04740	0,1563
30	17	113	0,00913	0,0301
31	18	19	0,01119	0,0493
32	19	20	0,02520	0,1170
33	19	34	0,07520	0,2470
34	20	21	0,01830	0,0849
35	21	22	0,02090	0,0970
36	22	23	0,03420	0,1590
37	23	24	0,01350	0,0492
38	23	25	0,01560	0,0800
39	23	32	0,03170	0,1153
40	24	70	0,00221	0,4115
41	24	72	0,04880	0,1960
42	26	25	0,00000	0,0382
43	25	27	0,03180	0,1630
44	26	30	0,00799	0,0860
45	27	28	0,01913	0,0855
46	27	32	0,02290	0,0755

Continuação

Linha	*Origem*	*Destino*	*Resistência R*	*Reatância X*
47	27	115	0,01640	0,0999
48	28	29	0,02370	0,0424
49	29	31	0,01080	0,0660
50	30	38	0,04640	0,1080
51	31	32	0,02980	0,1600
52	32	113	0,06150	0,0080
53	33	37	0,04150	0,0688
54	34	36	0,00871	0,0540
55	34	37	0,00256	0,0267
56	34	43	0,04130	0,0682
57	35	36	0,00224	0,0208
58	35	37	0,01100	0,0340
59	38	37	0,00000	0,0305
60	37	39	0,03210	0,0504
61	37	40	0,05930	0,0322
62	38	65	0,00901	0,0196
63	39	40	0,01840	0,0731
64	40	41	0,01450	0,0707
65	40	42	0,05550	0,0834
66	41	42	0,04100	0,1400
67	42	49	0,07150	0,2444
68	43	44	0,06080	0,1950
69	44	45	0,02240	0,0437
70	45	46	0,04000	0,0394
71	45	49	0,06840	0,1244
72	46	47	0,03800	0,1801
73	46	48	0,06010	0,5050
74	47	49	0,01910	0,3880
75	47	69	0,08440	0,1563
76	48	49	0,01790	0,0301
77	49	50	0,02670	0,0493
78	49	51	0,04860	0,1170
79	49	54	0,07300	0,2470
80	49	66	0,01800	0,0849
81	49	69	0,09850	0,0970
82	50	57	0,04740	0,1590
83	51	52	0,02030	0,0492
84	51	58	0,02550	0,0800
85	52	53	0,04050	0,1153
86	53	54	0,02630	0,4115
87	54	55	0,01690	0,1960
88	54	56	0,00275	0,0382
89	54	59	0,05030	0,1630
90	55	56	0,00488	0,0860
91	55	59	0,04739	0,0855
92	56	57	0,03430	0,0755
93	56	59	0,08250	0,1200

Continuação

Linha	*Origem*	*Destino*	*Resistência R*	*Reatância X*
94	59	60	0,03170	0,1450
95	59	61	0,03280	0,1500
96	63	59	0,00000	0,0386
97	60	61	0,00264	0,0135
98	60	62	0,01230	0,0561
99	61	62	0,00824	0,0376
100	64	61	0,00000	0,0268
101	62	66	0,04820	0,2180
102	62	67	0,02580	0,1170
103	63	64	0,00172	0,0200
104	64	65	0,00269	0,0302
105	65	66	0,00000	0,0370
106	65	68	0,00138	0,0160
107	66	67	0,02240	0,1015
108	68	69	0,00000	0,0370
109	68	81	0,00175	0,0202
110	68	116	0,00034	0,0040
111	69	70	0,03000	0,1270
112	69	75	0,04050	0,1220
113	69	77	0,03090	0,1010
114	70	71	0,00882	0,0355
115	70	74	0,04010	0,1323
116	70	75	0,04280	0,1410
117	71	72	0,04460	0,1800
118	71	73	0,00866	0,0454
119	74	75	0,01230	0,0406
120	75	77	0,06010	0,1999
121	75	118	0,01450	0,0481
122	76	77	0,04440	0,1480
123	76	118	0,01640	0,0544
124	77	78	0,01240	0,0124
125	77	80	0,01700	0,0331
126	77	82	0,02980	0,0853
127	78	79	0,00546	0,0244
128	79	80	0,01560	0,0704
129	81	80	0,00000	0,0370
130	80	96	0,02690	0,1820
131	80	97	0,01830	0,0934
132	80	98	0,02380	0,1080
133	82	83	0,01120	0,0366
134	82	96	0,01620	0,0530
135	83	84	0,06250	0,1320
136	83	85	0,04300	0,1480
137	84	85	0,03020	0,0641
138	85	86	0,03500	0,1230
139	85	88	0,02000	0,1020
140	85	89	0,02390	0,1730

Continuação

Linha	***Origem***	***Destino***	***Resistência R***	***Reatância X***
141	86	87	0,02828	0,2074
142	88	89	0,01390	0,0712
143	89	90	0,05180	0,0652
144	89	92	0,00990	0,0380
145	90	91	0,02540	0,0836
146	91	92	0,03870	0,1272
147	92	93	0,02580	0,0848
148	92	94	0,04810	0,1580
149	92	100	0,06480	0,2950
150	92	102	0,01230	0,0559
151	93	94	0,02230	0,0732
152	94	95	0,01320	0,0434
153	94	96	0,02690	0,0869
154	94	100	0,01780	0,0580
155	95	96	0,01710	0,0547
156	96	97	0,01730	0,0885
157	98	100	0,03970	0,1790
158	99	100	0,01800	0,0813
159	100	101	0,02770	0,1262
160	100	103	0,01600	0,0525
161	100	104	0,04510	0,2040
162	100	106	0,06050	0,2290
163	101	102	0,02460	0,1120
164	103	104	0,04660	0,1584
165	103	105	0,05350	0,1625
166	103	110	0,03906	0,1813
167	104	105	0,00994	0,0378
168	105	106	0,01400	0,0547
169	105	107	0,05300	0,1830
170	105	108	0,02610	0,0703
171	106	107	0,05300	0,1830
172	108	109	0,01050	0,0288
173	109	110	0,02780	0,0762
174	110	111	0,02200	0,0755
175	110	112	0,02470	0,0640
176	114	115	0,00230	0,0104
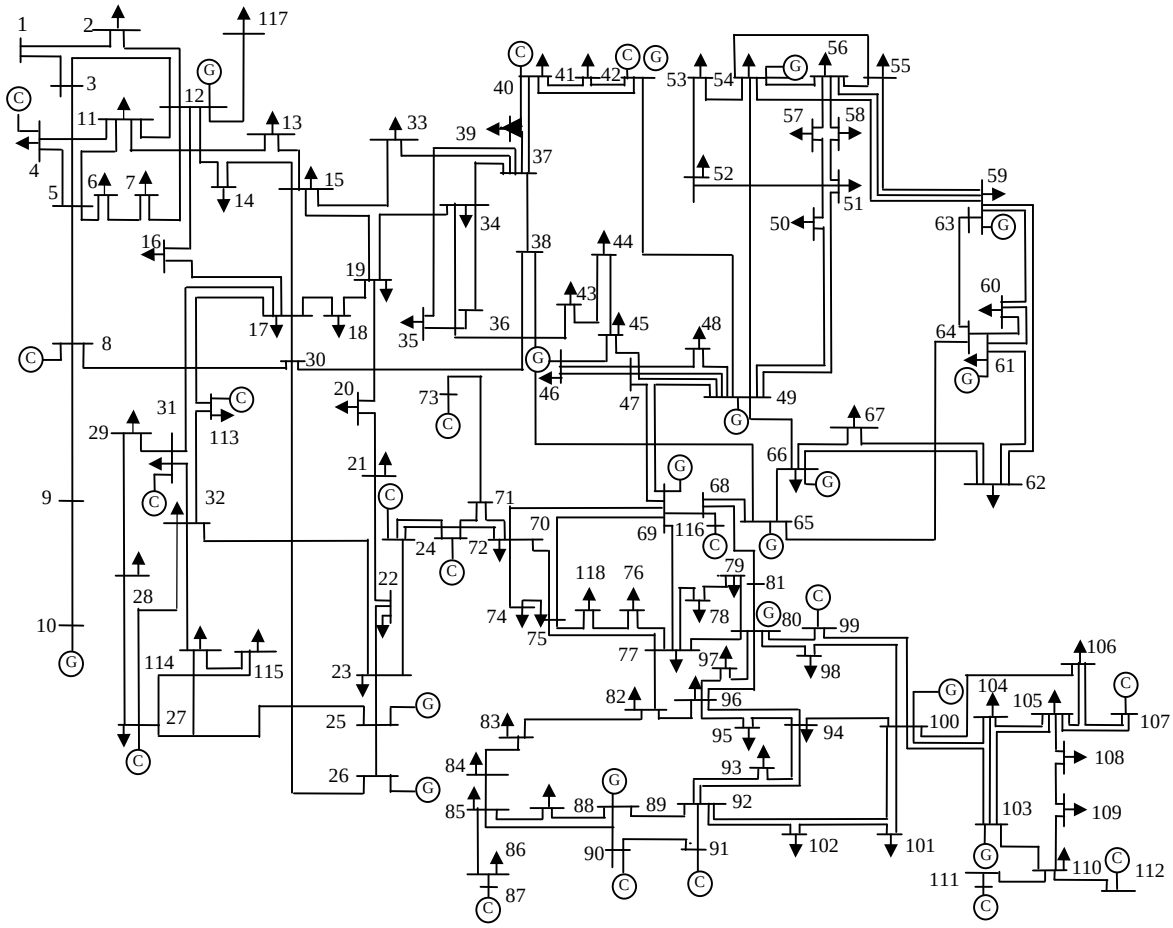
Diagrama do Sistema Teste IEEE de 118 Barras