

UNIVERSIDADE FEDERAL DE SANTA CATARINA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA
ELÉTRICA

RECONFIGURAÇÃO DE SISTEMAS DE
DISTRIBUIÇÃO PARA MINIMIZAÇÃO DE
PERDAS RESISTIVAS COM O AUXÍLIO DE
REDES NEURAS ARTIFICIAIS

Tese submetida à
Universidade Federal de Santa Catarina
como parte dos requisitos para a
obtenção do grau de Doutor em Engenharia Elétrica.

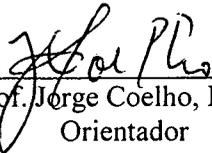
EDWARD GAUCHE

Florianópolis, Maio de 1999.

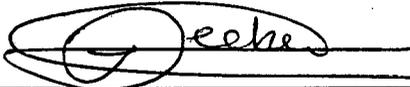
RECONFIGURAÇÃO DE SISTEMAS DE DISTRIBUIÇÃO PARA MINIMIZAÇÃO DE PERDAS RESISTIVAS COM O AUXÍLIO DE REDES NEURAIIS ARTIFICIAIS

Edward Gauche

‘Esta Tese foi julgada adequada para obtenção do Título de Doutor em Engenharia Elétrica, Área de Concentração em *Planejamento de Sistemas de Energia Elétrica*, e aprovada em sua forma final pelo Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal de Santa Catarina.’

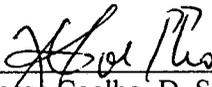


Prof. Jorge Coelho, D. Sc.
Orientador

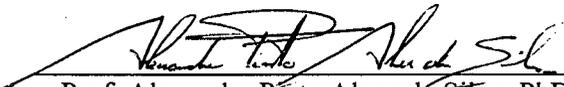


Prof. Ildemar Cassana Decker, D. Sc.
Coordenador do Programa de Pós-Graduação em Engenharia Elétrica

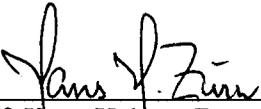
Banca Examinadora:



Prof. Jorge Coelho, D. Sc.
Presidente



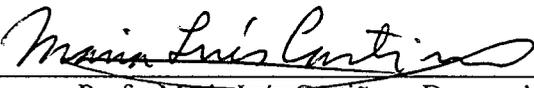
Prof. Alexandre Pinto Alves da Silva, PhD



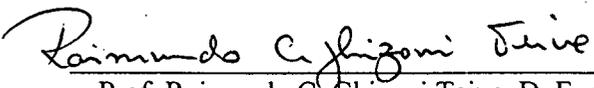
Prof. Hans-Helmut Zürn, PhD



Prof. Jorge Muniz Barreto, Dr.



Profa. Maria Inés Castiñera, Dra.



Prof. Raimundo C. Ghizoni Teive, D. Eng.

Dedicatória

A meu filho João Gabriel.

Agradecimentos

A todos que me abriram portas e mostraram caminhos.

Resumo da Tese apresentada à UFSC como parte dos requisitos necessários para a obtenção do grau de Doutor em Engenharia Elétrica.

RECONFIGURAÇÃO DE SISTEMAS DE DISTRIBUIÇÃO PARA MINIMIZAÇÃO DE PERDAS RESISTIVAS COM O AUXÍLIO DE REDES NEURAIAS ARTIFICIAIS

Edward Gauche

Maio/1999

Orientador: Prof. Jorge Coelho, D. Sc.

Área de Concentração: Planejamento de Sistemas de Energia Elétrica

Palavras-chave: Sistemas de Distribuição, Reconfiguração, Minimização de Perdas, Programação Inteira, Redes Neurais Artificiais.

Número de Páginas: 129.

RESUMO: Este trabalho apresenta o desenvolvimento de uma metodologia de reconfiguração de alimentadores primários de sistemas de distribuição, a ser aplicada em condições normais de operação e em tempo real, com o objetivo de reduzir as perdas elétricas resistivas. Neste sentido, para viabilizar a aplicação em tempo real, a metodologia é baseada em redes neurais artificiais, as quais após devidamente treinadas devem fornecer a topologia ótima do sistema de distribuição em tempo desprezível. Sorteios via Simulação Monte Carlo são utilizados de modo a representarem adequadamente a variabilidade de carga necessária à obtenção do conjunto de treinamento das redes neurais. A estocasticidade da carga considerada no treinamento deve propiciar às redes neurais, após treinadas para a solução do problema, capacidade de responder corretamente aos perfis de carga que vierem a ocorrer no sistema de distribuição. Para cada um dos perfis de carga obtidos através de sorteios via Simulação Monte Carlo é determinada a topologia com mínimas perdas resistivas. Este conjunto de dados, perfis de carga e correspondentes topologias com mínimas perdas, comporá o conjunto de treinamento das redes neurais artificiais. É também considerada a complexidade das RNA necessárias à solução do problema. Com o objetivo de verificar a otimalidade da solução fornecida para o sistema pelas redes neurais artificiais é utilizado um algoritmo de programação matemática inteira 0-1. Este algoritmo parte de uma condição inicial fornecida pelas redes neurais, por vezes sub-ótima, e obtém a topologia ótima em poucas iterações. O estudo de vários casos permite constatar a boa performance das redes neurais artificiais treinadas e a viabilidade de sua aplicação no gerenciamento de redes elétricas em tempo real.

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

DISTRIBUTION SYSTEMS RECONFIGURATION FOR RESISTIVE LOSSES MINIMIZATION BASED ON ARTIFICIAL NEURAL NETWORKS

Edward Gauche

May/1999

Advisor: Prof. Jorge Coelho, D. Sc.

Area of Concentration: Electrical Energy Systems Planning.

Keywords: Distribution Systems, Reconfiguration, Losses Minimization, Integer Programming, Artificial Neural Networks.

Number of Pages: 129.

ABSTRACT: This work presents the development of a methodology for reconfiguration of primary feeders in electrical energy distribution systems, to be applied in normal conditions of operation and real time, with the objective of reducing the resistive electrical losses. In order to make possible the application in real time, the methodology is based on artificial neural networks, which after duly trained must supply the optimal topology of the distribution system in negligible time. Monte Carlo Simulation is used to represent adequately the load variability, which is necessary for the attainment of the neural networks training set. The load stochasticity considered in the neural network training stage gives them the capacity of correctly responding to the load profiles that may occur in the distribution system. The topology with minimum resistive losses is determined for each one of the load profiles obtained through Monte Carlo Simulation. This data set, profiles of load and related topologies with minimum losses, will compose the artificial neural networks training set. It was also considered the neural networks complexity for the problem solution. An integer mathematical programming algorithm is used to verify the optimality of the solution supplied by the artificial neural networks. This algorithm starts from an initial condition, sometimes a sub-optimal one, supplied by the neural networks and gets the optimal topology in few iterations. The methodology applications to different systems allows concluding for both the good trained artificial neural networks solutions and the methodology application feasibility in the real time electrical networks management.

SUMÁRIO

Resumo	v
Abstract	vi
Sumário	vii
Lista de Figuras	xi
Lista de Tabelas	xii
1. Introdução	1
1.1 Motivação	2
1.2 Objetivo	5
1.3 Conteúdo	5
2. Revisão Bibliográfica	8
2.1 Introdução	8
2.2 O Problema da Redução de Perdas através da Reconfiguração de Redes	10
2.2.1 Quantificação da Redução de Perdas numa Transferência de Carga entre Alimentadores	11
2.2.2 Análise de Múltiplos Chaveamentos Simultâneos	12
2.2.3 Incorporação de Incerteza na Demanda	23
2.2.4 Utilização de Técnicas Neurais no Problema de Redução de Perdas	24
2.2.5 Utilização de Computação Evolucionária para a Solução do Problema	28
2.2.6 Utilização de Conjuntos Difusos na Reconfiguração de Sistemas de Distribuição	30
2.3 Conclusão	31
3. Redes Neurais Artificiais	33
3.1 Introdução	33
3.2 Formulação do Algoritmo de Treinamento <i>Backpropagation</i>	35
3.2.1 Respostas dos Neurônios das Diferentes Camadas	36
3.2.2 Cálculo dos Erros nas Camadas	39

3.2.3 Cálculo dos Ajustes dos Pesos	40
3.2.4 Incorporação do Momento e Cálculo dos Novos Pesos	41
3.2.5 Convergência da Etapa de Treinamento	41
3.3 Definição do Número de Neurônios de Cada Camada	42
3.3.1 Camada de Entrada	42
3.3.1.1 Método <i>Class-Mean-Separation</i> de Seleção de Características	43
3.3.2 Camada Intermediária	44
3.3.3 Camada de Saída	45
3.4 Conclusão	47
4. Minimização de Perdas	48
4.1 Introdução	48
4.2 Descrição do Método de Minimização de Perdas	48
4.3 Equacionamento	49
4.3.1 Função Objetivo	49
4.3.2 Redução de Perdas	50
4.3.3 Escolha do Ramo a ser Aberto	53
4.4 Exemplo da Aplicação do Método de Minimização de Perdas ao Sistema 1	54
4.4.1 Detalhamento dos Cálculos da 1ª Iteração	55
4.4.1.1 Cálculos para a Malha-1	57
4.4.1.2 Cálculos para a Malha-2	58
4.4.1.3 Determinação do Chaveamento Ótimo para o Sistema	59
4.5 Exemplo da Aplicação do Método de Minimização de Perdas ao Sistema 2	62
4.6 Conclusão	65
5. Otimalidade da Solução	68
5.1 Introdução	68
5.2 Formulação do Problema de Otimização através de Programação Matemática Inteira	69
5.2.1 Obtenção da Função Objetivo para um Sistema de 5 Barras	69

5.2.2 Sistema de 15 Barras	76
5.3 Método de Solução	81
5.4 Conclusão	83
6. Metodologia e Aplicações	84
6.1 Introdução	84
6.2 Algoritmo de RNA aplicado à Reconfiguração de Sistemas de Distribuição	84
6.2.1 Sorteio via Simulação Monte Carlo	85
6.2.2 A Minimização de Perdas Resistivas através de Método Heurístico	87
6.2.3 O Treinamento de RNA para a Solução do Problema	87
6.2.4 Verificação da Otimalidade através de Programação Matemática Inteira	89
6.3 Sistema Teste 1	90
6.3.1 Passos 1 e 2 - Sorteios dos Perfis de Carga e Determinação das Topologias Ótimas	91
6.3.2 Passo 3 – Treinamento de RNA para a Solução do Problema	93
6.3.3 Passo 4 - Verificação da Otimalidade da Solução	95
6.4 Sistema Teste 2	101
6.4.1 Passos 1 e 2 - Sorteios dos Perfis de Carga e Determinação das Topologias Ótima	104
6.4.2 Passo 3 - Treinamento de RNA para a Solução do Problema	105
6.4.3 Passo 4 - Verificação da Otimalidade da Solução	108
6.5 Conclusão	112
7. Considerações Finais	114
7.1 Contribuições do Trabalho	116
7.2 Sugestões para Trabalhos Futuros	117
Apêndice I – Método de Fluxo de Carga	119
AI.1 Introdução	119
AI.2 Equacionamento do Método de Malhas de Fluxo de Carga	119
AI.3 Algoritmo	121

Apêndice II – Algoritmo Híbrido <i>Backpropagation</i> /Marquardt-Levenberg	123
AII.1 - Introdução	123
AII.2 – Metodologia para a Reconfiguração Considerando-se a Minimização de Perdas	124
AII.3 – Resultados e Conclusões	125
Referências Bibliográficas	126

Lista de Figuras

Figura 1.1 - Fluxograma Simplificado da Metodologia	6
Figura 2.1 - Alimentador de Distribuição	13
Figura 2.2 - Alimentador de Distribuição com Chaveamento em L_8	20
Figura 3.1 - Arquitetura de uma Rede Neural MLP Contendo duas Unidades de Entradas, duas Unidades Escondidas, uma Unidade de Saída e duas Unidades Bias	37
Figura 3.2 - Erro em Função do Número de Neurônios na Camada Intermediária	45
Figura 3.3 - Determinação da Topologia Ótima a partir das RNA Treinadas	46
Figura 4.1 - Malha de uma Rede de Distribuição	51
Figura 4.2 - Alimentador Pertencente ao Sistema de Distribuição da Grande Florianópolis - Sistema 1	55
Figura 4.3 - Lado L da Malha 1	57
Figura 4.4 - Lados L e R da Malha 2	58
Figura 4.5 - Configuração Final do Sistema 2	66
Figura 5.1 - Interação entre RNA e Método de Programação Matemática Inteira 0-1	69
Figura 5.2 - Sistema de 5 Barras com Chaveamento em L_3	70
Figura 5.3 - Sistema real com 15 barras	77
Figura 5.4 - Transferência de Carga entre Subestações	81
Figura 5.5 - Procedimento de Busca da Solução Ótima para Sistemas com Auto-Restabelecimento	82
Figura 6.1 - Fluxograma do Algoritmo Proposto	86
Figura 6.2 - Alimentador Córrego Grande - Aeroporto Hercílio Luz (Florianópolis)	91
Figura 6.3 - Número de Perfis de Carga Mal-Classificados pela RNA versus Número de Neurônios da Camada Intermediária	94
Figura 6.4 - Configuração Inicial para os Perfis de Carga 1 e 2	96
Figura 6.5 - Configuração Inicial para o Perfil 3	100
Figura 6.6 - Sistema 2 com 32 Barras de Carga e 5 Linhas Alternativas de Chaveamento	102
Figura 6.7 - Número de Perfis de Carga Mal-Classificados pelas RNA versus Número de Neurônios da Camada Intermediária	106
Figura AI.1- Representação Monofásica do Sistema	120
Figura AI.2 - Fluxograma do Método de Malhas de Fluxo de Carga	122
Figura AII.1 - Algoritmo Híbrido <i>Backpropagation</i> /Marquardt-Levenberg	123
Figura AII.2 - Metodologia para Minimização de Perdas	125

Lista de Tabelas

Tabela 4.1 - Dados do Sistema 1	56
Tabela 4.2 - Valores em p.u. dos Ramos do Lado <i>L</i> da Malha 1	57
Tabela 4.3 - Valores em p.u. dos Ramos do Lado <i>L</i> da Malha 2	58
Tabela 4.4 - Valores em p.u. dos Ramos do Lado <i>R</i> da Malha 2	59
Tabela 4.5 - Chaveamento Ótimo para Cada Iteração	60
Tabela 4.6 - Carregamento dos Condutores do Sistema 1	61
Tabela 4.7 - Perfil de Tensão do Sistema 1	61
Tabela 4.8 - Dados do Sistema 2	63
Tabela 4.9 - Chaveamentos Ótimos para o Sistema 2	64
Tabela 4.10 - Perfil de Tensão do Sistema 2	65
Tabela 5.1 - Características do Sistema de 5 barras	70
Tabela 5.2 - Demandas do Sistema de 5 barras	73
Tabela 5.3 - Coeficientes das Equações das Correntes nos Ramos	73
Tabela 5.4 - Coeficientes das Equações das Correntes nos Ramos Elevadas ao Quadrado	75
Tabela 5.5 - Perdas nos Ramos do Sistema de 5 Barras	75
Tabela 5.6 - Obtenção da Solução para o Sistema de 5 Barras	76
Tabela 5.7 - Quadro Resumo das Equações das Correntes nos Ramos do Sistema	77
Tabela 5.8 - Demandas do Sistema	78
Tabela 5.9 - Coeficientes da Equação da Corrente nos Ramos do Sistema de 15 Barras	78
Tabela 5.10 - Coeficientes do Quadrado das Correntes dos Ramos do Sistema de 15 Barras	79
Tabela 5.11 - Perdas nos Ramos do Sistema de 15 Barras (kW)	80
Tabela 6.1 - Dados do Sistema 1	92
Tabela 6.2 - Alternativas de Chaveamento do Sistema 1	92
Tabela 6.3 - Configurações Ótimas	93
Tabela 6.4 - Perfis de Carga Mal-Classificados pela RNA (kW)	95
Tabela 6.5 - Dados do Sistema 2	103
Tabela 6.6 - Linhas Alternativas de Chaveamento	104
Tabela 6.7 - Configurações Ótimas	105
Tabela 6.8 - Perfis de Carga Mal-Classificados pelas RNA (kW)	107
Tabela 6.9 - Topologia Ótima para os Perfis da Tabela 6.8	108
Tabela 6.10 - Resultados da Aplicação do Método de Prog. Mat. Inteira ao Perfil de Carga 1	109
Tabela 6.11 - Resultados da Aplicação do Método de Prog. Mat. Inteira ao Perfil de Carga 2	110
Tabela 6.12 - Resultados da Aplicação do Método de Prog. Mat. Inteira ao Perfil de Carga 3	111
Tabela 6.13 - Resultados da Aplicação do Método de Prog. Mat. Inteira ao Perfil de Carga 4	111
Tabela 6.14 - Respostas das RNA e Prog. Inteira 0-1 para Perfis de Carga Mal-Classificados	112

Capítulo 1 - Introdução

O sistema elétrico tem como atribuições a geração, transmissão e distribuição de energia elétrica aos consumidores finais. As empresas do setor elétrico procuram minimizar a relação custo-benefício do fornecimento de energia elétrica. Na obtenção deste objetivo, considerando-se os inúmeros aspectos envolvidos, níveis aceitáveis de qualidade de serviço devem ser atingidos no atendimento das necessidades dos usuários de energia elétrica.

Os sistemas de distribuição podem ser definidos como redes usualmente operadas de modo radial constituídas de subestações, alimentadores, religadores, chaves seccionadoras e dispositivos de proteção (disjuntores, chaves fusíveis) adequadamente conectados que transportam a energia elétrica desde as subestações até o usuário final desta energia.

Nos últimos anos, a distribuição vem merecendo atenção crescente por parte dos pesquisadores do setor elétrico. O explosivo crescimento nas áreas de microcomputadores, microprocessadores e tecnologias de telecomunicação fornecem oportunidades de controle avançado dos sistemas elétricos de potência, particularmente na área de automação dos sistemas de distribuição. É também nesta parte do sistema onde ocorrem a maioria das falhas e a maior quantidade de perdas resistivas, influenciando decisivamente na qualidade do serviço e nos custos de fornecimento desta energia.

A automação dos sistemas de distribuição permite melhoras significativas nas condições de operação do sistema e na qualidade do fornecimento de energia elétrica (continuidade).

Sob condição normal, o sistema de distribuição é operado a partir de uma configuração básica previamente definida. Quando acontecem eventos como uma falha no sistema, manutenção programada ou sobrecarga nos alimentadores, os operadores reconfiguram o sistema a partir da mudança do estado de chaves seccionadoras, respeitando-se critérios estabelecidos de acordo com o objetivo pretendido (eliminar sobrecarga ou isolar falha, por exemplo).

A reconfiguração dos alimentadores permite a transferência de cargas de linhas ou transformadores altamente carregados para linhas ou transformadores menos carregados. Estas transferências são efetivas não apenas na alteração do nível de carregamento dos alimentadores, mas também na melhoria do perfil de tensão do sistema e na redução de perdas resistivas de todo o sistema [12,23].

1.1 Motivação

A redução das perdas nos alimentadores primários de distribuição é considerada como o objetivo principal da reconfiguração de alimentadores quando ocorre sobrecarga nos alimentadores em condições normais de operação [34].

Nos dias atuais, o problema de reconfiguração de alimentadores passa a ser analisado em aplicações de tempo real, resultantes da automação destes sistemas, a partir do momento em que as chaves seccionadoras começam a ser remotamente monitoradas e controladas.

Com o avanço crescente dos recursos e técnicas computacionais e o aumento da automação no controle dos sistemas de distribuição dos países em desenvolvimento (automação da operação das chaves seccionadoras), torna-se viável a utilização de um modelo *on-line* de redução de perdas nos alimentadores primários através da reconfiguração da rede.

Encontram-se na literatura inúmeras técnicas de reconfiguração, consolidadas pelo uso e eficientes computacionalmente, que são aplicadas na minimização das perdas resistivas, como se apresentará a seguir. Na grande maioria destes trabalhos a demanda foi considerada determinística. Recentemente na referência [41], ao contrário do apresentado em trabalhos anteriores, passou-se a modelar probabilisticamente a demanda, através da consideração da variabilidade desta demanda.

Nos últimos anos, novas tecnologias têm sido introduzidas na análise e projeto de complexos sistemas de grande porte. Uma destas tecnologias é a técnica de redes neurais artificiais (RNA), cujas principais vantagens estão nas áreas de algoritmos de aprendizagem, rápida computação paralela, interpolação inteligente de dados e aplicações *on-line* de sistemas dinâmicos (como é o caso de reconfiguração em tempo real de sistemas de distribuição).

Deve-se destacar, como apresentado por Barreto [2], que definir inteligência é bastante difícil e que tal tarefa tem suscitado muitas polêmicas. Uma definição de inteligência artificial (IA) que apresenta qualidades, embora não livre de críticas, segundo Barreto, é a apresentada por Cherniak e McDermott: “IA é o estudo das faculdades mentais com o uso de modelos computacionais” [10].

Redes neurais representam uma tecnologia nova e crescente como indicado pelas muitas aplicações (sensoreamento remoto, modelagem, controle, previsão de carga, classificações de padrões, otimização combinatorial) e pelo desenvolvimento de computadores com *hardware* neural [5,9,16,17,18,20,31,42,44,48,55].

As principais razões para este crescimento de aplicações estão na habilidade da RNA aprender complexas relações não-lineares e na sua estrutura modular que permite processamento paralelo.

Redes neurais têm sido apresentadas como solução de problemas de sistemas modelados (sistemas de representação matemática conhecida), e mais importante, na solução de problemas de sistemas ainda não modelados (representação matemática desconhecida) quando um banco de dados histórico deste sistema é disponível [48,55].

Com a consolidação ocorrida na última década e com o aumento recente de aplicações de redes neurais a sistemas de potência, esta nova técnica surge como alternativa importante a ser explorada na reconfiguração de redes elétricas em tempo real descrita acima.

As redes neurais auxiliam na resolução de determinado problema através da aprendizagem das características do comportamento do sistema, a partir de um conjunto de dados de treinamento (aprendizagem a partir de exemplos). O processo de treinamento é executado pelo ajuste das conexões (pesos) entre os elementos de processamento (neurônios) de acordo com regras apropriadas de treinamento. O processo de treinamento está completo quando o erro entre a saída atual e a saída desejada da rede neural está dentro da tolerância especificada, para o banco de dados considerado.

Sabe-se da teoria de redes neurais que o tempo de treinamento (aprendizagem) da rede neural costuma ser elevado, dependendo do porte do problema. Entretanto, este fato não se constitui numa restrição visto ser esta etapa realizada *off-line*.

Sabe-se também que após o treinamento da rede o tempo para obter-se a resposta da rede neural tipo *multilayer perceptrons* a uma entrada qualquer é desprezível, residindo neste ponto a grande vantagem de sua utilização em aplicações *on-line* da reconfiguração dos alimentadores primários, com o objetivo de redução das perdas resistivas nestes alimentadores.

Assim, efetuando-se o treinamento da rede para um conjunto adequado de diferentes perfis de carga (onde a cada perfil de carga corresponde uma topologia de rede ótima em nível de perdas), a rede após treinada deverá fornecer a resposta correta (estado das chaves seccionadoras que fornecem a topologia ótima) para qualquer perfil de carga aleatoriamente escolhido.

O algoritmo de reconfiguração de sistemas de distribuição baseado em RNA com as características acima pode fornecer a reconfiguração ótima (em condições normais de operação ou na presença de sobrecarga) do sistema em nível de perdas em tempo da ordem de microsegundos.

Imaginando-se que a RNA não apresente a resposta esperada para todo conjunto teste poder-se-ia, por fim, verificar a otimalidade da solução fornecida pela RNA utilizando-se um algoritmo de programação matemática inteira. Como o ponto de partida fornecido pela RNA se encontra próximo do ótimo, a solução do método de programação inteira é obtida muito mais rapidamente do que partindo-se da configuração base. Esta solução é também mais confiável comparando-se à solução fornecida por métodos heurísticos.

Vislumbra-se assim a importância que um algoritmo onde uma técnica eficiente de reconfiguração de redes utilizando técnicas neurais, para a redução de perdas resistivas, possa vir a ter na operação em condições normais de sistemas de distribuição.

1.2 Objetivo

O objetivo desta tese consiste no desenvolvimento de uma metodologia de reconfiguração em tempo real de alimentadores primários de sistemas de distribuição para redução de perdas resistivas, baseada fundamentalmente nas seguintes considerações:

- representação probabilística da variabilidade dos nós de carga, a ser utilizada na obtenção dos dados de entrada dos conjuntos de treinamento e teste de RNA;
- obtenção dos dados de saída do conjunto de treinamento e do conjunto teste de RNA via método *branch-exchange* heurístico;
- utilização de RNA na determinação da topologia com mínimas perdas do sistema;
- verificação da otimalidade da solução fornecida pelas RNA, se necessário, através de programação matemática inteira.

1.3 Conteúdo

O conteúdo deste trabalho é estruturado com a finalidade de manter a devida coerência com os passos da metodologia a ser proposta no capítulo 6, a qual é apresentada a seguir através do fluxograma da figura 1.1.

O fluxograma a seguir apresenta a estrutura modular da metodologia a ser desenvolvida nesta tese. A fundamentação de cada módulo da estrutura e seu encadeamento serão discutidos nos demais capítulos desta tese, respeitando-se a ordenação do conteúdo apresentada a seguir.

No capítulo 2, a seguir, são apresentados resumidamente os principais trabalhos relacionados à redução de perdas elétricas resistivas através da reconfiguração dos alimentadores primários de redes de distribuição, com o objetivo de colocar o leitor a par do estado da arte do problema. Dentre estes trabalhos pode-se verificar o início do emprego de técnicas de redes neurais artificiais e algoritmos genéticos na solução do problema de minimização de perdas elétricas.

O capítulo 3, por sua vez, apresenta conceitos fundamentais de RNA bem como a formulação detalhada do algoritmo *backpropagation* de treinamento e do algoritmo *class-mean*

separation de seleção de características do conjunto de dados de entrada utilizado no treinamento das RNA.

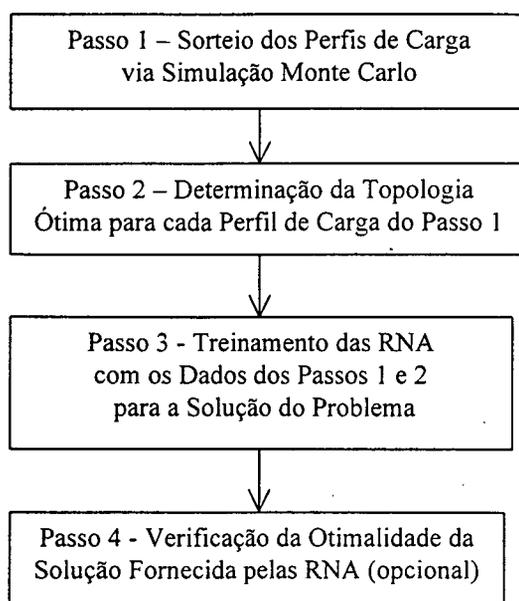


Figura 1.1 – Fluxograma Simplificado da Metodologia

No capítulo 4 encontra-se a formulação detalhada do algoritmo heurístico *branch-exchange* de reconfiguração de redes de distribuição para minimização de perdas resistivas adotado para a obtenção do conjunto de treinamento das RNA. Neste capítulo pode-se observar a utilização do método na obtenção da topologia ótima em nível de perdas da rede de distribuição para dois diferentes sistemas teste.

O capítulo 5 apresenta a formulação detalhada do algoritmo de programação matemática inteira 0-1 utilizado para verificar a qualidade da solução fornecida pelas RNA. Pode-se também observar sua aplicação passo a passo para dois sistemas exemplo.

No capítulo 6 são apresentados a metodologia desenvolvida nesta tese para a redução de perdas resistivas de sistemas de distribuição através da reconfiguração dos alimentadores primários do sistema e os resultados obtidos com a aplicação da metodologia proposta a diferentes sistemas teste. O emprego da Simulação Monte Carlo e do algoritmo de reconfiguração utilizados na obtenção do conjunto de treinamento, o treinamento das RNA

propriamente dito e a verificação da qualidade da solução fornecida pelas RNA através do método de programação matemática binária inteira podem ser observados para cada sistema teste.

O capítulo 7, por fim, apresenta as conclusões finais, contribuições, bem como sugestões para desenvolvimentos futuros.

Com o objetivo de manter a auto-concisão do trabalho, encontra-se no apêndice I o método de fluxo de carga [39] adotado no algoritmo de reconfiguração de redes radiais de distribuição detalhado no capítulo 4 e utilizado nesta tese na obtenção do conjunto de treinamento das RNA.

Capítulo 2 - Revisão Bibliográfica

2.1 Introdução

Condições anormais ocorrem diariamente na operação de sistemas de potência, devido a eventos programados (manutenção) ou aleatórios (falha de equipamentos, variação inesperada de demanda, etc). Estes eventos levam o sistema para um estado de emergência ou alerta no qual algumas magnitudes de tensão ou limites de carregamento dos condutores possam ser violados. Um conjunto de ações deve ser executado num tempo muito curto para evitar um parcial ou total colapso do sistema.

O operador deve exercer ações de ajuste tais como: alterar a geração de potência ativa e reativa, mudar a posição dos taps dos transformadores, executar chaveamento de capacitores ou reatores, proceder ao chaveamento ou seccionalização de linhas de transmissão e, se necessário, efetuar cortes de carga.

Embora a reconfiguração da rede seja um controle barato capaz de solucionar os problemas de violação em tensão e corrente, esta técnica tem sido pouco pesquisada no Brasil. A estratégia de chaveamento é usualmente determinada apenas pela experiência do operador, sem levar em consideração o processo de otimização relacionado.

Um experiente operador pode ser uma das mais importantes ferramentas para o sistema. Em muitos casos um operador é capaz de executar difíceis tarefas num curto espaço de tempo. Entretanto, o operador pode não estar familiarizado com todas as possíveis configurações da rede. Nestas condições o resultado que ele possa vir a conseguir pode não ser o mais recomendável. Como chaveamentos não acontecem a todo momento na operação de sistemas de potência, operadores podem não ter suficiente experiência para produzir uma estratégia de chaveamento apenas observando o diagrama do sistema e o seu atual ponto de operação.

A mudança da configuração através do chaveamento de linhas do sistema exclui o uso de modelos linearizados (as variáveis que representam as linhas são do tipo binário inteiro: iguais a 0 quando representam chaves seccionadoras abertas ou iguais a 1, no caso de chaves seccionadoras fechadas ou sem chaves no trecho considerado). Para obter uma solução eficiente,

costuma-se tratar a solução corretiva de chaveamento de linhas separadamente dos outros controles variáveis que necessitam ser representados por modelos linearizados.

Desta maneira, obter a configuração ótima da rede, através da aplicação de chaveamentos em linhas para corrigir as violações, passa a ser um objetivo importante na operação de um sistema elétrico.

O procedimento para gerar os possíveis chaveamentos não deve ser tão heurístico quanto é a experiência de um operador. Deve sim, ser um procedimento geral, sendo ainda rápido e preciso.

Chaves seccionadoras são usualmente utilizadas em sistemas de distribuição para proteção (isolando uma falta), para transferir carga entre alimentadores ou subestações, para possibilitar manutenções e também podem ser usadas no importante problema de gerência da reconfiguração da rede, ao ocorrerem mudanças das condições de operação [23,34].

A enumeração explícita de todos os possíveis casos requereria a simulação de 2^L (L é o número de linhas) chaveamentos para a escolha da alternativa de menor custo operacional. Na prática, entretanto, apenas um pequeno subconjunto das possíveis configurações necessita ser examinado, consistindo em um determinado número de chaveamentos, os quais são os mais efetivos na solução das possíveis violações.

Especialmente com a introdução da possibilidade de controle remoto dessas chaves, a gerência da configuração em tempo real passa a assumir um importante papel na automação da distribuição [8,53]. No passado, operar o sistema respeitando-se as suas restrições operacionais (limites de tensão e corrente) era uma solução satisfatória. Com o advento da automação, outros objetivos se apresentaram aos operadores, onde o problema de redução de perdas passou a receber atenção crescente, devido não apenas a fatores técnico-econômicos, mas também à qualidade da energia que o mercado competitivo exige.

A reconfiguração da rede para minimizar as perdas elétricas do sistema pode, além da otimização da operação, também ser usada em estudos de planejamento com uma outra

finalidade, para decidir, por exemplo, através de quais alimentadores os novos consumidores serão melhor atendidos.

2.2 O Problema da Redução de Perdas através da Reconfiguração de Redes

O estado atual do problema da redução de perdas através da reconfiguração de alimentadores de sistemas de distribuição vai ser abordado a seguir, a partir da análise de seis itens. Esta divisão em itens procura manter uma ordenação cronológica aproximada dos trabalhos, agrupá-los num mesmo item quando do uso de técnica comum e, destacar o uso de novas técnicas na solução do problema e novo enfoque na representação da variabilidade da demanda. A discussão dos trabalhos ficará praticamente restrita à redução de perdas através de técnicas de reconfiguração de redes visto ser este o tema da metodologia a ser proposta nesta tese no capítulo 6.

Primeiro item: compreende a quantificação da redução de perdas proveniente de uma única transferência de carga entre alimentadores [12].

Segundo item: a extensão do procedimento anterior para múltiplos chaveamentos e a aplicação de métodos heurísticos na determinação de estratégias de chaveamento para a obtenção da topologia ótima em nível de perdas [1,4,7,27,32,41,54].

Terceiro item: aborda a consideração da variabilidade na demanda no processo de reconfiguração de redes de distribuição para redução de perdas [41].

Quarto item: analisa o uso de redes neurais na redução de perdas através de reconfiguração em tempo real de alimentadores [22,23,30,34].

Quinto item: apresenta a aplicação de computação evolucionária na otimização da redução de perdas através da reconfiguração de redes de distribuição e na solução de um fluxo ótimo de potência multi-objetivo para sistemas de transmissão onde as perdas resistivas são consideradas [43,46].

Sexto item: aborda a aplicação de conjuntos difusos à restauração de sistemas de distribuição e à redução de perdas resistivas [33, 40, 45].

Cada um dos seis itens citados acima serão discutidos nas seções a seguir.

2.2.1 Quantificação da Redução de Perdas numa Transferência de Carga entre Alimentadores

Civanlar *et al.* na referência [12] apresentaram uma atrativa solução computacional para a redução de perdas resistivas através da técnica de reconfiguração de redes. Uma fórmula simplificada (equação (2.1)) foi obtida para calcular a redução nas perdas resultante de uma única transferência de carga entre alimentadores. Esta transferência de carga é efetuada fechando-se uma chave seccionadora inicialmente aberta que formará uma malha e após, abrindo-se uma chave seccionadora inicialmente fechada desta malha, com a finalidade de manter a radialidade do sistema.

$$\Delta P = \operatorname{Re}\left\{2\left(\sum_{i \in D} I_i\right)\left(E_m - E_n\right)^*\right\} + r_{loop} \left| \sum_{i \in D} I_i \right|^2 \quad (2.1)$$

Onde: ΔP é a variação nas perdas resultante da transferência de carga;

E_m é a tensão no terminal do lado de mais baixa tensão da chave que formará a malha;

E_n é a tensão no terminal do lado de mais alta tensão da chave que forma a malha;

D é o conjunto de nós de carga que são transferidos de um lado para outro da malha;

i são os nós de carga pertencentes ao conjunto D ;

r_{loop} é a resistência da malha;

* representa a notação de conjugado de números complexos.

Os autores provam que ΔP representa uma redução nas perdas resistivas quando o valor obtido é negativo. Como o segundo termo da fórmula acima é sempre positivo, somente com o primeiro termo tornando-se significativamente negativo se consegue uma redução significativa nas perdas.

Nesta análise são efetuadas as seguintes considerações:

- E_m e E_n estão praticamente em fase devido às pequenas diferenças angulares nos sistemas de distribuição;
- I_i está praticamente em fase com o vetor de tensões também devido à compensação capacitiva.

Assim, os autores concluem que só há uma significativa redução nas perdas se houver uma significativa diferença de tensão ($|E_m| < |E_n|$) entre os terminais da chave seccionadora, significando que as cargas devem ser transferidas do lado de menor tensão para o lado de mais alta tensão da malha. Esse critério constitui um importante fator a ser considerado para reduzir o número de indesejáveis opções candidatas ao chaveamento.

A sucessiva aplicação da fórmula proposta permite o desenvolvimento de uma estratégia de chaveamentos múltiplos. O detalhamento desta implementação, estava além do escopo do artigo, não sendo por isso considerado. Os excelentes resultados obtidos nesta aplicação motivaram o desenvolvimento de outros trabalhos com o objetivo de analisar chaveamentos múltiplos, como se observa na seção seguinte.

2.2.2 Análise de Múltiplos Chaveamentos Simultâneos

Os trabalhos apresentados nesta seção têm por objetivo determinar o conjunto de chaveamentos a serem executados simultaneamente, a partir de uma configuração inicial, para se alcançar a configuração ótima em nível de perdas resistivas do sistema de distribuição.

Castro e Watanabe [7] desenvolveram um algoritmo para redução de perdas através da reconfiguração de alimentadores, no qual um método aproximado é aplicado para calcular o novo perfil de tensão quando o sistema é analisado após uma transferência de carga obtida via chaveamentos nos ramos (*branch-exchange*).

Este cálculo aproximado do perfil de tensão baseia-se no fato da corrente de carga ser considerada constante, uma vez que operações de chaveamento em sistemas típicos de distribuição resultam em pequenas mudanças de tensão (inferiores a 5%). Deste modo se evita uma nova execução completa de um algoritmo de fluxo de carga. Tanto neste trabalho como nos trabalhos citados a seguir, a utilização de métodos aproximados de fluxo de carga visa diminuir o tempo de execução do algoritmo *branch-exchange*, melhorando sua eficiência computacional.

Observada a simplificação acima, os autores utilizam duas equações para o cálculo das quedas de tensão nos alimentadores, como será ilustrado a seguir .

A equação (2.2) é aplicada para o cálculo da queda de tensão nas seções dos alimentadores que tiveram um alívio no carregamento, resultando numa menor queda de tensão.

$$E_j' = E_j - R_{jk} \sum_{i \in D} I_i \quad (2.2)$$

Onde: D é o conjunto de barras desconectadas do alimentador;

j é a barra em questão;

k é a barra de intercâmbio desconectada;

R_{jk} é a resistência comum aos caminhos: subestação-barra sob análise e subestação-cargas desconectadas;

I_i é a corrente que passava no ramo aberto pelo chaveamento.

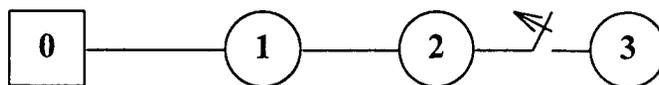


Figura 2.1. Alimentador de Distribuição

A aplicação deste procedimento pode ser visualizada através da figura 2.1, desconectando-se a barra 3. De acordo com a equação (2.2) tem-se:

$$E_2' = E_2 - R_{02} \cdot I_3$$

A equação (2.3), por sua vez, é aplicada para cálculo das quedas de tensão nos alimentadores que tiveram um aumento no carregamento, resultando numa maior queda de tensão.

$$E_j' = E_j + R_{jk} \sum_{i \in D'} I_i \quad (2.3)$$

Onde: D' é o conjunto de barras conectadas ao alimentador,

k é a barra de intercâmbio conectada.

Ao contrário de outros métodos [1,32] onde são descartadas todas as opções de chaveamento que implicariam num aumento inicial nas perdas ($|E_m| \geq |E_n|$), no procedimento acima, após o primeiro chaveamento estas opções deverão ser novamente analisadas pois, após o chaveamento inicial podem ainda resultar numa redução de perdas ($|E_m| < |E_n|$), o que resulta num aumento de tempo de processamento.

Os autores concluem através dos resultados apresentados que, embora as equações (2.2) e (2.3) não sejam exatas, os erros são pequenos o suficiente para justificar a aplicação do algoritmo, principalmente em operações em tempo real de sistemas de grande porte.

Shirmohammadi e Hong [54] apresentaram um método de reconfiguração de redes no qual buscam obter o fluxo ótimo de uma rede de distribuição. Fluxo ótimo de uma rede neste contexto é o fluxo de carga nos ramos desta rede que causará mínima perda resistiva em suas linhas.

Para estabelecer o fluxo ótimo da rede, este método inicia fechando todas as seccionadoras da rede, formando um sistema de distribuição malhado. Em seguida, os autores representam as chaves que foram fechadas como fontes de correntes ajustáveis que podem ser usadas para modificar o fluxo nos ramos. Como as redes de distribuição são operadas radialmente, as malhas são abertas, uma após a outra para manter a radialidade, de tal modo que o fluxo ótimo seja alterado pela mínima variação nas perdas. Elimina-se primeiro a malha que causar menor variação nas perdas de potência ativa, ou seja, abre-se primeiro a malha que possui o mais baixo valor de corrente no fluxo ótimo.

Uma limitação óbvia do método acima é que o fluxo ótimo é determinado para algumas malhas quando existe mais de uma malha na rede. Isto significa que os valores de tensão e potência a serem usados durante o processo de minimização são calculados no sistema malhado formado pelos chaveamentos propostos, o que não representa a real condição do ponto de operação do sistema. Por isso a chave a ser aberta será selecionada apropriadamente apenas no último passo da solução, quando restar apenas uma malha na rede e a parte restante for radial. Nos demais passos sempre existirá um número de malhas na rede que não corresponde à condição de radialidade da operação atual (implicando num valor de redução de perdas não

exato). Por esta razão a configuração dos alimentadores obtida através deste método pode não ser a ótima, mas somente estar próxima da ótima, representando um ótimo local.

O procedimento de solução para determinar o fluxo ótimo da rede malhada pode ser assim descrito:

- utilização de um fluxo de potência não-linear para determinar as injeções de corrente nos nós de carga;
- determinação das correntes nos ramos da rede resistiva e nas chaves normalmente abertas (fechadas para constituir o sistema malhado) a partir das correntes nodais.

Borozan *et al.* apresentam na referência [4] uma nova alternativa computacional à apresentada na metodologia anterior, a qual resulta na redução do tempo de obtenção da topologia com mínimas perdas resistivas do sistema.

Os autores, considerando que o tempo computacional necessário ao reordenamento dos ramos e obtenção da nova matriz de impedância de malha da rede é crucial na eficiência do método proposto, centram esforços nesses aspectos.

O ordenamento inicia a partir do nó raiz (nó fonte). Para cada ramo o nó mais próximo da fonte é considerado como nó inicial e o outro mais a jusante é considerado como nó final. Se o nó final de um ramo já ordenado é nó inicial de outro ramo, a este novo ramo a ser ordenado é atribuído um índice (nível hierárquico) maior que o ramo que o precede.

Para melhorar a eficiência do ordenamento, a numeração dos ramos de uma camada (mesmo nível hierárquico) inicia apenas após todos os ramos da camada anterior terem sido numerados.

O reordenamento ocorre na medida em que, após o chaveamento em uma malha, alguns ramos da malha irão mudar de orientação e camada (nível hierárquico). Este fato pode causar alterações também em outros ramos não pertencentes à malha chaveada, se existirem ramais laterais partindo dos nós pertencentes aos ramos que sofrem alterações na malha chaveada. A

idéia básica do reordenamento parcial consiste em considerar somente este conjunto de ramos que apresentam alteração de nível hierárquico após um chaveamento.

Por definição, durante a obtenção da matriz de impedância de malha Z_{loop} , os elementos da diagonal são as impedâncias das malhas e os elementos fora da diagonal são as impedâncias mútuas das malhas.

Se o ramo chaveado pertencia a mais de uma malha, os elementos da matriz Z_{loop} que necessitam ser recalculados após um chaveamento são:

- os elementos diagonais das malhas às quais pertencia o ramo aberto;
- os elementos não diagonais mútuos entre malhas do item acima;
- os elementos não diagonais mútuos entre malhas do primeiro item e malhas antigas (que não sofreram qualquer tipo de alteração).

Se o ramo chaveado pertencia apenas a uma malha, simplesmente omite-se a linha e coluna da malha correspondente da matriz Z_{loop} .

A partir dos resultados obtidos os autores concluem que, efetuando-se o reordenamento parcial dos ramos e recalculando-se apenas os elementos da matriz de impedâncias de malha que sofrem alteração após um chaveamento, foi obtida uma melhora na eficiência computacional em relação à metodologia apresentada em [54].

Baran e Wu na referência [1] fazem uso de dois diferentes métodos, com diferentes graus de precisão, para obter uma solução aproximada do fluxo de carga após uma transferência de carga.

Nos métodos aproximados de solução de fluxo de carga propostos, os fluxos de potência reativa estão explicitamente incluídos, podendo ser aplicados em alimentadores radiais de distribuição não compensados e em algoritmos que objetivam solucionar o problema de alocação de capacitores.

Para estabelecer a configuração ótima da rede, este método inicia formando arbitrariamente apenas uma malha na rede, tornando o sistema de distribuição malhado. Esta malha deverá ser aberta no ponto que causar a maior redução de perdas, mantendo-se a restrição operacional de radialidade do sistema.

Inicialmente o método irá verificar se há redução de perdas ao se abrir a malha no ramo adjacente ao ramo de intercâmbio (ramo que formou a malha), no lado de mais baixa tensão da malha.

Calcula-se, para este chaveamento, a possível redução resultante nas perdas de potência ativa com o auxílio da equação (2.4) abaixo:

$$\Delta LP_{bm} = 2P_m \left(\sum_{l \in L} r_l P_l - \sum_{l \in R} r_l P_l \right) + 2Q_m \left(\sum_{l \in L} r_l Q_l - \sum_{l \in R} r_l Q_l \right) - (P_m^2 + Q_m^2) \left[\sum_{l \in R \cup L} r_l \right] \quad (2.4)$$

Onde: ΔLP_{bm} é a variação nas perdas de potência ativa resultante da alteração do estado dos ramos b e m ;

b é o ramo que ao ser fechado forma a malha;

m é o ramo a ser aberto;

L é o lado da malha onde ocorrerá diminuição do fluxo de potência ativa;

R é o lado da malha onde ocorrerá aumento do fluxo de potência ativa;

P, Q são, respectivamente, as potências ativa e reativa no nó final de cada ramo;

r é a resistência do ramo.

Se para o ramo adjacente $\Delta LP_{bm} > 0$ (o que significa que há redução de perdas com o chaveamento nos ramos b e m), percorrem-se os ramos até o nó de início da malha calculando-se a redução nas perdas (função dos respectivos chaveamentos). Determina-se assim, o chaveamento que fornecerá a maior redução nas perdas de potência ativa.

Este procedimento é repetido com a configuração inicial para todas as malhas. Por fim a alteração a ser implementada será aquela que ocasionar a maior redução nas perdas dentre todas as máximas reduções de cada malha.

O uso da equação (2.4) apresenta um erro na estimativa da redução de perdas após um chaveamento na medida em que usa os dados do fluxo de carga antes do chaveamento. Entretanto, é importante destacar que este erro é conservativo [1].

Esta modificação de fechar uma malha de cada vez representa uma considerável melhora na determinação da configuração ótima da rede em comparação com a técnica desenvolvida em [54], visto que preserva as condições de operação (radialidade) durante todo o processo.

Goswami e Basu [27] apresentam um novo algoritmo de reconfiguração de alimentadores de distribuição para minimização de perdas. Como o método de Baran e Wu, este método também trabalha com uma malha de cada vez, para respeitar as condições de radialidade da operação dos sistemas de distribuição, durante a determinação do fluxo ótimo destes sistemas.

O algoritmo de reconfiguração de alimentadores inicia com a solução do fluxo de carga da rede radial. Uma chave seccionadora normalmente aberta é fechada para formar uma malha. A chave a ser fechada para formar uma malha será selecionada dependendo da tensão entre os terminais da chave ou arbitrariamente. Os autores desenvolveram três opções para determinar qual a configuração final ótima do sistema:

- i) fechar a chave normalmente aberta através da qual a tensão entre os seus terminais é máxima (esperando que este chaveamento ocasionará a maior redução nas perdas por causa da mais alta diferença de tensão em que passa a ser alimentada a carga transferida pelo chaveamento);
- ii) fechar a chave normalmente aberta através da qual a tensão entre os seus terminais é mínima (esperando que devido à mínima diferença de tensão, a solução modificada será obtida mais rapidamente);
- iii) selecionar a chave arbitrariamente, uma após a outra.

Em todos os casos o problema converge para a mesma solução. O critério usado para selecionar a chave resulta somente em diferentes caminhos para chegar à solução final. No artigo não é apresentado o tempo computacional requerido à obtenção da solução, considerando-se as três opções propostas.

O fluxo de potência de uma rede radial é uma das partes mais importantes dos algoritmos de reconfiguração de alimentadores. Estes autores adotaram um simples e flexível método de fluxo de carga, baseado na análise de malhas de circuito, com este propósito. O processo de solução deste fluxo é idêntico ao que foi utilizado na presente tese, diferindo apenas na determinação da convergência que é feita nesta tese com as tensões nas barras e não considerando-se somente o valor de perda resistiva da rede. Esta escolha do fluxo de carga é destacada por Goswami e Basu como uma importante contribuição ao aumento da eficiência da técnica de minimização de perdas.

Jasmon e Lee [32] apresentam uma modificação ao método proposto por Baran e Wu [1] que torna desnecessária a análise de todos os ramos do lado de mais baixa tensão de uma malha, os quais são candidatos ao chaveamento ótimo. O procedimento de busca da configuração ótima da rede e o fluxo de carga utilizados são aqueles propostos por Baran e Wu e consideram o chaveamento numa malha de cada vez, para preservar a radialidade do sistema durante todo o processo de busca.

Os autores levam em consideração que o fluxo de potência ativa é muito maior que o fluxo de potência reativa. Além disso, através da técnica de otimização utilizada, só dois ramos necessitam ser analisados na determinação do fluxo ótimo da malha. Estes ramos são aqueles cujos respectivos fluxos de potência ativa se situam imediatamente acima e abaixo do valor P_m^{\max} fornecido pela equação (2.5) abaixo, como se analisa a seguir.

$$P_m^{\max} = (\sum_{l \in L} r_l P_l - \sum_{l \in R} r_l P_l) / r_{loop} \quad (2.5)$$

Calcula-se a redução de perdas para o chaveamento nos dois ramos selecionados a partir da equação (2.5) e adota-se o chaveamento no ramo que ocasionar a maior redução de perdas.

Se o valor obtido pela aplicação da equação (2.5) não estiver situado entre os valores de fluxo de potência ativa de dois ramos do lado de mais baixa tensão da malha, verifica-se se há possibilidade de redução de perdas com o chaveamento no ramo adjacente (ramo nominal) ao ramo de intercâmbio (ramo que formou a malha). Se o valor fornecido pela equação (2.4) for

negativo (acrécimo nas perdas), então a malha está otimizada e nenhum novo chaveamento a ser implementado causará uma redução nas perdas resistivas do sistema.

O procedimento de otimização apresentado faz com que não se necessite mais analisar todos os ramos do lado de mais baixa tensão da malha na escolha de qual ramo virá a ser aberto, melhorando consideravelmente a eficiência da técnica *branch-exchange*. A formulação detalhada deste método é apresentada no capítulo 4.

Sarma e Rao [51] propõem um novo método, baseado em programação inteira 0-1, para minimização de perdas através da reconfiguração de alimentadores de sistemas de distribuição.

Seja a figura 2.2 a seguir. Ao se formar uma malha (como por exemplo fechando-se a chave do ramo L_8) o método permite que uma das cargas da extremidade do ramo normalmente aberto (nó 4 ou nó 7) seja transferida para o outro lado da malha, minimizando-se as perdas resistivas da malha.

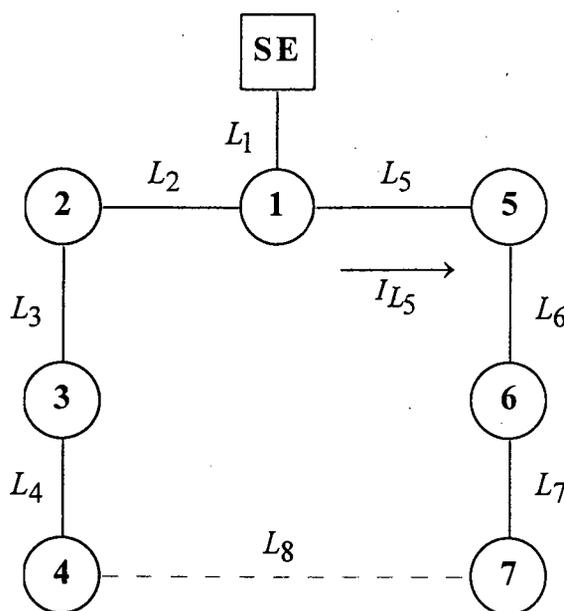


Figura 2.2 Alimentador de Distribuição com Chaveamento em L_8

A partir dessa suposição, definem-se como variáveis inteiras das malhas os ramos que possuem os nós das extremidades do ramo normalmente aberto. Para a malha do sistema da figura 2.2 as variáveis inteiras são os ramos L_4 e L_7 .

Se o procedimento de otimização indicar:

- a abertura do ramo L_4 , o nó de carga 4 é transferido para o outro lado da malha;
- a abertura do ramo L_7 , o nó de carga 7 é transferido para o outro lado da malha;
- a não abertura de nenhum dos ramos tidos como variáveis, a malha está otimizada.

Para a determinação da função objetivo ($\sum_{i=1}^{num.ramos} r_i I_{L_i}^2$), a ser otimizada através de programação matemática inteira, necessita-se determinar as correntes para cada ramo do sistema em função das variáveis inteiras 0-1, como descrito a seguir.

Considerando-se novamente o chaveamento em L_8 , quando se calcula a corrente no ramo L_5 na equação (2.6) o coeficiente de I_4 é $(1 - L_4)$ porque a corrente do nó 4 não contribui (no momento) para a corrente do ramo L_5 , pois o nó 4 está conectado ao lado da malha diferente ao que se está determinando a corrente.

Por sua vez, o coeficiente de I_7 é L_7 . Se a carga I_7 for transferida do lado da malha em que se encontra na figura 2.2 atribuindo-se à variável L_7 valor 0, esta parcela de carga não contribuirá mais para as correntes nos ramos do lado da malha em que inicialmente se encontrava, isto é, não contribuirá para o valor da corrente do ramo L_5 , fornecido pela equação 2.6, por exemplo. Assim, a determinação da corrente do ramo L_5 através das variáveis L_4 e L_7 seria:

$$I_{L_5} = I_5 + I_6 + L_7 I_7 + (1 - L_4) I_4 \quad (2.6)$$

Seguindo-se esse raciocínio determinam-se as correntes para todos os ramos do sistema e, por fim, a função objetivo. A função objetivo é então otimizada considerando-se a seguinte restrição, relacionada com os ramos adjacentes ao chaveamento no ramo L_8 :

$$L_4 + L_7 \geq 1 \quad (2.7)$$

A restrição acima representa o fato que ao menos uma das variáveis inteiras L_4 e L_7 permanece com seu valor igual a 1 (chave fechada), quando se transfere um nó de carga de um lado para o outro da malha da figura 2.2. O valor 0 é atribuído à variável (ramo) que inicialmente alimentava a carga transferida. Quando a malha está otimizada nenhuma transferência de carga é efetuada, nenhum dos ramos representados pelas variáveis inteiras mudam de estado em relação ao estado apresentado na figura 2.2, ou seja, $L_4 + L_7 = 2$.

Nesta referência os autores apresentam um procedimento para obtenção da função objetivo a partir de uma simples inspeção do grafo do sistema. Este procedimento pode ser observado em detalhes no capítulo 5, quando aplicado em sistemas de maior porte que apresentam a formação de um número maior de malhas.

Segundo os autores, formulando-se o problema de reconfiguração a mínimas perdas resistivas como um problema de programação inteira 0-1 (ao contrário da maioria dos métodos disponíveis na literatura que são baseados em heurísticas ou aproximações sucessivas considerando-se um chaveamento por vez) pode-se considerar múltiplos chaveamentos simultaneamente, obtendo-se um ótimo global para o problema de minimização das perdas elétricas totais do sistema de distribuição.

Pelo fato deste método garantir a otimalidade da solução em função de não considerar simplificações na obtenção da função objetivo (embora sem considerar o tempo necessário para tal), a aplicação do mesmo em conjunto com RNA para verificar a otimalidade da solução fornecida pelas RNA passa a ser de grande interesse. A aplicação em conjunto do método de programação matemática inteira e de RNA (quando a solução fornecida pelas RNA for próxima da ótima) deve conduzir a uma solução de maior qualidade obtida em tempo computacional aproximadamente equivalente ao obtido quando da aplicação das RNA isoladamente.

2.2.3 Incorporação de Incerteza na Demanda

Considerando-se hipoteticamente que a variabilidade da demanda possa ser representada por somente dois valores de demanda, uma rede com N nós de carga necessitaria de 2^N cálculos de reconfiguração determinísticos, para se obter as configurações ótimas da rede em nível de perdas resistivas para estas possíveis condições de cargas.

Assim, recentemente, com o trabalho apresentado na referência [41] por López *et al.*, ao contrário do apresentado nos trabalhos anteriores, passou-se a modelar probabilisticamente a demanda através da consideração da variabilidade desta demanda. Simulações Monte Carlo foram aplicadas para considerar o sorteio de n perfis de carga distintos, procurando-se evitar que o esforço computacional fosse aproximadamente n vezes o esforço computacional dos trabalhos que analisam uma configuração por vez.

Este trabalho apresenta como resultado o número de ocorrência de cada topologia ótima em função do grau de variabilidade considerado (desvio padrão adotado). Os valores das potências dos nós de carga foram adotados como valores de demanda máxima esperada (valores de pico), adotando-se dois níveis de desvio padrão (15% e 30%) sobre estes valores. O processo para determinar o número de sorteios necessários para se obter resultados satisfatórios é determinado empiricamente, observando-se como varia o comportamento do resultado (frequência de ocorrência de cada topologia) em função do número de sorteios realizados através de simulação Monte Carlo.

A partir dos resultados, os autores concluem que não necessariamente a topologia esperada (topologia com mínimas perdas correspondente à maioria dos perfis de carga analisados) produz a maior porcentagem de redução de perdas, podendo existir perfis de carga com menor probabilidade de ocorrência que através do processo de reconfiguração levem a um maior valor de redução de perdas. Entretanto, quanto maior a frequência de ocorrência da topologia esperada, maior será a redução nas perdas e a economia de energia elétrica ao longo do tempo.

Este tipo de análise não deixa de ser uma contribuição à reconfiguração de redes pois determina uma única topologia para operação do sistema, a qual ocasionará, levando-se em conta

a variação aleatória de carga de todo o dia, o menor montante médio diário de perdas para o sistema. Evita-se assim um grande número de chaveamentos e uma diminuição dos transitórios ocasionados por estes chaveamentos, o que resultaria num aumento da vida útil das chaves seccionadoras do sistema e num aumento da qualidade do fornecimento de energia ao consumidor.

2.2.4 Utilização de Técnicas Neurais no Problema de Redução de Perdas

Hsu *et al.* [30] propõem uma rede neural artificial (RNA) para uma análise quantitativa do nível de perdas em alimentadores de distribuição. A rede neural artificial proposta é do tipo *functional link network with sine layers* e usa-se o algoritmo *backpropagation* para ajustar as conexões (pesos) entre os elementos de processamento.

O tipo de rede neural escolhido justifica-se, segundo os autores, pelo fato de ser muito efetivo na área de aplicação de técnicas de regressão para estimar o comportamento de determinada função, como é o caso da função perdas resistivas desta aplicação.

As variáveis de entrada da rede neural são o carregamento dos alimentadores, o fator de potência, o comprimento dos alimentadores primários e secundários e a capacidade dos transformadores.

Um fluxo de carga trifásico é utilizado para quantificar as variáveis de entrada da rede neural, denominadas de 'fatores chaves'. Através da análise de sensibilidade destes 'fatores chaves' na determinação das perdas nos alimentadores do sistema, as simulações computacionais mostraram que as perdas são afetadas significativamente pelos seguintes fatores:

- carregamento: um aumento no carregamento ocasiona maior fluxo e conseqüentemente maiores perdas nas linhas e transformadores, podendo-se considerar que as perdas variam com o quadrado do carregamento.
- fator de potência: quanto maior o fator de potência, menor será a componente reativa do fluxo e menores são as perdas, as quais decrescem aproximadamente com o quadrado do fator de potência.

- comprimento: maiores comprimentos dos condutores primários e secundários correspondem a resistências de valores mais elevados. Assim, mantendo-se o mesmo carregamento e aumentando o comprimento, as perdas nas linhas crescerão. Por sua vez, as perdas nos transformadores decrescem levemente devido às maiores quedas de tensão. Deste modo é proposta uma representação onde as perdas são linearmente proporcionais ao comprimento do condutor primário.
- capacidade do transformador: se a capacidade aumenta, as perdas no ferro do transformador serão maiores e as perdas no cobre do transformador diminuirão, devido ao uso de uma bitola maior nos enrolamentos do transformador.

A RNA é utilizada pelos autores como uma caixa preta (quadripolo) equivalente ao modelo simplificado de perdas que considera os fatores chaves descritos acima.

A RNA obtida conseguiu estabelecer a complexa relação existente entre os fatores chaves fornecidos a sua camada de entrada e o montante de perdas nos alimentadores do sistema fornecido por sua camada de saída.

Comparando-se os resultados obtidos com os modelos de perdas derivados da técnica de regressão a partir de dados históricos, os autores concluem que o modelo proposto pode estimar as perdas nos alimentadores de uma maneira muito efetiva e fornece uma ferramenta para os engenheiros de distribuição melhorarem a eficiência da operação do sistema. Visto que o tempo de resposta da RNA treinada ser tão pequeno, o tempo necessário ao cálculo das perdas pode ser muito reduzido, com aplicações viáveis em operações de tempo real.

Kim *et al.* apresentam na referência [34], uma proposta de estratégia de reconfiguração de alimentadores do sistema de distribuição para reduzir a perda de potência ativa, usando redes neurais artificiais com habilidades de mapeamento entrada-saída.

Neste trabalho são designados dois grupos de redes neurais, com o objetivo de minimizar o tempo de treinamento da rede neural, simplificando-se a estrutura da rede neural artificial. É importante destacar que as simplificações adotadas neste trabalho possibilitaram sua aplicação no PC COMPAQ 386, utilizado pelos autores na época da realização do trabalho.

O primeiro grupo de redes neurais é usado para estimar o nível de carga, a partir de um banco de dados de carregamento de cada seção do sistema de distribuição, dividindo-se a carga em 4 níveis iguais a 40%, 60%, 85% e 100%, com base na demanda máxima do sistema.

Para este primeiro grupo de redes neurais, as variáveis de entrada são as potências ativas e reativas de cada seção da rede de distribuição. Estas redes neurais devem determinar, para cada seção, o nível de carga mais similar (dentre os quatros níveis adotados) de acordo com o patamar de carga atual de cada seção. A unidade de saída correspondente ao mais apropriado nível de carga da seção tem o valor 1, e os outros tem o valor 0, onde o valor de cada unidade está situado entre 0 e 1.

Através da experiência adquirida no tratamento do problema os autores determinam que a RNA tenha as seguintes características: 7 unidades na camada intermediária, 2 na camada de entrada (P e Q) e 4 na camada de saída (4 níveis de carga). Os valores de taxa de aprendizagem e momento são escolhidos, respectivamente, como 0,5 e 0,7 também em função da experiência com o treinamento.

O segundo grupo de redes neurais determina a topologia do sistema a partir dos níveis de carga obtidos com as redes neurais do primeiro grupo para cada seção. Este segundo grupo possui uma rede treinada para cada uma das possíveis topologias ótimas em nível de mínimas perdas resistivas.

As variáveis de entrada das redes neurais do segundo grupo são as saídas das redes neurais do primeiro grupo (níveis de carga) e fornecem como variável de saída os valores 0 ou 1, selecionando a correspondente topologia ótima do sistema em nível de perdas em função do atual perfil de carga. As redes neurais do segundo grupo possuem 13 neurônios na camada de entrada (13 seções de alimentadores), 18 neurônios na camada intermediária e 1 neurônio na camada de saída. Estas redes foram treinadas com taxa de aprendizagem e momento de 0,3 e 0,5, respectivamente, obtidas também através da experiência durante a fase de treinamento.

A carga de cada seção do sistema de distribuição é classificada como residencial, comercial ou industrial. Assim o sistema possui 4 possíveis cenários de padrão de carga

(40%,60%,85% e 100%) e 3 tipos de carga, obtendo-se com estas simplificações 64 padrões de carga (4^3) para o sistema. Os autores afirmam que sem essas simplificações seria impossível tratar o problema com os recursos disponíveis. Deve-se notar que este número de padrões de carga não é dependente do tamanho do sistema considerando-se as duas simplificações adotadas (tipos e padrões de carga).

Através do procedimento acima foram obtidas 7 diferentes topologias para os 64 diferentes padrões de carga. Por esta razão 7 redes neurais artificiais (uma para representar as características de cada topologia) foram utilizadas para determinar a topologia ótima em nível de perdas do sistema.

Neste trabalho, os autores concluem que a estratégia de reconfiguração de alimentadores usando redes neurais artificiais possui a capacidade e robustez necessária ao controle de redes elétricas com grande velocidade. Por esta razão é esperado aplicar este método no problema de reconfiguração de redes de distribuição em tempo real, para a minimização de perdas.

Observa-se contudo, nesta referência, que a eficiência da aplicação foi calculada utilizando-se 40 testes com diferentes níveis de carga para o sistema, sendo que 20 desses cenários de carga já foram utilizados durante a etapa de treinamento da rede neural, levando a resultados superestimados.

Gauche e Coelho apresentam na referência [23] uma proposta alternativa de reconfiguração de alimentadores a mínimas perdas resistivas utilizando-se redes neurais artificiais.

Como apresentado no trabalho anterior, passa-se a modelar probabilisticamente a demanda, através da consideração da variabilidade da carga em cada barra do sistema.

Nesta aplicação, contudo, não se utiliza a simplificação de adotar somente determinados valores de níveis de carga para cada seção do sistema de distribuição. Simulações Monte Carlo são adotadas para considerar o sorteio de n perfis de carga distintos, a partir da variação da

demanda em cada nó de carga (representação muito mais precisa da variabilidade na demanda do que a obtida com a definição de níveis de carga da referência anterior [34]).

Este trabalho utiliza somente uma rede neural, treinada para fornecer o status de todas as chaves seccionadoras do sistema (topologia). Embora esta estratégia necessite maior esforço computacional do que a anterior, fornece uma importante melhora na medida em que RNA de um único tipo fornecem a resposta desejada. Desta maneira não há a necessidade de transferência e análise das informações fornecidas pelas RNA de diferentes níveis hierárquicos da estratégia anterior, ganhando-se em eficiência no caso de sua possível aplicação *on-line*.

Este mesmo trabalho propõe, quando existem mais de duas topologias ótimas para o sistema, que uma RNA seja treinada para cada topologia ótima, a qual irá representar a relação existente entre os perfis de carga e a topologia ótima para a qual foi treinada, como pode ser observado em detalhes no capítulo 6. Procedendo-se desta maneira, obtém-se RNA de menor porte simplificando-se consideravelmente a etapa de treinamento.

Por fim, Gauche *et al.* [22] propõem a utilização do método de programação matemática inteira descrito na seção 2.2.2 para verificar a otimalidade da solução fornecida pelas RNA para cada um dos novos perfis de carga que venham a ocorrer no sistema.

Nesta tese, a aplicação híbrida do método de programação matemática inteira e redes neurais fica condicionada ao nível de acertos das RNA treinadas frente ao conjunto teste ou quando houver dúvida quanto à qualidade do conjunto de treinamento. O operador poderá também, se preferir, comparar a resposta fornecida pelo método híbrido (programação matemática inteira em conjunto com RNA) com a resposta fornecida somente pelas RNA, quando estas efetivamente são utilizadas isoladamente no gerenciamento do sistema.

2.2.5 Utilização de Computação Evolucionária para a Solução do Problema

Em 1970 Klockgether e Schwefel apresentam em [35] a aplicação pioneira de estratégias evolucionárias ao problema de otimização aerodinâmica de bicos de aviões. Este trabalho surge como resultado dos estudos em conjunto de Rechenberg e Schwefel no túnel de vento da Universidade Técnica de Berlim. Estes detalhes foram contados pelo falecido professor Helmut

Theodore Schreyer, do Instituto Militar de Engenharia, no regresso de uma viagem à Alemanha [2]. Posteriormente surgem inúmeros trabalhos que utilizam computação evolucionária em problemas de otimização, como é o caso do trabalho apresentado a seguir, relacionado à reconfiguração de sistemas de distribuição, com o objetivo de minimização de perdas resistivas.

Na referência [43] Nara *et al.* propõem o uso de algoritmos genéticos para a solução do problema de reconfiguração a mínimas perdas de sistemas de distribuição com o objetivo de se obter uma solução mais próxima ao ótimo global.

No algoritmo proposto os indivíduos (*strings*) são constituídos pelos estados das chaves seccionadoras. Por sua vez, a função de adaptação (*fitness*) consiste das perdas totais do sistema e de termos que penalizem violações de nível de tensão e capacidade de corrente.

O algoritmo descarta indivíduos originários do cruzamento (*crossover*) que representem sistemas malhados ou cargas sem suprimento de energia. Segundo os autores, pode-se observar pelos resultados apresentados que, uma solução próxima da solução ótima é obtida com redução de perdas superiores a 10%.

Fundamentalmente pode-se observar que os autores preocuparam-se e conseguiram obter uma solução equivalente à obtida utilizando-se recozimento simulado (*simulated annealing*) em menor tempo computacional.

O ponto negativo é que o tempo computacional é da ordem de horas usando-se algoritmos genéticos, ao contrário do tempo de 10 a 40s de processamento utilizando-se algoritmos do tipo *branch-exchange* para o sistema de larga escala considerado. Ressalve-se, contudo, o fato da solução obtida com algoritmos genéticos ser de melhor qualidade do que a solução obtida via *branch-exchange*.

Pinheiro e Vasconcelos propõem em [46] o acoplamento entre um fluxo de potência ótimo multi-objetivo e algoritmos genéticos.

A função objetivo a ser minimizada é constituída por um termo que representa a variação em torno do perfil de tensão desejado e outro que representa as perdas de potência ativa do sistema. Estes termos da função objetivo são multiplicados por parâmetros de ponderação utilizados para enfatizar o perfil de tensão ou as perdas resistivas totais do sistema.

Os autores concluem neste trabalho que a incorporação de algoritmos genéticos aumentaram as chances de se obter um ponto de ótimo global para a função objetivo a ser minimizada, fato este que pode ser observado nos resultados apresentados. Entretanto, a metodologia proposta por Pinheiro e Vasconcelos, em função do tempo de processamento envolvido (8s para a análise de cada indivíduo por geração), também não deve ser recomendada em se tratando de aplicações em tempo real.

2.2.6 Utilização de Conjuntos Difusos na Reconfiguração de Sistemas de Distribuição

Em 1997 Pereira e Murari [45] propõem a utilização de conjuntos nebulosos para a estimação de estado em sistemas de distribuição de energia elétrica aliado a um algoritmo heurístico para a reconfiguração do sistema na presença de uma contingência.

O algoritmo heurístico de reconfiguração considera as variáveis tensão, carregamento e custo de manobra como conjuntos difusos e incorpora a experiência dos operadores face às incertezas associadas ao tratamento destas variáveis de estado. Decisões do tipo: “*opere a chave a se a carga na barra b for leve*”, “*a operação da chave x é mais cara do que a operação da chave y* ” ou “*a carga da barra k está muito pesada para ser transferida para o alimentador z* ” são incorporadas ao algoritmo de reconfiguração.

Os autores concluem que a metodologia proposta permite tratar o nível de redundância dos diferentes pontos de monitoramento dos sistemas de distribuição reduzindo o esforço computacional para a obtenção da solução, possibilitando a aplicação da metodologia em tempo real.

Kagan e de Oliveira propõem em [33] a utilização de conjuntos difusos com a técnica de busca em árvore para a modelagem de problemas de decisão multi-objetivos com restrições. Neste trabalho apresenta-se a aplicação da metodologia à restauração de sistemas de distribuição

na presença de contingência, entretanto, os autores afirmam que através de alteração na modelagem do problema pode-se estender o modelo para a análise da reconfiguração considerando-se a minimização de perdas.

Em 1999 Lin *et al.* [40] desenvolvem um algoritmo heurístico tipo *branch-exchange* para redução de perdas resistivas nos alimentadores de sistemas de distribuição baseado em conjuntos difusos. A queda de tensão nos terminais da chave seccionadora, a corrente a ser transferida em função de um chaveamento e a razão entre a maior e a menor quantidade de perdas de um par de ramos candidatos ao chaveamento são consideradas na metodologia proposta como variáveis difusas.

Através dos testes realizados os autores constatam que os resultados obtidos são equivalentes aos resultados apresentados pela metodologia proposta por Goswami e Basu [27]. Ainda, como conclusão dos diversos sistemas reais de distribuição analisados, os autores citam que o algoritmo proposto baseado em lógica difusa considera um limitado número de soluções viáveis sendo computacionalmente eficiente e robusto.

2.3 Conclusão

Neste capítulo pode-se constatar a importância do esforço computacional no cálculo da redução de perdas elétricas de sistemas de distribuição, quando os estados das chaves seccionadoras são modificados, em busca de uma configuração próxima da configuração ótima do sistema em nível de perdas.

Neste sentido são propostos na literatura vários métodos simplificados de fluxo de carga (até mesmo a não execução do algoritmo de fluxo de carga após cada chaveamento) e diferentes procedimentos na busca da solução ótima (*branch-exchange* e heurísticas). Também destaca-se a importância da determinação do novo ponto de operação após cada chaveamento, mantendo-se sempre a radialidade do sistema.

Métodos como programação matemática inteira 0-1 e algoritmos genéticos são alternativas propostas para obter uma solução de melhor qualidade. Estas soluções, em função do

esforço computacional envolvido ao serem aplicadas em sistemas de grande porte, se adequam mais ao planejamento da operação (*off-line*) de sistemas de distribuição.

Baseando-se nos aspectos acima, é viabilizada a proposta deste trabalho de desenvolver um algoritmo que combina a eficiente técnica *branch-exchange* (especificamente o algoritmo desenvolvido por Baran e Wu [1] melhorado com a otimização apresentada por Jasmon e Lee [32]) com o método de solução que utiliza programação matemática inteira 0-1.

Com o objetivo de se evitar o tempo gasto com a execução do algoritmo *branch-exchange* utilizam-se RNA (treinadas com os dados fornecidos por este algoritmo), valendo-se do fato de que RNA *multilayer perceptrons* treinadas fornecem resposta em tempo desprezível, para viabilizar a aplicação em tempo real do algoritmo de reconfiguração de perdas. A solução fornecida pelas RNA pode então ser utilizada como ponto de partida do método de programação matemática inteira.

Deve-se observar que quando a resposta fornecida pelas RNA não for a ótima, esta resposta se encontra próxima da ótima, fazendo com que, se necessário, o algoritmo de programação matemática necessite somente de poucas iterações para garantir a otimalidade.

No capítulo 3, a seguir, é apresentada a formulação do algoritmo *backpropagation* de treinamento de redes neurais e do algoritmo *class-mean-separation* de seleção de características do conjunto de dados de entrada.

No capítulo 4 é apresentada a formulação do algoritmo *branch-exchange*, adotado neste trabalho para minimização de perdas através da reconfiguração do sistema de distribuição. Este algoritmo fornece para cada um dos perfis de carga obtidos através de sorteio de Monte Carlo, a configuração ótima ou quase ótima do sistema em nível de perdas elétricas resistivas, os quais (perfis de carga e topologias correspondentes) constituirão o conjunto de treinamento das RNA.

No capítulo 5 é apresentado detalhadamente o algoritmo de programação matemática inteira 0-1 proposto por Sarma e Rao na referência [51].

Capítulo 3 - Redes Neurais Artificiais

3.1 Introdução

Neste capítulo serão abordados conceitos fundamentais de redes neurais artificiais (RNA), a formulação detalhada do algoritmo *backpropagation* utilizado no treinamento de redes neurais tipo *multilayer perceptrons* (MLP) e algumas considerações sobre a definição do número de neurônios das diferentes camadas de redes MLP. Esta topologia de rede neural treinada com o algoritmo de treinamento *backpropagation* foi utilizada, na metodologia proposta nesta tese, para a reconfiguração de sistemas de distribuição com mínimas perdas resistivas.

Na grande maioria das aplicações (como também na reconfiguração de sistemas de distribuição para minimização de perdas [22,34]) a arquitetura de uma RNA consiste basicamente de três camadas de neurônios: uma camada de neurônios de entrada, uma camada de neurônios de saída e uma camada intermediária (denominada de camada escondida ou *hidden*) [55]. A camada intermediária pode ser substituída por mais de uma camada, eventualmente, em aplicações onde não se deseje um grande número de neurônios numa única camada intermediária.

Cada camada é composta por unidades de processamento (neurônios) constituídas por uma função, denominada função de ativação, que relaciona o valor de entrada do neurônio a um valor de saída do mesmo neurônio. A capacidade de processamento de cada unidade considerada em conjunto com as capacidades de processamento dos demais neurônios constituem a capacidade de processamento distribuído total da RNA.

Os diferentes modelos de RNA são definidos pela maneira como as camadas de neurônios estão conectadas (conexão) e pelas características dos próprios neurônios (diferentes funções de ativação). Por exemplo: nas redes neurais do tipo *feed-forward* as camadas de neurônios da RNA recebem entradas (conexões) apenas da camada de neurônios anterior, estando cada neurônio conectado com todos os neurônios da camada imediatamente anterior através de conexões sinápticas denominadas pesos. Já nas redes do tipo “Redes Neurais

Recorrentes” os neurônios de uma mesma camada também conectam-se entre si e realimentam-se, visto que a saída atual (estado atual) é a entrada para a obtenção do próximo estado da rede.

Os pesos da RNA são ajustados durante a etapa de aprendizagem (etapa de treinamento), a qual é uma das etapas mais importantes para sua aplicação na solução de problemas.

A etapa de treinamento pode conduzir às propriedades de [48,55]:

- memorização do conjunto de dados utilizado no treinamento (memorização da função). Esta propriedade garante que quando a rede neural artificial treinada é apresentada a uma entrada do conjunto de treinamento, a rede neural fornecerá resposta exatamente igual à obtida no treinamento. A resposta a outros dados diferentes dos contidos no conjunto de treinamento não é considerada no paradigma;
- generalização do conjunto de dados utilizado no treinamento, objetivando obter respostas similares às respostas fornecidas pelo sistema para um conjunto de entradas não utilizado durante o treinamento (como por exemplo na determinação da topologia ótima do sistema em nível de perdas elétricas).

Quanto à memorização, o principal problema consiste na definição do número de neurônios necessários a uma correta representação da função. O sistema físico deve fornecer a comparação para atestar a qualidade da resposta obtida a partir da RNA treinada.

Em se tratando da generalização, os principais aspectos a serem abordados referem-se à qualidade da resposta da RNA para padrões não utilizados no treinamento e à otimalidade desta resposta.

O fluxo de informação para o processamento do vetor de entrada numa RNA treinada é uni-direcional (da camada de entrada para a camada de saída). Os neurônios de uma camada fornecem informação (entrada) para os neurônios da camada seguinte de acordo com a saída da sua função de ativação.

Durante a etapa de treinamento, o fluxo de informações pode ser efetuado em duas direções:

- *forward* para determinar a saída atual,
- *backward* para propagar o erro em relação à saída desejada, atualizando os pesos.

Quando durante a fase de treinamento, a entrada e a resposta desejada a esta entrada são fornecidas à rede, diz-se que o treinamento é do tipo supervisionado. Por sua vez, quando a saída desejada não é fornecida durante o treinamento, diz-se que o treinamento é não supervisionado. Neste caso a classificação (organização) dos exemplos, que constituem o conjunto de treinamento, é feita de acordo com alguma propriedade estatística dos dados de entrada do treinamento.

Concluída a etapa de treinamento, diz-se que a rede encontra-se treinada e pode, a partir de então, ser utilizada na solução do problema para a qual foi treinada.

Na seção seguinte é apresentada a formulação do algoritmo *backpropagation* (nome devido à característica do algoritmo de retropropagação dos erros visando sua diminuição na próxima iteração) de treinamento de redes neurais, o qual se tornou amplamente conhecido pela comunidade científica após a publicação do trabalho de Rumelhart *et al.* em 1986 [49].

3.2 Formulação do Algoritmo de Treinamento *Backpropagation*

O algoritmo de treinamento de uma rede neural tem por objetivo atualizar os valores dos pesos entre os neurônios durante a aprendizagem das características do conjunto de dados (exemplos) considerado. Para tanto, utilizam-se diferentes técnicas de otimização com o objetivo de diminuir o erro das saídas da RNA (função do conjunto de pesos) em relação ao conjunto de entradas considerado.

O conjunto de pesos representará, após a convergência da etapa de treinamento, as características do conjunto de exemplos utilizado no treinamento, ou seja, as características do sistema.

Se o treinamento objetivar obter uma RNA capaz de “generalizar”, esta RNA adequadamente treinada deverá fornecer resposta equivalente à resposta do sistema real para um conjunto de entradas não utilizado durante o treinamento.

Durante a etapa de treinamento da rede neural, necessita-se obter a resposta de rede para cada entrada que está sendo usada para treinar a rede neural. Em função desta necessidade e do fato da rede ser do tipo *feed-forward* (informação propagada ‘para frente’, da camada de entrada para a camada de saída), necessita-se determinar a saída de cada neurônio desde a camada de entrada até a camada de saída, conforme será visto na seção a seguir.

3.2.1 Resposta dos Neurônios das Diferentes Camadas

Um neurônio j qualquer da camada de entrada da rede neural fornece como resposta o valor de saída da sua função de ativação (função de transferência do neurônio) s_j em função do valor do componente do vetor de entrada.

$$s_j = f(e_j) \quad (3.1)$$

Onde: e_j = e-jésimo componente do vetor de entrada;

s_j = saída do neurônio j .

É importante adiantar que a diminuição do erro (diferença entre a saída atual da última camada e a saída desejada) da etapa de treinamento pode ser acelerada com a utilização de uma escolha adequada da função de ativação e da informação fornecida pela sua derivada (como será visto na seção 3.2.2). Por este motivo, necessita-se usar uma função de ativação diferente da função degrau para garantir a continuidade e diferenciabilidade da função de transferência do neurônio. Usando-se a função degrau, a função composta produzida pela rede de neurônios interconectada seria descontínua e por essa razão a função do erro também o seria.

Uma das mais populares funções de ativação é a função sigmóide $f(x) = \frac{1}{1 + e^{-cx}}$ que mapeia $\mathfrak{R} \rightarrow (0,1)$. A constante c pode ser selecionada arbitrariamente e a forma da função sigmóide muda de acordo com o valor de c escolhido. Altos valores de c conduzem à forma da função sigmóide mais próxima da função degrau. No limite, quando $c \rightarrow \infty$ a função sigmóide tende para a função degrau na origem. A função sigmóide apresenta uma região de saída aproximadamente igual a 1 para x maior que 5 e uma região de saída aproximadamente igual a 0 para x menor que -5; estas regiões são denominadas ‘regiões de saturação’. Outras funções de

ativação, como a tangente hiperbólica, recomendadas na literatura [48,55], ainda não foram avaliadas em algoritmos de reconfiguração para minimização de perdas.

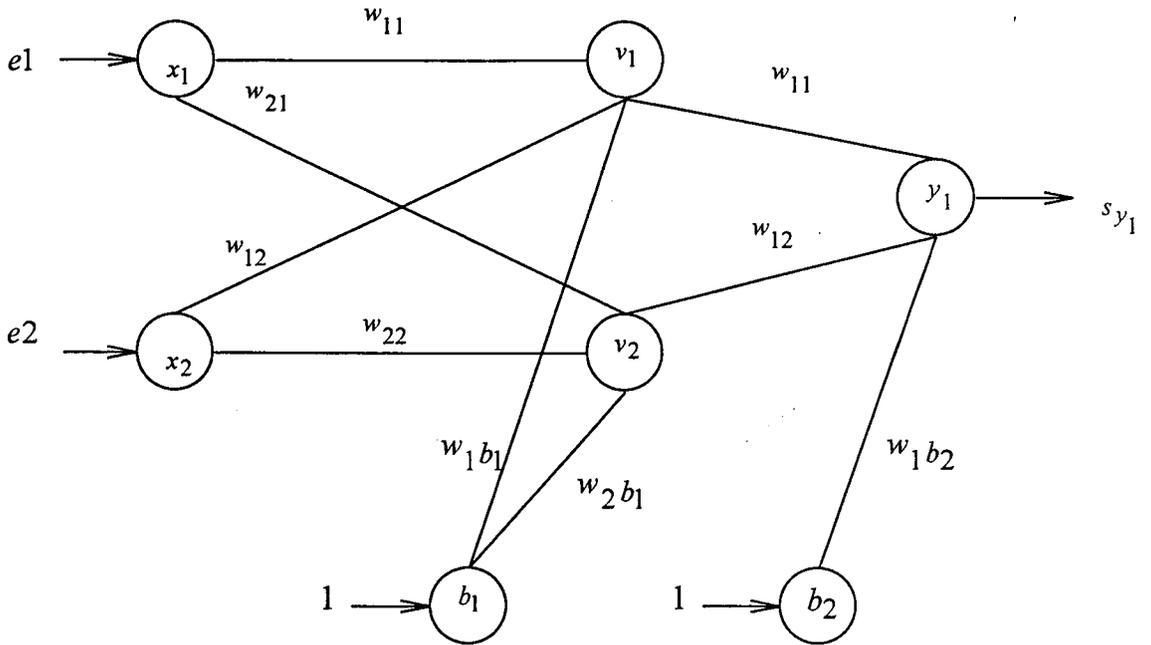


Figura 3.1 Arquitetura de uma Rede Neural MLP Contendo duas Unidades de Entradas, duas Unidades Escondidas, uma Unidade de Saída e duas Unidades Bias.

Uma vantagem da função sigmóide é que sua derivada pode ser representada através de uma expressão da própria função sigmóide, ou seja, a partir do valor da função sigmóide previamente calculado pode-se facilmente obter a sua derivada a ser usada posteriormente, de acordo com a equação (3.2). Na obtenção desta equação considerou-se $c = 1$ na função sigmóide.

$$f' = f(1 - f) \tag{3.2}$$

Para os neurônios da camada de entrada (x_1, x_2), da rede neural da figura 3.1, têm-se as seguintes saídas em função dos valores de entrada (e_1, e_2):

$$s_{x_1} = f(e_1) = \frac{1}{1 + e^{-e_1}}$$

$$s_{x2} = f(e2) = \frac{1}{1 + e^{-e2}}$$

Já para o caso da camada intermediária l , a função de ativação de um neurônio j qualquer fornece como resposta a saída s_j em função do somatório ($soma_j$) das saídas dos neurônios da camada anterior multiplicado pelos respectivos pesos.

$$s_j = f(soma_j) = \frac{1}{1 + e^{-soma_j}} \quad (3.3)$$

$$soma_j = \sum_{k=1}^K w_{jk} \cdot s_k \quad (3.4)$$

Onde:

w_{jk} = peso entre o neurônio j da camada l e o neurônio k da camada $l-1$;

$soma_j$ = somatório das entradas do neurônio j da camada l ;

s_k = saída do neurônio k da camada $l-1$;

K = número de neurônios da camada $l-1$.

A incorporação dos neurônios “bias” b_1, b_2 permitem maior diversidade na habilidade da rede neural aprender [18,48,55], na medida em que desloca o valor de entrada da função de ativação para sua região linear. Nas aplicações da metodologia proposta nesta tese para redução de perdas resistivas, apresentadas no capítulo 6, foram também utilizados neurônios bias durante o processo de treinamento das RNA.

Assim, para o exemplo da rede neural da figura 3.1 tem-se que as saídas dos neurônios da camada intermediária são compostas por:

$$s_{v1} = f[w_{11} \cdot f(e1) + w_{12} \cdot f(e2) + w_{1b1} \cdot f(1)] = f[w_{11} \cdot s_{x1} + w_{12} \cdot s_{x2} + w_{1b1} \cdot s_{b1}]$$

$$s_{v2} = f[w_{21} \cdot f(e1) + w_{22} \cdot f(e2) + w_{2b1} \cdot f(1)] = f[w_{21} \cdot s_{x1} + w_{22} \cdot s_{x2} + w_{2b1} \cdot s_{b1}]$$

Por último, os neurônios da camada de saída fornecem como resposta s_j em função do somatório $soma_j$ da camada anterior.

$$s_j = f(soma_j) \quad (3.5)$$

Onde: s_j = saída atual do neurônio j da camada de saída.

Assim, o neurônio da camada de saída da RNA da figura 3.1 terá como valor de saída de sua função de ativação:

$$s_{y1} = f[w_{11} \cdot s_{v1} + w_{12} \cdot s_{v2} + w_{1b2} \cdot s_{b2}]$$

3.2.2 Cálculo dos Erros nas Camadas

No caso da não obtenção de uma resposta dentro da tolerância especificada, calculam-se os erros das respostas dos neurônios de cada camada com o objetivo de ajustar os pesos, visando se aproximar da resposta desejada na próxima iteração.

Inicia-se o processo a partir da camada de saída, onde o erro δ_j no neurônio j é a diferença entre a saída desejada t_j e a saída atual do neurônio j , utilizando-se também a informação fornecida pela derivada da função sigmóide.

$$\delta_j = (t_j - s_j) \cdot f'(soma_j) \quad (3.6)$$

Onde: t_j = saída desejada do neurônio j da camada de saída.

A derivada da função sigmóide na equação (3.6) acima é utilizada com o objetivo de acelerar a convergência. Quanto menor o valor da derivada mais próximo se está da solução desejada.

Para as camadas intermediárias o erro δ_j , função dos erros da camada posterior, obtido via *backpropagation*, é:

$$\delta_j = \left[\sum_k \delta_k \cdot w_{kj} \right] \cdot f'(soma_j) \quad (3.7)$$

Também neste caso o objetivo da utilização da derivada da função sigmóide é acelerar a convergência. Como se pode ver na seção seguinte, o ajuste nos pesos depende de δ_j que, por sua vez, depende de $f'(soma_j)$. Assim, quanto mais longe da solução desejada, ou seja, quanto maior o valor de $f'(soma_j)$, maior será o ajuste nos pesos.

3.2.3 Cálculo dos Ajustes dos Pesos

Após terem sido calculados os erros em cada neurônio para todas as camadas, procede-se ao ajuste das conexões (pesos) entre os neurônios, que serão utilizadas na iteração seguinte. Pode-se dizer que esta é a ação denominada de ‘aprendizagem’ da rede neural, a qual finaliza com a rede treinada.

Este ajuste é calculado com o auxílio da equação (3.8) abaixo.

$$\Delta w_{jk}(l) = \eta \cdot \delta_j(l) \cdot s_j(l) \cdot [1 - s_j(l)] \cdot s_k(l-1) \quad (3.8)$$

Onde: η representa a taxa de aprendizagem da etapa de treinamento.

Esta equação fornece a variação (ajuste) dos pesos, que é proporcional à taxa de aprendizagem, erro e saída do neurônio j e saída do neurônio k . É importante observar que o ajuste é diretamente proporcional à parcela $s_j(l)[1 - s_j(l)]$ da equação 3.8, que representa o valor da derivada da função sigmóide para o neurônio j da camada l (gradiente do processo de otimização).

Normalmente se está interessado em acelerar o processo de convergência na busca do mínimo da função erro, o que pode ser feito aumentando-se a taxa de aprendizagem até um valor

máximo que ainda garanta a convergência. A introdução do parâmetro ‘momento’ permite a atenuação das oscilações no processo iterativo de busca do valor mínimo da função erro, fato que acelera a convergência.

3.2.4 Incorporação do Momento e Cálculo dos Novos Pesos

Quando o mínimo da função erro, para dada tarefa de aprendizagem, reside em um ‘vale’, seguir a direção do gradiente pode levar a amplas oscilações no processo de busca. Neste caso a melhor solução é orientar a busca em direção ao centro do vale. Entretanto, como o gradiente não aponta nesta direção, uma solução é introduzir o termo ‘momento’. Desta maneira, ao se computar para cada novo conjunto de pesos o gradiente da função erro, ao invés de se seguir a direção negativa do gradiente segue-se uma ‘média ponderada’ do gradiente atual e do gradiente anterior.

Assim, com o objetivo de se evitar grandes oscilações do algoritmo de treinamento na busca do mínimo da função erro, incorpora-se o parâmetro momento α à variação de pesos calculada na equação (3.8) acima.

Desta maneira, a variação de pesos da equação (3.8) Δw_{jk}^n passa a levar em consideração o ajuste nos pesos da iteração anterior Δw_{jk}^{n-1} e o parâmetro momento α :

$$\Delta w_{jk}^n(l) = \eta \cdot \delta_j(l) \cdot s_j(l) \cdot [1 - s_j(l)] \cdot s_k(l-1) - \alpha \cdot \Delta w_{jk}^{n-1}(l) \quad (3.9)$$

Assim, os novos pesos w_{jk} da próxima iteração (iteração n) passam a ser corrigidos através de:

$$w_{jk}^n = w_{jk}^{n-1} + \Delta w_{jk}^n \quad (3.10)$$

3.2.5 Convergência da Etapa de Treinamento

O ajuste dos parâmetros taxa de aprendizagem e momento para obter a melhor convergência possível é normalmente feito através do processo de ‘tentativa e erro’ (como pode ser visto nas aplicações do capítulo 6), podendo contar também com o auxílio de algoritmos de busca do tipo algoritmos genéticos [26,47,55].

Diz-se que a etapa de treinamento convergiu quando o conjunto de pesos atual da RNA fornece respostas dentro da tolerância desejada para o conjunto de todas (ou quase todas) as entradas utilizadas durante a etapa de treinamento.

Uma justificativa para se aceitar a convergência sem se obter a resposta esperada para a totalidade do conjunto de entrada reside no fato de algumas dessas entradas situarem-se na região de intersecção (zona 'confusa') de diferentes classes, podendo ser difícil uma perfeita separação das classes sem se incorrer numa memorização demasiada do conjunto de entrada. Este fato pode ocorrer quando não se adota um eficiente pré-processamento dos dados.

A rede neural MLP treinada deve fornecer respostas adequadas, não somente para o conjunto de entradas utilizada na sua etapa de treinamento, mas também para um entrada qualquer em tempo desprezível, isto é, possuir a capacidade de generalização referida na introdução deste capítulo.

3.3 Definição do Número de Neurônios de Cada Camada

Uma das etapas principais na aplicação de RNA consiste na determinação do tamanho da topologia (número de neurônios nas camadas), o qual fortemente condiciona a qualidade do treinamento. Assim, apresenta-se a seguir algumas considerações referentes à definição do número de neurônios para as camadas de entrada, intermediária e de saída.

3.3.1 Camada de Entrada

A princípio o número de neurônios da camada de entrada é igual ao número de variáveis consideradas na resolução do problema físico. No caso deste trabalho, o número de neurônios da camada de entrada é a princípio igual ao número de barras de carga da rede primária de distribuição.

Como na presente aplicação este número de barras de carga é normalmente grande, pode-se valer de algoritmos de seleção de características encontrados na literatura (como *class-mean-separation* e Karhunen-Loève) para reduzir a dimensão do vetor de entrada e conseqüentemente simplificar o processo de treinamento. Estes algoritmos de seleção de características são

aplicáveis a RNA do tipo MLP, embora sua aplicação a este tipo de rede não seja fortemente recomendável. A aplicação destes algoritmos seria fortemente recomendada em se tratando de redes não-supervisionadas do tipo das redes de Kohonen [55].

No capítulo 6 encontra-se referência à aplicação do algoritmo *class-mean-separation* na solução do problema de reconfiguração a mínimas perdas elétricas. A explicação de sua filosofia e seu equacionamento apresentam-se a seguir.

3.3.1.1 Método *Class-Mean-Separation* de Seleção de Características

Este método se baseia na distância entre as classes que se deseja separar. Considerando-se que as classes são constituídas de vetores de ordem n , o índice F_i fornece uma medida da importância da variável x_i na separação das classes 1 e 2. Não necessariamente as classes 1 e 2 são classes vizinhas, podendo F_i no caso de mais de duas classes representar a separabilidade de uma das classes em relação às restantes.

$$F_i = \frac{|m_i(1) - m_i(2)|}{|V_i(1) - V_i(2)|} \quad 1 \leq i \leq n \quad (3.11)$$

Onde:

$$m_i(1) = \frac{1}{M_1} \sum_{j=1}^{M_1} x_{i,j}(1) \quad \text{é a média da componente } i \text{ da classe 1;}$$

$$m_i(2) = \frac{1}{M_2} \sum_{j=1}^{M_2} x_{i,j}(2) \quad \text{é a média da componente } i \text{ da classe 2;}$$

$$V_i(1) = \frac{1}{M_1} \sum_{j=1}^{M_1} [x_{i,j}(1) - m_i(1)]^2 \quad \text{é a variância da componente } i \text{ da classe 1;}$$

$$V_i(2) = \frac{1}{M_2} \sum_{j=1}^{M_2} [x_{i,j}(2) - m_i(2)]^2 \quad \text{é a variância da componente } i \text{ da classe 2;}$$

M_1 é o número de elementos da classe 1;

M_2 é o número de elementos da classe 2.

As variáveis são então classificadas em ordem decrescente do valor associado à variável fornecido pela equação (3.11), compondo uma lista. As variáveis do topo da lista, que portanto

receberam o maior índice de importância, são selecionadas e utilizadas. O número de variáveis é acrescido se o número anterior não possibilita fornecer solução adequada ao problema.

As variáveis do fim da lista podem ser selecionadas se estas variáveis possuírem baixo coeficiente de correlação com as variáveis selecionadas do topo da lista, indicando que têm características diferentes e não contempladas pelas variáveis do topo da lista. O coeficiente de correlação é obtido com o auxílio da equação (3.12) abaixo.

$$CC_{i,j} = \frac{E\{x_i x_j\} - E\{x_i\}E\{x_j\}}{V_i V_j} \quad (i \neq j / i, j = 1, 2, \dots, n) \quad (3.12)$$

$$\text{Onde: } E\{x_i x_j\} = \frac{1}{M_1 + M_2} \sum_{k=1}^{M_1 + M_2} x_{k,i} x_{k,j}$$

A seleção do número de variáveis adequadas à solução do problema de reconfiguração para redução de perdas é o resultado da solução de compromisso entre a qualidade da classificação e o custo do processo de classificação (esforço computacional), o qual é fortemente influenciado pelo problema físico que se pretende resolver. Quanto maior o número de barras de carga e maior a quantidade de perfis de carga necessários para representar a variabilidade da demanda do sistema, tanto maior o esforço computacional para seleção das variáveis de entrada.

3.3.2 Camada Intermediária

A validação cruzada das topologias com diferentes números de neurônios na camada intermediária é utilizada para a definição do número de neurônios da camada intermediária. Considere-se, por exemplo, a figura 3.2 a seguir obtida de [55], que relaciona o erro quadrático do conjunto teste (constituídos de padrões não utilizados no treinamento) ao número de neurônios da camada intermediária.

Nesta figura pode-se observar que ocorre uma região de menor erro (quase constante) para diferentes números de neurônios na camada intermediária. Deve-se optar, a princípio, pelo número de neurônios que leve ao menor erro (considerando-se essa região de erro quase

constante) ou pelo número de neurônios de mais rápida convergência do processo de treinamento (não necessariamente um menor número de neurônios implica em maior rapidez do treinamento).

É interessante observar que o erro para um neurônio (quando o treinamento convergir) é menor do que o erro máximo para muitos neurônios. Deve-se essa característica ao fato da RNA, quando se utilizam poucos neurônios, não possuir graus de liberdade (conexões) suficientes para uma adequada classificação e, por outro lado, para muitos neurônios irá ocorrer uma completa memorização do conjunto de treinamento.

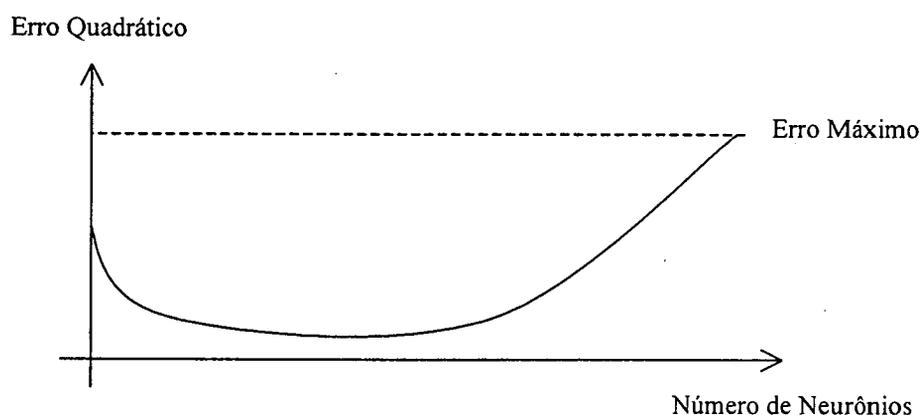


Figura 3.2 Erro em Função do Número de Neurônios na Camada Intermediária

Para a metodologia desenvolvida nesta tese podem ser observadas curvas semelhantes à apresentada na figura 3.2, quando de sua aplicação a diferentes sistemas de distribuição (capítulo 6).

3.3.3 Camada de Saída

A definição do número de neurônios da camada de saída é executada considerando-se duas diferentes abordagens de aplicação de RNA à solução do problema:

- utilizando-se uma única rede na classificação de todos os perfis de carga, o número de neurônios da camada de saída é igual a n , correspondendo a até 2^n topologias ótimas;
- utilizando uma rede para cada topologia ótima necessita-se somente de um neurônio na camada de saída, correspondendo a n RNA.

No segundo caso, em que cada RNA é treinada para reconhecer determinada topologia ótima, a classificação restringe-se à separação entre duas classes. A RNA deve ser capaz de classificar o perfil de carga de entrada como pertencente ou não à topologia ótima para a qual foi treinada. Assim, a rede treinada para classificar a topologia ótima m deve fornecer:

- valor 1 como resposta, sempre que se fornecer uma entrada correspondente à topologia ótima m ,
- valor 0 como resposta, sempre que se fornecer uma entrada não correspondente à topologia ótima m .

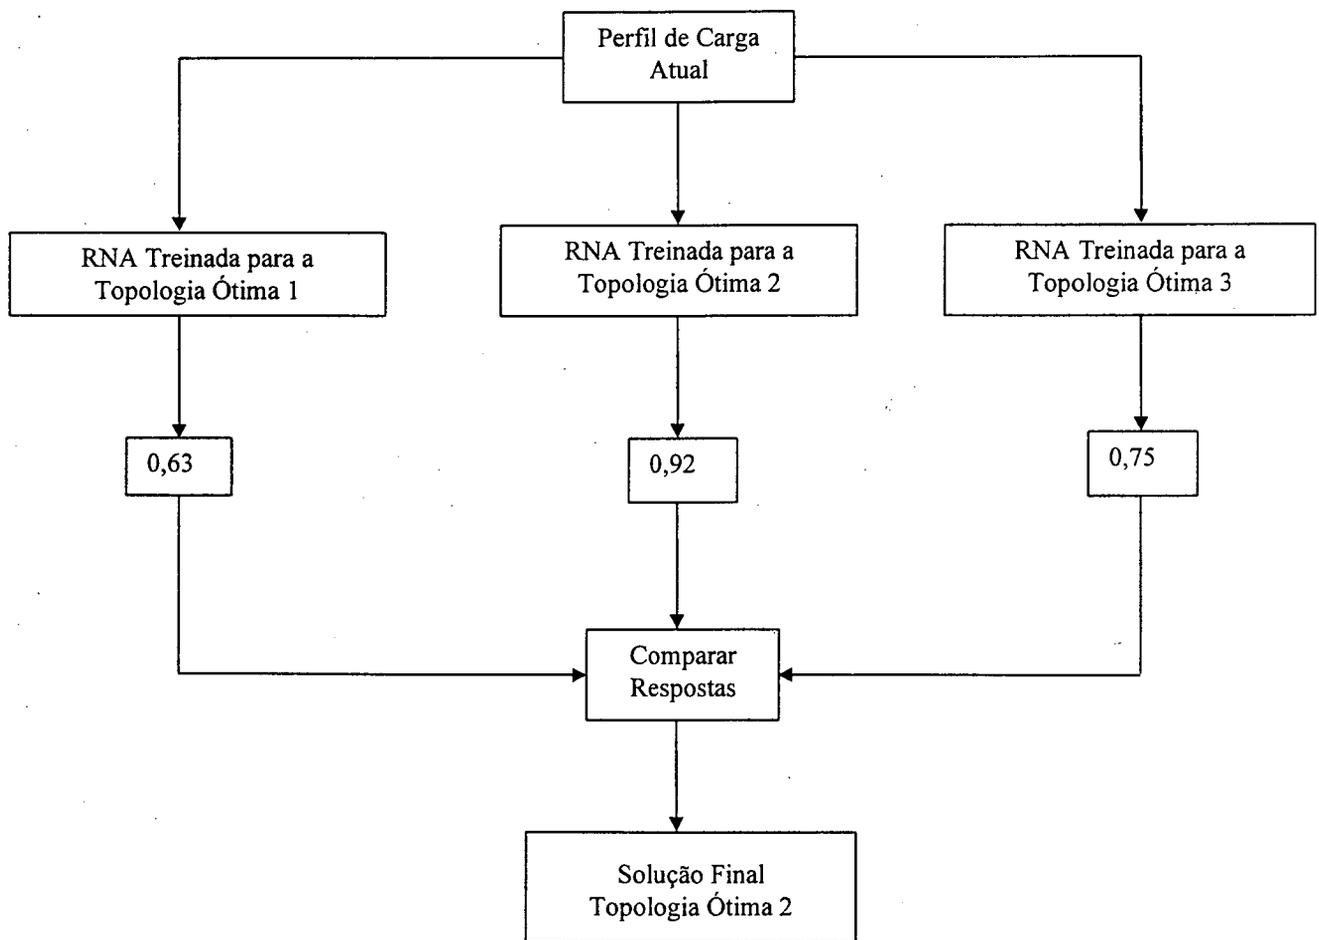


Figura 3.3 – Determinação da Topologia Ótima a partir das RNA Treinadas

Trabalhando-se com uma função de ativação que permite valores de saída compreendidos entre 0 e 1 (como é o caso da função sigmóide explicitada anteriormente), a RNA treinada para

classificar a topologia m deverá fornecer (quando apresentado um perfil de carga correspondente à topologia m) valor de saída maior do que o valor de saída das outras RNA (treinadas para representar as outras topologias ótimas) quando submetidas à mesma entrada. Por exemplo, se para a RNA treinada para representar a topologia m for apresentada uma entrada teste correspondente à topologia m e a sua saída for igual a 0,92, as saídas correspondentes às RNA treinadas para representar as outras topologias devem ser significativamente inferiores a 0,92 (quando submetidas à mesma entrada teste). Na figura 3.3 pode-se observar, através de um exemplo, o procedimento de determinação da solução considerando-se três RNA.

3.4 Conclusão

Uma das etapas que merecem maior preocupação em qualquer algoritmo baseado em técnicas neurais é a etapa de treinamento da rede neural, devido à alta carga computacional requerida na maioria das aplicações. Embora esta etapa não se constitua numa restrição pelo fato de ser realizada *off-line*, a aplicação do algoritmo neural pode vir a ser comprometida se o tempo de treinamento da rede neural for comparável ao tempo requerido para a mudança das condições que determinam o conjunto de dados de treinamento.

Deve-se observar que a escolha dos parâmetros taxa de aprendizagem e momento é definida a partir da experiência (simulações) adquirida no tratamento do problema. Outro importante fator reside na escolha e definição da região da função de ativação, a qual é usada durante a etapa de treinamento, de modo a evitar que demasiados neurônios permaneçam na região de saturação, comprometendo assim o treinamento.

A definição da necessidade ou não do uso de algoritmos de seleção de características para se obter um eficiente treinamento é fortemente condicionada pelo problema (qualidade dos dados de treinamento e tipo de RNA utilizada), sendo indicada, normalmente, quando a dimensão do vetor de entrada for significativamente elevada.

O conjunto de dados de treinamento da rede neural utilizada nesta tese é obtido a partir dos dados de entrada e saída do algoritmo de minimização de perdas apresentado no capítulo 4, a seguir.

Capítulo 4 - Minimização de Perdas

4.1 Introdução

O objetivo deste capítulo é apresentar a formulação do método heurístico *branch-exchange* de minimização de perdas elétricas adotado para obter a solução do problema de reconfiguração a mínimas perdas resistivas de sistemas de distribuição.

Após a formulação do método heurístico *branch-exchange* apresenta-se sua aplicação a dois sistemas teste. Para o primeiro sistema, de menor porte, a aplicação é apresentada de maneira bem detalhada, objetivando facilitar a compreensão da formulação. A aplicação ao segundo sistema se justifica por se tratar de um sistema de maior porte e bastante utilizado na literatura [1,27,32], e que será utilizado no capítulo 6, na aplicação da metodologia desenvolvida nesta tese.

Este eficiente método permitirá obter o conjunto de exemplos (dados) necessários ao treinamento das RNA que fornecerão a solução do problema em tempo real. Esta solução é obtida em tempo desprezível, visto a etapa de aquisição dos dados de treinamento ser realizada *off-line*.

4.2 Descrição do Método de Minimização de Perdas

O método heurístico *branch-exchange*, descrito neste capítulo, é constituído do algoritmo desenvolvido por Baran e Wu [1] em conjunto com a simplificação proposta por Jasmon e Lee [32]. Neste procedimento, a minimização de perdas em sistemas de distribuição é obtida reconfigurando-se o sistema através da mudança do estado de determinadas chaves seccionadoras. Esta simplificação resultou numa maior rapidez na determinação da reconfiguração da rede que minimiza suas perdas elétricas.

A simplificação adotada, citada acima, possibilita que não seja necessário determinar a redução das perdas para o chaveamento em todos os ramos do lado de mais baixa tensão da malha, que era o procedimento usual. Neste caso é necessário determinar a redução apenas para os ramos cujos fluxos de potência ativa se situem em torno do valor de fluxo ótimo da malha, como será visto a seguir.

O esquema de solução desta técnica de minimização inicia com uma rede malhada, obtida fechando-se uma chave normalmente aberta. Uma malha é analisada a cada vez considerando-se todas as possíveis malhas do sistema, caracterizando uma análise de múltiplos chaveamentos. Um ramo deverá ser aberto nesta malha, para manter a radialidade do sistema. O ramo a ser aberto para manter a radialidade do sistema será aquele que maximize a redução de perdas em sua malha.

A malha a ser alterada em cada iteração será aquela que possibilitar a maior redução de perdas considerando-se todas as possíveis malhas do sistema. O ramo aberto nesta malha passa a ser uma nova possibilidade de minimização nas iterações seguintes. Após este chaveamento, executa-se um algoritmo de fluxo de carga para determinar o novo estado (ponto de operação) do sistema.

Se ao final de uma iteração o recurso (chaveamento) escolhido a ser implementado causar sobrecarga em alguma parte do sistema, a sua possibilidade de mudança de estado é excluída e se executa novamente a iteração sem considerar a possibilidade de chaveamento deste ramo. Esta possibilidade de chaveamento é novamente introduzida no conjunto de chaveamento viáveis no momento em que não causar mais sobrecarga.

4.3 Equacionamento

4.3.1 Função Objetivo

Como primeira etapa do processo de minimização de perdas elétricas em sistemas de distribuição, necessita-se definir a função objetivo a ser utilizada. A função objetivo comumente utilizada para minimizar as perdas elétricas $r_i I_i^2$ no sistema pode ser apresentada da seguinte forma:

$$F.O. = \min \sum_i r_i \frac{P_i^2 + Q_i^2}{V_i^2} \quad (4.1)$$

Onde:

- i são os ramos do sistema,
- P, Q, V são respectivamente as potências ativa e reativa e a tensão no nó final do ramo i .

Considerando-se $V_i^2 \approx 1 pu$, obtém-se uma simplificação na função objetivo e também, conseqüentemente, na equação que quantifica a redução das perdas resistivas em função de um chaveamento (equação 4.7), bem como na obtenção da derivada da equação (4.10) necessária à otimização das perdas em cada malha (equação (4.11)):

$$F.O. = \min \sum_i r_i (P_i^2 + Q_i^2) \quad (4.2)$$

Como resultado da simplificação acima, em sistemas onde a maioria das tensões nas barras de carga são inferiores a 1 p.u. (fornecendo maior valor para a equação (4.1) do que para a equação (4.2)), obtém-se um valor menor de redução de perdas com o método do que o realmente obtido na prática. Desta forma, comparando-se a redução de perdas obtida através do método de minimização e a redução obtida através do método de fluxo de carga adotado, obtém-se uma diferença conservativa, podendo-se concluir que a simplificação adotada não compromete a qualidade dos resultados.

4.3.2 Redução de Perdas

Após definir a função objetivo do processo de minimização, necessita-se quantificar a redução de perdas a ser obtida através de um chaveamento qualquer no sistema. Para isso, inicia-se considerando o chaveamento entre o ramo b (originalmente aberto) e o ramo j (originalmente fechado) da figura 4.1, que representa uma possível malha a ser obtida no sistema com o fechamento da chave seccionadora do ramo b . Com o chaveamento determinar-se-á quais as cargas que passarão a ser alimentadas pelo ramo b , e a conseqüente redução nas perdas em função da transferência de carga.

O fluxo nos ramos da malha da figura 4.1 irá mudar na quantia P_k, Q_k devido ao chaveamento $b-j$. O lado da malha que contém o ramo j terá o fluxo diminuído de P_k, Q_k e o lado da malha que contém o ramo b terá o fluxo aumentado de P_k, Q_k para suprir as cargas das extremidades do ramo k .

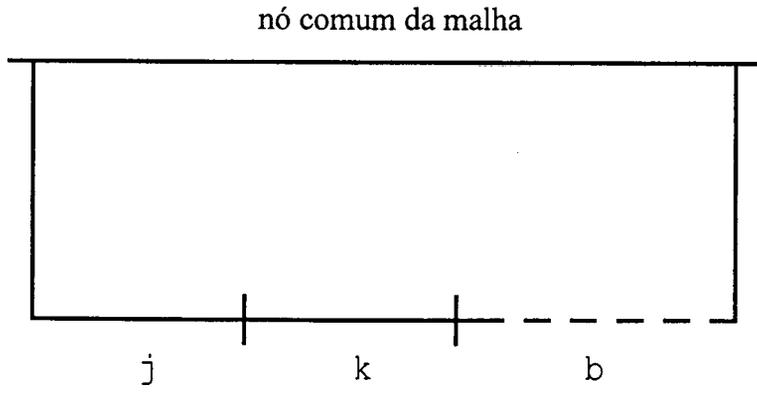


Figura 4.1 Malha de uma Rede de Distribuição

$$P_i' = P_i - P_k \quad Q_i' = Q_i - Q_k \quad i \in L \quad (4.3a)$$

$$P_i' = P_i + P_k \quad Q_i' = Q_i + Q_k \quad i \in R \quad (4.3b)$$

Onde: L é o lado da malha onde ocorrerá diminuição no fluxo de potência ativa após o chaveamento e R é o lado da malha onde ocorrerá aumento no fluxo de potência ativa após o chaveamento.

Para o caso geral de chaveamento entre dois ramos quaisquer, pode-se facilmente verificar que o fluxo na malha da figura 4.1 será mudado por P_m, Q_m , isto é,

$$P_i' = P_i - P_m \quad Q_i' = Q_i - Q_m \quad i \in L \quad (4.4a)$$

$$P_i' = P_i + P_m \quad Q_i' = Q_i + Q_m \quad i \in R \quad (4.4b)$$

Agora pode-se calcular a redução das perdas de potência ativa devido ao chaveamento de b (originalmente aberto) e de m (originalmente fechado), como segue. Pela equação (4.2), as perdas iniciais em L e R são:

$$RP_L \approx \sum_{i \in L} r_i (P_i^2 + Q_i^2) \quad (4.5a)$$

$$RP_R \approx \sum_{i \in R} r_i (P_i^2 + Q_i^2) \quad (4.5b)$$

Estes termos são novamente calculados após o chaveamento com os dados do fluxo de carga adotado [39] para determinar o estado atual do sistema. Denominam-se estes novos termos de RP'_L e RP'_R . Assim, a redução de perdas ΔRP_{bm} devido ao chaveamento nos ramos $b - m$ será:

$$\Delta RP_{bm} = \Delta RP_L + \Delta RP_R = (RP_L - RP'_L) + (RP_R - RP'_R) \quad (4.6)$$

Substituindo as equações (4.5a) e (4.5b) na equação (4.6) e rearranjando os termos obtém-se, por fim, a redução de perdas obtidas com estas manobras:

$$\begin{aligned} \Delta RP_{bm} = & \sum_{i \in L} r_i (P_i^2 + Q_i^2) - \sum_{i \in L} r_i (P_i^2 - 2P_i P_m + P_m^2 + Q_i^2 - 2Q_i Q_m + Q_m^2) \\ & + \sum_{i \in R} r_i (P_i^2 + Q_i^2) - \sum_{i \in R} r_i (P_i^2 + 2P_i P_m + P_m^2 + Q_i^2 + 2Q_i Q_m + Q_m^2) \end{aligned}$$

$$\Delta RP_{bm} = 2P_m \left(\sum_{i \in L} r_i P_i - \sum_{i \in R} r_i P_i \right) + 2Q_m \left(\sum_{i \in L} r_i Q_i - \sum_{i \in R} r_i Q_i \right) - (P_m^2 + Q_m^2) \left[\sum_{i \in R \cup L} r_i \right] \quad (4.7)$$

A equação acima permite quantificar a possível redução de perdas fechando-se o ramo b e abrindo-se um ramo qualquer m no lado de mais baixa tensão da malha. Esta equação incorre num erro na medida em que determina uma redução de perdas considerando a configuração atual e futura utilizando somente o ponto de operação atual do sistema. Entretanto, os autores afirmam que este erro é conservativo já que:

- i) quando a redução de perdas é grande ($\Delta RP_{bm} \gg 0$), o erro tende a ser positivo ($\Delta RP_{bm}^{real} - \Delta RP_{bm} \geq 0$), ou seja, a redução real ΔRP_{bm}^{real} é maior do que a calculada ΔRP_{bm} no processo,
- ii) e quando há um significativo acréscimo nas perdas ($\Delta RP_{bm} \ll 0$), o erro tenderá a ser negativo ($\Delta RP_{bm}^{real} - \Delta RP_{bm} \leq 0$), ou seja, o acréscimo real ΔRP_{bm}^{real} é menor do que o calculado ΔRP_{bm} .

Problemas podem acontecer quando a redução ou acréscimo são pequenos ($\Delta RP_{bm} \approx 0$) e o erro pode ser tanto negativo como positivo. Neste caso pode resultar que algum chaveamento com $\Delta RP_{bm} < 0$ (acrécimo) seja identificado como um chaveamento de redução de perdas. Na prática este problema não existe, na medida em que chaveamentos que levem a reduções muito pequenas não são executados em função de sua não viabilidade econômica.

Como citado anteriormente, pode-se adotar uma simplificação para melhorar a eficiência do método, aplicando a equação 4.7 apenas para os dois ramos cujos fluxos de potência ativa situam-se em torno do fluxo ótimo, e não mais para todos os ramos do lado de mais baixa tensão da malha, como será apresentado a seguir.

4.3.3 Escolha do Ramo a ser Aberto

Finalmente necessita-se determinar o ramo a ser aberto na malha, de modo a proporcionar a maior redução nas perdas de potência ativa, de acordo com a equação 4.7. Considerando-se as partes ativa e reativa desta equação separadamente, obtém-se a variação das perdas em função de P_m e Q_m :

$$\Delta RP_{bm} = f(P_m) + f(Q_m) \quad (4.8)$$

Com o auxílio da equação (4.7) obtém-se :

$$f(P_m) = 2P_m(\sum r_l P_l - \sum r_r P_r) - r_{loop} \cdot P_m^2 \quad (4.9a)$$

$$f(Q_m) = 2Q_m(\sum r_l Q_l - \sum r_r Q_r) - r_{loop} \cdot Q_m^2 \quad (4.9b)$$

Onde: r_{loop} é a soma das resistências de todos os ramos que compõem a malha.

Como o fluxo de potência ativa P em qualquer ramo é muito maior que o fluxo de potência reativa Q , isto é ($P \gg Q$), $f(P_m)$ é a função dominante em ΔRP_{bm} . Desta forma, analisando-se somente $f(P_m)$, determina-se qual ramo deverá ser aberto quando é efetuado um chaveamento em determinada malha.

Aplicando-se o procedimento tradicional de obtenção de máximos e mínimos de funções, diferencia-se $f(P_m)$ e obtém-se a equação (4.10) a seguir.

$$\partial(f(P_m)) / \partial(P_m) = 2(\sum r_l P_l - \sum r_r P_r) - 2 \cdot r_{loop} \cdot P_m \quad (4.10)$$

Igualando-se o segundo membro da equação (4.10) a zero, obtém-se o valor de P_m , que representa a máxima redução de perdas da malha devido ao fato de que a segunda derivada desta equação é negativa ($-2 \cdot r_{loop}$). Assim, obtém-se o valor P_m^{\max} :

$$P_m^{\max} = (\sum r_l P_l - \sum r_r P_r) / r_{loop} \quad (4.11)$$

O valor obtido através da equação (4.11) deve ser alocado entre 2 ramos cujos fluxos de potência ativa sejam imediatamente inferior e superior a este valor de potência ativa no lado de mais baixa tensão da malha. Estes dois ramos são os candidatos ao chaveamento na malha. Dentre estes dois ramos, adota-se o chaveamento no ramo que causar a maior redução nas perdas de potência ativa (maior valor positivo da equação (4.7)).

Se P_m^{\max} não puder ser alocado entre 2 ramos n e $n-1$, onde $P_{n-1} < P_m^{\max} < P_n$, então a única possibilidade para uma redução de perdas é o ramo nominal (ramo nominal é o ramo adjacente ao ramo aberto no lado de mais baixa tensão da malha). Isto deve-se ao fato do ramo nominal ser o ramo de menor potência ativa do lado de baixa tensão da malha e ser superior ao valor de P_m^{\max} . Se a redução de perdas devido ao ramo nominal for negativa, significa que a malha já foi otimizada e nenhum chaveamento pode ser implementado para produzir uma redução de perdas positiva.

A seguir apresenta-se, a título de exemplo, a solução do método descrito para um único perfil de carga dos sistemas que serão considerados no capítulo 6. Para o primeiro sistema a aplicação é apresentada de maneira bastante detalhada, objetivando facilitar a compreensão do método heurístico *branch-exchange*.

4.4 Exemplo da Aplicação do Método de Minimização de Perdas ao Sistema 1

O Sistema 1 (Figura 4.2) é parte do Sistema de Distribuição da Região Metropolitana da Grande Florianópolis, sendo seus dados fornecidos pela concessionária. Este sistema possui uma subestação, 15 pontos de carga e nível de tensão de 13,8 kV. Como nenhuma possibilidade de

reconfiguração existe no sistema, duas alternativas de chaveamento são propostas no exemplo (tabela 4.1), representadas pelas linhas tracejadas. A carga total para a configuração base é 3.636 kW e 1.551 kVAr, para as potências ativa e reativa, respectivamente.

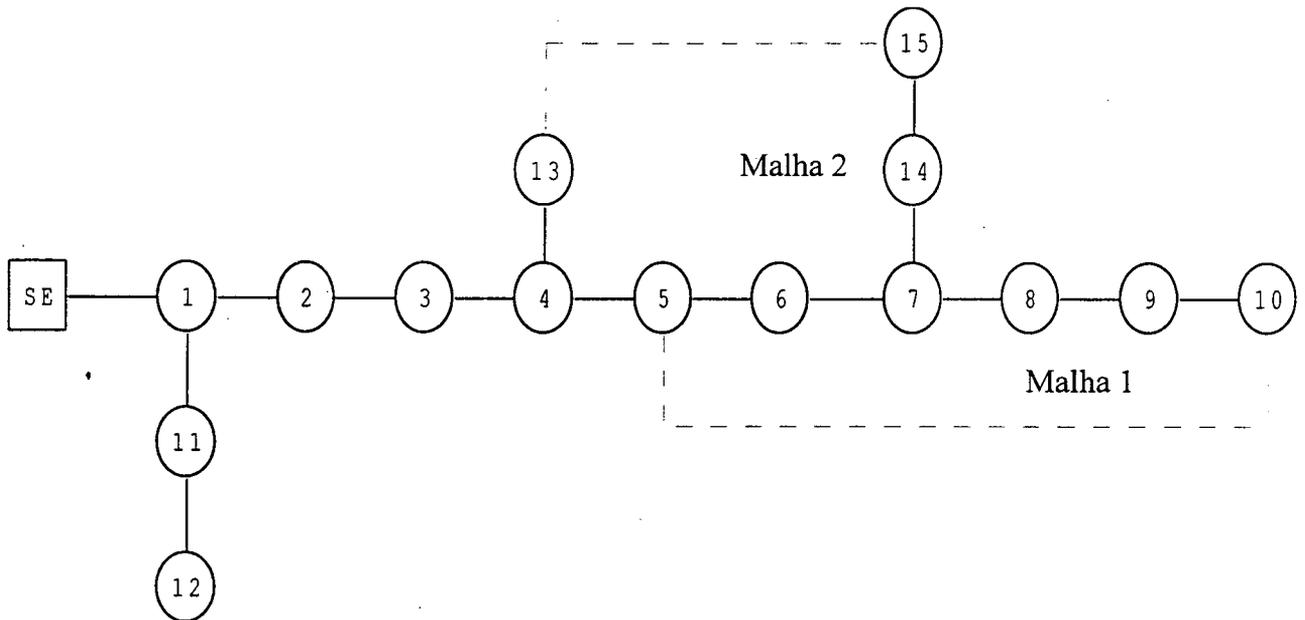


Figura 4.2 Alimentador Pertencente ao Sistema de Distribuição da Grande Florianópolis - Sistema 1

Os dados do sistema (conexão dos nós, cargas e impedâncias das linhas), bem como as alternativas de chaveamento propostas no exemplo, encontram-se na tabela 4.1.

4.4.1 Detalhamento dos Cálculos para a 1ª Iteração

A seguir são apresentados os cálculos executados na primeira iteração do processo de minimização de perdas para o Sistema 1. Como para este sistema são propostas duas alternativas de chaveamento, surgem duas possíveis malhas no sistema. Para cada uma destas duas malhas determina-se o chaveamento ótimo em relação às perdas, adotando-se na reconfiguração do sistema, para a próxima iteração, o chaveamento na malha que causar a maior redução.

Denomina-se de Malha 1, a malha formada a partir da linha 5-10 e de Malha 2, a malha formada a partir da linha 13-15. Para estas duas malhas, como primeiro passo, necessita-se determinar o valor de potência ativa que maximiza a redução de perdas na malha. Este valor é obtido a partir da equação (4.11), reescrita a seguir.

Tabela 4.1 - Dados do Sistema 1

Conexão dos Nós		Cargas		Impedâncias	
Ramo	Início-Fim	P(kW)	Q(kVAr)	r(Ω)	x(Ω)
L ₁	0-1	56,3	24,0	0,863	1,860
L ₂	1-2	115,0	49,0	0,116	0,250
L ₃	2-3	138,0	58,8	0,075	0,161
L ₄	3-4	0,0	0,0	0,022	0,048
L ₅	4-5	390,4	166,3	0,340	0,733
L ₆	5-6	214,4	91,4	0,686	0,979
L ₇	6-7	137,4	58,6	0,478	0,683
L ₈	7-8	560,7	238,9	0,249	0,356
L ₉	8-9	229,0	97,6	0,476	0,250
L ₁₀	9-10	454,2	193,5	1,401	1,100
L ₁₁	1-11	274,5	117,0	0,683	0,975
L ₁₂	11-12	401,2	171,0	0,446	0,636
L ₁₃	4-13	151,5	64,6	1,654	0,535
L ₁₄	7-14	190,1	81,0	0,300	0,263
L ₁₅	14-15	323,7	137,9	0,327	0,286
Alternativas de Chaveamento					
L ₁₆	5-10	--	--	3,500	2,500
L ₁₇	13-15	--	--	2,500	1,500

$$P_m^{\max} = (\sum r_l P_l - \sum r_r P_r) / r_{loop}$$

A partir do valor de potência ativa obtido nesta equação, determina-se a redução de perdas para os dois ramos, cujos valores de potência ativa encontram-se imediatamente acima e abaixo desse valor. O ramo que apresentar a maior redução é o ramo a ser aberto na malha. O valor da redução de perdas para cada ramo é obtido a partir da equação (4.7), reescrita abaixo.

$$\Delta RP_{bm} = 2P_m \left(\sum_{i \in L} r_i P_i - \sum_{i \in R} r_i P_i \right) + 2Q_m \left(\sum_{i \in L} r_i Q_i - \sum_{i \in R} r_i Q_i \right) - (P_m^2 + Q_m^2) \left[\sum_{i \in R \cup L} r_i \right]$$

O índice b representa o ramo que contém a chave a ser fechada e o índice m o ramo da chave a ser aberta. De posse da máxima redução de perdas em cada malha, reconfigura-se o sistema através do chaveamento ótimo (dentre todas as malhas) para iniciar a nova iteração.

4.4.1.1 Cálculos para a Malha 1

Para a Malha 1 formada a partir da alternativa de chaveamento 5-10, tem-se apenas o lado da malha composto pelos ramos L_6 , L_7 , L_8 , L_9 e L_{10} . Como o chaveamento deve ocorrer neste lado da malha, este será o lado a ter redução no fluxo de potência ativa, sendo, portanto, designado de lado L da malha.

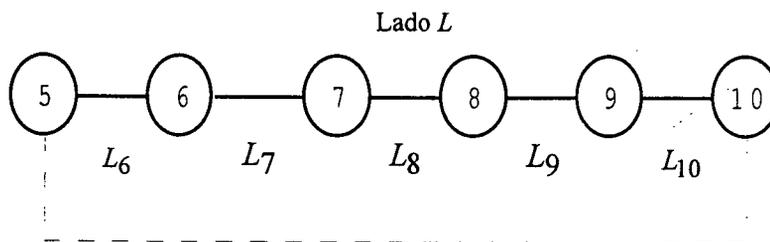


Figura 4.3 – Lado L da Malha 1

O valor $rloop$ é obtido somando-se todas as resistências da malha. Logo, será o valor do somatório das resistências, segunda coluna da última linha da tabela 4.2, mais o valor da resistência da alternativa de chaveamento (em p.u.). Nesta tabela foram considerados como valores base do sistema 13,8 kV e 1 MVA.

Tabela 4.2 – Valores em p.u. dos Ramos do Lado L da Malha 1

Ramos	r(p.u.)	P(p.u.)	Q(p.u.)	rP(p.u.)	rQ(p.u.)
L_6	0,0036022	2,109	0,900	0,0075970	0,0032420
L_7	0,0025100	1,895	0,809	0,0047565	0,0020306
L_8	0,0013075	1,244	0,531	0,0016265	0,00069428
L_9	0,0024995	0,683	0,292	0,0017072	0,00072985
L_{10}	0,0073566	0,454	0,194	0,0033399	0,0014272
Σ	0,017276	-	-	0,019027	0,0081239

$$rloop = 0,017276 + 0,018378 = 0,035654 \text{ p.u.}$$

$$P_m^{\max} = (0,019027 - 0) / 0,035654 = 0,53366 \text{ p.u.}$$

O valor de P_m^{\max} que maximiza a redução de perdas de potência ativa, para esta malha (0,533 p.u.), encontra-se entre os valores de potência ativa dos ramos L_9 (0,683 p.u.) e L_{10} (0,454 p.u.), conforme observa-se na tabela 4.2 . Necessita-se então, determinar a redução de perdas para estes dois ramos (equação (4.7)). Estas reduções são:

$$\Delta RP_{L_{16}-L_9} = 11,06 \text{ kW}$$

$$\Delta RP_{L_{16}-L_{10}} = 11,74 \text{ kW}$$

Destes dois valores de redução de perdas, conclui-se que o chaveamento ótimo, nesta malha, é o chaveamento do ramo L_{16} e a abertura do ramo L_{10} .

4.4.1.2 Cálculos para a Malha 2

Nesta malha, formada a partir da alternativa de chaveamento 13-15, temos dois lados. O lado onde ocorrerá o chaveamento será o lado pertencente à extremidade de mais baixa tensão, relacionada com a alternativa de expansão. Logo, verificando-se o perfil de tensão do sistema determina-se que o lado L será o lado que contém o ramo L_{15} .

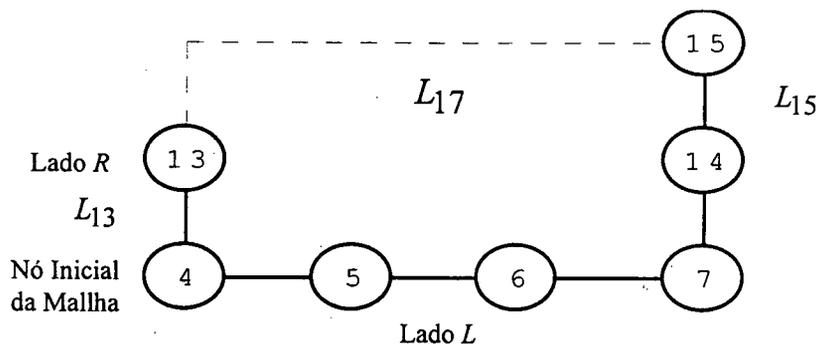


Figura 4.4 – Lados L e R da Malha 2

Tabela 4.3 - Valores em p.u. dos Ramos do Lado L da Malha 2

Ramos	r(p.u.)	P(p.u.)	Q(p.u.)	rP(p.u.)	rQ(p.u.)
L_5	0,0017853	2,499	1,066	0,0044615	0,0019031
L_6	0,0036022	2,109	0,900	0,0075970	0,0032420
L_7	0,0025100	1,895	0,809	0,0047565	0,0020306
L_{14}	0,0015753	0,514	0,219	0,00080970	0,00034499
L_{15}	0,0017171	0,324	0,138	0,00055634	0,00023696
Σ	0,011190	-	-	0,018181	0,0077577

Tabela 4.4 - Valores em p.u. dos Ramos do Lado R da Malha 2

Ramos	r(p.u.)	P(p.u.)	Q(p.u.)	rP(p.u.)	rQ(p.u.)
L_{13}	0,0086852	0,152	0,065	0,0013202	0,00056454
Σ	0,0086852	-	-	0,0013202	0,00056454

$$rloop = 0,011190 + 0,0086852 + 0,013127 = 0,033002 \text{ p.u.}$$

$$P_m^{\max} = (0,018181 - 0,0013202) / 0,033202 = 0,50782 \text{ p.u.}$$

O valor de P_m^{\max} que maximiza a redução de perdas de potência ativa, para esta malha, encontra-se entre os valores de potência ativa dos ramos L_{14} e L_{15} , conforme observa-se na tabela 4.3. Necessita-se então, utilizando-se a equação (4.7), determinar a redução de perdas para estes dois ramos. Estas reduções são:

$$\Delta RP_{L_{17}-L_{14}} = 10,18 \text{ kW}$$

$$\Delta RP_{L_{17}-L_{15}} = 8,82 \text{ kW}$$

Destes dois valores de redução de perdas, conclui-se que o chaveamento ótimo, nesta malha, determina o fechamento da chave do ramo L_{17} e a abertura da chave do ramo L_{14} .

4.4.1.3 Determinação do Chaveamento Ótimo para o Sistema

Nesta etapa, deve-se comparar todas as maiores reduções de perdas para cada malha. Assim, a maior redução na Malha 1 é a redução devido ao chaveamento $L_{16} - L_{10}$ (11,74 kW) e a maior redução na Malha 2 é a redução devido ao chaveamento $L_{17} - L_{14}$ (10,18 kW). Portanto, na 1ª iteração reconfigura-se a rede adotando-se o chaveamento $L_{16} - L_{10}$ na Malha 1. Esta nova configuração passa a ser a configuração inicial para a iteração seguinte. Proceda-se desta maneira até não existir mais nenhuma possibilidade de redução de perdas (critério de convergência).

Resultados da execução do algoritmo para determinar o chaveamento ótimo em cada iteração podem ser observados na tabela 4.5. Foram adotados os chaveamentos que

possibilitaram as maiores reduções em cada iteração, chaveamentos dos ramos $L_{16} - L_{10}$ para a 1ª iteração e nos ramos $L_{17} - L_{14}$ na 2ª iteração.

Tabela 4.5 – Chaveamento Ótimo para Cada Iteração

Ramo Fechado	Ramo Aberto	Redução nas Perdas (kW)
1ª Iteração		
L_{16}	L_{10}	11,74
L_{17}	L_{14}	10,18
Reconfiguração Implementada: $L_{16} - L_{10}$		
2ª Iteração		
L_{10}	L_9	-0,67
L_{17}	L_{14}	6,81
Reconfiguração Implementada: $L_{17} - L_{14}$		
3ª Iteração		
L_{10}	L_9	-2,38
L_{14}	L_7	-39,84
Perdas Minimizadas		

Como todas as possibilidades de chaveamento na 3ª iteração levariam ao aumento nas perdas (valores negativos de redução de perdas da tabela 4.5 acima), na 2ª iteração o sistema encontra-se otimizado e mais nenhuma reconfiguração é executada.

Observa-se na tabela 4.6, apresentada a seguir, que durante as iterações a grande maioria das correntes nos ramos decresce de valor, aliviando o carregamento dos condutores. Não se constata também nenhuma violação das capacidades máximas de corrente nos alimentadores. Esta característica foi também observada em vários outros sistemas analisados.

Calculando-se as perdas para as configurações inicial e final do sistema através do fluxo de carga adotado (executado a cada iteração do processo de minimização de perdas), obtém-se 145,43 kW (4% da potência ativa total do sistema) e 124,71 kW (3,4%) de perdas de potência ativa, respectivamente, representando uma redução efetiva de 14,25%.

Na tabela 4.6 são apresentados os dados de carregamento dos alimentadores e a capacidade de corrente máxima de cada alimentador. Na tabela 4.7 são apresentados os perfis de tensão para as configurações inicial e final do sistema.

Tabela 4.6 - Carregamento dos Condutores do Sistema 1

Ramo	Correntes (A)			
	Corrente Máx (A)	1ª Iteração	2ª Iteração	3ª Iteração
L_1	510	298	298	298
L_2	510	239	239	239
L_3	510	230	230	230
L_4	510	219	219	219
L_5	510	207	207	164
L_6	340	175	137	94
L_7	340	158	120	77
L_8	340	104	66	66
L_9	170	57	19	19
L_{10}	165	38	--	--
L_{11}	340	54	54	54
L_{12}	340	32	32	32
L_{13}	125	12	12	55
L_{14}	230	43	43	--
L_{15}	230	27	27	16
L_{16}	209	--	38	38
L_{17}	209	--	--	43

Na tabela 4.7 pode-se observar a sensível melhora no perfil de tensão da configuração final, sobretudo nas barras do final da linha.

Tabela 4.7 - Perfil de Tensão do Sistema 1

Nó de Carga	Config. Inicial	Config. Final	Nó de Carga	Config. Inicial	Config. Final
1	0,996	0,996	9	0,955	0,969
2	0,993	0,993	10	0,950	0,971
3	0,991	0,991	11	0,993	0,993
4	0,990	0,990	12	0,991	0,991
5	0,981	0,983	13	0,989	0,983
6	0,968	0,976	14	0,959	0,974
7	0,960	0,972	15	0,958	0,974
8	0,957	0,970			

Deve-se observar que esta redução (20,72 kW), em relação ao valor de perdas da configuração inicial obtido através do programa de fluxo de carga, não é idêntica à obtida através da técnica de minimização (18,55 kW = 11,74 kW + 6,81 kW). Isto se deve ao fato da

simplificação adotada para as tensões no método de minimização (todas iguais a 1 p.u.). Conforme havia sido comentado anteriormente, constata-se aqui que esta simplificação leva a resultados conservativos, fornecendo uma redução nas perdas inferior ao valor efetivamente atingido, porém tornando o processamento mais rápido.

4.5 Exemplo da Aplicação do Método de Minimização de Perdas ao Sistema 2

Este sistema de maior porte, e conseqüentemente com maior número de possibilidades de chaveamento, possui uma subestação, 32 pontos de carga e nível de tensão de 12,66 kV. A carga total para a configuração base é 3.715 kW e 2.300 kVAr. Neste exemplo são utilizadas as mesmas 5 alternativas de chaveamento das referências [1,27,32], podendo os resultados ser comparados. Os dados do Sistema 2 e as alternativas de chaveamento deste sistema estão apresentados na tabela 4.8, mostrada a seguir.

Os resultados da execução para determinar o chaveamento ótimo em cada iteração podem ser observados na tabela 4.9. Como todas as possibilidades de chaveamento na 8ª iteração levariam ao aumento nas perdas (valores negativos na 3ª coluna da tabela 4.9), após a 7ª iteração o sistema encontra-se otimizado e mais nenhum chaveamento é executado.

Na tabela 4.10 pode-se observar a melhora significativa no perfil de tensão da configuração final. As tensões em algumas barras de carga tiveram um acréscimo acima de 0,03 p.u. na configuração final.

Calculando-se as perdas para as configurações inicial e final do sistema, obtém-se 202,7 kW (5,4% da potência ativa total do sistema) e 145,2 kW (3,9% da potência ativa), respectivamente, de perdas de potência ativa. Estes valores representam uma redução efetiva de 57,5 kW ou 28,73%. Com o método de minimização adotado a redução foi de 49,01kW (redução obtida ao se somar os valores da redução de perdas de cada iteração), confirmando-se a afirmativa de que os resultados são conservativos e confiáveis.

A configuração final do sistema, figura 4.5, e os resultados (valores numéricos de redução de perdas para cada malha, em cada iteração) são idênticos aos apresentados em [32], comprovando a efetiva implementação do método de heurístico *branch-exchange* e do método de fluxo de carga.

Tabela 4.8 - Dados do Sistema 2

Conexão dos Nós		Cargas		Impedâncias	
Ramo	Início-Fim	P(kW)	Q(kVAr)	r(Ω)	x(Ω)
L ₁	0-1	100	60	0,0922	0,0470
L ₂	1-2	90	40	0,4930	0,2511
L ₃	2-3	120	80	0,3660	0,1864
L ₄	3-4	60	30	0,3811	0,1941
L ₅	4-5	60	20	0,8190	0,7070
L ₆	5-6	200	100	0,1872	0,6188
L ₇	6-7	200	100	0,7114	0,2351
L ₈	7-8	60	20	1,0300	0,7400
L ₉	8-9	60	20	1,0440	0,7400
L ₁₀	9-10	45	30	0,1966	0,0650
L ₁₁	10-11	60	35	0,3744	0,1238
L ₁₂	11-12	60	35	1,4680	1,1550
L ₁₃	12-13	120	80	0,5416	0,7129
L ₁₄	13-14	60	10	0,5910	0,5260
L ₁₅	14-15	60	20	0,7463	0,5450
L ₁₆	15-16	60	20	1,2890	1,7210
L ₁₇	16-17	90	40	0,7320	0,5740
L ₁₈	1-18	90	40	0,1640	0,1565
L ₁₉	18-19	90	40	1,5042	1,3554
L ₂₀	19-20	90	40	0,4095	0,4784
L ₂₁	20-21	90	40	0,7089	0,9373
L ₂₂	2-22	90	50	0,4512	0,3083
L ₂₃	22-23	420	200	0,8980	0,7091
L ₂₄	23-24	420	200	0,8960	0,7011
L ₂₅	5-25	60	25	0,2030	0,1034
L ₂₆	25-26	60	25	0,2842	0,1447
L ₂₇	26-27	60	20	1,0590	0,9337
L ₂₈	27-28	120	70	0,8042	0,7006
L ₂₉	28-29	200	600	0,5075	0,2585
L ₃₀	29-30	150	70	0,9744	0,9630
L ₃₁	30-31	210	100	0,3105	0,3619
L ₃₂	31-32	60	40	0,3410	0,5302
Alternativas de Chaveamento					
L ₃₃	7-20	--	--	2,0000	2,0000
L ₃₄	8-14	--	--	2,0000	2,0000
L ₃₅	11-21	--	--	2,0000	2,0000
L ₃₆	17-32	--	--	0,5000	0,5000
L ₃₇	24-28	--	--	0,5000	0,5000

Tabela 4.9 – Chaveamentos Ótimos para o Sistema 2

Ramo Fechado	Ramo Aberto	Redução nas Perdas (kW)	Ramo Fechado	Ramo Aberto	Redução nas Perdas (kW)
1 ^a Iteração			5 ^a Iteração		
L ₃₃	L ₇	33,88	L ₇	L ₆	-0,62
L ₃₄	L ₁₄	4,51	L ₃₄	L ₁₄	0,89
L ₃₅	L ₈	37,82	L ₁₁	L ₃₅	-11,24
L ₃₆	L ₁₇	0,00	L ₃₆	L ₃₂	1,34
L ₃₇	L ₂₈	19,69	L ₃₇	L ₂₈	-0,01
Reconfiguração Implementada: L ₃₅ - L ₈			Reconfiguração Implementada: L ₃₆ - L ₃₂		
2 ^a Iteração			6 ^a Iteração		
L ₃₃	L ₆	5,14	L ₇	L ₃₃	-8,33
L ₃₄	L ₁₄	0,27	L ₃₄	L ₁₄	1,19
L ₈	L ₉	-0,34	L ₁₁	L ₃₅	-13,21
L ₃₆	L ₃₂	1,74	L ₃₂	L ₃₁	-4,20
L ₃₇	L ₂₈	4,60	L ₃₇	L ₂₈	-0,49
Reconfiguração Implementada: L ₃₃ - L ₆			Reconfiguração Implementada: L ₃₄ - L ₁₄		
3 ^a Iteração			7 ^a Iteração		
L ₆	L ₇	-0,38	L ₇	L ₃₃	-20,47
L ₃₄	L ₁₄	0,27	L ₁₄	L ₃₄	-1,19
L ₈	L ₁₁	1,54	L ₁₁	L ₉	1,36
L ₃₆	L ₃₂	0,08	L ₃₂	L ₃₁	-3,15
L ₃₇	L ₂₈	-4,62	L ₃₇	L ₂₈	-0,49
Reconfiguração Implementada: L ₈ - L ₁₁			Reconfiguração Implementada: L ₁₁ - L ₉		
4 ^a Iteração			8 ^a Iteração		
L ₆	L ₇	0,62	L ₇	L ₃₃	-15,86
L ₃₄	L ₁₄	-0,68	L ₁₄	L ₃₄	-4,14
L ₁₁	L ₃₅	-14,38	L ₉	L ₈	-5,31
L ₃₆	L ₃₂	0,51	L ₃₂	L ₃₁	-2,13
L ₃₇	L ₂₈	-4,62	L ₃₇	L ₂₈	-0,49
Reconfiguração Implementada: L ₆ - L ₇			Perdas Minimizadas		

Tabela 4.10 - Perfil de Tensão do Sistema 2

Nó de Carga	Config. Inicial	Config. Final	Nó de Carga	Config. Inicial	Config. Final
1	1,027	1,027	17	0,946	0,978
2	1,013	1,017	18	1,027	1,025
3	1,006	1,013	19	1,023	1,009
4	0,999	1,009	20	1,022	1,004
5	0,981	0,998	21	1,022	1,001
6	0,978	0,997	22	1,010	1,014
7	0,973	0,993	23	1,004	1,007
8	0,967	0,990	24	1,000	1,004
9	0,962	0,993	25	0,979	0,996
10	0,961	0,993	26	0,977	0,994
11	0,959	0,993	27	0,966	0,983
12	0,953	0,991	28	0,958	0,976
13	0,951	0,990	29	0,955	0,973
14	0,950	0,984	30	0,951	0,969
15	0,949	0,982	31	0,950	0,969
16	0,947	0,979	32	0,949	0,978

Este procedimento é repetido para cada um dos perfis de carga obtidos através de sorteios via Simulação Monte Carlo. O conjunto dos perfis de carga sorteados e as correspondentes topologias ótimas, obtidas com o método heurístico apresentado neste capítulo, constituirão a base de conhecimento necessária ao treinamento das RNA.

4.6 Conclusão

O método apresentado neste capítulo reduz o esforço computacional necessário para a busca da configuração com mínimas perdas elétricas resistivas. Esta redução se deve ao fato do método heurístico somente calcular a redução de perdas oriunda da abertura das chaves que possuem valores de fluxo de potência ativa imediatamente acima e abaixo do valor que maximiza a redução de perdas na malha, diminuindo a explosão combinatorial inerente à determinação da solução do problema.

Quanto maior o porte do sistema, maior será a eficiência computacional do método em comparação aos métodos de programação inteira. Por outro lado, em função da heurística adotada, quanto maior o porte do sistema maior será a probabilidade de se obter um ótimo local.

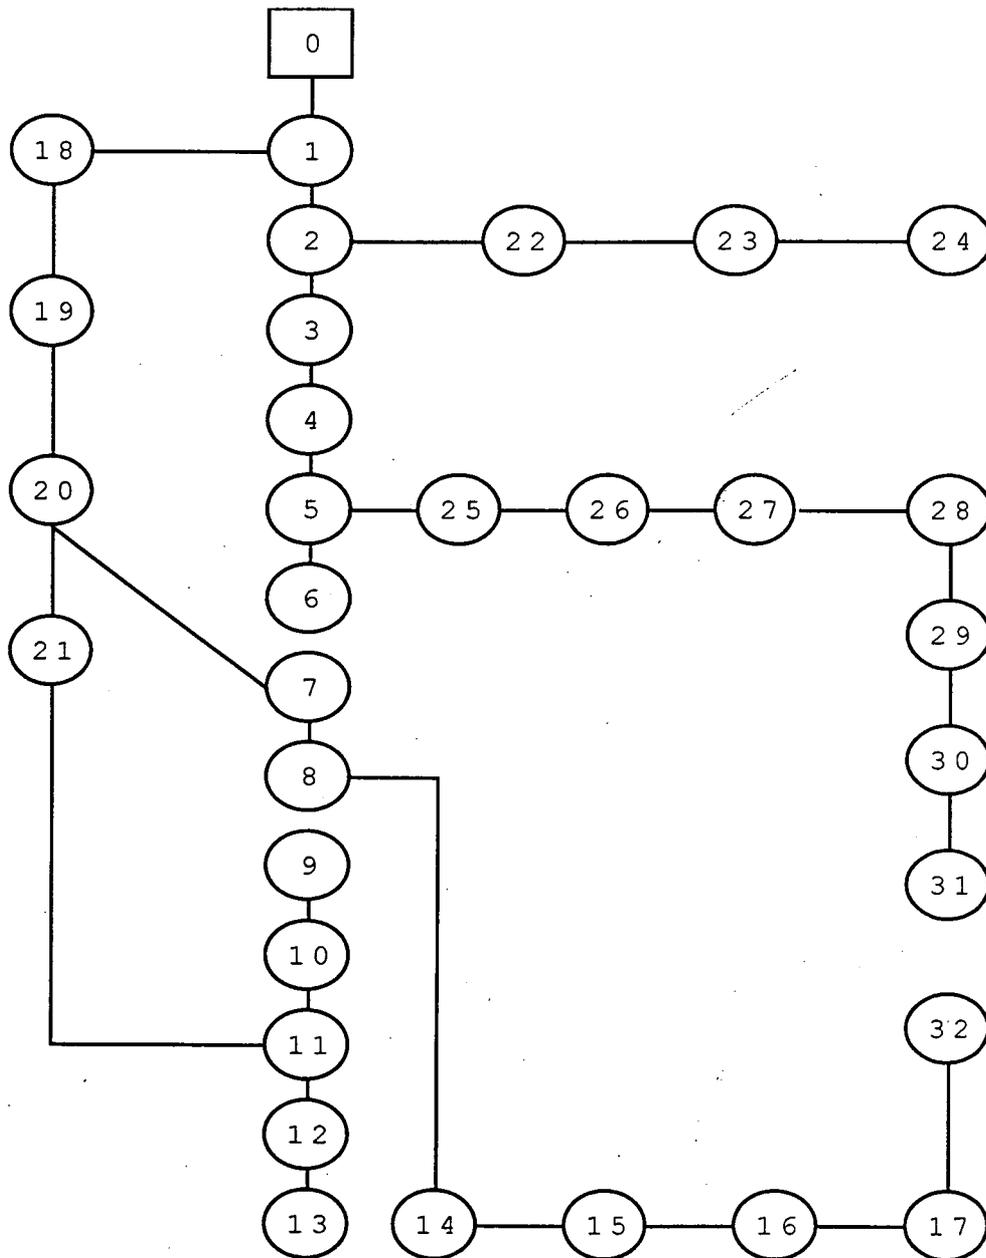


Figura 4.5 Configuração Final do Sistema 2

O método heurístico de solução aqui apresentado será utilizado na obtenção do conjunto de dados de treinamento das RNA que fornecerão em tempo desprezível a solução para o sistema de distribuição.

Como existe a possibilidade da solução fornecida pelas RNA ser um ótimo local, passa-se então a utilizar as RNA em conjunto com um método de programação matemática inteira. Este método determinará a partir da solução fornecida pelas RNA, por fim, a solução ótima global em poucas iterações (uma ou duas).

No capítulo 5, a seguir, é apresentada a formulação detalhada do método de programação matemática inteira 0-1 com aplicações a dois diferentes sistemas de distribuição. O capítulo 6, por sua vez, contempla a metodologia completa desenvolvida nesta tese para a reconfiguração em tempo real de sistemas de distribuição com o objetivo de minimizar suas perdas resistivas e, aplicações da metodologia a dois diferentes sistemas de distribuição.

Capítulo 5 - Otimalidade da Solução

5.1 Introdução

Neste capítulo é apresentada a formulação utilizada para verificar a otimalidade da solução fornecida pela rede neural artificial. Utiliza-se com esse objetivo o método de programação matemática inteira 0-1 proposto por Sarma e Rao [51], após se obter a solução inicial da RNA, o que caracteriza uma formulação híbrida de RNA e programação matemática inteira (figura 5.1).

Como será visto a seguir, neste método os autores obtêm uma função que quantifica as perdas totais do sistema considerando-se os possíveis estados aberto/fechado (0-1) das chaves seccionadoras. Esta função deverá ser minimizada considerando-se ainda as restrições de continuidade e radialidade.

Como ponto de partida para o método de programação matemática inteira, utiliza-se a solução fornecida pela RNA. Caso a solução fornecida pela RNA seja a solução ótima, o algoritmo de programação inteira não adotará nenhum novo chaveamento no sistema, confirmando a otimalidade da solução. Caso contrário, o algoritmo de Sarma deve ser capaz de atingir a configuração desejada em poucas iterações.

Este método, ao contrário dos métodos de solução aproximada baseados em heurísticas e/ou na técnica *branch-exchange* (que consideram um chaveamento por vez), permite considerar múltiplos chaveamentos na obtenção da topologia ótima do sistema, pois considera simultaneamente todos os possíveis estados das chaves seccionadoras.

Pode-se visualizar através do fluxograma da figura 5.1 apresentado a seguir, a interação entre o método de programação matemática inteira e as redes neurais treinadas, na determinação da topologia com mínimas perdas para os perfis de cargas que venha a ocorrer no sistema.

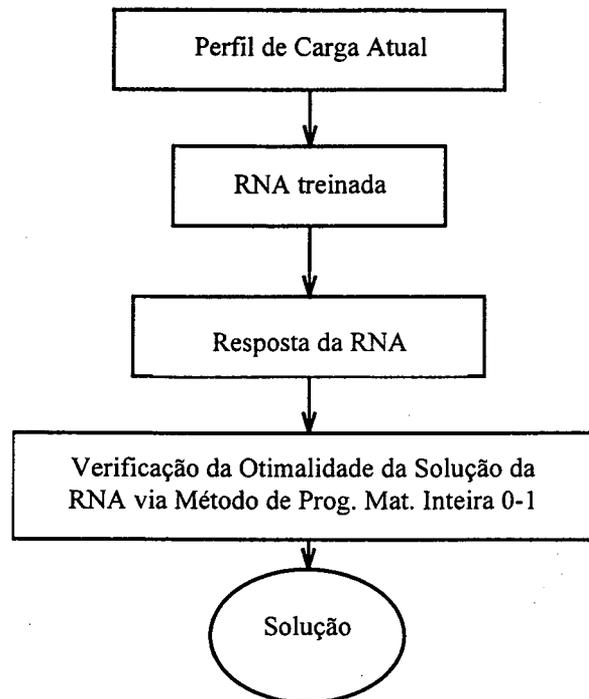


Figura 5.1 Interação entre RNA e Método de Programação Matemática Inteira 0-1

5.2 Formulação do Problema de Otimização através de Programação Matemática Inteira

Para a apresentação do desenvolvimento da formulação do método de programação matemática inteira 0-1 utiliza-se inicialmente o sistema de pequeno porte de 5 barras, da figura 5.2 [23], com a finalidade de apresentar em detalhes os passos do algoritmo para a obtenção da função objetivo necessária à solução do problema. Como segundo exemplo utiliza-se um alimentador real de 15 barras [22,24], com o objetivo de se analisar a aplicação do método a sistemas com mais de uma malha.

Convém destacar que a apresentação da formulação em conjunto com sua aplicação facilita sobremaneira sua compreensão, como pode ser observado a seguir.

5.2.1 Obtenção da Função Objetivo para um Sistema de 5 Barras

Os sistemas de distribuição podem ser representados por um diagrama em forma de árvore orientada. Os nós e os ramos correspondem, respectivamente, às barras do sistema e às linhas que conectam estas barras. A subestação é a única fonte alimentadora do circuito e corresponde à barra *swing* com tensão fixa e é o nó raiz da árvore [13].

Para o sistema de 5 barras da figura 5.2 a subestação corresponde ao nó 1, os restantes nós representam as barras de carga do sistema. A linha tracejada L_3 representa a alternativa inicial de chaveamento a ser utilizada na reconfiguração da rede de distribuição. Os dados referentes ao nó inicial, nó final e resistência de cada ramo encontram-se na tabela 5.1.

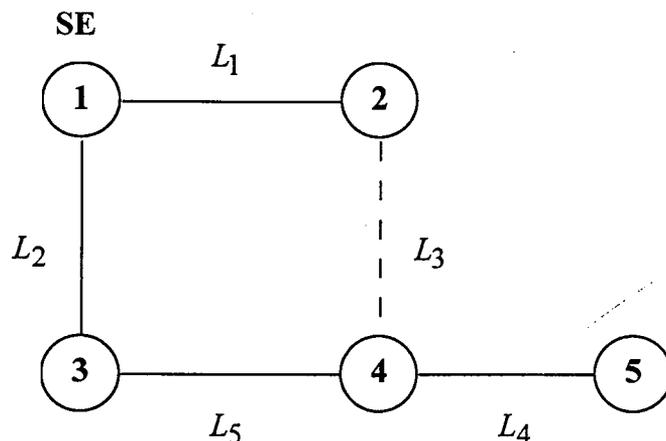


Figura 5.2 Sistema de 5 Barras com Chaveamento em L_3

Tabela 5.1 – Características do Sistema de 5 Barras

Ramo	Nó Inicial	Nó Final	Resistência (p.u.)
L_1	1	2	0,003
L_2	1	3	0,002
L_3	2	4	0,002
L_4	4	5	0,001
L_5	3	4	0,001

Na obtenção da função objetivo a ser minimizada (perdas resistivas do sistema), necessita-se inicialmente selecionar as variáveis binárias 0-1 (chaves seccionadores passíveis de mudança de estado) do sistema da figura 5.2, como será visto a seguir no passo 1.

Passo 1 – Determinação das Variáveis Inteiras para o Circuito Considerado.

Pode-se alterar o caminho da alimentação dos nós de uma malha do sistema, utilizando-se o ramo inicialmente aberto. Este ramo ao ser fechado formará uma malha, que necessita ser aberta em algum outro ponto, de modo a manter a radialidade do sistema. Abrindo-se esta malha em qualquer ponto diferente do ponto que foi fechado para formar a malha, muda-se o percurso da alimentação de algumas cargas do sistema.

O método permite que um nó por malha seja alimentado por outro caminho (outro lado da malha) utilizando-se o ramo aberto da malha. Desta maneira, os ramos que podem mudar de estado (variáveis inteiras) são os ramos que alimentam os nós 2 e 4 situados nas extremidades do ramo inicialmente aberto. Assim, para o sistema da figura 5.2, as variáveis inteiras de decisão são os ramos: L_1 e L_5 . Inicialmente, para a determinação das equações das correntes no ramos, as variáveis de decisão têm valor igual a um ($L_1 = 1$ e $L_5 = 1$).

Passo 2 – Determinação das Correntes que Contribuem para as Perdas em Cada Ramo.

Determinam-se as correntes nos ramos, em função dos nós de carga que já são alimentados através do ramo em análise e da corrente do nó que pode vir a ser alimentado pelo ramo em análise após o chaveamento (transferência de carga), considerando-se os estados das variáveis inteiras definidas no passo 1.

Para facilitar a implementação deste passo são definidas as seguintes regras gerais [51]:

- i) A expressão da corrente no ramo terá tantos termos de primeira ordem quantas forem as variáveis das malhas às quais pertence o ramo, além de um termo constante.
- ii) O coeficiente do termo constante é igual à soma das correntes dos nós que serão necessariamente alimentados pelo ramo (não situam-se nas extremidades do ramo aberto), mais a corrente do nó que pode vir a ser alimentado pelo ramo.
- iii) Os coeficientes das variáveis inteiras são:
 - para a variável do mesmo lado do ramo em questão: igual ao valor da corrente do nó alimentado pela variável,
 - para a variável do outro lado da malha do ramo em questão: igual a menos o valor da corrente do nó alimentado pela variável.

Assim, a situação atual dos ramos do sistema de 5 barras, representada na figura 5.2, está definida pelas 5 correntes de ramos como colocado a seguir.

$$I_{L_1} = L_1 I_2 + (1 - L_5)(I_4 + I_5) \quad (5.1)$$

O valor da corrente I_2 aparece multiplicado por L_1 pois a corrente do nó 2 (nó da extremidade do ramo inicialmente aberto) só poderá vir a ser alimentada pelo outro lado da

malha se o ramo L_1 for aberto ($L_1 = 0$). Utilizando raciocínio semelhante, enquanto permanecer $L_5 = 1$ as correntes dos nós 4 e 5 não contribuem para a corrente do ramo em questão.

$$I_{L_2} = I_3 + (1 - L_1)I_2 + L_5(I_4 + I_5) \quad (5.2)$$

Para este ramo a corrente do nó 3 não pode ser alimentada pelo outro lado da malha pela ação do chaveamento em L_3 , pois só se permite a transferência dos nós das extremidades do ramo aberto. Se L_1 permanecer igual a 1, a corrente do nó 2 não contribui para a corrente deste ramo. Se $L_5 = 0$, as correntes dos nós 4 e 5 não contribuem para a corrente do ramo.

$$I_{L_3} = (1 - L_1)I_2 + (1 - L_5)(I_4 + I_5) \quad (5.3)$$

Para o ramo inicialmente aberto, se nenhuma das variáveis mudar de estado a corrente deste ramo é nula. Isto significa que a solução do processo de otimização indicou que a malha já está otimizada e que nenhum outro chaveamento permitirá reduzir as perdas resistivas.

$$I_{L_4} = I_5 \quad (5.4)$$

A igualdade acima indica que a corrente deste ramo é sempre constante e igual à corrente do nó 5.

$$I_{L_5} = (1 - L_1)I_2 + L_5(I_4 + I_5) \quad (5.5)$$

O nó 2 contribui para a corrente deste ramo se $L_1 = 0$ e os nós 4 e 5 contribuem para a corrente deste ramo se $L_5 = 1$.

Considere-se que se deseja otimizar as perdas resistivas do sistema para os dados de carga da tabela 5.2, representadas por suas correntes.

Tabela 5.2 – Demandas do Sistema de 5 barras

Nó de Carga	Corrente (p.u.)
1	Subestação
2	0,3679
3	0,8560
4	0,5893
5	0,9714

Utilizando-se os valores de demanda da tabela 5.2 (correntes I_1 a I_5) nas equações (5.1) a (5.5), como exemplo, obtêm-se as equações para as correntes dos ramos, conforme abaixo:

$$I_{L_1} = 0,3679L_1 + (1 - L_5)(0,9714 + 0,5893) = 1,5607 + 0,3679L_1 - 1,5607L_5 \quad (5.6)$$

$$I_{L_2} = 0,8560 + (1 - L_1)0,3679 + L_5(0,9714 + 0,5893) = 1,2239 - 0,3679L_1 + 1,5607L_5 \quad (5.7)$$

$$I_{L_3} = (1 - L_1)0,3679 + (1 - L_5)(0,9714 + 0,5893) = 1,9286 - 0,3679L_1 - 1,5607L_5 \quad (5.8)$$

$$I_{L_4} = I_5 = 0,9714 \quad (5.9)$$

$$I_{L_5} = (1 - L_1)0,3679 + L_5(0,9714 + 0,5893) = 0,3679 - 0,3679L_1 - 1,5607L_5 \quad (5.10)$$

Os coeficientes destas equações encontram-se na tabela 5.3. Deve-se observar que o ramo L_4 não pertence à malha, não necessitando ser considerado para determinar a topologia ótima da malha. Entretanto, este ramo é necessário caso se deseje quantificar as perdas totais do sistema.

Tabela 5.3 – Coeficientes das Equações das Correntes nos Ramos

Ramo	Constante	L_1	L_5
L_1	1,5607	0,3679	-1,5607
L_2	1,2239	-0,3679	1,5607
L_3	1,9286	-0,3679	-1,5607
L_4	0,9714		
L_5	0,3679	-0,3679	1,5607

Passo 3 – Determinação dos Valores Quadráticos das Correntes dos Ramos.

Após se determinar a contribuição de cada nó de carga para a função de perdas do ramo em questão, determina-se o valor quadrático para a corrente do ramo. Esse valor quadrático passa

a ter os seguintes termos: constante, de primeira ordem e de segunda ordem. Estes termos são definidos como a seguir.

Termo constante: o termo constante é igual ao quadrado do valor das correntes dos nós necessariamente alimentados pelo ramo mais o valor de corrente do nó que pode vir a ser alimentado pelo ramo em questão. Excluem-se as correntes dos nós alimentados pelas variáveis inteiras do mesmo lado do ramo considerado, ou seja, o termo constante do valor quadrático da corrente do ramo é igual ao quadrado do termo constante da tabela 5.3. Assim, para o ramo L_1 tem-se:

$$(0,5893 + 0,9714)^2 = 1,5607^2 = 2,4358$$

Termo de primeira ordem: o número de variáveis de primeira ordem é igual ao número de variáveis inteiras das malhas às quais pertence o ramo. Seu valor corresponde à soma de duas parcelas. A primeira parcela é:

- para variável do mesmo lado da malha: igual a duas vezes o valor do termo constante multiplicado pela corrente do nó alimentado pela variável inteira ou,
- para variável do outro lado da malha: igual a menos duas vezes o valor do termo constante multiplicado pelo valor da corrente do nó alimentado pela variável inteira.

A segunda parcela é igual ao quadrado do coeficiente, encontrado na tabela 5.3, da variável para a qual se está determinando o coeficiente.

Exemplo: na determinação da equação da corrente no ramo L_1 o coeficiente da variável de decisão L_1 (do mesmo lado da malha) é:

$$+ 2 \cdot 1,5607 \cdot 0,3679 + 0,3679^2 = 1,2837$$

Termo de segunda ordem: termo onde aparecem todas as combinações possíveis das variáveis inteiras da malha tomadas duas a duas. Este produto das duas variáveis tem como coeficiente:

- $2 \cdot \text{coef}L_x \cdot \text{coef}L_y$, quando os dois nós de carga que são alimentados pelas variáveis inteiras do produto estão, ou não, simultaneamente sendo alimentados pelo ramo em questão.

- $-2 \cdot \text{coef}L_x \cdot \text{coef}L_y$, quando um dos dois nós de carga que são alimentados pelas variáveis inteiras do produto não está sendo alimentado pelo ramo em questão.

Exemplo: para o ramo L_1 o coeficiente do termo L_1L_5 é:

$$+ 2 \cdot 0,3679 \cdot -1,5607 = -1,1484$$

Com estas considerações e com os valores da tabela 5.3, obtêm-se os valores da tabela 5.4.

Tabela 5.4 – Coeficientes das Equações das Correntes nos Ramos Elevadas ao Quadrado

Ramo	Constante	L_1	L_5	L_1L_5
L_1	2,4358	1,2837	-2,4358	-1,1484
L_2	1,4979	-0,7652	6,2561	-1,1484
L_3	3,7195	-1,2837	-3,5841	1,1484
L_4	0,9436			
L_5	0,1354	-0,1354	3,5841	-1,1484

Por fim, necessita-se determinar a função objetivo a ser minimizada e suas restrições.

Passo 4 - Determinação da Função Objetivo

Inicialmente o valor quadrático da corrente em cada ramo do sistema é multiplicado pela respectiva corrente do ramo. A seguir, procede-se ao somatório das perdas de cada ramo do sistema. Este somatório corresponderá à função objetivo a ser minimizada e está na última linha da tabela 5.5.

Tabela 5.5 - Perdas nos Ramos do Sistema de 5 Barras

Ramo	Constante	L_1	L_5	L_1L_5
L_1	0,007307	0,003851	-0,007307	-0,003445
L_2	0,002996	-0,001530	0,01251	-0,002297
L_3	0,007439	-0,002567	-0,007168	0,002297
L_4	0,0009436			
L_5	0,0001354	-0,0001354	0,003584	-0,001148
Σ	0,01882	-0,0003841	0,001619	-0,004593

$$F.O. = \min(0,01882 - 0,0003841L_1 + 0,001619L_5 - 0,004593L_1L_5) \quad (5.11)$$

Para que não haja nenhuma carga sem alimentação após a reconfiguração (continuidade do fornecimento), ao menos uma das variáveis de decisão da malha necessita estar sendo utilizada (ramo fechado). Caso contrário, ter-se-iam os nós de carga das extremidades da alternativa de chaveamento sem possibilidade de alimentação. Assim, a função objetivo acima é minimizada considerando a restrição abaixo:

$$L_1 + L_5 \geq 1 \tag{5.12}$$

A solução para o processo de otimização pode ser observada na tabela 5.6.

Tabela 5.6 – Obtenção da Solução para o Sistema de 5 Barras

Estado de L_1	Estado de L_5	Perdas Totais (p.u.)
1	0	0,01844
0	1	0,02044
1	1	0,01546

Esta solução indica que as variáveis inteiras L_1 e L_5 não devem mudar de estado já que a malha (o sistema) encontra-se otimizado em relação às perdas resistivas. Esta solução, topologia ótima do sistema, confirma a solução inicial fornecida pela RNA.

5.2.2 Sistema de 15 Barras

Como segundo exemplo utiliza-se o alimentador da figura 5.3 a seguir. Este alimentador, que faz parte do sistema de distribuição de Florianópolis, é composto por 1 subestação e 15 pontos de carga operando à tensão nominal de 13,8 kV. Os dados deste alimentador (dados de carga, nós inicial e final, e impedâncias dos ramos) encontram-se na tabela 6.1, pois este sistema também será utilizado nas aplicações da metodologia apresentada no capítulo 6.

Passo 1 - Determinação das Variáveis Inteiras para o Circuito Considerado: para este sistema constata-se a partir de uma inspeção na figura 5.3 que as variáveis inteiras são: L_8 , L_{10} , L_{14} e L_{17} , visto serem estes os ramos adjacentes ao ramo de intercâmbio (ramo com a chave seccionadora aberta).

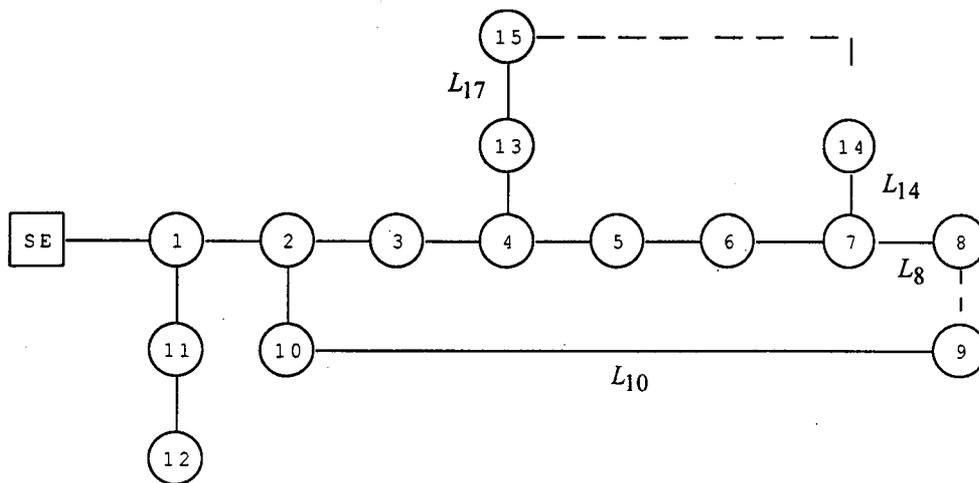


Figura 5.3 - Sistema real com 15 barras

Passo 2 - Determinação das Correntes que Contribuem para as Perdas em Cada Ramo: considerando-se os possíveis estados das variáveis inteiras definidas no passo 1, obtêm-se as correntes nos ramos do alimentador, as quais são listadas na tabela 5.7. Utilizando-se as equações das correntes dos ramos da tabela 5.7 com os dados de carga do sistema (tabela 5.8), obtêm-se os coeficientes das equações das correntes nos ramos (tabela 5.9).

Tabela 5.7 – Quadro Resumo das Equações das Correntes nos Ramos do Sistema

Ramo	Equação da Corrente do Ramo	Ramo	Equação da Corrente do Ramo
L_1	$\sum_{n=1}^{15} I_n$	L_{10}	$(1 - L_8)I_8 + L_{10}I_9$
L_2	$\sum_{\substack{n=2 \\ n \neq 11,12}}^{15} I_n$	L_{11}	$I_{11} + I_{12}$
L_3	$\sum_{n=3}^7 I_n + L_8 I_8 + (1 - L_{10})I_9 + \sum_{n=13}^{15} I_n$	L_{12}	I_{12}
L_4	$\sum_{n=4}^7 I_n + L_8 I_8 + (1 - L_{10})I_9 + \sum_{n=13}^{15} I_n$	L_{13}	$I_{13} + (1 - L_{14})I_{14} + L_{17}I_{15}$
L_5	$\sum_{n=5}^7 I_n + L_8 I_8 + (1 - L_{10})I_9 + L_{14}I_{14} + (1 - L_{17})I_{15}$	L_{14}	$L_{14}I_{14} + (1 - L_{17})I_{15}$
L_6	$\sum_{n=6}^7 I_n + L_8 I_8 + (1 - L_{10})I_9 + L_{14}I_{14} + (1 - L_{17})I_{15}$	L_{15}	$(1 - L_{14})I_{14} + (1 - L_{17})I_{15}$
L_7	$I_7 + L_8 I_8 + (1 - L_{10})I_9 + L_{14}I_{14} + (1 - L_{17})I_{15}$	L_{16}	$I_{10} + (1 - L_8)I_8 + L_{10}I_9$
L_8	$L_8 I_8 + (1 - L_{10})I_9$	L_{17}	$(1 - L_{14})I_{14} + L_{17}I_{15}$
L_9	$(1 - L_8)I_8 + (1 - L_{10})I_9$		

Passo 3 - Determinação dos Valores Quadráticos das Correntes dos Ramos: utilizando-se o procedimento proposto para a determinação dos coeficientes das equações das correntes nos ramos, quando elevadas ao quadrado, como foi visto detalhadamente para o primeiro exemplo, pode-se obter os coeficientes da tabela 5.10.

Tabela 5.8 - Demandas do Sistema

Nó de Carga	Corrente (p.u.)
1	0,0473
2	0,1231
3	0,1374
4	nó de ligação
5	0,4056
6	0,1533
7	0,1428
8	0,3905
9	0,2353
10	0,5593
11	0,2329
12	0,4447
13	0,1312
14	0,2324
15	0,2852

Tabela 5.9 – Coeficientes da Equação da Corrente nos Ramos do Sistema de 15 Barras

Ramo	Constante	L_8	L_{10}	L_{14}	L_{17}
L_1	3,5210				
L_2	2,7961				
L_3	1,7232	0,3905	-0,2353		
L_4	1,5858	0,3905	-0,2353		
L_5	1,2222	0,3905	-0,2353	0,2324	-0,2852
L_6	0,8166	0,3905	-0,2353	0,2324	-0,2852
L_7	0,6633	0,3905	-0,2353	0,2324	-0,2852
L_8	0,2353	0,3905	-0,2353		
L_9	0,6258	-0,3905	-0,2353		
L_{10}	0,3905	-0,3905	0,2353		
L_{11}	0,6776				
L_{12}	0,4447				
L_{13}	0,3636			-0,2324	0,2852
L_{14}	0,2852			0,2324	-0,2852
L_{15}	0,5176			-0,2324	-0,2852
L_{16}	0,9498	-0,3905	0,2353		
L_{17}	0,2324			-0,2324	0,2852

Passo 4 – Determinação da função objetivo: multiplicando-se as equações quadráticas de corrente nos ramos da tabela 5.10 pelos respectivos valores das resistências em p.u. dos ramos, obtêm-se os valores das perdas nos ramos do sistema (tabela 5.11). Efetuando-se o somatório das perdas dos ramos (última linha da tabela 5.11) obtém-se, por fim, a função objetivo desejada. Esta função (equação 5.12) ao ser minimizada fornecerá a topologia ótima do sistema para o perfil de carga em análise.

Tabela 5.10 – Coeficientes do Quadrado das Correntes dos Ramos do Sistema de 15 Barras

Ramo	Cte.	L_8	L_{10}	L_{14}	L_{17}	L_8L_{10}	L_8L_{14}	L_8L_{17}	$L_{10}L_{14}$	$L_{10}L_{17}$	$L_{14}L_{17}$
L_1	12,3974										
L_2	7,8182										
L_3	2,9694	1,4983	-0,7556			-0,1838					
L_4	2,5148	1,3910	-0,6909			-0,1838					
L_5	1,4938	1,1070	-0,5198	0,6221	-0,6158	-0,1838	0,1815	-0,2227	-0,1094	0,1342	-0,1326
L_6	0,6668	0,7903	-0,3289	0,4336	-0,3844	-0,1838	0,1815	-0,2227	-0,1094	0,1342	-0,1326
L_7	0,4400	0,6705	-0,2568	0,3623	-0,2970	-0,1838	0,1815	-0,2227	-0,1094	0,1342	-0,1326
L_8	0,0554	0,3363	-0,0554			-0,1838					
L_9	0,3916	-0,3363	-0,2391			0,1838					
L_{10}	0,1525	-0,1525	0,2391			-0,1838					
L_{11}	0,4591										
L_{12}	0,1978										
L_{13}	0,1322			-0,1150	0,2887						-0,1326
L_{14}	0,0813			0,1866	-0,0813						-0,1326
L_{15}	0,2679			-0,1866	-0,2139						0,1326
L_{16}	0,9021	-0,5893	0,5023			-0,1838					
L_{17}	0,0540			-0,0540	0,2139						-0,1326

Tabela 5.11 - Perdas nos Ramos do Sistema de 15 Barras (kW)

Ramo	Constante	L_8	L_{10}	L_{14}	L_{17}	L_8L_{10}	L_8L_{14}	L_8L_{17}	$L_{10}L_{14}$	$L_{10}L_{17}$	$L_{14}L_{17}$
L_1	56,1804										
L_2	4,7622										
L_3	1,1693	0,5901	-0,2976			-0,0724					
L_4	0,2905	0,1607	-0,0798			-0,0212					
L_5	2,6669	1,9764	-0,9280	1,1106	-1,0994	-0,3281	0,3240	-0,3977	-0,1953	0,2396	-0,2367
L_6	2,4021	2,8466	-1,1849	1,5618	-1,3849	-0,6620	0,6538	-0,8024	-0,3940	0,4835	-0,4775
L_7	1,1043	1,6830	-0,6445	0,9094	-0,7455	-0,4613	0,4556	-0,5591	-0,2745	0,3369	-0,3327
L_8	0,0724	0,4397	-0,0724			-0,2403					
L_9	0,9789	-0,8405	-0,5977			0,4593					
L_{10}	1,1218	-1,1218	1,7592			-1,3519					
L_{11}	1,6467										
L_{12}	0,4631										
L_{13}	1,1482			-0,9987	2,5077						-1,1513
L_{14}	0,1281			0,2939	-0,1281						-0,2088
L_{15}	0,4600			-0,3204	-0,3673						0,2276
L_{16}	9,4741	-6,1889	5,2756			-1,9299					
L_{17}	0,4254			-0,4254	1,6848						-1,0441
Σ	88,4944	-0,4547	3,2299	2,1312	0,4673	-4,6078	1,4334	-1,7592	-0,8638	1,0600	-3,2235

$$F.O. = \min(84,4944 - 0,4547L_8 + 3,2299L_{10} + 2,1312L_{14} + 0,4673L_{17} - 4,6078L_8L_{10} + 1,4334L_8L_{14} - 1,7592L_8L_{17} - 0,8638L_{10}L_{14} + 1,0600L_{10}L_{17} - 3,2235L_{14}L_{17}) \quad (5.12)$$

A função objetivo acima, a qual representa as perdas totais do sistema, está sujeita às restrições de continuidade e radialidade do sistema (nenhuma carga deve ficar sem fornecimento de energia e toda malha formada a partir do fechamento de uma chave seccionadora de um ramo deve ser aberta em algum ponto da malha para manter a radialidade). Assim, sua otimização deve considerar as restrições representadas abaixo.

$$L_8 + L_{10} \geq 1 \quad (5.13)$$

$$L_{14} + L_{17} \geq 1 \quad (5.14)$$

A solução da função objetivo da equação (5.12) considerando-se as restrições das equações (5.13) e (5.14) fornece como resposta: $L_8 = L_{10} = L_{14} = L_{17} = 1$ e $F.O. = 81,91$ kW. Esta solução confirma a topologia inicial como topologia ótima do sistema.

5.3 Método de Solução

Observando-se a função objetivo da equação (5.12) constata-se que a mesma depende de 4 variáveis inteiras 0-1, ou seja, depende das variáveis L_8 , L_{10} , L_{14} e L_{17} . As variáveis L_8 e L_{10} correspondem à malha 1 e as variáveis L_{14} e L_{17} correspondem à malha 2 do sistema de distribuição.

O método de programação matemática inteira 0-1 como formulado originalmente em [51] não pode ser utilizado quando as variáveis de decisão pertencem a mais de uma malha simultaneamente, o que não era o caso da configuração do sistema da figura 5.3, mas pode vir a ocorrer. Esta restrição deve-se ao fato do método de programação matemática inteira proposto naquele trabalho determinar transferências de carga entre subestações, cujos alimentadores individualmente considerados não possuem possibilidades de reconfiguração (figura 5.4).

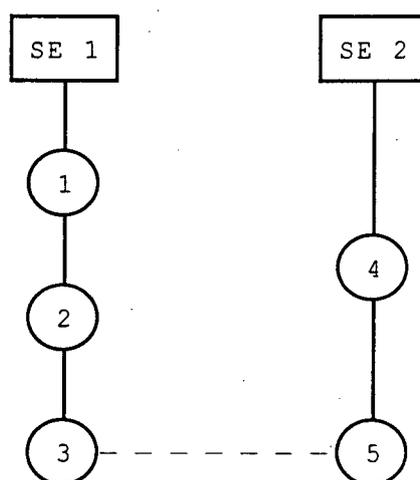


Figura 5.4 – Transferência de Carga entre Subestações

Desta maneira, para possibilitar a utilização do método de programação matemática binária inteira 0-1, em se tratando de um alimentador com possibilidades de auto-restabelecimento [36,52], definiu-se um procedimento de busca da configuração ótima do sistema análogo ao procedimento de outros trabalhos [1,32] (figura 5.5):

- obter a função objetivo para cada malha do sistema separadamente;

- após a obtenção de cada função objetivo, com a respectiva restrição da malha, a mesma é otimizada para determinar a máxima redução das perdas da malha;
- quando se conhecem as reduções nas perdas resistivas para cada malha, comparam-se estas reduções para determinar a maior;
- reconfigura-se o sistema adotando-se o chaveamento que causa a maior redução nas perdas obtida no passo anterior, obtendo-se a configuração inicial da próxima iteração.

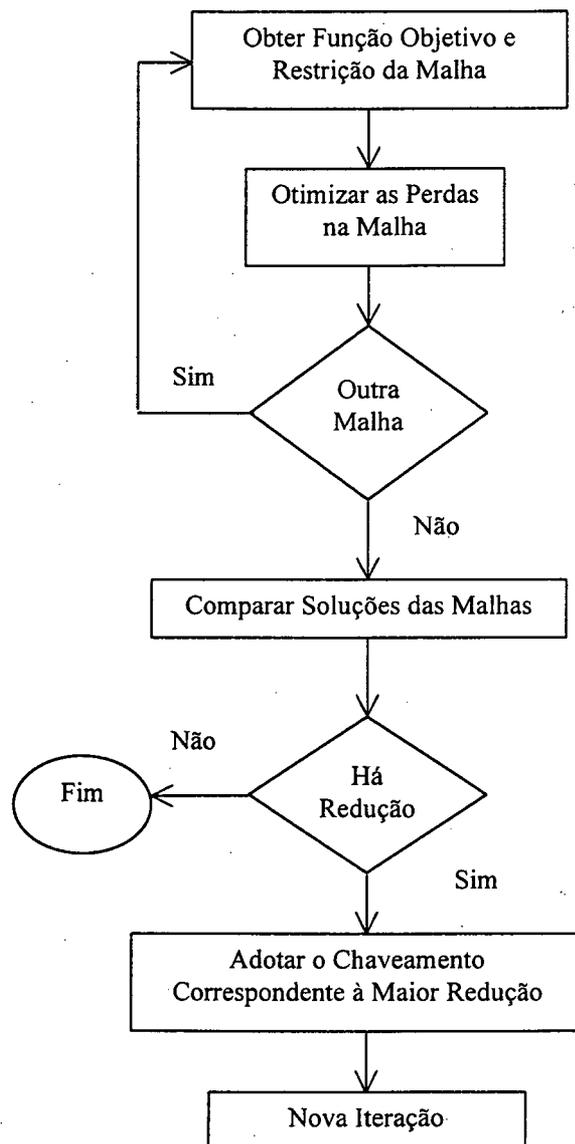


Figura 5.5 – Procedimento de Busca da Solução Ótima para Sistemas com Auto-Restabelecimento

Este procedimento de determinação da topologia ótima de cada malha do sistema de distribuição, quando da otimização da função objetivo, necessita considerar somente três das quatro possibilidades das variáveis de decisão da malha (0-1, 1-0 e 1-1) [29], visto que a possibilidade 0-0 é excluída em função da restrição de continuidade do fornecimento de energia às barras de carga, o que simplifica a otimização das perdas da malha.

Nas aplicações da metodologia desenvolvida nesta tese, no capítulo a seguir, observar-se-á a aplicação deste procedimento de busca da topologia ótima de sistemas de distribuição.

5.4 Conclusão

Como pode ser observado a partir dos sistemas analisados o método de programação matemática inteira 0-1 permite a obtenção da topologia ótima em nível de perdas resistivas, considerando-se todos os possíveis estados das chaves seccionadoras do sistema.

Comparando-se com o método de solução aproximada (método heurístico *branch-exchange* do capítulo 4) o método de programação matemática inteira tende a ser menos eficiente (em termos de recursos computacionais) quanto maior for o porte do sistema, embora sua solução seja mais precisa em função de não adotar simplificações na obtenção da função objetivo a ser otimizada.

A aplicação do método de programação matemática fica fortemente condicionada à sua condição inicial, isto é, fica condicionada à eficiência da solução fornecida pelas RNA quando estes métodos forem utilizados em conjunto. A aplicação do método de programação inteira deve ser considerada, entretanto, em caso de dúvida de ótimo local, o qual pode ocorrer em função do método utilizado durante a obtenção do conjunto de treinamento ou, de acordo com a decisão do operador se a RNA fornecer resultado diferente do de otimização.

Em função dessas características, o método de programação matemática inteira 0-1 foi adotado, na metodologia apresentada a seguir, para verificar a otimalidade da solução fornecida pelas RNA, quando existe desconfiança de que a solução fornecida pelas RNA não representa a melhor topologia. Os resultados da aplicação do método de programação inteira, com esse objetivo, podem ser observados a seguir.

Capítulo 6 – Metodologia e Aplicações

6.1 Introdução

No capítulo 2 foram apresentadas diferentes técnicas aplicadas à minimização de perdas resistivas de sistemas de distribuição, através da reconfiguração dos alimentadores primários destes sistemas elétricos. Dentre os diversos trabalhos apresentados, encontra-se a pioneira proposta desenvolvida por Kim e Young [34], a qual incorpora a utilização de técnicas de redes neurais artificiais (RNA) à solução do problema, objetivando o emprego da metodologia à operação em tempo real da rede primária de sistemas de distribuição. Convém destacar, como foi visto no capítulo 2, que certos aspectos daquele trabalho (a representação da variabilidade da carga, a definição do conjunto teste utilizado na validação dos resultados e os recursos computacionais utilizados) deveriam, a princípio, ser melhor ponderados. Entretanto, devem ser destacados o ineditismo e a contribuição da metodologia no gerenciamento a mínimas perdas resistivas dos sistemas radiais de distribuição.

6.2 Algoritmo de RNA aplicado à Reconfiguração de Sistemas de Distribuição

Este capítulo tem como finalidade analisar a adequação e robustez da metodologia composta pelos 4 passos apresentados no fluxograma da figura 6.1 [22,23]. Sobre este fluxograma pode-se salientar os seguintes pontos:

- Um método heurístico iterativo foi apresentado no capítulo 4 para obtenção da melhor topologia em nível de perdas resistivas de sistemas de distribuição. Basicamente, a heurística do método consiste em somente se analisar a transferência de carga para outras seções do sistema de distribuição com maior tensão, comparando-se com a tensão em que era alimentada a carga antes da transferência. Este método heurístico foi utilizado para obtenção das topologias com mínimas perdas resistivas durante o passo 2, para cada um dos perfis de carga obtidos via Simulação Monte Carlo (passo 1).
- Conceitos fundamentais de RNA e o detalhamento do algoritmo de treinamento *backpropagation*, bastante aplicado em sistemas de potência, utilizado em RNA do tipo *multilayer perceptrons* (MLP), são encontrados no capítulo 3. O algoritmo de treinamento *backpropagation* e redes MLP foram utilizados no passo 3. Este algoritmo

de treinamento, como se verá a seguir, mostrou-se adequado para aplicação no treinamento de RNA a serem utilizadas na definição da topologia com mínimas perdas resistivas dos sistemas radiais analisados.

- Uma técnica de programação matemática inteira 0-1 foi apresentada no capítulo 5, a qual pode vir a ser utilizada a critério do decisor, para verificar a otimalidade da solução fornecida pelas RNA de acordo com o passo 4. O critério principal para a sua aplicação à solução fornecida pelas RNA, deve se basear no nível de acertos das redes neurais treinadas. Obtendo-se índice de acertos da ordem dos apresentados neste capítulo (nível de acertos superior aos apresentados em [34]), pode-se optar diretamente pela reconfiguração em tempo real dos sistemas de distribuição a partir da solução apresentada pelas RNA, sem o emprego do método de programação matemática inteira. O seu emprego pode ainda, ser justificado pela dúvida da qualidade do conjunto de treinamento.

É importante destacar que os quatro passos do algoritmo são executados na ordem da figura 6.1, e que cada passo é executado somente uma vez, se o número de sorteios inicialmente escolhido mostrar-se adequado para a solução do problema através das RNA. Se o número de sorteios se mostrar insuficiente, do passo 3 retorna-se ao passo 1 considerando-se a obtenção de maior número de perfis de carga, de modo a aumentar o conjunto de dados para efetuar uma nova fase de treinamento. Estes quatro passos serão discutidos nos itens 6.1.1 a 6.1.4, a seguir.

6.2.1 Sorteio via Simulação Monte Carlo

O sorteio dos perfis de carga via Simulação Monte Carlo visa representar de maneira adequada a variabilidade da carga, de modo que a metodologia apresente resposta apropriada às futuras situações de carga. A estocasticidade da demanda, que será considerada no processo de treinamento das RNA do passo 3, é representada através de uma distribuição normal com um desvio padrão adotado em torno do valor médio de cada ponto de carga, de modo análogo a [37,38]. Quanto maior o desvio padrão da carga, maior será o número de configurações ótimas em nível de perdas obtidas no passo 2.

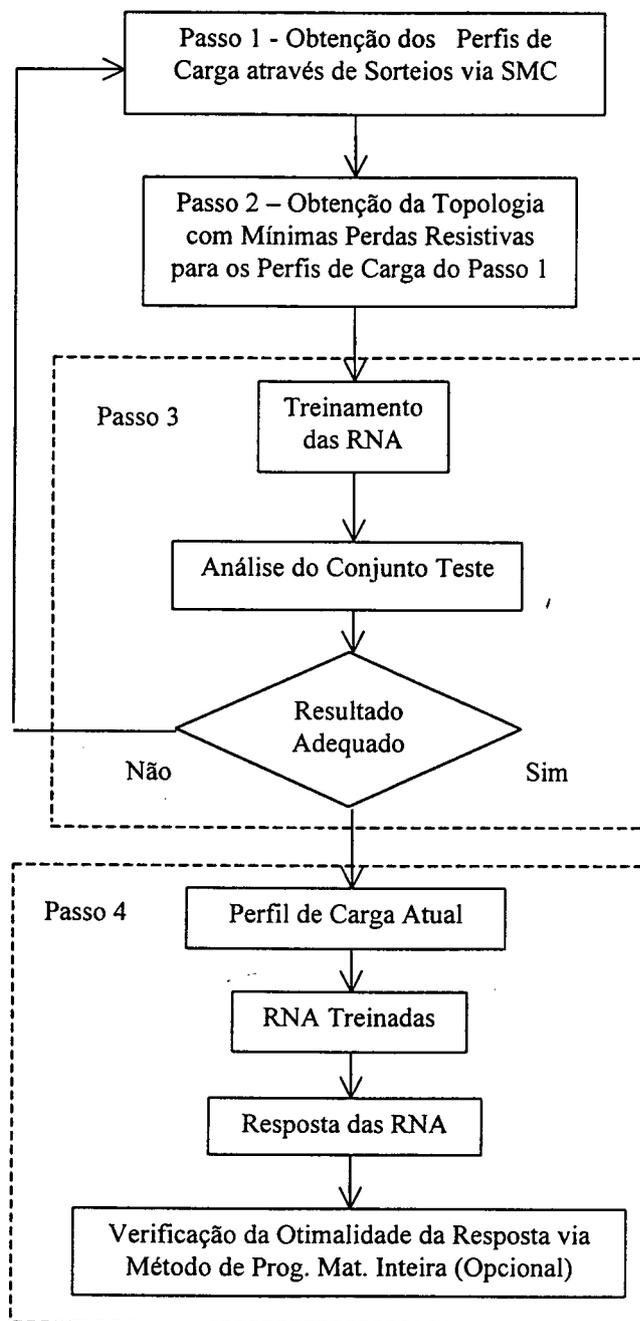


Figura 6.1 - Fluxograma do Algoritmo Proposto

O desvio padrão de 10% adotado nas aplicações apresentadas nos itens 6.3 e 6.4 pode ser considerado demasiado elevado para o caso brasileiro que apresenta um desvio anual da ordem de 2 a 5%. A finalidade de se adotar uma variabilidade maior é de prevenção no caso de uma variação atípica de carga e, também procurar fornecer um maior número de topologias ótimas (fornecidas pelo passo 2) para o treinamento das RNA, aumentando-se assim a robustez do processo.

6.2.2 A Minimização de Perdas Resistivas através de Método Heurístico

No passo 2 utiliza-se o método de Baran e Wu, modificado por Jasmon e Lee [32], para se obter a configuração ótima em nível de perdas, para cada condição inicial de carga obtida no passo 1. A partir da configuração inicial, a rede de distribuição é reconfigurada utilizando-se os ramos que apresentam chaves seccionadoras abertas, obtendo-se a topologia ótima em nível de perdas para cada perfil de carga desejado.

O algoritmo de minimização de perdas é utilizado tantas vezes quanto for o número adotado de sorteios via Simulação Monte Carlo, obtendo-se assim uma configuração ótima para cada perfil de carga sorteado. Deve-se ressaltar que a configuração que aparece com maior frequência como solução do problema na maioria das vezes não é, necessariamente, a que apresenta a menor perda média de potência ativa [41].

Os perfis de carga sorteados no passo 1 e as correspondentes topologias com mínimas perdas elétricas resistivas para cada perfil de carga obtidas através de método heurístico, neste passo, constituem o conjunto entrada-saída de treinamento das RNA do passo 3.

Como apresentado em trabalhos anteriores [12,23,41], a minimização de perdas proporciona implicitamente uma melhora no perfil de tensão do sistema, em virtude da diminuição do carregamento do sistema com a conseqüente redução das perdas elétricas.

6.2.3 O Treinamento de RNA para a Solução do Problema

A rede neural implementada é do tipo MLP (*multilayer perceptrons*) treinada com o algoritmo de retropropagação de erros. A rede neural tipo MLP é recomendada para aplicações de mapeamento não-linear entrada-saída [18,48,55], sendo por isto utilizada neste trabalho. Esta também é a topologia de RNA utilizada nos trabalhos encontrados na literatura que empregam RNA na obtenção dos chaveamentos que levam à topologia com mínimas perdas resistivas [22,23,34].

Para cada um dos estados de carga sorteados no passo 1 é obtida no passo 2 a configuração ótima da rede em nível de perdas correspondente a aquele perfil de carga. Assim sendo, têm-se os perfis de carga como dado de entrada da rede neural e como dado de saída as

configurações ótimas correspondentes a cada perfil de carga. O número de conjuntos entrada-saída da rede neural é igual ao número de sorteios Monte Carlo.

Para cada topologia ótima obtida no passo 2 é treinada uma RNA. Considere-se, como exemplo, três topologias ótimas em nível de perdas. Neste caso serão atribuídas uma RNA para cada uma das topologias ótimas e o treinamento é efetuado da seguinte maneira:

i) para a RNA correspondente à topologia ótima 1, o conjunto de dados entrada-saída de treinamento é assim composto:

Dado de Entrada	Dado de Saída
perfil de carga que corresponda à topologia 1	valor próximo a 1
perfil de carga que corresponda às topologias 2 ou 3	valor próximo a 0

ii) RNA correspondente à topologia ótima 2, o conjunto de dados de treinamento é:

Dado de Entrada	Dado de Saída
perfil de carga que corresponda à topologia 2	valor próximo a 1
perfil de carga que corresponda às topologias 1 ou 3	valor próximo a 0

ii) RNA correspondente à topologia ótima 3:

Dado de Entrada	Dado de Saída
perfil de carga que corresponda à topologia 3	valor próximo a 1
perfil de carga que corresponda às topologias 1 ou 2	valor próximo a 0

O número de pares de treinamento para cada RNA depende de um processo iterativo supervisionado pelo decisor ou depende de níveis de precisão (percentual de acertos para o conjunto teste) já definidos no próprio algoritmo. Desta maneira, a decisão pode aumentar também o número de sorteios via Simulação Monte Carlo necessários na etapa de treinamento da rede neural, quando se deseja uma eficiência maior do que a obtida com o conjunto de treinamento atual.

De acordo com as características do conjunto de treinamento de cada uma das RNA acima, adota-se neste trabalho a seguinte convenção:

➤ as RNA após a fase de treinamento deverão atribuir valor próximo a 0 quando, para o perfil de carga sob análise, a configuração ótima for diferente da configuração ótima para a qual a RNA foi treinada;

➤ deverão atribuir valor próximo a 1 quando, para o perfil de carga considerado, a configuração ótima for igual à configuração ótima para a qual a RNA foi treinada.

Portanto, após o treinamento das RNA, as mesmas deverão atribuir para cada perfil de carga valores indicativos próximos a 0,0 ou 1,0, que se esperam sejam iguais aos obtidos caso fosse executado o algoritmo de minimização de perdas original (passo 2), isto é, espera-se que as RNA resolvam o problema da reconfiguração, porém automaticamente e rapidamente, para viabilizar sua aplicação em tempo real.

Ao final, ter-se-á um conjunto de RNA aptas para fornecerem a topologia ótima correspondente ao perfil de carga real do sistema de distribuição. Esta informação pode ser utilizada imediatamente para a reconfiguração do sistema automatizado ou, a critério do decisor, pode ser verificada sua otimalidade, utilizando-se um método de programação matemática inteira 0-1.

6.2.4 Verificação da Otimalidade através de Programação Matemática Inteira

O algoritmo de programação matemática binária inteira 0-1, aplicado como detalhado no capítulo 5, servirá para verificar a habilidade das RNA em selecionar as topologias do sistema correspondentes aos diferentes perfis de carga nas barras do sistema [22,23].

Quando da aplicação das RNA em tempo real, não se terá nenhuma outra informação a respeito da topologia ótima correspondente ao perfil atual de carga, além da solução fornecida pelas RNA. Este fato significa que não se tem garantia da otimalidade da topologia fornecida pelas RNA, excetuando-se o conhecimento do comportamento das RNA frente ao conjunto de treinamento e ao conjunto teste.

As aplicações do método de programação matemática inteira 0-1, aos sistemas teste deste capítulo foram efetuadas para alguns dos perfis de carga mal-classificados do conjunto teste pelas RNA. Este procedimento pode ser sugerido quando da utilização da metodologia desta tese

em tempo real, para ratificar as decisões obtidas via RNA, e consiste em aplicar o método de programação matemática para algumas das primeiras condições de carga ocorridas após o início da operação automatizada do sistema. Apresentando as RNA um nível de acertos considerado adequado pelo decisor, não se utiliza mais o método de programação matemática para validar a solução fornecida pelas RNA.

Para a verificação da otimalidade da solução dos perfis mal-classificados, considerem-se três topologias ótimas (RNA 1, RNA 2 e RNA 3) com:

- a RNA 1 é a rede treinada que representa a relação entre os perfis de cargas que levam à topologia ótima 1;
- a RNA 2 é a rede treinada que representa a relação entre os perfis de cargas que levam à topologia ótima 2;
- por último, a RNA 3 é treinada para representar a relação entre os perfis de cargas que levam à topologia ótima 3 (como visto no item anterior).

Quando, ao se submeter um igual perfil de carga (com configuração ótima 1) para as três RNA acima, resultar que a RNA 1 apresenta um atributo (valor) no neurônio da camada de saída superior aos valores fornecidos pelas demais RNA, tem-se que a topologia ótima referente a este perfil de carga será a topologia 1. Neste caso pode-se afirmar que o conjunto de RNA apresentaram a resposta correta. Caso contrário, ou seja, valor superior para a RNA 2 ou RNA 3 (resposta incorreta/perfil mal-classificado), o método de programação matemática deverá, a princípio, a partir desta condição inicial (configuração 2 ou 3) obter a configuração ótima 1 em poucas iterações (uma ou duas), possibilitando também a execução deste passo em tempo real.

6.3 Sistema Teste 1

Como primeiro sistema teste utiliza-se o alimentador da figura 6.2 a seguir. Este alimentador faz parte do sistema de distribuição da Região Metropolitana da Grande Florianópolis, sendo composto por uma subestação, 15 pontos de carga e nível de tensão de 13,8 kV. A carga total da configuração é 3.636 kW e 1.551 kVAr [14,15,22,24,25]. Os dados deste sistema (conexão dos nós, cargas e impedâncias das linhas) encontram-se na tabela 6.1.

Este sistema radial de distribuição possui duas outras linhas (ramos tracejados na figura 6.2, tabela 6.2) que irão ser utilizadas como alternativas de chaveamento durante a etapa de reconfiguração, no passo 2, com a finalidade de melhorar o nível de perdas elétricas do sistema.

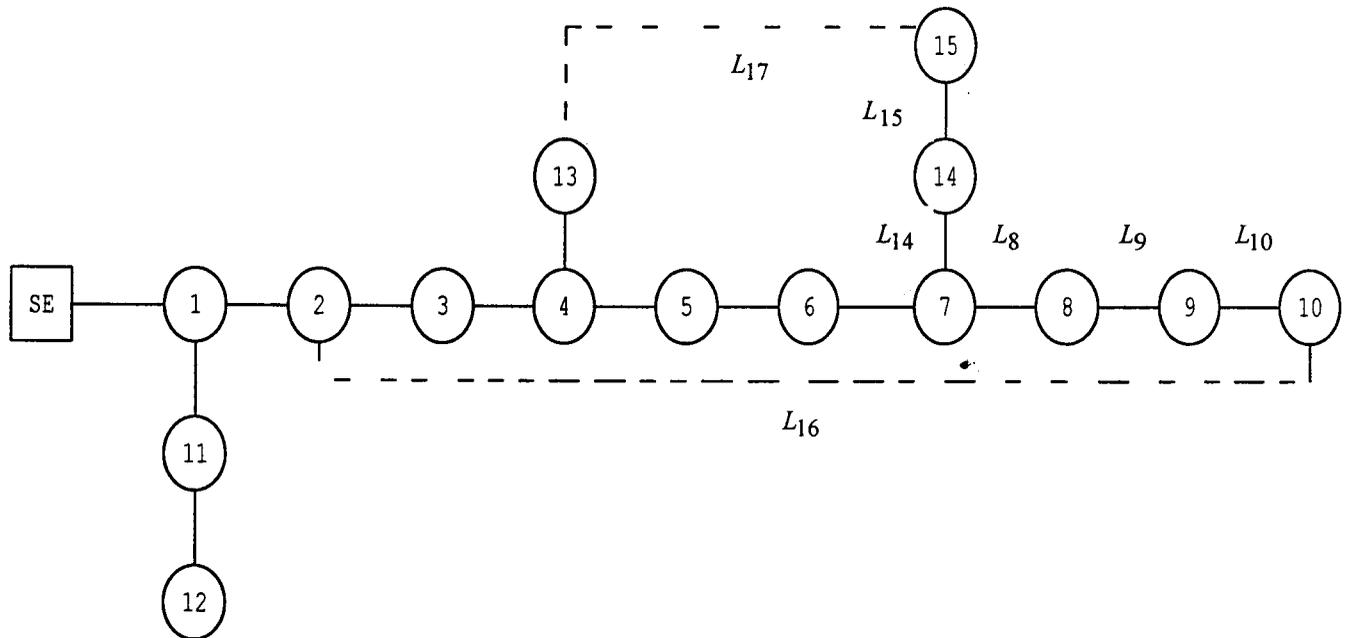


Figura 6.2 - Alimentador Córrego Grande - Aeroporto Hercílio Luz (Florianópolis)

Sempre que um dos ramos L_{16} e L_{17} (que constituem as alternativas de chaveamento) é utilizado, forma-se uma malha no sistema de distribuição, a qual deverá ser aberta (no ponto ótimo em nível de perdas) para se manter a radialidade do sistema.

A partir dos dados de carga e da configuração inicial da tabela 6.1 obter-se-á os perfis de carga e os correspondentes chaveamentos e topologias com mínimas perdas, como se pode observar nos passos 1 e 2 a seguir.

6.3.1 Passos 1 e 2 - Sorteio dos Perfis de Carga e Determinação das Topologias Ótimas

Os diferentes perfis de carga nas barras, a serem utilizados no treinamento das RNA do passo 3, foram obtidos através de sorteios via Simulação Monte Carlo (SMC), adotando-se uma distribuição normal com desvio padrão de 10% em relação aos valores médios de carga.

Tabela 6.1 - Dados do Sistema 1

Conexão dos Nós		Cargas		Impedâncias	
Ramo	Início-Fim	P(kW)	Q(kVAr)	r(Ω)	x(Ω)
L_1	0-1	56,3	24,0	0,863	1,860
L_2	1-2	115,0	49,0	0,116	0,250
L_3	2-3	138,0	58,8	0,075	0,161
L_4	3-4	0,0	0,0	0,022	0,048
L_5	4-5	390,4	166,3	0,340	0,733
L_6	5-6	214,4	91,4	0,686	0,979
L_7	6-7	137,4	58,6	0,478	0,683
L_8	7-8	560,7	238,9	0,249	0,356
L_9	8-9	229,0	97,6	0,476	0,250
L_{10}	9-10	454,2	193,5	1,401	1,100
L_{11}	1-11	274,5	117,0	0,683	0,975
L_{12}	11-12	401,2	171,0	0,446	0,636
L_{13}	4-13	151,5	64,6	1,654	0,535
L_{14}	7-14	190,1	81,0	0,300	0,263
L_{15}	14-15	323,7	137,9	0,327	0,286

Tabela 6.2 – Alternativas de Chaveamento do Sistema 1

Conexão dos Nós		Cargas		Impedâncias	
Ramo	Início-Fim	P(kW)	Q(kVAr)	r(Ω)	x(Ω)
L_{16}	2-10	--	--	2,000	1,000
L_{17}	13-15	--	--	1,500	1,000

Para estes perfis de carga, considerando-se diferente número de sorteios obteve-se, utilizando o método heurístico descrito no capítulo 4, duas diferentes configurações ótimas em nível de perdas. Na tabela 6.3 pode ser observado o número de ocorrências de cada uma destas duas topologias ótimas para 500, 1000 e 2000 sorteios.

Observa-se na tabela 6.3 que tanto para 500, 1000 e 2000 sorteios o sistema tem praticamente a mesma característica, ou seja, apresenta percentual semelhante de ocorrência para cada topologia considerada, o que indica que a Simulação Monte Carlo convergiu, fato este que isoladamente não garante a qualidade do treinamento. Entretanto pode-se, a partir das diferentes

topologias ótimas obtidas na tabela 6.3, definir o número de RNA necessárias à solução do problema e, analisar o desempenho destas RNA frente a conjuntos de dados de treinamento de diferentes tamanhos (como se verá no passo 3).

Tabela 6.3 - Configurações Ótimas

Número de Sorteios	Topologia Ótima Ramos Abertos	Número de Ocorrências (vezes)	Percentual de Ocorrência (%)
500	$L_9 - L_{15}$ τ_1	279	55,80
	$L_9 - L_{14}$ τ_2	221	44,20
1000	$L_9 - L_{15}$	569	56,90
	$L_9 - L_{14}$	431	43,10
2000	$L_9 - L_{15}$	1106	55,30
	$L_9 - L_{14}$	894	44,70

6.3.2 Passo 3 - Treinamento de RNA para a Solução do Problema

Para este sistema teste treinou-se somente uma única rede neural, visto que se a topologia ótima não for a topologia ótima 1 (ramos abertos $L_9 - L_{15}$) só pode ser a topologia ótima 2 (ramos abertos $L_9 - L_{14}$). Assim, é suficiente treinar uma RNA para a topologia ótima 1, que indicará para qualquer perfil de carga se o mesmo corresponde, ou não, à topologia ótima 1. Existindo um conjunto maior de topologias candidatas dever-se-á, necessariamente, treinar uma RNA para cada topologia, como foi observado no item 6.1.3.

Após se definir o número de RNA necessárias à solução do problema, necessita-se definir o número de dados de entrada-saída do conjunto de treinamento que possibilite às RNA, após treinadas, fornecerem respostas adequadas a novos perfis de carga que não foram utilizados no processo de treinamento.

Deste modo, efetuou-se o treinamento de uma rede do tipo *multilayer perceptrons* (MLP) de 3 camadas, com diferentes números de dados de perfis de carga nas barras. Para esta RNA foram adotados 14 neurônios na camada de entrada pelo fato de se ter 14 diferentes barras de carga no sistema (pois o nó 4 é apenas um nó de ligação), e um neurônio na camada de saída pelo fato de se designar uma RNA para cada topologia ótima.

O conjunto de 200 perfis de carga de treinamento foi o que apresentou os melhores resultados. Com um número menor de dados de treinamento, 150 perfis de carga, se observou menor índice de acertos para o conjunto teste e, por sua vez, com o conjunto de 250 perfis de carga de treinamento se observou um aumento considerável do tempo de treinamento.

Através da experiência com o processo de treinamento, considerando-se os conjuntos com diferentes números de perfis de carga, pode-se definir os valores de 0,3 e 0,5 para os parâmetros taxa de aprendizagem e momento, respectivamente. O tempo médio de treinamento para o conjunto de 200 perfis de carga foi de aproximadamente 20 minutos, levando-se em conta diferentes números de neurônios na camada intermediária. A utilização do algoritmo de seleção de características *class-mean-separation* não apresentou redução significativa do tempo de treinamento.

Apresenta-se no gráfico da figura 6.3 abaixo o índice de acertos para diferentes número de neurônios na camada intermediária considerando-se um conjunto teste de 200 perfis de carga. Este conjunto teste foi obtido nas mesmas condições de variabilidade da demanda (desvio-padrão) e não foi utilizado durante o treinamento da rede neural.

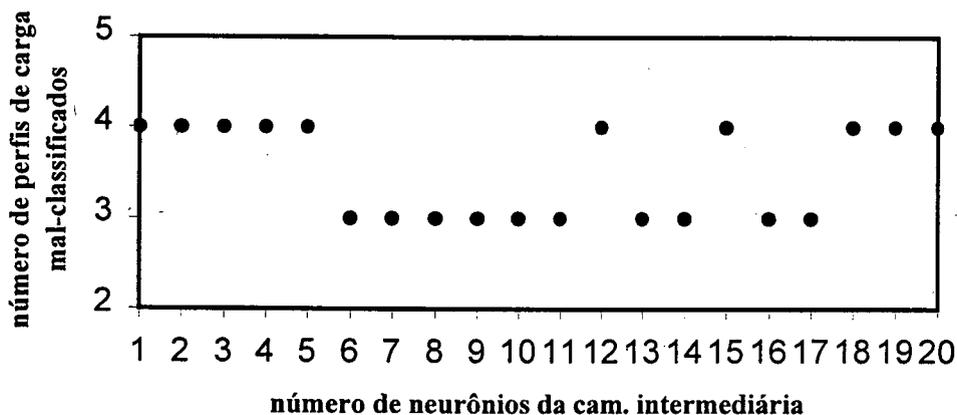


Figura 6.3 – Número de Perfis de Carga Mal-Classificados pela RNA versus Número de Neurônios da Camada Intermediária

Os resultados da figura 6.3 permitem concluir pela robustez da solução fornecida pela RNA, dado o elevado percentual de 98,5% de acerto para os perfis de carga do conjunto teste. Para apenas 3 dos 200 perfis de carga, a RNA não apresenta solução igual à solução do método heurístico utilizado na fase de treinamento.

6.3.3 Passo 4 – Verificação da Otimalidade da Solução

Na tabela 6.4 apresentam-se os três perfis de carga mal-classificados pela RNA, que foram detectados na figura 6.3. Também pode-se observar nesta tabela a resposta fornecida pela RNA e a resposta esperada (fornecida pelo método heurístico no passo 2) para cada um destes três perfis de carga.

Para cada um destes perfis de carga, utilizou-se o método de programação matemática binária inteira 0-1 para obter a solução ótima, comprovando ou não, a otimalidade da solução fornecida pela RNA.

Tabela 6.4 Perfis de Carga Mal-Classificados pela RNA (kW)

Barra de Carga	Perfil 1	Perfil 2	Perfil 3
1	56,85	53,84	46,89
2	125,08	89,72	138,31
3	167,24	152,35	159,42
4	-	-	-
5	321,86	452,94	448,12
6	178,22	201,28	222,32
7	160,82	99,93	156,80
8	667,83	698,86	632,70
9	195,43	218,24	227,67
10	405,28	428,26	368,61
11	220,52	387,94	266,05
12	465,60	346,71	427,22
13	126,20	143,81	192,36
14	189,85	196,49	231,43
15	370,36	355,97	338,62
Respostas (Ramos Abertos)			
RNA	$L_9 - L_{15}$	$L_9 - L_{15}$	$L_9 - L_{14}$
Esperada	$L_9 - L_{14}$	$L_9 - L_{14}$	$L_9 - L_{15}$

A seguir apresentam-se os resultados desta aplicação do método de programação inteira, cuja condição inicial corresponde à solução fornecida pela RNA. Se a topologia fornecida pela RNA for a topologia ótima, o método de programação inteira confirma na 1ª iteração a condição de otimalidade.

Perfil 1

1ª Iteração (condição inicial: ramos abertos $L_9 - L_{15}$)

A condição inicial da 1ª iteração é a resposta fornecida pela RNA, cuja otimalidade será verificada, pelo método de programação matemática inteira 0-1. Esta condição, para o perfil 1, é encontrada na tabela 6.4 e, indica que os ramos $L_9 - L_{15}$ são os únicos ramos com chave seccionadora aberta na configuração do sistema fornecida pela RNA (figura 6.4).

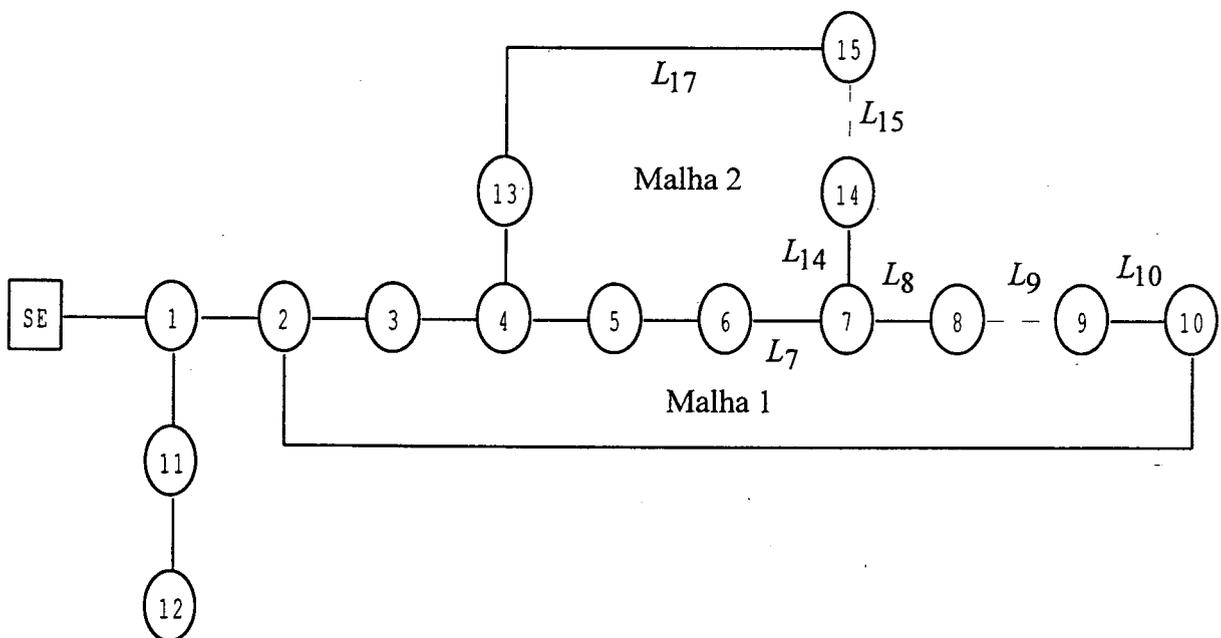


Figura 6.4 – Configuração Inicial para os Perfis de Carga 1 e 2

A partir desta configuração inicial, utilizando-se o método de programação matemática inteira 0-1, obter-se-á a função objetivo e suas restrições para as duas malhas do sistema. Após se otimizar as perdas nas duas malhas, efetua-se o chaveamento na malha que apresentar maior redução nas perdas do sistema, o que define a configuração inicial para a próxima iteração (como será visto a seguir).

Malha 1

$$\text{Min}F.O. = \text{Min}(94,346 - 1,795 \cdot L_8 + 3,912 \cdot L_{10} - 6,545 \cdot L_8 \cdot L_{10})$$

$$\text{Sujeito a } L_8 + L_{10} \geq 1$$

Solução: $F.O. = 89,918$ kW, $L_8 = 1$ e $L_{10} = 1$, isto é, deve-se manter a atual configuração da malha 1, pois a otimização indica que os ramos L_8 e L_{10} , adjacentes ao ramo aberto da malha, devem permanecer fechados.

Malha 2

$$\text{Min}F.O. = \text{Min}(92,261 + 3,424 \cdot L_{14} - 2,348 \cdot L_{17} - 3,419 \cdot L_{14} \cdot L_{17})$$

$$\text{Sujeito a } L_{14} + L_{17} \geq 1$$

Solução: $F.O. = 89,913$ kW, $L_{14} = 0$ e $L_{17} = 1$, ou seja, deve-se abrir o ramo L_{14} e alimentar a barra de carga 15 pelo outro lado da malha, fechando a chave seccionadora do ramo L_{15} , evitando que a barra 15 fique sem alimentação.

Na 1ª iteração somente a malha 2 apresenta possibilidade de redução de perdas. Portanto o chaveamento indicado nesta malha é o que deve ser realizado, ou seja os ramos abertos são L_9 e L_{14} . Com este chaveamento obtém-se a configuração inicial para a 2ª iteração. Se existir outras malhas que possibilitem redução nas perdas, adota-se o chaveamento na malha que levar ao menor valor da função objetivo.

2ª Iteração (atual configuração: ramos abertos $L_9 - L_{14}$)

A 2ª iteração terá como condição inicial os ramos L_9 e L_{14} abertos, pois na 1ª iteração, que tinha como condição inicial os ramos L_9 e L_{15} abertos, o chaveamento selecionado foi abrir o ramo L_{14} e fechar ramo L_{15} .

Malha 1

$$\text{Min}F.O. = \text{Min}(95,757 - 3,797 \cdot L_8 + 4,498 \cdot L_{10} - 6,545 \cdot L_8 \cdot L_{10})$$

Sujeito a $L_8 + L_{10} \geq 1$

Solução: $F.O. = 89,913$ kW, $L_8 = 1$ e $L_{10} = 1$, manter a atual configuração da malha.

Malha 2

$$\text{Min}F.O. = \text{Min}(105,57 - 15,659 \cdot L_7 + 7,735 \cdot L_{15} - 7,740 \cdot L_7 \cdot L_{15})$$

Sujeito a $L_7 + L_{15} \geq 1$

Solução: $F.O. = 89,913$ kW, $L_7 = 1$ e $L_{15} = 1$, manter a configuração da malha.

Como na 2ª iteração mais nenhum chaveamento conduz a uma redução nas perdas do sistema, a condição inicial da 2ª iteração, ramos abertos L_9 e L_{14} , é a solução ótima para este perfil de carga, confirmando a solução fornecida pelo método heurístico (tabela 6.4). É importante observar que as perdas para este perfil de carga diminuíram do valor de 89,918 kW correspondente à solução fornecida pela RNA, para o valor de 89,913 kW fornecido pelo método de programação matemática inteira, ou seja, as soluções são muito próximas.

Perfil 2

1ª iteração (condição inicial: ramos abertos $L_9 - L_{15}$)

Este perfil também tem, de acordo com a solução fornecida pela RNA na tabela 6.4, como condição inicial a configuração representada pela figura 6.4, porém com dados de carga diferentes em cada barra. O método de otimização está apresentado a seguir:

Malha 1

$$\text{Min}F.O. = \text{Min}(103,094 - 2,249 \cdot L_8 + 4,720 \cdot L_{10} - 7,648 \cdot L_8 \cdot L_{10})$$

Sujeito a $L_8 + L_{10} \geq 1$

Solução: $F.O. = 97,917$ kW, $L_8 = 1$ e $L_{10} = 1$, isto é, deve-se manter a configuração da malha, já que o processo de otimização indica que os ramos L_8 e L_{10} devem permanecer fechados.

Malha 2

$$\text{Min}F.O. = \text{Min}(100,033 + 3,477 \cdot L_{14} - 2,192 \cdot L_{17} - 3,401 \cdot L_{14} \cdot L_{17})$$

Sujeito a $L_{14} + L_{17} \geq 1$

Solução: $F.O. = 97,841$ kW, $L_{14} = 0$ e $L_{17} = 1$, deve-se abrir o ramo L_{14} e fechar a chave seccionadora do ramo L_{15} , que é o ramo inicialmente aberto da malha.

Nesta iteração adota-se o chaveamento indicado pelo processo de otimização para a malha 2, que se constitui na única possibilidade para reduzir as perdas do sistema. Assim, como o chaveamento selecionado indica a abertura no ramo L_{14} , este ramo passa a estar aberto na condição inicial da próxima iteração.

2ª Iteração (condição inicial: ramos abertos $L_9 - L_{14}$)

Malha 1

$$\text{Min}F.O. = \text{Min}(104,510 - 4,418 \cdot L_8 + 5,397 \cdot L_{10} - 7,648 \cdot L_8 \cdot L_{10})$$

Sujeito a $L_8 + L_{10} \geq 1$

Solução: $F.O. = 97,841$ kW, $L_8 = 1$ e $L_{10} = 1$, manter a atual configuração da malha.

Malha 2

$$\text{Min}F.O. = \text{Min}(111,951 - 14,034 \cdot L_7 + 7,647 \cdot L_{15} - 7,722 \cdot L_7 \cdot L_{15})$$

Sujeito a $L_7 + L_{15} \geq 1$

Solução: $F.O. = 97,841$ kW, $L_7 = 1$ e $L_{15} = 1$, manter a configuração da malha.

Na 2ª iteração nenhum novo chaveamento é indicado, confirmando que a condição inicial desta iteração (ramos abertos L_9 e L_{14}) é a solução ótima para o perfil de carga. Esta solução também é igual à apontada pelo método heurístico de otimização de perdas apresentado no capítulo 4. Para este perfil de carga a RNA fornece o valor de 97,917 kW e o método de programação matemática inteira o valor de 97,841 kW para as perdas totais do sistema, valores bastante próximos.

Perfil 3

1ª Iteração (condição inicial: ramos abertos $L_9 - L_{14}$) . Esta condição inicial corresponde à topologia com mínimas perdas, fornecida pela RNA para este perfil de carga, como pode ser observado na tabela 6.4. A figura 6.5 apresenta a configuração do sistema equivalente a esta condição inicial.

Malha 1

$$MinF.O. = Min(104,164 - 1,881 \cdot L_8 + 4,609 \cdot L_{10} - 7,223 \cdot L_8 \cdot L_{10})$$

Sujeito a $L_8 + L_{10} \geq 1$

Solução: $F.O. = 99,669$ kW, $L_8 = 1$ e $L_{10} = 1$, manter a configuração da malha.

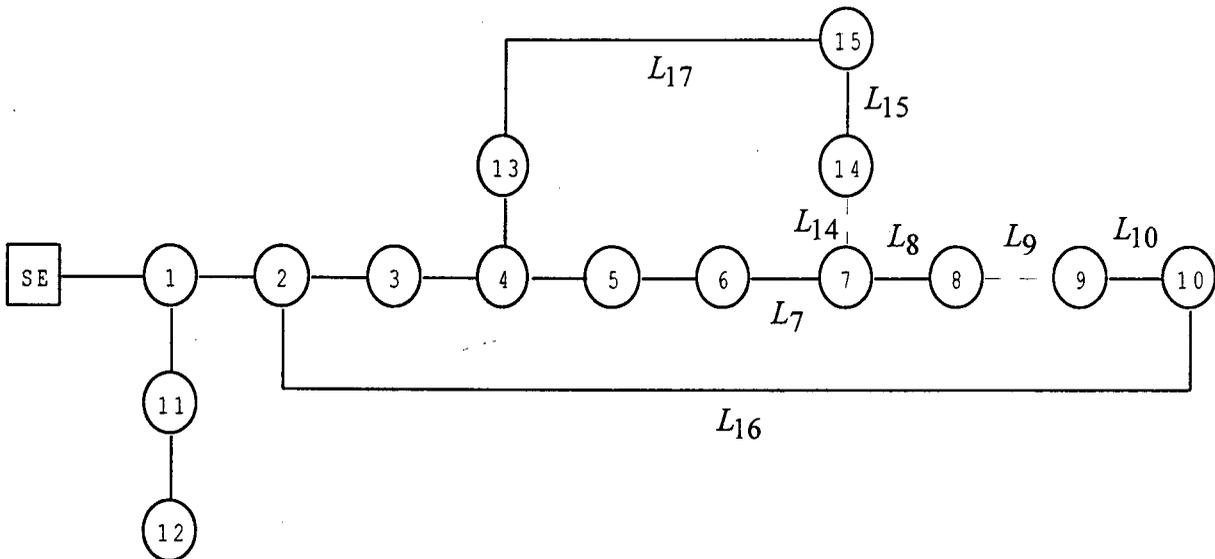


Figura 6.5 – Configuração Inicial para o Perfil 3

Malha 2

$$MinF.O. = Min(113,119 - 13,481 \cdot L_7 + 9,020 \cdot L_{15} - 8,990 \cdot L_7 \cdot L_{15})$$

Sujeito a $L_7 + L_{15} \geq 1$

Solução: $F.O. = 99,638$ kW, $L_7 = 1$ e $L_{15} = 0$, abrir o ramo L_{15} e fechar o ramo L_{14} , que é o ramo aberto da malha.

Adota-se o chaveamento indicado pelo processo de otimização da malha 2, obtendo-se a configuração do sistema para a 2ª iteração.

2ª Iteração (condição inicial: ramos abertos $L_9 - L_{15}$)

Malha 1

$$\text{Min}F.O. = \text{Min}(102,653 + 0,431 \cdot L_8 + 3,777 \cdot L_{10} - 7,223 \cdot L_8 \cdot L_{10})$$

Sujeito a $L_8 + L_{10} \geq 1$

Solução: $F.O. = 99,638$ kW, $L_8 = 1$ e $L_{10} = 1$, manter a configuração da malha.

Malha 2

$$\text{Min}F.O. = \text{Min}(101,170 + 3,781 \cdot L_{14} - 1,501 \cdot L_{17} - 3,811 \cdot L_{14} \cdot L_{17})$$

Sujeito a $L_{14} + L_{17} \geq 1$

Solução: $F.O. = 99,638$ kW, $L_{14} = 0$ e $L_{17} = 1$, manter a configuração da malha.

Nesta iteração nenhum novo chaveamento possibilita redução de perdas para o sistema, o que mantém a configuração inicial da iteração como a topologia ótima do sistema. As perdas do sistema para este perfil de carga obtidas com a RNA representam 99,669 kW e com o método de programação matemática inteira 99,638 kW, valores que podem ser considerados equivalentes.

Para os três perfis de carga mal-classificados pela RNA, o método de programação matemática obteve a configuração ótima esperada. Como foi visto, as soluções fornecidas nos três casos pela RNA e pelo método de otimização são muito próximas (diferença não superior a 0,076 kW). A partir deste fato pode-se concluir que quando a solução fornecida pela RNA não for a ótima, esta solução está muito próxima da ótima, destacando-se a qualidade do treinamento realizado. Por fim, para este sistema pode-se recomendar o emprego da RNA no gerenciamento do sistema de distribuição analisado, sem a necessidade da utilização do método de otimização para verificar a qualidade da solução fornecida pela RNA para o perfil de carga do momento.

6.4 Sistema Teste 2

Neste item, proceder-se-á ao estudo de um segundo sistema teste, com a finalidade de se analisar a robustez da metodologia proposta a sistemas de maior porte, com maior número de topologias ótimas em nível de perdas e maior número de RNA a serem treinadas. Com este objetivo, selecionou-se o sistema 2 representado na figura 6.6, o qual já foi analisado na literatura constituindo-se como um importante sistema a ser investigado [1,27,32,41]. Este

sistema possui uma subestação, 32 pontos de carga e nível de tensão de 12,66 kV. A carga total para a configuração base é de 3.715 kW e 2.300 kVAr.

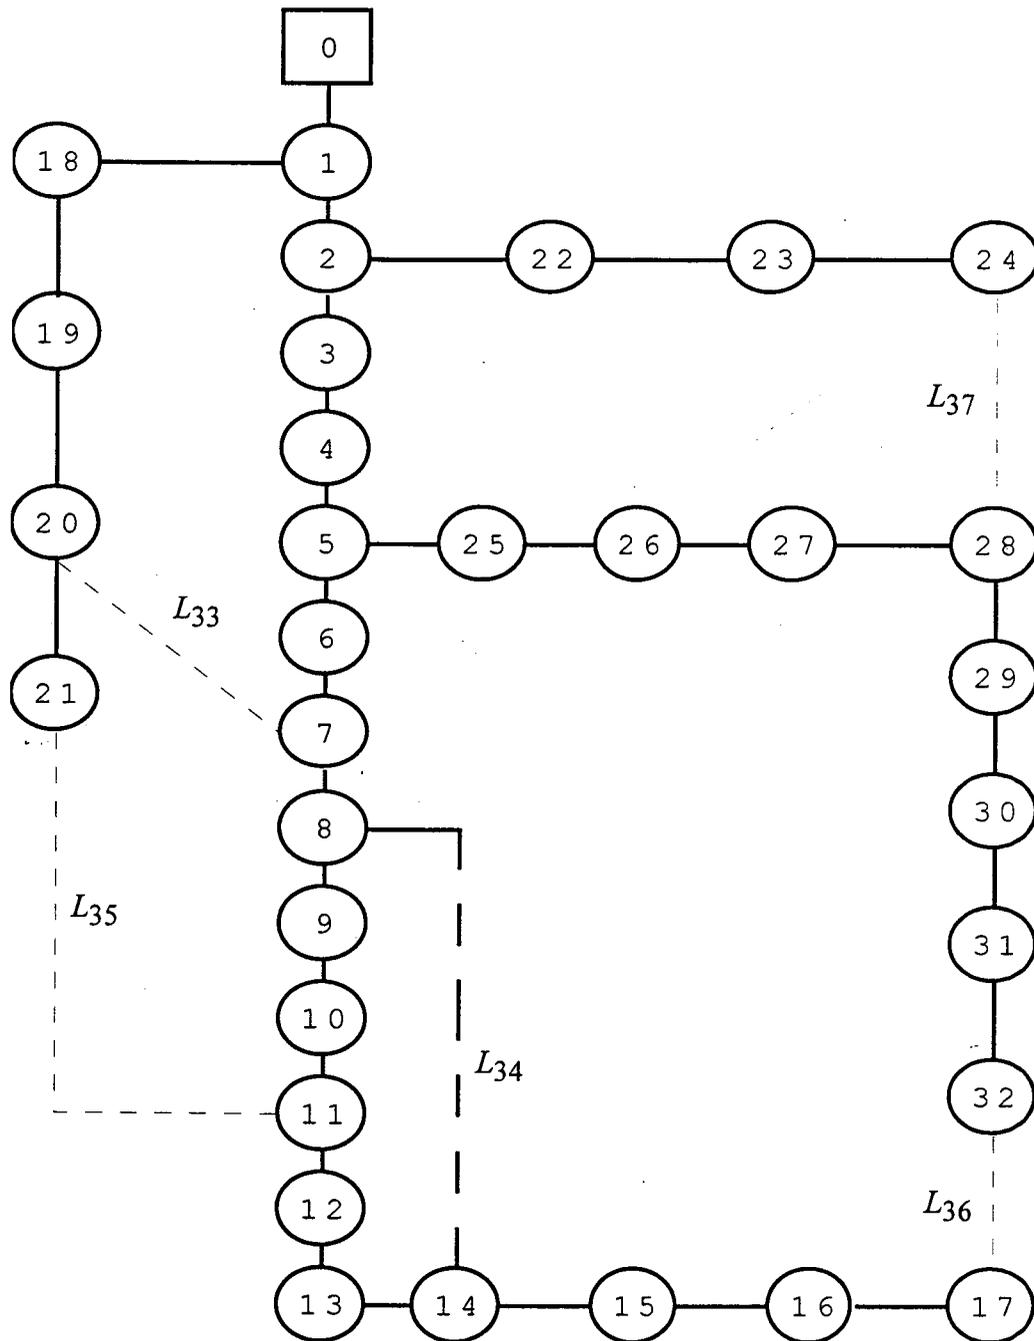


Figura 6.6 Sistema 2 com 32 Barras de Carga e 5 Linhas Alternativas de Chaveamento

Tabela 6.5 - Dados do Sistema 2

Conexão dos Nós		Cargas		Impedâncias	
Ramo	Início-Fim	P(kW)	Q(kVAr)	r(Ω)	x(Ω)
L_1	0-1	100	60	0,0922	0,0470
L_2	1-2	90	40	0,4930	0,2511
L_3	2-3	120	80	0,3660	0,1864
L_4	3-4	60	30	0,3811	0,1941
L_5	4-5	60	20	0,8190	0,7070
L_6	5-6	200	100	0,1872	0,6188
L_7	6-7	200	100	0,7114	0,2351
L_8	7-8	60	20	1,0300	0,7400
L_9	8-9	60	20	1,0440	0,7400
L_{10}	9-10	45	30	0,1966	0,0650
L_{11}	10-11	60	35	0,3744	0,1238
L_{12}	11-12	60	35	1,4680	1,1550
L_{13}	12-13	120	80	0,5416	0,7129
L_{14}	13-14	60	10	0,5910	0,5260
L_{15}	14-15	60	20	0,7463	0,5450
L_{16}	15-16	60	20	1,2890	1,7210
L_{17}	16-17	90	40	0,7320	0,5740
L_{18}	1-18	90	40	0,1640	0,1565
L_{19}	18-19	90	40	1,5042	1,3554
L_{20}	19-20	90	40	0,4095	0,4784
L_{21}	20-21	90	40	0,7089	0,9373
L_{22}	2-22	90	50	0,4512	0,3083
L_{23}	22-23	420	200	0,8980	0,7091
L_{24}	23-24	420	200	0,8960	0,7011
L_{25}	5-25	60	25	0,2030	0,1034
L_{26}	25-26	60	25	0,2842	0,1447
L_{27}	26-27	60	20	1,0590	0,9337
L_{28}	27-28	120	70	0,8042	0,7006
L_{29}	28-29	200	600	0,5075	0,2585
L_{30}	29-30	150	70	0,9744	0,9630
L_{31}	30-31	210	100	0,3105	0,3619
L_{32}	31-32	60	40	0,3410	0,5302

Os dados do sistema 2 encontram-se na tabela 6.5. e as alternativas de chaveamento deste sistema, representadas pelas 5 linhas tracejadas da figura 6.6, estão na tabela 6.6.

Tabela 6.6 – Linhas Alternativas de Chaveamento

Conexão dos Nós		Cargas		Impedâncias	
Ramo	Início-Fim	P(kW)	Q(kVAr)	$r(\Omega)$	$x(\Omega)$
L_{33}	7-20	--	--	2,0000	2,0000
L_{34}	8-14	--	--	2,0000	2,0000
L_{35}	11-21	--	--	2,0000	2,0000
L_{36}	17-32	--	--	0,5000	0,5000
L_{37}	24-28	--	--	0,5000	0,5000

Este sistema de distribuição possui cinco linhas alternativas (ramos L_{33} , L_{34} , L_{35} , L_{36} e L_{37}) que podem ser utilizadas no passo 2, durante o procedimento de reconfiguração para a obtenção da topologia ótima em nível de perdas para os diferentes perfis de carga sorteados. Deve ser recordado que sempre que um destes ramos for utilizado, forma-se uma malha no sistema de distribuição, a qual deverá ser aberta para manter a radialidade da operação do sistema.

6.4.1 Passos 1 e 2 - Sorteio dos Perfis de Carga e Determinação das Topologias Ótimas

Para o sistema 2, utilizando-se também o método heurístico de minimização de perdas utilizado para o sistema 1 e as alternativas de chaveamento da tabela 6.6, obteve-se 6 diferentes configurações ótimas em relação a perdas elétricas considerando-se diferentes números de sorteios via SMC (distribuição normal com desvio padrão de 10% em relação aos valores médios dos nós de carga), como pode ser observado na tabela 6.7.

A tabela 6.7 mostra que o sistema tem praticamente a mesma característica (denotando a convergência da Simulação Monte Carlo) para 500, 1000 ou 2000 sorteios. Como as duas topologias ótimas constituídas pelos ramos abertos $L_7-L_{11}-L_{32}$ e $L_{10}-L_{28}-L_{32}$ aparecem apenas uma única vez em 2000 sorteios (pouca probabilidade de ocorrência), estas topologias serão desconsideradas no passo seguinte.

Em função da observação anterior, considerar-se-ão 4 topologias ótimas para a operação do sistema com mínimas perdas resistivas. Como este número de topologias ótimas é maior do que o obtido para o sistema 1 (somente 2 topologias ótimas), neste exemplo far-se-á necessário um maior número de RNA para a solução do problema, como será analisado no passo 3.

Tabela 6.7 - Configurações Ótimas

Número de Sorteios	Topologia Ótima Ramos Abertos	Número de Ocorrências (vezes)	Percentual de Ocorrência (%)
500	<i>L7-L9-L14-L32</i>	298	59,60
	<i>L7-L9-L14-L28-L32</i>	175	35,00
	<i>L11-L28-L32</i>	23	4,60
	<i>L7-L9-L14-L31</i>	4	0,80
1000	<i>L7-L9-L14-L32</i>	587	58,70
	<i>L7-L9-L14-L28-L32</i>	368	36,80
	<i>L11-L28-L32</i>	39	3,90
	<i>L7-L9-L14-L31</i>	5	0,50
	<i>L7-L11-L32</i>	1	0,10
2000	<i>L7-L9-L14-L32</i>	1174	58,70
	<i>L7-L9-L14-L28-L32</i>	726	36,30
	<i>L11-L28-L32</i>	88	4,40
	<i>L7-L9-L14-L31</i>	10	0,50
	<i>L7-L11-L32</i>	1	0,05
	<i>L10-L28-L32</i>	1	0,05

6.4.2 Passo 3 - Treinamento de RNA para a Solução do Problema

Com diferentes números de perfis de carga, efetuou-se o treinamento de quatro RNA do tipo MLP de 3 camadas, com 32 neurônios na camada de entrada e um neurônio na camada de saída. A razão para se adotar 32 neurônios na camada de entrada deve-se ao fato de serem representadas 32 barras de carga no sistema. Adota-se um neurônio na camada de saída, pelo fato de se treinar uma RNA para cada topologia ótima. Como analisado anteriormente, o neurônio da camada de saída vai indicar se o perfil de carga submetido a RNA corresponde à topologia ótima para a qual a rede neural foi treinada.

Para este sistema, a experiência com o treinamento das RNA levou a definir os valores de 0,25 e 0,5 para os parâmetros taxa de aprendizagem e momento, respectivamente, e indicou um valor em torno de 200 dados como tamanho aproximado do conjunto de treinamento. O tempo médio de treinamento para o conjunto de 200 perfis de carga foi de aproximadamente 40 minutos, levando-se em conta até 15 neurônios na camada intermediária.

O gráfico da figura 6.7 apresenta o resultado do estudo para a definição do número de neurônios da camada intermediária, apontando o número de perfis de carga mal-classificados pelas RNA considerando-se um conjunto teste de 200 entrada-saídas. Este conjunto teste também foi sorteado nas mesmas condições de representação da variabilidade da demanda e não foi utilizado durante o treinamento das rede neurais. Estes resultados foram obtidos comparando-se as respostas das quatro RNA, sendo uma RNA treinada para cada topologia ótima. A RNA com maior valor do neurônio de saída (maior resposta), correspondente a cada perfil de carga do conjunto teste, determina a topologia ótima do sistema (topologia para a qual a RNA com maior resposta foi treinada).

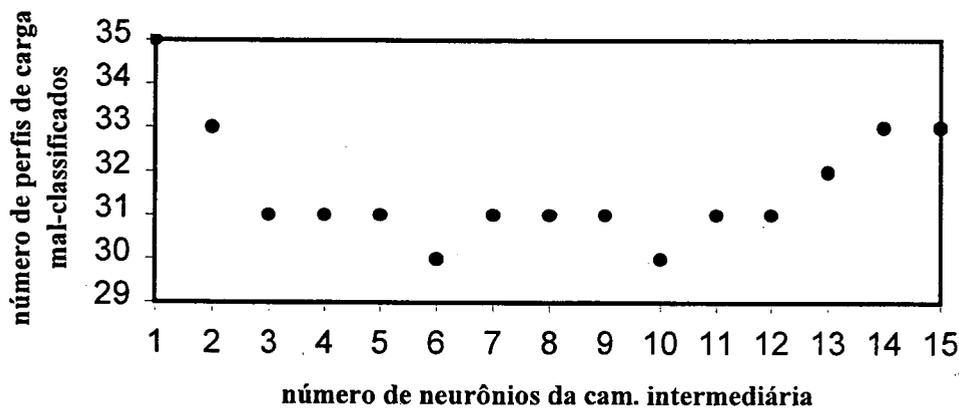


Figura 6.7 – Número de Perfis de Carga Mal-Classificados pelas RNA versus Número de Neurônios da Camada Intermediária

Os resultados da figura 6.7 indicam que a solução fornecida pela RNA apresenta um percentual de aproximadamente 85% de acerto para os perfis de carga do conjunto teste. Considerando-se de 6 a 10 neurônios na camada intermediária, para 30/31 dos 200 perfis de carga, a RNA não apresenta solução igual à solução do método heurístico utilizado no treinamento e também como comparação. Este percentual de acerto, comparado com a referência [34], é significativamente melhor e foi obtido considerando-se um sistema de maior porte. Na tabela 6.8 apresentam-se 4 dos perfis de carga mal-classificados, os quais serão analisados pelo

método de programação matemática inteira objetivando-se ratificar a qualidade do treinamento das RNA.

Tabela 6.8 - Perfis de Carga Mal-Classificados pelas RNA (kW)

Barra de Carga	Perfil 1	Perfil 2	Perfil 3	Perfil 4
1	82,58	98,20	92,50	109,20
2	80,49	86,03	93,43	82,75
3	119,66	105,02	109,47	106,95
4	49,70	51,41	65,62	80,50
5	62,09	61,06	74,23	67,59
6	202,76	193,26	207,05	238,81
7	165,27	197,65	197,06	168,58
8	66,38	60,71	59,38	54,46
9	65,37	56,45	68,42	62,00
10	49,70	49,40	48,62	44,04
11	55,92	66,36	54,64	56,90
12	67,36	65,55	60,53	64,44
13	113,37	133,42	126,24	115,01
14	46,51	57,52	72,31	57,63
15	69,67	60,00	59,41	61,55
16	62,82	57,65	56,37	68,72
17	105,38	99,45	99,07	70,25
18	83,61	91,06	94,08	112,15
19	97,20	82,89	104,85	84,69
20	79,70	93,13	90,51	87,26
21	91,88	103,30	95,28	80,50
22	97,80	90,68	93,64	89,22
23	381,81	381,99	388,55	506,20
24	435,17	421,70	424,87	423,98
25	57,42	65,96	48,57	53,32
26	52,31	58,76	53,48	65,05
27	58,41	66,81	59,19	48,98
28	120,18	119,79	101,16	126,37
29	199,53	194,02	187,04	227,12
30	159,23	130,16	135,35	165,50
31	209,22	224,88	201,70	203,71
32	55,05	54,85	63,91	67,76

6.4.3 Passo 4 – Verificação da Otimalidade da Solução

Para os 4 perfis de carga da tabela 6.8, os quais foram mal-classificados pelas RNA treinadas para a solução do problema, pode-se observar na tabela 6.9 diferente topologia esperada em nível de perdas (obtida via método heurístico).

Tabela 6.9 – Topologia Ótima para os Perfis da Tabela 6.8

Ramos Abertos				
Método de solução	Perfil 1	Perfil 2	Perfil 3	Perfil 4
RNA	$L_7 L_9 L_{14} L_{28} L_{32}$	$L_7 L_9 L_{14} L_{32}$	$L_7 L_9 L_{14} L_{32}$	$L_7 L_9 L_{14} L_{32}$
Heurístico	$L_7 L_9 L_{14} L_{32}$	$L_7 L_9 L_{14} L_{28} L_{32}$	$L_{11} L_{28} L_{32}$	$L_7 L_9 L_{14} L_{31}$

Os resultados da aplicação do método de programação matemática inteira 0-1, para obter a topologia ótima a partir da solução fornecida pelas RNA, para cada um dos 4 padrões de carga da tabela 6.8, são encontrados nos quadros resumo apresentados nas tabelas de 6.10 a 6.13, com os comentários referentes a cada iteração.

Perfil de Carga 1

De acordo com os resultados apresentados na tabela 4.10, como na 1^a iteração apenas a malha 4 apresenta possibilidade para redução de perdas, efetua-se o chaveamento indicado para aquela malha. Efetuando-se o chaveamento selecionado, abrir em L_{37} e fechar em L_{28} , obtém-se a condição inicial para a 2^a iteração (ramos abertos $L_7 L_9 L_{14} L_{32}$). Esta condição inicial não representa o ramo L_{37} pois este ramo é uma alternativa de chaveamento com chave seccionadora normalmente aberta. Para esta condição inicial somente foram utilizadas as alternativas de chaveamento L_{33} , L_{34} , L_{35} e L_{36} .

Na 2^a iteração nenhum novo chaveamento é indicado para reduzir as perdas. Confirma-se assim, que a condição inicial da iteração (ramos abertos $L_7 L_9 L_{14} L_{32}$) é a solução ótima para o perfil de carga. Esta solução também é igual à solução esperada para este perfil de carga (fornecida pelo método heurístico, tabela 6.9), confirmando o não acerto da RNA. Contudo este ótimo fornece um valor de perdas igual a 142,76 kW e as RNA apresentam 147,00 kW de perdas, significando uma diferença de 4,24 kW.

Tabela 6.10 – Resultados da Aplicação do Método de Prog. Mat. Inteira ao Perfil de Carga 1

1ª Iteração (Condição Inicial: Ramos Abertos L_7 L_9 L_{14} L_{28} L_{32})		
Malha	Função Objetivo, Restrição e Solução	Ação
1	$\min F.O. = \min(154,410 + 7,869 \cdot L_6 + 0,942 \cdot L_{33} - 16,219 \cdot L_6 \cdot L_{33})$ $L_6 + L_{33} \geq 1$ $F.O. = 147,00 \text{ kW}, L_6 = 1 \text{ e } L_{33} = 1$	Manter a Configuração
2	$\min F.O. = \min(152,768 - 4,171 \cdot L_8 + 1,893 \cdot L_{10} - 3,485 \cdot L_8 \cdot L_{10})$ $L_8 + L_{10} \geq 1$ $F.O. = 147,00 \text{ kW}, L_8 = 1 \text{ e } L_{10} = 1$	Manter a Configuração
3	$\min F.O. = \min(148,277 + 3,899 \cdot L_{13} + 3,620 \cdot L_{34} - 8,794 \cdot L_{13} \cdot L_{34})$ $L_{13} + L_{34} \geq 1$ $F.O. = 147,00 \text{ kW}, L_{13} = 1 \text{ e } L_{34} = 1$	Manter a Configuração
4	$\min F.O. = \min(141,680 + 1,084 \cdot L_{27} + 9,307 \cdot L_{37} - 5,069 \cdot L_{27} \cdot L_{37})$ $L_{27} + L_{37} \geq 1$ $F.O. = 142,76 \text{ kW}, L_{27} = 1 \text{ e } L_{37} = 0$	Abrir em L_{37} Fechar em L_{28}
5	$\min F.O. = \min(149,349 - 0,850 \cdot L_{31} + 2,834 \cdot L_{36} - 4,329 \cdot L_{31} \cdot L_{36})$ $L_{31} + L_{36} \geq 1$ $F.O. = 147,00 \text{ kW}, L_{31} = 1 \text{ e } L_{36} = 1$	Manter a Configuração
2ª Iteração (Condição Inicial: Ramos Abertos L_7 L_9 L_{14} L_{32})		
Malha	Função Objetivo, Restrição e Solução	Ação
1	$\min F.O. = \min(160,080 + 13,323 \cdot L_6 - 14,418 \cdot L_{33} - 16,219 \cdot L_6 \cdot L_{33})$ $L_6 + L_{33} \geq 1$ $F.O. = 142,76 \text{ kW}, L_6 = 1 \text{ e } L_{33} = 1$	Manter a Configuração
2	$\min F.O. = \min(148,530 - 4,171 \cdot L_8 + 1,893 \cdot L_{10} - 3,485 \cdot L_8 \cdot L_{10})$ $L_8 + L_{10} \geq 1$ $F.O. = 142,76 \text{ kW}, L_8 = 1 \text{ e } L_{10} = 1$	Manter a Configuração
3	$\min F.O. = \min(144,040 + 3,899 \cdot L_{13} + 3,620 \cdot L_{34} - 8,794 \cdot L_{13} \cdot L_{34})$ $L_{13} + L_{34} \geq 1$ $F.O. = 142,76 \text{ kW}, L_{13} = 1 \text{ e } L_{34} = 1$	Manter a Configuração
4	$\min F.O. = \min(142,646 + 4,357 \cdot L_{24} + 38,072 \cdot L_{28} - 42,310 \cdot L_{24} \cdot L_{28})$ $L_{24} + L_{28} \geq 1$ $F.O. = 142,76 \text{ kW}, L_{24} = 1 \text{ e } L_{28} = 1$	Manter a Configuração
5	$\min F.O. = \min(144,858 - 0,338 \cdot L_{31} + 2,912 \cdot L_{36} - 4,666 \cdot L_{31} \cdot L_{36})$ $L_{31} + L_{36} \geq 1$ $F.O. = 142,76 \text{ kW}, L_{31} = 1 \text{ e } L_{36} = 1$	Manter a Configuração
Perdas Minimizadas		

Perfil de Carga 2

Tabela 6.11 - Resultados da Aplicação do Método de Prog. Mat. Inteira ao Perfil de Carga 2

1ª Iteração (Condição Inicial: Ramos Abertos L_7 L_9 L_{14} L_{32})		
Malha	Função Objetivo, Restrição e Solução	Ação
1	$\min F.O. = \min(159,814 + 12,685 \cdot L_6 - 14,578 \cdot L_{33} - 15,912 \cdot L_6 \cdot L_{33})$ $L_6 + L_{33} \geq 1$ $F.O. = 142,01 \text{ kW}, L_6 = 1 \text{ e } L_{33} = 1$	Manter a Configuração
2	$\min F.O. = \min(147,451 - 4,146 \cdot L_8 + 1,599 \cdot L_{10} - 2,894 \cdot L_8 \cdot L_{10})$ $L_8 + L_{10} \geq 1$ $F.O. = 142,01 \text{ kW}, L_8 = 1 \text{ e } L_{10} = 1$	Manter a Configuração
3	$\min F.O. = \min(143,095 + 4,230 \cdot L_{13} + 4,730 \cdot L_{34} - 10,045 \cdot L_{13} \cdot L_{34})$ $L_{13} + L_{34} \geq 1$ $F.O. = 142,01 \text{ kW}, L_{13} = 1 \text{ e } L_{34} = 1$	Manter a Configuração
4	$\min F.O. = \min(141,563 + 3,633 \cdot L_{24} + 36,663 \cdot L_{28} - 39,850 \cdot L_{24} \cdot L_{28})$ $L_{24} + L_{28} \geq 1$ $F.O. = 142,01 \text{ kW}, L_{24} = 1 \text{ e } L_{28} = 1$	Manter a Configuração
5	$\min F.O. = \min(145,316 - 1,701 \cdot L_{31} + 3,393 \cdot L_{36} - 4,998 \cdot L_{31} \cdot L_{36})$ $L_{31} + L_{36} \geq 1$ $F.O. = 142,01 \text{ kW}, L_{31} = 1 \text{ e } L_{36} = 1$	Manter a Configuração
Perdas Minimizadas		

Para este perfil de carga o método de otimização confirma a condição inicial da 1ª iteração, ou seja, confirma a solução apresentada pelas RNA.

Perfil de Carga 3

Para este perfil de carga, o método de programação matemática inteira 0-1 também confirma a solução obtida através das RNA, como pode ser observado na tabela 6.12.

Perfil de Carga 4

Para o perfil de carga 4 o método de programação matemática inteira também confirma a solução fornecida pelas RNA, tabela 6.13.

Tabela 6.12 - Resultados da Aplicação do Método de Prog. Mat. Inteira ao Perfil de Carga 3

1ª Iteração (Condição Inicial: Ramos Abertos L_7 L_9 L_{14} L_{32})		
Malha	Função Objetivo, Restrição e Solução	Ação
1	$\min F.O. = \min(157,312 + 13,094 \cdot L_6 - 12,548 \cdot L_{33} - 17,618 \cdot L_6 \cdot L_{33})$ $L_6 + L_{33} \geq 1$ $F.O. = 140,24 \text{ kW}, L_6 = 1 \text{ e } L_{33} = 1$	Manter a Configuração
2	$\min F.O. = \min(145,641 - 3,610 \cdot L_8 + 1,900 \cdot L_{10} - 3,869 \cdot L_8 \cdot L_{10})$ $L_8 + L_{10} \geq 1$ $F.O. = 140,24 \text{ kW}, L_8 = 1 \text{ e } L_{10} = 1$	Manter a Configuração
3	$\min F.O. = \min(141,263 + 4,249 \cdot L_{13} + 4,856 \cdot L_{34} - 10,127 \cdot L_{13} \cdot L_{34})$ $L_{13} + L_{34} \geq 1$ $F.O. = 140,24 \text{ kW}, L_{13} = 1 \text{ e } L_{34} = 1$	Manter a Configuração
4	$\min F.O. = \min(141,017 + 3,040 \cdot L_{24} + 33,716 \cdot L_{28} - 37,533 \cdot L_{24} \cdot L_{28})$ $L_{24} + L_{28} \geq 1$ $F.O. = 140,24 \text{ kW}, L_{24} = 1 \text{ e } L_{28} = 1$	Manter a Configuração
5	$\min F.O. = \min(143,434 - 1,851 \cdot L_{31} + 3,881 \cdot L_{36} - 5,223 \cdot L_{31} \cdot L_{36})$ $L_{31} + L_{36} \geq 1$ $F.O. = 140,24 \text{ kW}, L_{31} = 1 \text{ e } L_{36} = 1$	Manter a Configuração
Perdas Minimizadas		

Tabela 6.13 - Resultados da Aplicação do Método de Prog. Mat. Inteira ao Perfil de Carga 4

1ª Iteração (Condição Inicial: Ramos Abertos L_7 L_9 L_{14} L_{32})		
Malha	Função Objetivo, Restrição e Solução	Ação
1	$\min F.O. = \min(173,287 + 16,318 \cdot L_6 - 14,900 \cdot L_{33} - 18,361 \cdot L_6 \cdot L_{33})$ $L_6 + L_{33} \geq 1$ $F.O. = 156,34 \text{ kW}, L_6 = 1 \text{ e } L_{33} = 1$	Manter a Configuração
2	$\min F.O. = \min(161,341 - 3,567 \cdot L_8 + 1,668 \cdot L_{10} - 3,098 \cdot L_8 \cdot L_{10})$ $L_8 + L_{10} \geq 1$ $F.O. = 156,34 \text{ kW}, L_8 = 1 \text{ e } L_{10} = 1$	Manter a Configuração
3	$\min F.O. = \min(157,534 + 3,776 \cdot L_{13} + 3,598 \cdot L_{34} - 8,565 \cdot L_{13} \cdot L_{34})$ $L_{13} + L_{34} \geq 1$ $F.O. = 156,34 \text{ kW}, L_{13} = 1 \text{ e } L_{34} = 1$	Manter a Configuração
4	$\min F.O. = \min(155,643 + 5,973 \cdot L_{24} + 38,018 \cdot L_{28} - 43,291 \cdot L_{24} \cdot L_{28})$ $L_{24} + L_{28} \geq 1$ $F.O. = 156,34 \text{ kW}, L_{24} = 1 \text{ e } L_{28} = 1$	Manter a Configuração
5	$\min F.O. = \min(155,903 + 3,690 \cdot L_{31} + 2,341 \cdot L_{36} - 5,592 \cdot L_{31} \cdot L_{36})$ $L_{31} + L_{36} \geq 1$ $F.O. = 156,34 \text{ kW}, L_{31} = 1 \text{ e } L_{36} = 1$	Manter a Configuração
Perdas Minimizadas		

Para os 4 perfis de carga considerados, a resposta das RNA foi confirmada em 3 dos 4 casos, em detrimento da resposta esperada de início, fornecida pelo método heurístico. Os resultados para os demais perfis de carga mal-classificados pelas RNA podem ser observados na

tabela 6 14. Estes resultados elevam o índice de acertos para 90,5%, ou seja, 181 acertos em 200 (considerando-se diferente número de neurônios na camada intermediária para as 4 RNA). Deste fato pode-se concluir que as RNA em conjunto com o método de programação inteira possuem a capacidade de verificar os dados do conjunto de treinamento, aumentando a eficiência da metodologia. Pode-se concluir também que a utilização do método heurístico na obtenção do conjunto de treinamento, mesmo para sistemas de grande porte, não inviabiliza a aplicação das RNA para o gerenciamento da reconfiguração de tais sistemas.

Tabela 6.14 – Respostas das RNA e Prog. Inteira 0-1 para Perfis de Carga Mal-Classificados

PERFIL DE CARGA	RESPOSTA DA RNA 1	RESPOSTA DA RNA 2	RESPOSTA DA RNA 3	RESPOSTA DA RNA 4	RESPOSTA DA P. I. 0-1
7	0,5444	0,5996	0,2435	0,3662	Topologia 1
17	0,5526	0,5806	0,2109	0,4273	Topologia 1
26	0,4289	0,4164	0,4674	0,3927	Topologia 1
31	0,6109	0,4331	0,2563	0,3577	Topologia 1
35	0,2199	0,7140	0,5617	0,3491	Topologia 1
42	0,1354	0,7961	0,5163	0,3495	Topologia 2
49	0,1514	0,7852	0,5617	0,3405	Topologia 1
55	0,2493	0,6705	0,5062	0,3687	Topologia 1
79	0,5023	0,5977	0,2478	0,3759	Topologia 1
86	0,4044	0,4619	0,6050	0,3423	Topologia 1
118	0,4563	0,4472	0,4119	0,3597	Topologia 1
122	0,4132	0,5419	0,2354	0,4565	Topologia 1
130	0,6657	0,5555	0,2052	0,4534	Topologia 1
146	0,5327	0,3434	0,5290	0,3553	Topologia 1
158	0,5897	0,5810	0,2366	0,3753	Topologia 1
159	0,3730	0,6133	0,2609	0,4653	Topologia 1
161	0,4858	0,3688	0,3369	0,4260	Topologia 1
191	0,3163	0,5591	0,6021	0,3304	Topologia 1
194	0,1742	0,7601	0,7103	0,3378	Topologia 1
195	0,3160	0,6487	0,4752	0,3616	Topologia 1
196	0,6759	0,2660	0,6927	0,3167	Topologia 1
197	0,5861	0,2671	0,6338	0,3609	Topologia 1
198	0,1467	0,7853	0,6887	0,3767	Topologia 1
199	0,2653	0,6810	0,6363	0,3653	Topologia 1
200	0,1689	0,7770	0,6593	0,3395	Topologia 1

6.5 Conclusão

A partir dos resultados obtidos neste trabalho pode-se constatar, em comparação com os resultados apresentados na literatura, a adequação e a robustez da metodologia baseada em RNA aplicada na operação de sistemas de distribuição com o objetivo de redução das perdas elétricas resistivas do sistema em tempo real.

A melhoria nos resultados e sua robustez deve ser atribuída, em parte, à melhor representação da variabilidade da carga utilizada, e também ao melhor processo de treinamento das RNA utilizados no desenvolvimento deste trabalho em relação ao próprio.

Convém destacar que a utilização de várias RNA para a solução do problema, sendo uma RNA treinada para representar as características dos perfis de carga correspondentes à cada topologia ótima do sistema, facilita consideravelmente o processo de treinamento, que passa a ser bastante rápido e apresenta bons resultados.

É importante observar que a utilização do método de programação inteira 0-1 permite, além de verificar a otimalidade da solução fornecida pelas RNA para perfis de carga a ocorrerem no sistema, comprovar a qualidade do conjunto de dados de treinamento utilizado e a eficiência do próprio processo de treinamento das RNA.

A melhoria na qualidade da solução do problema, obtida através da aplicação do método de programação matemática inteira, vêm confirmar a adequação do processo de busca da topologia ótima do método de programação inteira (o qual considera individualmente cada malha do sistema), bem como a adequação do processo de busca da topologia ótima da metodologia como um todo.

Baseados na qualidade dos resultados alcançados e no tempo desprezível de resposta das RNA, confirma-se a viabilidade da utilização da metodologia proposta na reconfiguração de alimentadores de sistemas automatizados de distribuição.

Capítulo 7 – Considerações Finais

Recursos computacionais de alto desempenho vêm se tornando continuamente menos dispendiosos nos últimos anos. Devido a este fato, tarefas que requerem a utilização de seus recursos se apresentam cada vez mais viáveis do ponto de vista econômico. Por outro lado também os algoritmos se tornam cada vez mais sofisticados, melhorando a eficiência técnica da solução de problemas.

Estas características se adequam ao problema de reconfiguração de alimentadores de sistemas de distribuição de energia, devido a sua natureza combinatorial. Na solução deste problema, diferentes algoritmos são utilizados: heurísticos, de otimização, heurísticos e de otimização conjuntamente, e de inteligência artificial.

Os algoritmos baseados em técnicas heurísticas caracterizam-se pela rápida obtenção da configuração do sistema com perdas reduzidas. Para sistemas de pequeno porte, como qualquer outro algoritmo considerado, as heurísticas apresentam bons resultados, entretanto, não existe nenhuma garantia da otimalidade da sua solução, principalmente quando aplicadas em sistemas de grande porte.

Para os sistemas de grande porte são necessárias regras heurísticas mais sofisticadas e melhor definidas para melhorar os resultados. Neste sentido, aproxima-se da fronteira existente entre os métodos heurísticos e os métodos de otimização, que procuram modelar o problema da forma mais precisa possível. Os métodos híbridos heurístico-otimalistas se adequam à última afirmação, onde as técnicas de otimização são utilizadas para tornar a solução menos dependente de regras heurísticas, fornecendo uma solução mais próxima do ótimo global.

Os resultados obtidos no capítulo 6 demonstram que os métodos heurísticos não devem necessariamente ser descartados para a obtenção de conjunto de treinamento de redes neurais.

Os algoritmos baseados exclusivamente em técnicas de otimização preocupam-se em obter o ótimo global do problema, sem considerações quanto ao tempo computacional envolvido. Embora matematicamente rigorosos, estes algoritmos se tornam, em função do tempo de solução, inviáveis para aplicação em tempo real, quando aplicados a sistemas de maior porte.

Entretanto, pode-se recomendar a utilização dos algoritmos baseados em técnicas de otimização para verificar a adequação da solução fornecida por algoritmos de inteligência artificial em aplicações em tempo real. Este procedimento foi empregado na metodologia desenvolvida nesta tese, onde também os resultados obtidos indicaram a importante contribuição relacionada à qualidade da solução obtida com um método híbrido que agrega redes neurais artificiais e programação matemática inteira.

Dentre os algoritmos baseados em inteligência artificial pode-se destacar aqueles que utilizam redes neurais artificiais, os quais podem se tornar bastante recomendáveis a aplicações em tempo real devido ao tempo reduzido de resolução, inclusive para sistemas de grande porte. Os algoritmos baseados em redes neurais artificiais conseguem estabelecer a relação altamente não-linear existente entre os perfis de carga e as topologias com mínimas perdas resistivas correspondentes a estes perfis.

Também para este tipo de algoritmo, certos fatores devem ser considerados:

- O tempo requerido para o treinamento das redes neurais artificiais costuma ser elevado e tende a crescer proporcionalmente com a dimensão do sistema, o que implica em redes neurais também de maior porte. Porém, como o treinamento é realizado anteriormente à aplicação em tempo real do algoritmo, o tempo de treinamento não inviabiliza, necessariamente, qualquer tipo de aplicação em tempo real. Para cada tipo de aplicação faz-se necessário uma análise relativa a este aspecto. Para a aplicação proposta nesta tese, o tempo de treinamento utilizando-se o algoritmo *backpropagation* mostrou-se adequado à efetivação da metodologia, visto que é significativamente menor que o tempo requerido para uma mudança de configuração do sistema de distribuição (expansão ou manobra da rede). Ainda assim, no sentido de se reduzir o tempo de treinamento efetuaram-se estudos preliminares, onde foi desenvolvido um novo algoritmo híbrido de treinamento de redes neurais que utiliza conjuntamente métodos de otimização de 1ª ordem e de 2ª ordem [22]. No artigo citado utilizou-se inicialmente o algoritmo *backpropagation* durante o processo de treinamento das redes neurais artificiais, e em seguida o algoritmo Marquardt-Levenberg [28]. O algoritmo de Marquardt-Levenberg é utilizado a partir do momento que a convergência do algoritmo *backpropagation* se apresenta lenta, de acordo com a experiência no processo de

treinamento (ver apêndice AII). Dos resultados deste trabalho pode-se concluir que a utilização conjunta dos dois algoritmos apresenta uma redução significativa do tempo de treinamento. Também deve-se destacar que o algoritmo Marquardt-Levenberg torna o processo de treinamento mais sensível ao conjunto de dados, recomendando-se com mais ênfase a utilização de um eficiente algoritmo de pré-processamento de dados.

- O treinamento deve ser executado para cada diferente sistema de distribuição, e as subsequentes alterações em nível topológico do sistema devem ser necessariamente consideradas. Estas alterações topológicas, na grande maioria das vezes, requerem um novo treinamento para as redes neurais artificiais, o que não inviabiliza a aplicação de redes neurais artificiais, pois o tempo de treinamento das redes neurais é muito menor que o tempo necessário a mudanças na topologia do sistema. Porém, se requer que tais alterações sejam conhecidas com antecedência, o que não representa nenhuma restrição se o treinamento das redes neurais for realizado pela própria empresa concessionária do sistema de distribuição ou comunicado a tempo ao engenheiro planejador da operação. Se a rede neural for suficientemente robusta, suportará pequenas variações de configuração.
- Deve ser obtido um conjunto de treinamento apropriado para que as redes neurais artificiais apresentem resultados adequados. Um conjunto de treinamento com dados que não representam as características do sistema, obtidos de maneira não-satisfatória, acarreta um aumento do tempo de treinamento e pode mesmo inviabilizar o treinamento.

Em relação ao tipo de rede neural artificial utilizada, *multilayer perceptrons*, e ao algoritmo de treinamento utilizado, *backpropagation*, os resultados mostraram que estas escolhas são viáveis para a obtenção da solução do problema com eficiência elevada. Entretanto, é importante destacar que, a princípio, outras topologias podem ser indicadas para serem empregadas na solução do problema (memórias associativas, redes auto-organizáveis tipo Kohonen, e redes de Hopfield), bem como diferentes algoritmos de treinamento.

7.1 Contribuições do Trabalho

As principais contribuições do presente trabalho são listadas a seguir.

- Foi desenvolvida uma metodologia híbrida nova e eficiente baseada em redes neurais artificiais e programação matemática inteira, utilizada na reconfiguração em tempo real dos alimentadores primários de redes de distribuição, com o objetivo de obter a topologia com mínimas perdas resistivas em tempo desprezível;
- Foi verificada a otimalidade da solução fornecida pelas redes neurais através da utilização de programação matemática inteira 0-1. A aplicação de programação matemática inteira com o objetivo de verificar a otimalidade da topologia proposta pelas redes neurais apresentava-se, até então, como inédita na literatura [22,23];
- Desenvolveu-se um novo procedimento de busca dos chaveamentos ótimos, modificando o método de programação inteira apresentado na literatura [51], visando sua aplicação a sistemas de distribuição com auto-restabelecimento, ou seja, a redes constituídas por uma única subestação cujo alimentador apresenta possibilidades de reconfiguração;
- A obtenção de conjuntos de treinamento de melhor qualidade obtidos através de sorteios via Simulação Monte Carlo, se comparados aos conjuntos de treinamento que representavam a variabilidade da demanda através de níveis pré-definidos de carga;
- Desenvolveram-se estudos e aplicações iniciais de um novo algoritmo híbrido de treinamento de redes neurais artificiais, baseado no algoritmo de treinamento de 1ª ordem *backpropagation* e no algoritmo de treinamento de 2ª ordem Marquardt-Levenberg, apontando para uma importante redução do tempo de treinamento.

7.2 Sugestões para Trabalhos Futuros

Como sugestão para trabalhos futuros pode-se citar:

- A análise do comportamento da metodologia frente à adoção de um valor mínimo de redução de perdas para se efetuar um chaveamento;
- A utilização de diferentes topologias de redes neurais artificiais e de diferentes algoritmos de treinamento para a solução do problema;

- A utilização de algoritmos de pré-processamento de dados na análise da qualidade do conjunto de treinamento;
- A análise da influência do nível de redundância dos pontos de medição dos sistemas de distribuição na qualidade do conjunto de treinamento;
- Em se tratando de economia de energia resultante da redução de perdas de potência ativa, a ponderação de fatores econômicos (custo do chaveamento, da energia) e de fatores político-sócio-ambientais (políticas de conservação de energia);
- Análise do efeito da reconfiguração do sistema na qualidade do serviço e na confiabilidade do sistema (coordenação da proteção);
- Considerar o efeito transitório resultante das operações de chaveamento;
- Análise do nível de curto-circuito do sistema reconfigurado.

Por fim, se deseja destacar que se espera com este trabalho, motivar a aplicação de sistemas inteligentes na melhoria da eficiência das empresas do setor e em estudos de pesquisadores com interesse na aplicação destes sistemas na solução de problemas técnico-econômicos do setor elétrico brasileiro.

Apêndice I – Método de Fluxo de Carga

AI.1 – Introdução

A escolha de um método de solução de fluxo de carga é frequentemente difícil. Ela requer uma cuidadosa análise comparativa dos méritos e deméritos de cada método com respeito à capacidade de memória, velocidade computacional e características de convergência. As dificuldades surgem do fato de nenhum método possuir todas as características desejáveis dos outros.

O tradicional método de Newton-Raphson requer análise quanto a requisitos de memória, entretanto sua característica de convergência quadrática lhe confere preferência. Por sua vez o método de Gauss-Seidel apresenta desfavorável característica de convergência e favorável característica de requisitos de memória em comparação com o fluxo de carga via Newton-Raphson.

O método adotado requer mais capacidade de memória do que o fluxo de carga via Gauss-Seidel (em virtude de armazenar Ibarra e Imalha), mas apresenta confiabilidade de convergência comparável e um menor tempo de execução que o Newton-Raphson. Este método pode ser implementado eficientemente em microcomputadores de limitada capacidade de memória, sendo enfatizada a velocidade computacional visando possíveis aplicações *on-line* [39].

AI.2 - Equacionamento do Método de Malhas de Fluxo de Carga

Na formulação do modelo são efetuadas as seguintes simplificações:

- i) o sistema é trifásico equilibrado,
- ii) o carregamento das barras de carga é representado por fonte de potência constante.

Neste trabalho a utilização do fluxo de carga destina-se à reconfiguração da rede primária de distribuição com o objetivo de minimizar suas perdas elétricas. As barras de carga são principalmente transformadores de tensão primária para tensão secundária. Em virtude deste fato, em estudos de operação, permite-se trabalhar com diferentes níveis de carregamento destes transformadores, justificando-se a utilização da simplificação ii) acima.

Em consequência da simplificação i) acima é utilizada a representação monofásica no equacionamento do modelo. Um típico diagrama com esta representação monofásica é mostrada na figura AI.1 .

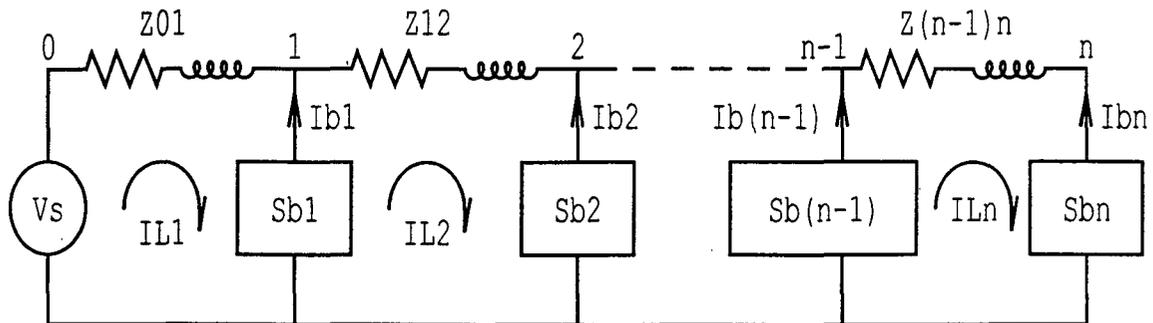


Figura AI.1- Representação Monofásica do Sistema

A partir da figura AI.1, as seguintes equações podem ser obtidas para um sistema radial com n barras usando-se teoria de circuitos elétricos.

A potência aparente da barra de carga é definida como:

$$Sb_i = -Vb_i \cdot Ib_i^* \quad i = 1, 2, \dots, n \quad (\text{AI-1})$$

Onde: i são as barras de carga; Sb_i é a potência aparente da barra de carga i ; Vb_i é a tensão da barra de carga i ; Ib_i é a corrente da barra de carga i . O sinal negativo da equação (AI-1) deve-se ao fato da corrente de barra estar orientada do ponto de menor potencial para o ponto de maior potencial da barra de carga.

Aplicando-se a lei de Kirchoff para as malhas, obtêm-se as quedas de tensão nas seções dos alimentadores de cada malha:

$$E_1 = V_S - V_1 \quad E_i = V_{i-1} - V_i \quad i = 2, 3, \dots, n \quad (\text{AI-2})$$

Visto que E_i é também relacionada à impedância da linha e à corrente que flui através dela, um outro conjunto de equações equivalente pode ser obtido:

$$E_1 = Z_{01} \cdot I_{L1} \quad E_2 = Z_{12} \cdot I_{L2}$$

$$E_n = Z_{(n-1)n} \cdot I_{Ln} \quad (\text{AI-3})$$

Onde: I_{Li} é a corrente na seção do alimentador da malha i .

Aplicando-se a lei das correntes de Kirchhoff aos nós tem-se:

$$I_{Li} = -I_{bi} + I_{L(i+1)} \quad i = 1, \dots, n-1 \quad I_{Ln} = -I_{bn} \quad i = n \quad (\text{AI-4})$$

Com os valores de todas as correntes de malha (correntes nos alimentadores) e o valor da tensão na subestação, calculando-se as quedas de tensão nos alimentadores, da subestação até o fim da linha, obtém-se todos os outros valores de tensão.

AI.3 Algoritmo

A partir da formulação da seção anterior, a solução do fluxo de carga de sistemas de distribuição pode ser obtida através dos seguintes passos, utilizando-se o método iterativo básico de Gauss:

- 1) leitura dos dados do sistema;
- 2) estimativa inicial da tensão em cada barra;
- 3) cálculo das correntes de barra através da equação (AI-1);
- 4) cálculo das correntes de malha através da Equação (AI-4) usando substituição reversa (sentido malha n - malha 1);
- 5) cálculo das quedas de tensão usando a Equação (AI-3);
- 6) cálculo das novas tensões de barra através da Equação (AI-2) usando substituição direta (sentido malha 1 - malha n);
- 7) determinar as diferenças de tensão entre a iteração atual e a iteração anterior;
- 8) se a diferença de tensão calculada no passo 7 para alguma barra for maior que a tolerância, retornar ao passo 3 com os novos valores de tensões, caso contrário, calcular as informações necessárias a aplicação desejada (por exemplo, as perdas elétricas nas linhas) e imprimir os resultados. O fluxograma do algoritmo é apresentado na figura AI-2, a seguir.

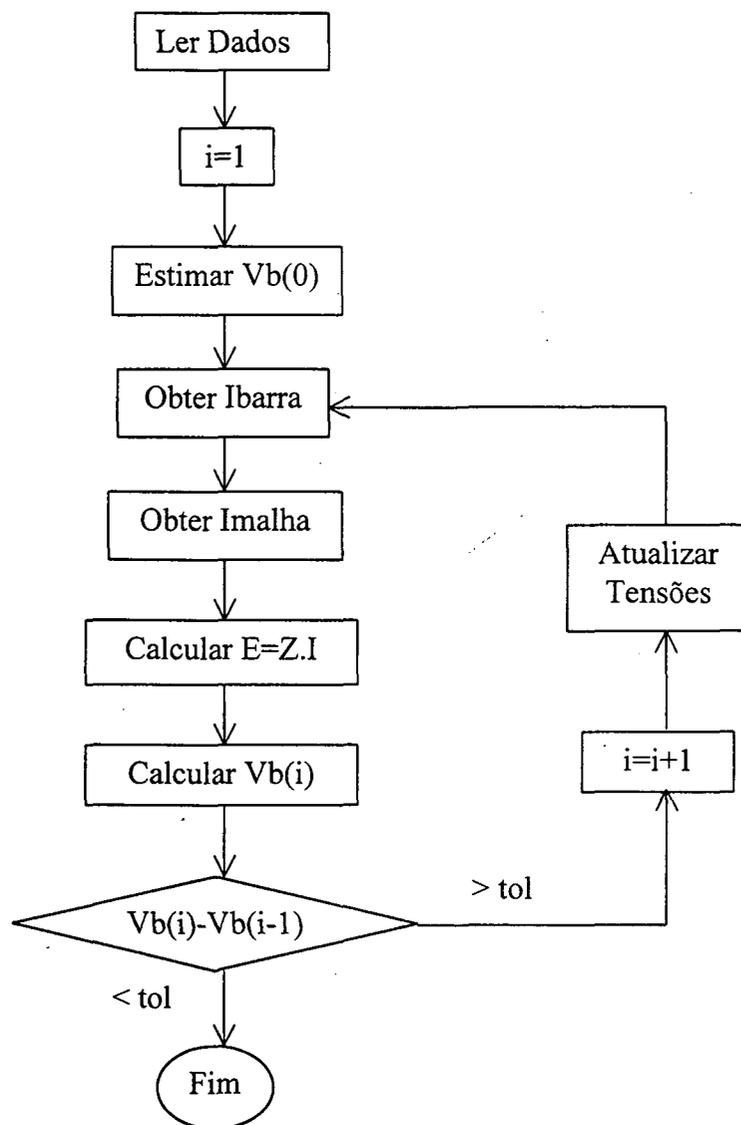


Figura AI.2 - Fluxograma do Método de Malhas de Fluxo de Carga

Apêndice II – Algoritmo Híbrido *Backpropagation*/Marquardt-Levenberg

AII.1 – Introdução

O algoritmo de treinamento de redes neurais artificiais de 1ª ordem *backpropagation* apresenta em determinadas aplicações convergência lenta, ou até mesmo a não convergência para o conjunto utilizado de dados de treinamento. Os algoritmos de treinamento de 2ª ordem, por sua vez, apresentam maior rapidez de convergência, embora sejam mais sensíveis a mínimos locais quando o ponto de partida está situado distante do ótimo global.

Gauche *et al.* propõem em [22] a utilização conjunta de um algoritmo de treinamento de 1ª ordem (*backpropagation*) e de um algoritmo de treinamento de 2ª ordem (Marquardt-Levenberg), procurando aproveitar as boas características complementares dos dois algoritmos (figura AII.1).

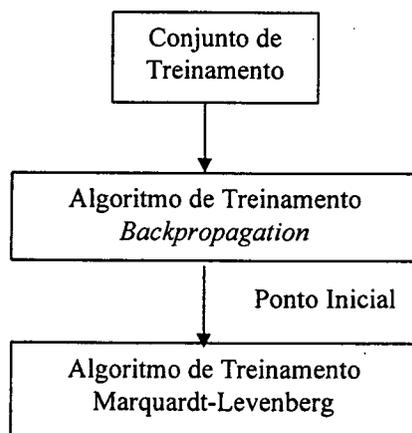


Figura AII.1 – Algoritmo Híbrido *Backpropagation*/Marquardt-Levenberg

O algoritmo de 1ª ordem é utilizado para se obter um melhor ponto de partida para o algoritmo de 2ª ordem, evitando-se assim mínimos locais indesejáveis. Por sua vez, a

convergência do algoritmo híbrido se torna mais rápida do que a convergência do algoritmo de 1ª ordem utilizado isoladamente.

O início da utilização do algoritmo de treinamento Marquardt-Levenberg é definido em função do erro do conjunto de treinamento. Este valor é obtido empiricamente através da experiência com o treinamento para a aplicação desejada [22].

O ajuste dos pesos através do algoritmo de treinamento Marquardt-Levenberg é obtido através da equação AII-1.

$$\Delta \bar{x} = [J^t(\bar{x}) \cdot J(\bar{x}) + \eta I]^{-1} J^t(\bar{x}) \cdot e(\bar{x}) \quad (\text{AII-1})$$

Onde: $J(\bar{x})$ é a matriz jacobiana obtida considerando-se a variação do erro de cada entrada em função da variação do valor das conexões da rede neural;

$e(\bar{x})$ é o vetor que representa a diferença entre o valor desejado de saída da rede neural e o valor obtido para cada entrada;

I é a matriz identidade;

η é uma constante.

A constante η (geralmente menor que um) é multiplicada por β (geralmente maior do que um) cada vez que uma iteração resulta num acréscimo do erro quadrático total de treinamento, e dividida por β , caso contrário [28].

AII.2 - Metodologia para a Reconfiguração Considerando-se a Minimização de Perdas

A metodologia utilizada para a reconfiguração de sistemas de distribuição objetivando a minimização das perdas resistivas é basicamente a mesma apresentada no capítulo 6. A diferença reside no passo 3 onde, no lugar do algoritmo de 1ª ordem *backpropagation* é utilizado o algoritmo híbrido de treinamento (figura AII-2), com a finalidade de reduzir o tempo de treinamento.

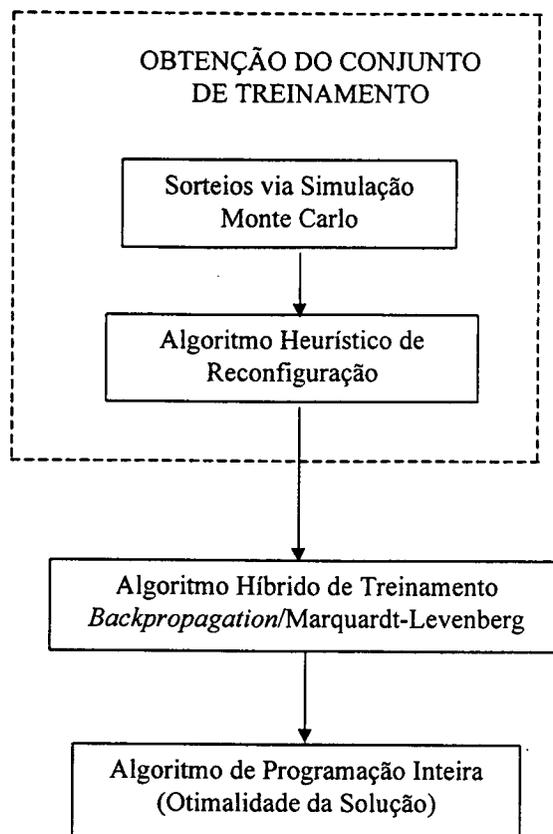


Figura AII.2 – Metodologia para Minimização de Perdas

AII.3 – Resultados e Conclusões

O bteve-se para o sistema teste 1 do capítulo 6, com a metodologia híbrida de treinamento, resultados preliminares equivalentes aos obtidos no capítulo 6 com o algoritmo *backpropagation*, porém com tempo de treinamento aproximadamente 40% inferior [22]. Sistemas de maior porte devem ser analisados para a obtenção de um melhor julgamento da metodologia, visto que a convergência do algoritmo de Marquardt-Levenberg, “torna-se mais lenta quando a rede neural apresenta pouco mais que algumas centenas de conexões” [28].

Referências Bibliográficas

- [1] Baran M. E. and Wu F. F., Network Reconfiguration in Distribution Systems for Loss Reduction and Load Balancing, IEEE Trans. on PWRD, vol. 4, pp. 1401-1407, 1989.
- [2] Barreto J. M.; Inteligência Artificial – No Limiar do Século XXI, pp9 Edições, Florianópolis, 1997.
- [3] Borozan V. and Raiakovic N.; Application Assessments of Distribution Network Minimum Loss Reconfiguration, IEEE Trans. on PWRD, vol.12, pp. 1786-1792, 1997.
- [4] Borozan V., Rajcic D. and Ackovski R.; Improved Method for Loss Minimization in Distribution Networks, IEEE Trans. on PWRD, vol. 10, pp. 1420-1425, 1995.
- [5] Butler K. L. and Momoh J. A.; A Neural Net Based Approach for Fault Diagnosis in Distribution Networks, IEEE Winter Meeting, pp. 353-356, New York, USA, 1999.
- [6] Casari F., Mantovani J.R.S. e Romero R.; Reconfiguração de Sistemas de Distribuição de Energia Elétrica para Planejamento da Operação, XII Congreso Chileno de Ingeniería Eléctrica, Temuco, Chile, 1997.
- [7] Castro Jr. C. A., Watanabe A.A.; An Efficient Reconfiguration Algorithm for Loss Reduction of Distribution Systems, Electric Power Systems Research, vol. 19, pp. 137-144, 1990.
- [8] Celik M. K.; Integration of Advanced Applications for Distribution Automation, IEEE Winter Meeting, pp. 366-369, New York, USA, 1999.
- [9] Chen C.-L., Chen J.-L.; A Neural Network Approach for Evaluating Distribution Systems Reliability, Electric Power Systems Research, vol. 26, pp. 225-229, 1993.
- [10] Cherniak E. and McDermott D.; Introduction to Artificial Intelligence, Addison-Wesley, Massachusetts, 1985.
- [11] Chiang H. D. and Jean-Jumeau R.; Optimal Network Reconfiguration in Distribution Systems, A Solution Algorithm and Numerical Results, IEEE Trans. on PWRD, vol. 5, pp. 1568-1575, 1990.
- [12] Civanlar S., Grainger J. J., Yin H., and Lee S. S. H.; Distribution Feeder Reconfiguration for Loss Reduction, IEEE Trans. on PWRD, vol. 3, pp. 1217-1223, 1988.
- [13] Coelho J.; Representação Probabilística da Carga em Fluxo de Potência de Sistemas de Distribuição, Concurso para Professor Titular do Depto. de Engenharia Elétrica da UFSC, 1998.
- [14] Coelho J., Gauche E.; Melhorias do Atendimento a Clientes Especiais sob o Enfoque de Tensão e Confiabilidade, II ENTEEC - Encuentro em Tecnologías Eléctricas, Electrónicas e Computacionales, pp. 1.2.1-1.2.6, Oruro, Bolívia, 1995.
- [15] Coelho J., Gauche E.; Uma Metodologia para o Planejamento de Sistemas de Distribuição, IV Congreso IEEE Chile de Sistemas de Potencia e I Congreso Chileno de Sistemas de Distribución, pp. 339-343, Santiago, Chile, 1994.
- [16] Dillon T. S.; Artificial Neural Network Applications to Power Systems and their Relationship to Symbolic Methods, Electric Power & Energy Systems, vol. 13, pp. 66-72, 1991.
- [17] El Sharkawi M.A. and Huang S.I.; Application of Genetic-Based Neural Networks to Power Systems Static Security Assessments, Intelligent Systems Applied to Power Systems, Montpellier, França, 1997.
- [18] El-Sharkawi M. A.; Neural Network and its Ancillary Techniques as Applied to Power Systems, V SEPOPE, Recife, Brasil, 1996.

[19] Fan J.-Y., Zhang L. and McDonald J.D.; Distribution Network Reconfiguration: Single Loop Optimization, IEEE Trans. on PWRs, pp.1643-1647, 1996.

[20] Francelin R.A.; Otimização de Sistemas Através de Redes Neurais Multi-camadas, XI CBA, São Paulo, Brasil, 1996.

[21] Gallego R.A., Monticelli A. e Romero R.; Um Método Aproximado de Otimização Usado na Reconfiguração de Redes de Distribuição, XI Congreso Chileno de Ingeniería Eléctrica, vol. A., pp. 86-91, Punta Arenas, Chile, 1995.

[22] Gauche E., Coelho J. and Teive R.C.G.; A Mixed Back-Propagation/Marquardt-Levenberg Algorithm for Optimizing the Distribution Electrical Systems Operation, IEEE PES Transmission and Distribution Conference and Exposition, New Orleans-LA, USA, 1999.

[23] Gauche E., Coelho J. and Teive R.C.G.; An On-Line Optimal Distribution Feeder Reconfiguration Algorithm for Resistive Loss Reduction Using a Multilayer Perceptron, IEEE ICNN - International Conference on Neural Networks, pp. 179-182, Houston-TX, USA, 1997.

[24] Gauche E., Coelho J.; Uma Proposta de Utilização de Redes Neurais na Reconfiguração de Redes de Distribuição com Incerteza na Demanda, 3^o ELAB - Encontro Luso-Afro-Brasileiro de Planejamento e Exploração de Redes de Energia, ST 6B – 22, Porto, Portugal, 1996.

[25] Gauche E., Minimização de Perdas Elétricas de Sistemas de Distribuição através de Reconfiguração de Redes, Dissertação de Mestrado, Universidade Federal de Santa Catarina, 1994.

[26] Goldberg D.; Genetic Algorithm in Search, Optimization and Machine Learning, Editora Addison-Wesley, USA, 1989.

[27] Goswami S. K. and Basu S. K., A New Algorithm for the Reconfiguration of Distribution Feeders for Loss Minimization, IEEE Trans. on PWRD, vol. 7, pp. 1484-1490, 1992.

[28] Hagan M. T. and Menhaj M. B., Training Feedforward Networks with the Marquardt Algorithm, IEEE Trans. on Neural Networks, vol. 5, pp. 989-993, 1994.

[29] Hillier F.S. and Lieberman G.J.; Introduction to Mathematical Programming, 2nd Edition, McGraw-Hill, USA, 1995.

[30] Hsu C. T., Tzeng Y. M., Chen C. S. and Cho M. Y.; Distribution Feeder Loss Analysis by Using an Artificial Neural Network, Electric Power Systems Research, vol. 34, pp. 85-90, 1995.

[31] Hsu Y.-Y. and Huang H.-M.; Distribution System Service Restoration Using the Artificial Neural Network Approach and Pattern Recognition Method, IEEE Proc. on Gener. Trans. Distrib., vol.142, pp. 251-256, 1995.

[32] Jasmon G. B. and Callistus C. Lee L. H., A Modified Technique for Minimization of Distribution System Losses, Electric Power System Research, vol. 20, pp. 81-88, 1991.

[33] Kagan N. e de Oliveira C. C. B.; Reconfiguração de Redes de Distribuição de Energia Elétrica através de Ferramenta para Solução de Problemas de Decisão com Múltiplos Objetivos e Incertezas, Revista Controle & Automação da SBA (Sociedade Brasileira de Automática), pp. 18-29, Vol. 9-1, 1998.

[34] Kim H., Ko Y., Jung K.-H.; Artificial Neural Network Based Feeder Reconfiguration for Loss Reduction in Distribution Systems, IEEE Trans. on PWRD, vol. 8, pp. 1356-1366, 1993.

[35] Klockgether J. and Schwefel, Two-Phase Nozzle and Hollow Core Jet Experiments, Proc. 11th Symp. Engineering Aspects of Magnetohydrodynamics, pp. 141-148, Pasadena – CA, USA, 1970.

- [36] Lee S. J., Lim S. I. and Ahn B. S.; Service Restoration of Primary Distribution Systems Based on Fuzzy Evaluation of Multicriteria, IEEE Trans. on PWRS, 1998.
- [37] Leite da Silva A. M., Blanco F. A. F. P. and Coelho J.; Discrete Convolution in Generating Capacity Reliability Evaluation – LOLE Calculations and Uncertainty Aspects, IEEE Trans. on PWRS, vol. 3, pp. 1616-1624, 1988.
- [38] Leite da Silva A. M., Geber de Melo A. C., Coelho J., Pazo Blanco F. A. F. and Cunha S. H. F.; The Effects of Uncertainties in Generating Capacity Reliability Evaluation, 2nd Int. Symp. on Probabilistic Methods Applied to Electrical Power Systems, Oakland, USA, 1988.
- [39] Lin C. E., Huang Y. W., Distribution System Load Flow Calculation with Microcomputer Implementation, Electric Power System Research, vol. 13, pp. 139-145, 1987.
- [40] Lin W.-M., Chin H.-C. and Yu G.-J.; An Effective Algorithm for Distribution Feeder Loss Reduction by Switching Operations, pp. 597-602, IEEE Winter Meeting, New York, USA, 1999.
- [41] Lopez E.P., Opazo H.M., Pedrero P.P., Martinez M.; Reconfiguración Primaria a Mínimas Pérdidas Considerando Incertidumbre en la Demanda - Um Modelo de Exploración Aleatoria, XI Congreso Chileno de Ingeniería Eléctrica, vol. A, pp. 300-305, Punta Arenas, Chile, 1995.
- [42] Mohamed E. A., Rao N. D.; Artificial Neural Networks Based Fault Diagnostic Systems for Electric Power Distribution Feeders, Electric Power Systems Research, vol. 35, pp. 1-10, 1995.
- [43] Nara K., Shiose A., Kitagawa M. and Ishibara T.; Implementation of Genetic Algorithm for Distribution Systems Loss Minimum Reconfiguration, IEEE Trans. on PWRS, vol. 7, pp. 1044-1051, 1992.
- [44] Novak B.; Superfast Autoconfiguring Artificial Neural Network and Their Application to Power Systems, Electric Power Systems Research, vol. 35, pp.11-16, 1995.
- [45] Pereira M. A. e Murari C. A. F.; Álgebra Nebulosa Aplicada à Restauração de Redes de Distribuição de Energia Elétrica, 3^o Simpósio Brasileiro de Automação Inteligente, pp. 248-253, Vitória, Brasil, 1997.
- [46] Pinheiro F. A. e de Vasconcelos J. A.; Minimização das Perdas em Sistemas Elétricos de Potência Utilizando Algoritmos Genéticos, XII Congresso Brasileiro de Automática, Uberlândia, 1998.
- [47] Popovic D. and Murty K.; Retaining Diversity of Search Point Distribution Through a Breeder Genetic Algorithm for Neural Network Learning, IEEE ICNN, pp. 495-498, 1997.
- [48] Rojas R.; Neural Networks – A Systematic Introduction, Editora Springer-Verlag, Alemanha, 1996.
- [49] Rumelhart D.E., Hinton G.E. and Williams R.J.; Learning Internal Representations by Backpropagating Errors, Nature 323, pp. 696-699, 1986.
- [50] Sarfi R. A., Salama M. M. A. and Chikhani A. Y.; A Survey of the State of the Art in Distribution System Reconfiguration for System Loss Reduction, Electric Power Systems Research, vol. 31, pp. 61-70, 1994.
- [51] Sarma and Rao, A New 0-1 Integer Programming Method of Feeder Reconfiguration for Loss Minimization in Distribution Systems, Electric Power Systems Research, vol. 33, pp. 125-131, 1995.
- [52] Scaramutti J. C.; Aplicação de Algoritmos Genéticos no Restabelecimento de Energia em Sistemas de Distribuição, Dissertação de Mestrado, UFSC, 1999.

[53] Schaffer G.; Distribution System Control and Automation, Electric Power & Energy Systems, vol.16, pp. 197-205, 1994.

[54] Shirmohammadi D. and Hong H.W., Reconfiguration of Electric Distribution Networks for Resistive Line Losses Reduction, IEEE Trans. on PWRD, vol. 4, pp. 1492-1498, 1989.

[55] Tutorial Course on Artificial Neural Networks with Applications to Power Systems, IEEE PES, 1996.

[56] Zhou Q., Shirmohammadi D. and Liu W.-H.E.; Distribution Feeder Reconfiguration for Operating Loss Reduction, IEEE Trans. on PWRS, vol.12, pp. 730-735, 1997.