

UNIVERSIDADE FEDERAL DE CAMPINA GRANDE
CENTRO DE ENGENHARIA ELÉTRICA E INFORMÁTICA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

Dissertação de Mestrado

Desenvolvimento de Ferramenta Computacional baseado em Técnicas de Inteligência Artificial para Avaliação de Estabilidade de Tensão

Ferdinando Fernandes Machado

Ferdinando Fernandes Machado

**Desenvolvimento de Ferramenta Computacional baseado
em Técnicas de Inteligência Artificial para Avaliação de
Estabilidade de Tensão**

*Dissertação apresentada à Coordenação do Programa
de Pós-Graduação em Engenharia Elétrica da
Universidade Federal de Campina Grande, em
cumprimento às exigências para obtenção do Grau de
Mestre em Ciências no Domínio da Engenharia
Elétrica.*

Área de Concentração: Estabilidade de Tensão

Wellington Santos Mota, Ph.D.
Orientador

Benemar Alencar de Sousa, D.Sc.
Orientador

Campina Grande – Paraíba – Brasil
Outubro de 2009

UNIVERSIDADE FEDERAL DE CAMPINA GRANDE

Ferdinando Fernandes Machado

UFMG - BIBLIOTECA - CAMPUS I	
810	24-05-09

Desenvolvimento de Ferramenta Computacional baseada em Técnicas de Inteligência Artificial para Avaliação de Estabilidade de Tensão

Dissertação apresentada à Faculdade de Engenharia de Física da Pós-Graduação em Engenharia Elétrica da Universidade Federal de Campina Grande em cumprimento de exigências para obtenção do Grau de Mestre em Ciências no âmbito da Engenharia Elétrica.

FICHA CATALOGRÁFICA ELABORADA PELA BIBLIOTECA CENTRAL DA UFG

M149d

2009 Machado, Ferdinando Fernandes.

Desenvolvimento de ferramenta computacional baseado em técnicas de inteligência artificial para avaliação de estabilidade de tensão / Ferdinando Fernandes Machado. — Campina Grande, 2009.

61 f.: il.

Dissertação (Mestrado em Engenharia Elétrica) – Universidade Federal de Campina Grande, Centro de Engenharia Elétrica e Informática.

Referências:

Orientador: Prof. Dr. Wellington Santos Mota, Prof. Dr. Benemar Alencar de Sousa.

1. Estabilidade de Tensão. 2. Técnicas de Inteligência Artificial. 3. Base de Dados. I. Título.

CDU – 621.315:004.93'1(043)

DESENVOLVIMENTO DE FERRAMENTA COMPUTACIONAL BASEADO EM
TÉCNICAS DE INTELIGÊNCIA ARTIFICIAL PARA AVALIAÇÃO DE
ESTABILIDADE DA TENSÃO

FERDINANDO FERNANDES MACHADO

Dissertação Aprovada em 30.10.2009



WELLINGTON SANTOS MOTA, Ph.D.

Orientador



BENEMAR ALENCAR DE SOUZA, D.Sc., UFCG

Orientador



MANOEL AFONSO DE CARVALHO JÚNIOR, Ph.D., UFPE

Componente da Banca



WASHINGTON LUIZ ARAUJO NEVES, Ph.D., UFCG

Componente da Banca

CAMPINA GRANDE - PB
OUTUBRO - 2009

À meus pais Carlos e Gleide pelo apoio e, ao meu tio Dalfran pelo suporte em minhas decisões profissionais.

AGRADECIMENTOS

Agradeço primeiramente a Deus por guiar meus passos, por permitir que as oportunidades surjam.

Aos professores Wellington Santos Mota e Benemar Alencar de Souza por me orientarem em minha pesquisa, e por confiarem na minha capacidade para realizar este trabalho.

Ao engenheiro Eduardo de Aguiar Sodré – CHESF, diretor do projeto de P&D em que este trabalho foi baseado, pelos ensinamentos, conselhos, paciência e disposição para discutir os problemas surgidos durante esta pesquisa.

Aos professores Damásio Fernandes Jr., Benedito Antônio Luciano e Washington Luiz Araújo Neves, que mesmo não sendo meus orientadores, deram as suas contribuições nos momentos em que recorri a eles.

Aos amigos do Laboratório de Alta Tensão (LAT) Célio, Wilker, Flávio, Helon, Henrique, Michelle, Francisco e Karcus. E aos que já não se encontram neste laboratório Kléber, Ângelo, Thyago, Eubis, Estácio, Max e Antônio Carlos, por terem contribuído de alguma forma para a realização deste trabalho.

Agradeço em particular à minha futura esposa, Bartira Brandão da Cunha pelo apoio nos momentos difíceis durante esses últimos seis anos de companheirismo.

Ferdinando Fernandes Machado

RESUMO

O desenvolvimento de uma ferramenta computacional capaz de avaliar a segurança de um sistema de potência em relação à instabilidade de tensão, utilizando técnicas de Inteligência Artificial (IA) é apresentado. Um método baseado em técnicas de IA para a avaliação da segurança de tensão dos sistemas de potência, composto por um arranjo híbrido de uma rede neural *Resilient Propagation* (RPROP) em série com uma Levenberg-Marquardt, é proposto. Bases de dados foram construídas, utilizando-se a Área Leste do Subsistema Nordeste, pertencente à rede básica da CHESF, e o *software* ANAREDE[®], objetivando o treinamento, validação e teste das técnicas de IA analisadas. O desempenho desse sistema foi verificado através dos recursos computacionais *Neural Network Toolbox* e *Fuzzy Logic Toolbox*, do MATLAB[®]. O *software* foi desenvolvido utilizando-se a linguagem de programação C++.

Palavras-chave: Estabilidade de tensão, técnicas de inteligência artificial, base de dados.

ABSTRACT

The development of a computational tool capable of evaluating the security of a power system in relation to the voltage instability, using techniques of Artificial Intelligence (AI) is presented. An AI-based method for the assessment of voltage safety of power systems, composed of a hybrid arrangement of a Resilient Propagation neural network (RPROP) in series with a Levenberg-Marquardt, is proposed. Databases were constructed using the Area Least of Northeast Subsystem, belonging to the CHESF's core network, and the software ANAREDE[®], to the training, validation and testing techniques of AI analyzed. The performance of this system was verified through computer resources Neural Network Toolbox and Fuzzy Logic Toolbox of MATLAB[®]. The software was developed using the programming language C + +.

Keywords: Voltage stability, techniques of artificial intelligence, database.

SUMÁRIO

LISTA DE FIGURAS	vii
LISTA DE TABELAS	viii
Capítulo 1	1
Introdução	1
1.1 Motivação	1
1.2 Objetivos.....	2
1.3 Revisão Bibliográfica	3
1.3.1 Grupo de Análise Rápida.....	3
1.3.2 Grupo de Simulação Rápida no Tempo.....	4
1.3.3 Grupo de Inteligência Artificial.....	5
1.4 Estrutura da Dissertação	11
Capítulo 2	12
Estabilidade de Tensão	12
4.1 Introdução.....	12
2.2 Colapso de Tensão.....	13
2.3 Métodos de Avaliação da Estabilidade de Tensão	13
2.2 Critérios de Segurança.....	15
Capítulo 3	17
Técnicas de Inteligência Artificial.....	17
3.1 Introdução.....	17
3.2 Reconhecimento de Padrões	17
3.3 Redes Neurais Artificiais.....	19
3.2.1 Algoritmo de Treinamento <i>Backpropagation</i>	21
3.2.2 Algoritmo de Treinamento <i>Resilient Propagation</i> (RPROP).....	24
3.2.3 Algoritmo de Treinamento Levenberg-Marquardt.....	25
3.3 Sistemas Fuzzy	26
3.4 Sistema Neuro-Fuzzy (ANFIS)	27
3.5 Sistema Híbrido RPROP	29
Capítulo 4	31
Método Proposto e Base de Dados	31
4.1 Introdução.....	31
4.2 Método Proposto: Sistema Híbrido LM	31
4.3 Base de Dados	33
4.3.1 Exemplo Prático de Avaliação da Estabilidade de Tensão	35
Capítulo 5	39
Avaliação das Técnicas de Inteligência Artificial	39
5.1 Introdução.....	39
5.2 Resultados dos Sistemas Classificadores	39
5.4 Conclusões dos Resultados.....	43
5.5 Desenvolvimento do <i>Software</i>	44
Capítulo 6	46
Conclusões.....	46
REFERÊNCIAS	49

LISTA DE FIGURAS

Figura 2.1 – Curva PV.....	15
Figura 3.1 – Espaço de Características.....	19
Figura 3.2 – Modelo de Um Neurônio Artificial.....	20
Figura 3.3 – Rede Multilayer Perceptron (MLP).	21
Figura 3.4 – Sistema Fuzzy.	27
Figura 3.5 – Arquitetura ANFIS.....	28
Figura 3.6 – Sistema Classificador Híbrido RPROP.....	30
Figura 4.1 – Sistema Classificador Híbrido LM.	31
Figura 4.2 – Principais Troncos de 500kV do Sistema Norte-Nordeste ano 2010.....	33
Figura 4.3 – Sistema de Avaliação da Estabilidade de Tensão por Áreas.....	34
Figura 4.4 – Trecho do Sistema Norte-Nordeste.....	36
Figura 4.5 – Curva PV da Barra Penedo 230 kV Pré-Contingência.....	37
Figura 4.6 – Curva PV da Barra Penedo 230 kV Pós-Contingência.	37
Figura 5.1 – Treinamento do Sistema Híbrido LM via <i>software</i> TreinaRNA.exe.....	45
Figura 5.2 – Classificação do Sistema de Potência via <i>software</i> ExecutaRNA.exe.....	45
Figura 6.1 – <i>Software</i> para Análise de Segurança de Tensão em Sistemas de Grande Porte.....	47

LISTA DE TABELAS

Tabela 3.1 – Exemplos de Reconhecimento de Padrões	18
Tabela 5.1 – Resultados Considerando 5 Barras Críticas.....	41
Tabela 5.2 – Resultados Considerando 17 Barras Críticas.....	42
Tabela 5.3 – Resultados Considerando 41 Barras Críticas.....	43

Capítulo 1

Introdução

A estabilidade de tensão em sistemas de potência tem sido um grande desafio para engenheiros e pesquisadores. Segundo Kundur (1998), os primeiros problemas de estabilidade de tensão foram notificados em 1920. Estes problemas estavam associados ao suprimento de grandes centros metropolitanos através de geração hidrelétrica transmitida a longa distância.

O modelo do setor elétrico vem sofrendo mudanças radicais durante os últimos anos, tais como introdução da concorrência entre os diferentes agentes do mercado de energia e privatizações dos ativos do setor. Além disso, vem ocorrendo outros fatos importantes: interconexão de sistemas anteriormente independentes com novos sistemas, aumento do uso de dispositivos rápidos de compensação de reativos, restrições ambientais cada vez mais severas (Van Cutsem, 2000). Tudo isso, levou os sistemas de potência a operarem próximos à sua capacidade máxima de transmissão, elevando o grau de complexidade dos problemas de estabilidade, necessitando, desta forma, de uma análise mais minuciosa, além do desenvolvimento de técnicas e ferramentas para sua avaliação.

1.1 Motivação

O problema da estabilidade de tensão vem sendo analisado de várias maneiras. Atualmente existem na literatura diversos procedimentos que permitem avaliar o nível de segurança de um sistema em termos da estabilidade de tensão. No entanto, os métodos tradicionais não satisfazem as necessidades de eficiência desejadas pelos operadores do sistema em situações de tempo real. Neste contexto, os métodos baseados em técnicas de Inteligência Artificial (IA) têm sido bastante utilizados por se mostrarem suficientemente seguras e eficientes.

O potencial de utilização das técnicas de IA em sistemas de potência inclui: análise de segurança, diagnóstico de falhas, estimação de estado, controle, previsão de

carga, etc. Na literatura são apresentadas diversas técnicas de IA como, por exemplo, a Lógica Fuzzy, Algoritmos Genéticos, KNN (*K-nearest neighborhood*) e as Redes Neurais Artificiais. Neste trabalho procura-se determinar o método mais apropriado, tendo em vista a análise de segurança de tensão, para sua implementação em uma ferramenta computacional.

Esta pesquisa está relacionada com trabalhos do Grupo de Sistemas Elétricos (GSE) da Universidade Federal de Campina Grande (UFCG) inseridos na linha de pesquisa denominada Estabilidade de Tensão em Sistemas de Potência, a exemplo de um projeto de Pesquisa e Desenvolvimento (P&D) concluído, com recursos aportados pela Companhia Hidroelétrica do São Francisco (CHESF).

1.2 Objetivos

Este trabalho tem por objetivo a avaliação de técnicas de inteligência artificiais para o desenvolvimento de uma ferramenta computacional, em linguagem de programação C++, capaz de realizar a avaliação da segurança de um sistema de potência em relação à instabilidade de tensão. O *software* desenvolvido será utilizado em um projeto de P&D da CHESF.

Também é proposto um sistema híbrido baseado em técnicas de IA, denominado Sistema Híbrido LM.

Os objetivos específicos deste trabalho são:

- Analisar o estado da arte da utilização de técnicas de IA para avaliação da estabilidade de tensão;
- Investigar a técnica de IA mais adequada para a avaliação de segurança de tensão de um sistema de potência, através dos recursos computacionais *Neural Network Toolbox* e *Fuzzy Logic Toolbox* do MATLAB®;
- Desenvolver um *software* em linguagem de programação C++ capaz de avaliar a segurança de tensão através da técnica de IA escolhida.

1.3 Revisão Bibliográfica

Os estudos mais recentes de avaliação da estabilidade de tensão são divididos em três grupos:

- 1 – Análise Rápida;
- 2 – Simulação Rápida no Tempo;
- 3 – Inteligência Artificial.

Estes grupos foram desenvolvidos com o propósito de solucionar os problemas da estabilidade de tensão de forma mais eficiente. Para este trabalho, foram selecionados os artigos mais relevantes dos grupos de Análise Rápida e Simulação Rápida no Tempo, porém com maior enfoque sobre o grupo de Inteligência Artificial, o qual se constitui a base deste trabalho.

1.3.1 Grupo de Análise Rápida

O grupo de análise rápida é composto por técnicas que se utilizam das tradicionais técnicas de análise em regime permanente ou de transitório eletromecânico.

O trabalho de Zambroni *et al.* (2000), apresenta uma metodologia para a avaliação de estabilidade de tensão em tempo real, na qual primeiramente é modelada a operação do sistema por um estimador de estados e em seguida o ponto de colapso de tensão é determinado pela extrapolação do vetor tangente do Método da Continuação. Foram realizados testes usando o sistema IEEE-14 barras para a validação do método.

Ming Ni *et al.* (2003) apresentam uma abordagem para avaliação de segurança *on-line* do sistema de potência baseada em risco (*Online Risk-Based Security Assessment - OL-RBSA*). Esta abordagem resulta numa quantificação *on-line* rápida do nível de segurança do sistema associada a uma condição de operação existente ou estimada. São determinados índices para cada tipo de contingência através da solução do fluxo de carga, os quais são computados como uma soma da probabilidade de ocorrência de certa contingência multiplicada pela severidade da mesma. Tais índices constituem uma função de severidade a qual reflete as conseqüências da contingência e as condições de carregamento do sistema, sendo usados pelos operadores para determinar o nível de segurança do sistema.

Jardim *et al.* (2004) apresentam as principais características adotadas para um sistema de avaliação da segurança dinâmica, o qual tem sido implementado no ambiente de planejamento e de tempo real do Operador Nacional de Sistemas Elétricos – ONS. Basicamente, o sistema consiste na automação dos procedimentos tradicionais de avaliação de segurança, ou seja, na computação sistemática de soluções de fluxo de carga e de transitórios eletromecânicos para várias condições de carga, geração ou rede. Este sistema também possibilita uma avaliação estática de segurança.

1.3.2 Grupo de Simulação Rápida no Tempo

O grupo de simulação rápida no tempo compreende os trabalhos que utilizam um algoritmo de simulação quase-estática, o qual possui uma simulação relativamente rápida, considerando apenas a dinâmica de longo prazo dos componentes de controle do sistema de potência.

Franchi *et al.* (2003) descrevem um sistema de avaliação *on-line* denominado Xdsa-Web desenvolvido pelo Operador do Sistema Independente Italiano – GRTN através de programas de fluxo de carga (CRESO) e de cálculo de transitórios (SICRE). Este sistema utiliza dados provenientes de um estimador de estados para análise, em ambiente de simulação, das contingências que ameaçam a segurança da operação do sistema. O Xdsa-Web compreende basicamente:

- Um módulo de processamento para realizar a avaliação de segurança dinâmica (ASD), que por sua vez, utiliza a função STIMA a qual executa em modo *quasi-online*;
- Um processamento dos resultados e um módulo de exibição que utiliza o formato de visualização HTML.

No funcionamento do Xdas-Web, os operadores recebem informações das conseqüências que cada contingência poderia causar na operação do sistema de potência com 15 minutos de antecedência, permitindo a avaliação e a tomada de medidas preventivas. O Xdas-Web possui um banco de dados contendo avaliações de contingências, que são coletados periodicamente por operadores e profissionais de sistemas elétricos experientes.

No artigo de Bihain *et al.* (2003) é apresentada a estrutura global e os resultados de um projeto denominado de OMASES – *Open Market Access and Security Assessment System*. Este sistema provém aos operadores dos SGE's (Sistema de

Gerenciamento de Energia) uma ferramenta de avaliação de segurança dinâmica (ASD) para ser utilizado em tempo-real durante o ciclo normal de operação, no planejamento de operação e como um simulador de treinamento incluindo uma simulação do ambiente desregulado do mercado de energia. A ASD é realizada através de diferentes funções de aplicação: AST – Avaliação de Estabilidade Transitória, AET – Avaliação de Estabilidade de Tensão, ST – Simulação de Treinamento e SM – Simulação de Mercado.

A aplicação AET inclui análise dos impactos das contingências relevantes e a determinação dos limites de operação seguro dos sistemas em relação às transferências de potência nas áreas críticas ou a potência consumida nas áreas de carga. A análise do sistema é baseada numa abordagem quase-estática (*Quase Steady State - QSS*). Para a validação da plataforma OMASES foram disponibilizados dois sistemas experimentais, um pelo Operador do Sistema de Transmissão Helênico (HTSO) da Grécia e o outro pelo CESI da Itália.

No trabalho de Van Cutsem *et al.* (2004) é descrito a aplicação da função OMASES-AET *on-line* pelo Operador do Sistema de Transmissão Helênico (HTSO). Esta plataforma pode rodar em três modos: *real-time*, *study* e *expert*. No modo *real-time*, o SGE alimenta a plataforma com as soluções de um estimador de estados. No modo *study*, a execução da AET é realizada manualmente pelo usuário, contento um banco de dados para a operação neste modo. E por fim, no modo *expert*, o usuário pode ter acesso a ferramentas de diagnósticos, como a avaliação de sensibilidade e análises dos autovetores da matriz Jacobiana.

1.3.3 Grupo de Inteligência Artificial

Neste grupo as técnicas de IA são utilizadas, tais como, as redes neurais artificiais, sistemas fuzzy, etc.

No trabalho de Mendes *et al.* (2000b) é proposta a aplicação das técnicas de RNA para auxiliar a avaliação em tempo real da estabilidade de tensão nos sistemas de potência. Uma rede de MLP's é treinada com padrões de treinamento que refletem diversas condições operativas do Sistema *New England* de 39 barras utilizando-se o algoritmo de treinamento *Optimal Estimate Training - OET 2*. Os dados relativos à estabilidade de tensão do sistema são obtidos através de avaliações sucessivas do fluxo de potência com correspondente decomposição em valores singulares da matriz

Jacobiana reduzida de sensibilidade Q-V, onde esta matriz agrega os modelos dinâmicos dos principais componentes do sistema. Os erros máximos verificados nos testes foram inferiores a 2%, e o tempo médio de treinamento de cada RNA foi de 5 min em um microcomputador Pentium de 166 MHz.

No artigo de Dinavahi & Srivastava (2001) é apresentada uma rede neural artificial modelada para a predição da margem de estabilidade de tensão, onde um indicador baseado numa função de energia é utilizado para a definição desta margem. As redes neurais utilizadas foram a MLP (*Multi Layer Perceptron*) e a RBF (*Radial Basis Function*), onde as simulações foram realizadas no sistema exemplo de 5 barras Stagg e El-Abiad. As entradas da rede neural consistem das injeções de potência ativa e reativa de todas as barras do sistema para uma condição particular de carregamento. Já a saída da rede representa a margem de energia. O modelo pode prover uma estimativa bastante precisa da margem ao operador com obtenção da resposta em menos de 5ms.

No artigo de Zhang & Zhou (2002) é proposta uma eficiente metodologia para seleção de contingências relacionadas à estabilidade de tensão, chamada Método RSI Melhorado baseado em redes neurais artificiais (RNA's). Essa metodologia combina as vantagens de conceituação física do método RSI e a velocidade e precisão da RNA. O RSI (*Reactive Support Index*) é baseado na idéia de que contingências severas tendem a causar maiores variações no fornecimento de potência reativa dos geradores em todo o sistema (Vaahedi, *et al.*, 1999) (Begovic and Phadke, 1992). O método proposto foi comparado com o método RSI simples e o ponderado, utilizando o sistema teste de 39 barras do IEEE, onde 45 contingências foram testadas. O método RSI Melhorado se mostrou efetivo o suficiente para conduzir a seleção de contingência *on-line* nos sistemas de potência. A RNA aplicada é constituída de duas camadas ocultas, com algoritmo de treinamento - Levenberg-Marquardt.

Andrade *et al.* (2006) apresentam a aplicação de redes neurais artificiais (RNA's) para a avaliação da distância ao ponto de colapso de tensão de um sistema de potência com o objetivo de reduzir o tempo de computação. Também é usado o novo método FSQV para o cálculo do ponto de colapso de tensão. O método FSQV descrito em (Andrade and Barbosa, 2005) é definido como a soma total dos coeficientes de sensibilidade obtidos através do fluxo de carga pelo método de Newton Raphson, ou seja, o somatório dos elementos da diagonal da matriz Jacobiana ($\partial Q_i / \partial V_i$). O modelo MLP (*Multilayer Perceptron*) foi utilizado para a RNA, onde o algoritmo de

treinamento escolhido foi o backpropagation. Foram utilizadas quatro topologias, em que todas possuíam uma camada oculta e um neurônio na camada de saída. O sistema teste 57-barras do *IEEE* foi utilizado para as análises, onde as potências reativas de 41 barras foram consideradas como entradas da RNA. Os testes foram realizados utilizando o MATLAB®, onde o tempo de cálculo da distância ao ponto de colapso de tensão através de sucessivos fluxos de potência era realizado em 90 segundos, enquanto que a RNA treinada levava alguns segundos.

Amjady (2003) propõe a avaliação dinâmica da segurança de tensão através de um combinador de redes neurais. O conjunto de sub-redes (RNA's) pode estabelecer uma avaliação precisa das condições de operação e da segurança dinâmica de tensão fornecendo uma estimativa da margem de estabilidade para cada barra do sistema. O método foi examinado em uma porção do Sistema de transmissão Sudoeste Iraniano. Foi utilizado um conjunto de padrões para treinamento e um para teste, os quais foram obtidos através de simulações dinâmicas. A arquitetura do combinador de RNA's é composta pela combinação em paralelo de redes MLP's, onde o algoritmo de treinamento é baseado numa generalização da regra delta (*Generalized Delta Rule – GDR*) apresentada em (Amjady and Ehsan, 1999). A principal desvantagem do método proposto é a necessidade de um grande número de sub-redes para sistemas mais complexos.

O artigo de Suthar & Balasubramanian (2007) apresenta um método baseado em redes neurais artificiais para a avaliação *on-line* da estabilidade de tensão. A análise modal para a matriz Jacobiana reduzida e a computação dos fatores de participação das barras, do ponto de vista da estabilidade de tensão, são utilizadas para a identificação das barras de carga mais vulneráveis do sistema. Para cada barra de carga vulnerável do sistema foi treinada uma RNA, com o objetivo de registrar as margens de potência reativa disponíveis nas mesmas. O método proposto foi aplicado no sistema teste 30-barras do *IEEE* que compreende 6 geradores e 41 linhas.

Os padrões utilizados para as entradas das RNA's consistem dos momentos de potência ativa e reativa obtidos pelo produto das contribuições dos vários geradores para as barras de carga vulneráveis pela distância elétrica entre os geradores e a barra de carga correspondente (Teng, 2005). Também são utilizadas as margens de potência reativa dos geradores, potência ativa, reativa e magnitude de tensão em certas barras de carga como entradas para as RNA's. A saída para cada padrão é obtida computando a distância entre o ponto de operação do sistema e o colapso de tensão usando um

algoritmo de fluxo de potência continuado (*Contour Program*). Para o treinamento das RNA's o método de Levenberg-Marquardt foi utilizado através do *Neural Network Toolbox* do MATLAB®. A arquitetura utilizada para cada RNA é constituída de apenas uma camada oculta contendo 10 neurônios, sendo utilizada a função sigmoïdal tangente como função de ativação, e um neurônio na camada de saída da rede, sendo utilizada função linear para o mesmo. Apesar de este método ter sido testado em uma única área de um sistema de potência, o mesmo pode se estender para um sistema mais complexo seguindo o procedimento proposto para cada área.

Sodré e Mota (2000) demonstram a viabilidade da utilização das tecnologias das Redes Neurais Artificiais (RNA's) e da Lógica Fuzzy, através de um método denominado ANFIS (*Adaptive Neuro-Fuzzy Inference System*) (Jang, 1993), para a análise de segurança da estabilidade de tensão, em comparação com o uso de uma rede neural MLP (*Multilayer Perceptron*) atuando sozinha e do método kNN (*k-Nearest Neighbours*). O objetivo do Sistema Neuro-Fuzzy é classificar o ponto de operação do sistema entre seguro ou alerta, onde as condições de segurança são determinadas em função do Índice Margem, obtido através do Método da Continuação abordado em (Sodré, Almeida e Salgado, 1997) e (Cañizares, Souza and Quintana, 1996). A metodologia é aplicada no subsistema Sul-Sudeste de 77 barras do Brasil.

Os elementos dos conjuntos de treinamento e teste foram gerados para simular uma parte da curva de carga diária do sistema, levando em consideração também uma análise de contingências. Nesses padrões de treinamento e teste foram consideradas apenas 5 barras críticas a partir das quais os valores de potência ativa e reativa, ângulo e tensão foram utilizadas. O treinamento foi realizado utilizando o algoritmo *backpropagation* com termo *momentun* e constante $\alpha = 0.95$, conjuntamente a um algoritmo adaptativo para a variação dinâmica do coeficiente de aprendizado da rede. Os resultados mostraram que o Sistema Neuro-Fuzzy ANFIS apresentou a mesma taxa de acerto que a MLP, porém com tempo de treinamento 1000 vezes menor que esta última. Já o método kNN apresentou a menor taxa de acerto e o tempo de treinamento foi análogo ao do ANFIS.

Jeyasurya (2000) apresenta uma metodologia baseada em RNA's para a avaliação da estabilidade de tensão através do mapeamento da relação entre a condição de operação de um sistema de potência e a sua correspondente margem de estabilidade de tensão. Uma rede MLP com apenas uma camada oculta e com o algoritmo de treinamento Levenberg-Marquardt é utilizada através do *Neural Network Toolbox* do

MATLAB[®]. Os padrões de treinamento são compostos pela carga ativa e reativa das barras, as magnitudes de tensão e as gerações de potência ativa e reativa. Utilizou-se o PCA (*Principal Component Analysis*) (Haykin, 1994) para a redução dos padrões de treinamento. O método proposto foi utilizado para a estimação da estabilidade de tensão do sistema IEEE 118 barras.

Semelhantemente ao trabalho apresentado por Jeyasurya (2000), Saikat Chakrabarti & B. Jeyasurya (2004) propõe uma metodologia para monitoração *on-line* de estabilidade de tensão usando redes neurais artificiais e uma maneira sistemática de treinamento das mesmas. Redes neurais separadas foram utilizadas para o mapeamento da relação entre a condição de operação de um sistema de potência e o índice margem de estabilidade de tensão. As redes neurais MLP utilizadas possuem apenas uma camada oculta, onde o algoritmo de treinamento escolhido foi o *backpropagation*. Os padrões de treinamento foram obtidos para o caso base e para contingências selecionadas separadamente para diferentes níveis de carregamento. Esses padrões são compostos por fluxos de potência ativa e reativa e a margem de potência ativa disponível representa a saída desejada do sistema. As soluções dos fluxos de carga foram obtidas através do *software* VSAT (*Voltage Stability Assessment Tool*), o qual realiza sucessivas soluções do fluxo de carga até alcançar um ponto próximo à instabilidade de tensão. Para reduzir a dimensão dos padrões de entrada primeiramente é realizada uma análise de contingência e, em seguida, os resultados desta análise são usados pela PCA (Haykin, 1994) para a escolha das características principais que constituirão os padrões de treinamento finais para as RNA's. A metodologia proposta foi testada no sistema modelo *New England* 39-barras. A maneira sistemática de seleção das características mais importantes resulta em uma compacta e eficiente arquitetura de RNA a qual se demonstra factível para a monitoração *on-line* da estabilidade de tensão.

A tese de doutorado de Eduardo de Aguiar Sodr  (2006) apresenta os resultados da avalia o de seguran a dos sistemas de pot ncia reais (Sul-Sudeste de 77 barras; e o sistema Norte-Nordeste de 482 barras) em rela o   instabilidade de tens o utilizando um sistema h brido composto por uma estrutura s rie de uma rede neural com algoritmo de aprendizagem RPROP e o sistema neuro-fuzzy ANFIS (*Adaptive Neuro-Fuzzy Inference System*). O desempenho deste sistema h brido foi comparado com os desempenhos apresentados por uma rede neural MLP, uma rede RPROP, pela t cnica kNN (*k – Nearest Neighbours*) e pelo sistema Neuro-Fuzzy ANFIS atuando de forma singular. S o apresentados tamb m os resultados utilizando um combinador de RNA's

através dos classificadores RBF-DDA e kNN, os quais foram combinados utilizando o método da Soma Máxima Ponderada Modificada (SMPM).

O estado de segurança de tensão do sistema foi obtido em função do Índice Margem, oriundo do Método da Continuação. É ressaltada a importância da correta formação dos padrões de treinamento e teste, e da estratégia da divisão do sistema em áreas para aumentar o desempenho da metodologia proposta. O sistema Híbrido RPROP proposto mostrou-se ser o melhor sistema para a avaliação de segurança. Uma importante característica adquirida por este sistema híbrido seria a facilidade da apropriação de um novo conhecimento, ou seja, qualquer nova regra adicionada num sistema *fuzzy* será avaliada em paralelo em relação a todas as regras já existentes.

Modi *et al.* (2008) apresentam um sistema Híbrido Neuro-Fuzzy de múltiplas entradas e saída única a qual calcula a margem de estabilidade de um sistema de potência considerando os compensadores estáticos (*Static Var Compensator – SVC*). Para a geração dos padrões de treinamento e teste do sistema Híbrido Neuro-Fuzzy, o *software* de solução do fluxo de potência UWPFLOW, o qual é implementado utilizando o Método da Continuação e que permite a inclusão dos SVC's, é utilizado. Os padrões de entrada do sistema Híbrido Neuro-Fuzzy são compostos pelas cargas ativas e reativas de todas as barras do sistema, gerações de potência ativa e reativa, além da tensão da barra que contém o SVC, seu ângulo de disparo e a potência reativa injetada por este equipamento. Para a redução dos padrões de entrada do sistema, é utilizada uma rede neural não-supervisionada Kohonen SOM, a qual seleciona as entradas para que o sistema Neuro-Fuzzy receba as informações de forma simplificada e suficiente para uma boa generalização do problema. A RNA do sistema Neuro-Fuzzy é composta por apenas uma camada oculta, onde o algoritmo de treinamento utilizado foi o Levenberg-Marquardt. A metodologia proposta foi aplicada no sistema IEEE de 30-barras e no sistema IEEE 118-barras, onde foram assumidos um SVC de $\pm 100\text{Mvar}$ e um SVC de $\pm 200\text{Mvar}$ respectivamente. Para o sistema IEEE 30-barras utilizou-se 12 neurônios na camada oculta. Já para o sistema IEEE 118-barras utilizou-se 6 neurônios na camada oculta. Os resultados mostraram que a metodologia produz uma saída com boa precisão tanto para pequenos sistemas como para grandes sistemas de potência e, que esta metodologia pode ser utilizada para estudos *on-line*.

1.4 Estrutura da Dissertação

Esta dissertação está organizada em sete capítulos. No capítulo 2, a fundamentação teórica referente à estabilidade de tensão é abordada. No capítulo 3, é apresentada uma breve introdução sobre as técnicas de IA utilizadas nesta pesquisa.

Os aspectos relativos ao método proposto são apresentados no capítulo 4, juntamente com os critérios e métodos necessários para o levantamento de uma base de dados para o treinamento e teste das técnicas de IA.

No capítulo 5, são apresentados os desempenhos das técnicas de IA, juntamente com uma análise dos resultados visando a escolha de uma das técnicas para o desenvolvimento do *software*, finalizando com a apresentação da ferramenta desenvolvida.

Por fim, no capítulo 6 são apresentadas as conclusões e propostas para trabalhos futuros, visando o incentivo a pesquisa de técnicas de IA mais eficientes e, uma adaptação do *software* desenvolvido para trabalhar de forma *on-line*.

Capítulo 2

Estabilidade de Tensão

4.1 Introdução

A estabilidade de um sistema de potência pode ser definida como uma propriedade do sistema de potência que o permite manter-se operando em equilíbrio em condições normais e após ter se submetido a distúrbios, nesse último caso, o estado de operação ainda mantendo um equilíbrio aceitável (Kundur, 1994). Caso essa condição não seja satisfeita, o sistema entrará em estado de instabilidade.

Os primeiros problemas de estabilidade dos sistemas elétricos estavam associados ao comportamento dinâmico das máquinas síncronas após a ocorrência de uma perturbação. A capacidade do conjunto das máquinas síncronas de uma determinada rede se manter em sincronismo após ocorrência de um distúrbio é denominada de *estabilidade de ângulo*, a qual depende do equilíbrio entre o torque mecânico e o torque eletromagnético destas máquinas.

Entretanto, a instabilidade dos sistemas de potência pode ocorrer sem que haja a perda do sincronismo das máquinas síncronas, podendo esta ser caracterizada por uma progressiva depreciação da magnitude da tensão em uma ou mais barras do sistema. Este fenômeno é denominado de *instabilidade de tensão* e está associado à deficiência no suporte de reativos dos sistemas.

A instabilidade de tensão é proveniente da ocorrência de contingências no sistema de potência como, por exemplo, curtos-circuitos, desligamentos de linhas de transmissão, perda de grandes unidades geradoras e desligamento de grandes cargas. De acordo com o tipo de perturbação, a instabilidade de tensão pode se manifestar em poucos segundos caracterizando a instabilidade de tensão transitória ou após vários minutos consistindo na instabilidade de tensão de longo prazo.

Os dispositivos rápidos de controle de tensão e os componentes de dinâmica rápida como os motores de indução tem grande influência sobre a instabilidade de tensão transitória. Já para a instabilidade de tensão de longo prazo, os transformadores com comutação automática de tap sob carga (LTC), cargas termostáticas,

compensadores síncronos, chaveamento de bancos de capacitores e indutores, tratam-se dos principais responsáveis por este fenômeno.

Diante da operação do sistema próximo aos seus limites de transferência e das reservas de geração de potência reativa praticamente esgotada nos centros de carga, a ocorrência de distúrbios no sistema leva à instabilidade. Idealmente, o sistema deve ser capaz de suportar pequenas e grandes perturbações, caso contrário, é desencadeado um novo fenômeno conseqüente do prolongamento da instabilidade de tensão denominado colapso de tensão.

2.2 Colapso de Tensão

Nas últimas décadas tem-se registrado inúmeras ocorrências do fenômeno de colapso de tensão em diferentes países, como os de 1978 e 1987 na França, 1987 no Japão, 1982 na Bélgica, 1982 e 1983 na Suécia (Taylor, 1994), 2003 nos Estados Unidos e Canadá (U. S. – Canada Task Force, 2004).

A depreciação progressiva da tensão causada por um carregamento desordenado ou uma contingência, ao atingir uma condição de equilíbrio cujos perfis de tensão se encontrem abaixo dos valores aceitáveis, caracteriza o colapso de tensão.

Um sistema pode apresentar instabilidade de tensão sem a evolução da mesma para um colapso de tensão, logo ao se manter estável após um aumento exagerado de carga ou uma contingência significativa o sistema é denominado seguro em relação à tensão.

2.3 Métodos de Avaliação da Estabilidade de Tensão

Através da análise da estabilidade de tensão é possível executar estratégias que visem garantir o suprimento de energia com qualidade, evitando ou minimizando, a interrupção do fornecimento de energia aos consumidores. Logo, se faz necessário a utilização de métodos capazes de predizer o colapso de tensão nos sistemas de potência quantificando, as margens de estabilidade e os limites de transferência de potência, identificando os pontos fracos de tensão do sistema, as áreas susceptíveis à instabilidade e os fatores chave para sua ocorrência, que forneçam as características do sistema para a adoção de ações corretivas.

Os métodos de avaliação de estabilidade são classificados em estáticos e dinâmicos. Os métodos estáticos se baseiam na análise de sistemas de equações algébricas obtidas a partir do modelo de fluxo de potência. Já os métodos dinâmicos se baseiam em soluções no tempo de sistemas de equações diferenciais e algébricas de forma a representar o comportamento dinâmico dos elementos do sistema.

Apesar da estabilidade de tensão ser um processo dinâmico, oriundo do comportamento dinâmico das cargas e a interação dos mecanismos de controle, os métodos de avaliação estática são de extrema importância, já que sob certas condições a análise estática leva a resultados similares a análise dinâmica com uma eficiência computacional superior. Em geral, estes métodos buscam a determinação do estado de operação do sistema com respeito ao limite de estabilidade de tensão.

Um dos indicadores mais importantes de segurança de tensão de um sistema elétrico de potência em relação à estabilidade é conhecido como índice margem, o qual é baseado na análise da curva PV (Taylor, 1994). Tal índice pode ser obtido através do cálculo de uma suposta margem de carregamento a partir de um ponto de operação até o ponto de máxima transferência de potência, quantificando a carga máxima que o sistema pode suportar até que seu limite de estabilidade de tensão estática seja atingido.

A curva PV pode ser obtida mediante solução sucessiva de fluxos de carga de acordo com o incremento de carga e da geração do sistema, segundo uma direção pré-estabelecida, obtendo-se, para cada incremento, a tensão correspondente na barra em análise.

O ponto de carregamento máximo ou ponto de colapso de tensão é característico da curva PV (Figura 2.1). A distância entre esse ponto e o de operação do sistema determina a margem de estabilidade estática de tensão do sistema (também referenciada como índice margem). Logo, com o conhecimento desta margem é possível avaliar se diante de um distúrbio o sistema poderá operar de forma segura no novo ponto de operação. A restrição da utilização de métodos convencionais de fluxo de potência para a obtenção da curva PV é dada pela divergência do método em determinadas situações, já que no ponto de máximo carregamento, a matriz Jacobiana é singular. Esse ponto é conhecido como Ponto Crítico.

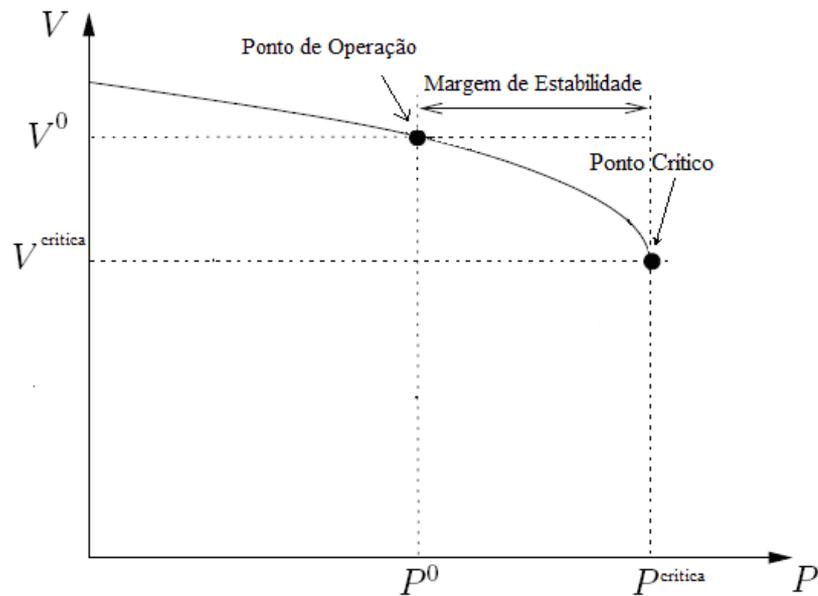


Figura 2.1 – Curva PV.

O ponto crítico da curva PV não necessariamente é o limite de instabilidade de tensão do sistema. A instabilidade e o colapso de tensão podem surgir antes mesmo que o sistema alcance este ponto (Taylor, 1994).

2.2 Critérios de Segurança

Em face do aumento de registros dos casos de instabilidade de tensão dos sistemas elétricos que acarretaram em grandes prejuízos financeiros, como o blecaute que atingiu parte do Canadá e Estados Unidos em 2003, diversos agentes reguladores estabeleceram critérios de segurança nas normas de acesso a transmissão.

O Western Electricity Coordinating Council (WECC) dos EUA sugere uma margem de estabilidade de tensão mínima de 5% considerando uma contingência simples (N-1), 2,5% para contingências duplas e para múltiplas contingências (três ou mais), margem maior que zero. Também se recomenda que a margem para o sistema operando em condições normais seja superior ao sistema operando sobre contingência simples (WECC, 1998).

No Brasil, o Operador Nacional do Sistema Elétrico (ONS) iniciou os estudos de estabilidade de tensão recomendando o atendimento de uma margem mínima de 6% para o caso de contingências simples (ONS, 2002). Hoje, o ONS recomenda como critério geral para os estudos de ampliação, reforços e de planejamento da operação, em

seu manual de procedimentos de redes, uma margem mínima de 7% para o caso do sistema sem contingência e 4% para o caso do sistema com contingência (ONS, 2007).

Capítulo 3

Técnicas de Inteligência Artificial

3.1 Introdução

Nos últimos anos a utilização de técnicas de IA tem sido proposta como um método alternativo de solução de problemas complexos, para os quais os métodos tradicionais não são suficientemente eficientes (Taylor, 1998). Como os estudos da instabilidade de tensão necessitam de uma análise de segurança correta deste fenômeno é preciso levar em consideração muitos aspectos da operação e do funcionamento dos componentes do sistema. Devido a essa complexidade, as técnicas de IA se tornam viáveis para os estudos de estabilidade de tensão.

Este capítulo trata dos princípios e conceitos das técnicas de IA utilizadas para o reconhecimento de padrões, em específico as redes neurais artificiais, os sistemas fuzzy e o sistema neuro-fuzzy ANFIS.

3.2 Reconhecimento de Padrões

Os seres humanos são capazes de reconhecer padrões com grande rapidez, através da coleta de informações, as quais são comparadas com as propriedades e comportamentos conhecidos armazenados em sua mente. No contexto de IA esta tarefa não é trivial, e conta com muitas ferramentas e métodos matemáticos para a solução do problema de reconhecimento de padrões (Jesan, 2005).

O problema de reconhecimento de padrões compreende o reconhecimento de itens de duas categorias: *concretos* e *abstratos*. O reconhecimento de itens concretos abrange o reconhecimento de impressões digitais, assinaturas, formas de ondas, faces, voz, objetos físicos, etc. Já os elementos abstratos abrangem os itens sem forma física como a solução de um determinado problema.

Na Tabela 3.1 são mostradas várias tarefas de classificação, para um sistema de reconhecimento de padrões.

Tabela 3.1 – EXEMPLOS DE RECONHECIMENTO DE PADRÕES.

Problemas para Classificação	Dados de Entrada	Dados de Saída
Reconhecimento de voz	Voz	Identificação da palavra
Reconhecimento de caracteres	Sinais ópticos	Nome do caractere
Diagnósticos médicos	Sintomas	Identificação da patologia
<i>Previsão do tempo</i>	Mapas atmosféricos	Chuva, sol, etc.

Basicamente, o reconhecimento de padrões envolve a filtragem de entrada, extração de características e classificação. A filtragem de entrada objetiva eliminar dados desnecessários ou ruídos fazendo com que a entrada apresente apenas dados relevantes para o reconhecimento. A extração de características representa a análise dos dados de entrada para a extração de informações necessárias ao processo de reconhecimento. Essa fase é de importância fundamental para um bom desempenho do classificador, necessitando de um conhecimento específico sobre o problema em estudo. Por fim, a classificação determina a categoria em que o objeto de análise se enquadra.

Usualmente muitas medidas são necessárias para que os padrões possam ser adequadamente categorizados. Para um determinado objeto que se deseje classificar, são necessárias n medidas do objeto. Cada uma dessas medidas tem característica única, o que possibilita ser criado um vetor de características de dimensão n do objeto em questão, que por sua vez será a entrada do classificador. Este vetor de dimensão n determina o que se chama o *espaço de características*.

A seguir, na Figura 3.1, temos o espaço de características para um problema de reconhecimento de padrões com duas dimensões, cuja finalidade é distinguir entre dois grupos de jogadores de futebol, aqueles que pertencem ao grupo dos jogadores do sexo masculino e os que pertencem ao grupo feminino.

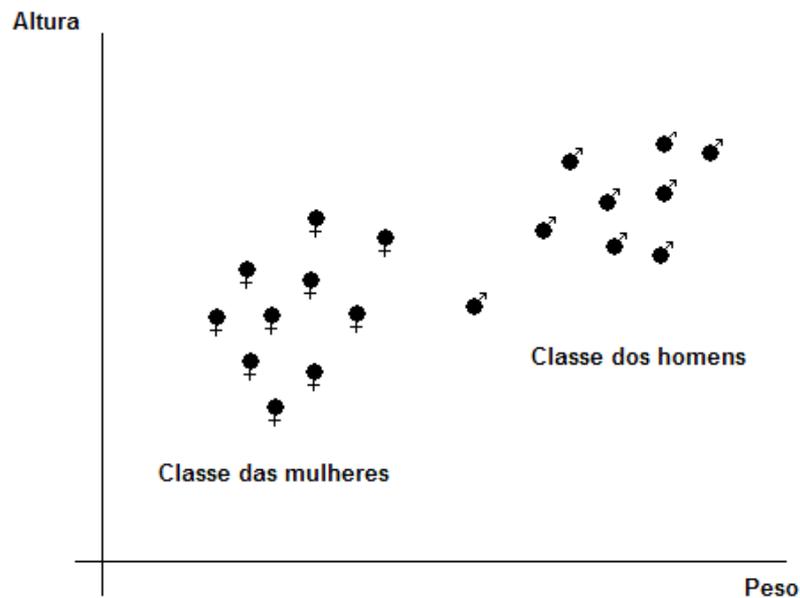


Figura 3.1 – Espaço de Características.

Algumas técnicas de reconhecimento de padrões são: k -Vizinhos mais Próximos (k -Nearest Neighbour – kNN), RNA e Lógica fuzzy. Onde, as duas últimas técnicas serão abordadas neste trabalho.

3.3 Redes Neurais Artificiais

As redes neurais artificiais – RNA's, são modelos matemáticos com capacidade computacional adquirida por meio de aprendizagem e generalização semelhantes às estruturas neurais biológicas (Haykin, 2001). O aprendizado está normalmente associado à capacidade das RNA's em ajustarem seus parâmetros como consequência de sua interação com os padrões de treinamento. Já a generalização de uma RNA está associada à sua capacidade de dar respostas coerentes para dados não apresentados anteriormente durante o treinamento.

O modelo de um neurônio artificial é apresentado na Figura 3.2. Similarmente ao neurônio biológico, o artificial recebe um ou mais sinais de entrada e devolve um único sinal de saída.

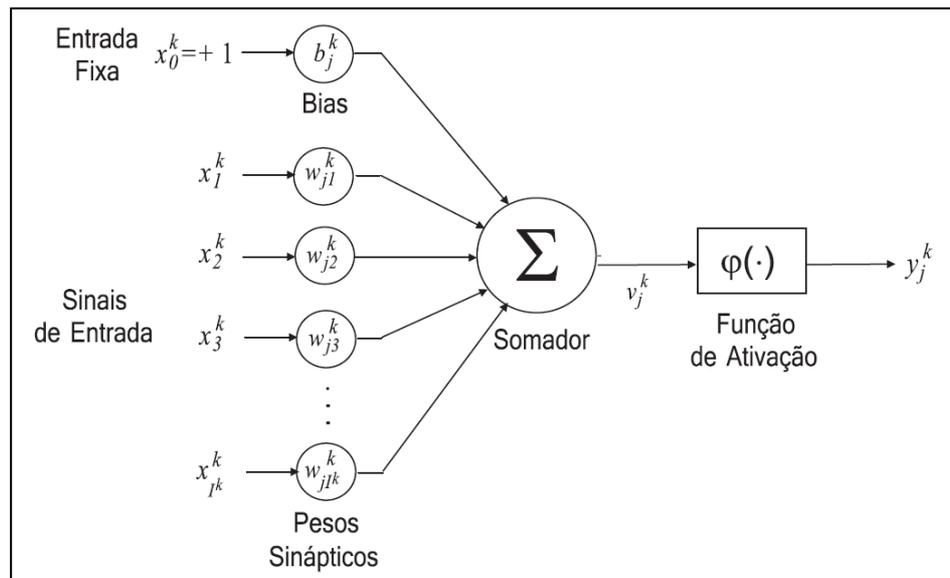


Figura 3.2 – Modelo de Um Neurônio Artificial.

Cada neurônio de uma RNA possui um conjunto de sinapses (conexões), caracterizados pelo seu peso sináptico (w_{ji}^k), que por sua vez indica o grau de influência da entrada do neurônio sobre a determinação de sua saída. Todas as conexões do neurônio passam por um somador, cuja função é realizar uma combinação linear dos sinais de entrada, ponderados de acordo com os pesos sinápticos de suas ligações. Uma função de ativação (ϕ_j^k) é aplicada à saída do somador, para limitar sua amplitude em um intervalo normalizado. Cada somador recebe uma entrada fixa denominada de polarização (b_j^k), que tem o objetivo de aumentar o grau de liberdade da função de ativação e, conseqüentemente, a capacidade de aproximação da rede. O valor da polarização é ajustado da mesma maneira que o dos pesos sinápticos.

A formulação matemática para um neurônio j , localizado na camada k , é dada pelas seguintes equações:

$$v_j^k = b_j^k + \sum_{i=1}^{I^k} w_{ji}^k x_i^k \quad (3.1)$$

$$y_j^k = \phi_j^k(v_j^k), \quad (3.2)$$

em que I^k representa o número de entradas da camada k ; x_i^k os sinais de entrada; v_j^k a saída do somador denominado de potencial de ativação; y_j^k o sinal de saída.

Dentre as funções de ativação mais utilizadas temos a sigmóide logística definida no intervalo $[0,1]$ e descrita pela seguinte equação:

$$\varphi(v_j^k) = \frac{1}{1 + \exp(-av_j^k)}, \quad (3.3)$$

sendo a um parâmetro maior que zero, que estabelece a suavidade da função.

Uma RNA é constituída por diversos neurônios dispostos em camadas, denominadas: camada de entrada, camada oculta e camada de saída. A topologia de uma RNA é definida pela quantidade de neurônios e de camadas, como também pela forma de interligação dos neurônios. O tipo de RNA mais utilizado para aplicações em sistemas de potência é a *multilayer perceptron*, ou *perceptron* de múltiplas camadas (MLP). Esse tipo de topologia representa uma generalização da rede do tipo *perceptron* de camada única. Os sinais de entrada são propagados através das camadas até atingir a última, que se trata da camada de saída. Uma RNA tipo MLP é apresentada na Figura 3.3.

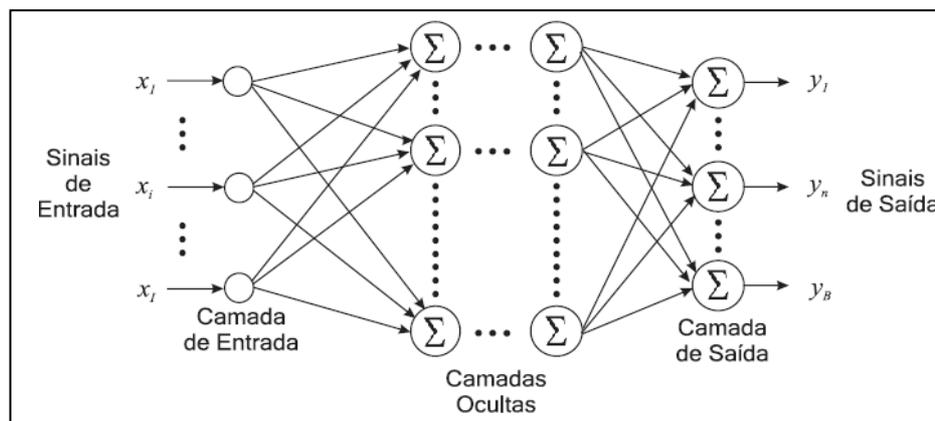


Figura 3.3 - Rede *Multilayer Perceptron* (MLP).

3.2.1 Algoritmo de Treinamento *Backpropagation*

O treinamento de uma RNA é caracterizado por um comportamento adaptativo que produz melhoria gradual no desempenho da rede. Para que seja possível realizar um treinamento supervisionado de uma RNA é necessário que um conjunto de dados entrada-saída, com as informações relevantes ao perfil do problema seja apresentado a mesma. Vetores de entrada com seus respectivos vetores de saída desejados formam os padrões de treinamento. Este treinamento é visto como um problema de otimização

numérica, onde o objetivo é reduzir a função custo, representada pela *função energia de erro*, em função dos ajustes dos pesos e polarizações através de um algoritmo de treinamento. A *função energia de erro* trata-se do erro médio quadrático representado pela seguinte equação:

$$\xi(n) = \frac{1}{2} \sum_{j=1}^B [d_j(n) - y_j(n)]^2, \quad (3.4)$$

sendo y_j e d_j as respostas calculada e desejada para o neurônio j , respectivamente; B o número de neurônios da camada de saída.

Dentre os diversos algoritmos de treinamento aplicados às RNA's, o algoritmo de retropropagação de erro (*backpropagation*) é amplamente utilizado. Este consiste basicamente de duas etapas: propagação e retropropagação.

A propagação ocorre quando os sinais de entrada são aplicados aos pesos sinápticos da RNA passando pelo somador onde é calculado o campo local induzido e, em seguida, como resultado obtêm-se os sinais de saída para todos os neurônios da camada em questão. Estes sinais de saída são distribuídos como sinais de entrada para os neurônios da camada posterior e assim sucessivamente, até o sinal chegar à camada de saída, dando origem ao vetor de sinais de saída da rede. Já na retropropagação, os pesos sinápticos e polarizações são reajustados pelo algoritmo de treinamento, com o objetivo de minimizar a *função de energia de erro*.

O algoritmo *backpropagation* utiliza-se de um método de otimização denominado gradiente descendente para o reajuste dos pesos sinápticos e das polarizações.

$$\Delta w_{ji}^k(n) = -\eta \frac{\partial \xi(n)}{\partial w_{ji}^k(n)} \quad (3.5a)$$

$$\Delta b_j^k(n) = -\eta \frac{\partial \xi(n)}{\partial b_j^k(n)} \quad (3.5b)$$

onde $0 < \eta \leq 1$ é o parâmetro *taxa de aprendizagem* (ou *coeficiente de aprendizagem*) e n representa o n -ésimo vetor padrão.

Aplicando a regra da cadeia nas equações (3.5), se tem:

$$\Delta w_{ji}^k(n) = \eta \delta_j^k(n) y_i^{k-1}(n) \quad (3.6a)$$

$$\Delta b_j^k(n) = \eta \delta_j^k(n), \quad (3.6b)$$

sendo $y_i^{k-1}(n)$ a saída do neurônio i da camada $k-1$ para o n -ésimo padrão de treinamento; δ_j^k o gradiente local que indica a sensibilidade da função de custo em relação as variações no neurônio j da camada k .

O gradiente local depende do tipo de camada em que o neurônio se encontra. Deste modo, este é representado segundo as condições a seguir:

$$\delta_j^k = \begin{cases} \phi_j^{k'}(v_j^k(n))(d_j(n) - y_j(n)), & \text{para } k = \text{camada de saída;} \\ \phi_j^{k'}(v_j^k(n)) \sum_{l \in D^{k+1}} \delta_l^{k+1}(n) w_{jl}^{k+1}(n), & \text{para } k = \text{camada oculta,} \end{cases} \quad (3.7)$$

em que D^{k+1} representa o conjunto de neurônios da camada $k+1$.

Quanto à frequência de atualização dos pesos e polarizações da rede, temos como principais aplicações o modo de treinamento seqüencial (ou *on-line*) e o treinamento por lote (do inglês, *batch*) (Haykin, 2001).

No modo seqüencial a atualização dos pesos e polarizações é realizada após a apresentação de cada padrão de treinamento, ou seja, após a apresentação do vetor de entrada e de sua respectiva saída. Este modo de treinamento necessita de um coeficiente de aprendizagem $\eta \ll 1$ para que a aprendizagem seja estável, tornando-se um processo muito lento.

No modo *batch* o ajuste dos pesos é realizado após a apresentação de todos os padrões de treinamento que constituem uma época. Deste modo, os pesos e polarizações são reajustados apenas no final de cada época, através do valor médio dos reajustes acumulados. A função custo neste modo de treinamento é dada pela *função energia de erro média*:

$$\xi_{med}(m) = \frac{1}{2N} \sum_{n=1}^N \sum_{j=1}^B [d_j(n) - y_j(n)]^2, \quad (3.8)$$

onde N é o número de padrões do conjunto de treinamento.

Este modo de ajuste dos pesos e polarizações apresenta uma maior estabilidade, podendo-se utilizar maiores valores de η , acelerando o processo de convergência.

3.2.2 Algoritmo de Treinamento *Resilient Propagation* (RPROP)

O algoritmo RPROP se trata de um método obtido através de uma modificação no algoritmo *backpropagation* descrito por Simon Haykin (Haykin, 2001). A diferença entre eles é que, no RPROP, o valor da atualização dos pesos é calculado segundo uma adaptação direta da taxa de aprendizado η , baseado na avaliação do sinal do gradiente local de cada peso, e não de seu valor, de uma interação para outra. Isto elimina problemas encontrados com o algoritmo *backpropagation* e faz com que a convergência na fase de treinamento se torne rápida (Riedmiller and Braun, 1993). Cada parâmetro de uma MLP possui uma atualização individual Δ_{ij} que determina o grau de ajuste deste peso e é feita do seguinte modo:

$$\Delta_{ij}^{(t)} = \begin{cases} \eta^+ \cdot \Delta_{ij}^{(t-1)}, & \text{se } \frac{\partial \xi_{med}^{(t-1)}}{\partial w_{ij}} \cdot \frac{\partial \xi_{med}^{(t)}}{\partial w_{ij}} > 0 \\ \eta^- \cdot \Delta_{ij}^{(t-1)}, & \text{se } \frac{\partial \xi_{med}^{(t-1)}}{\partial w_{ij}} \cdot \frac{\partial \xi_{med}^{(t)}}{\partial w_{ij}} < 0, \\ \Delta_{ij}^{(t-1)}, & \text{caso contrário} \end{cases} \quad (3.9)$$

em que $0 < \eta^- < 1 < \eta^+$, ξ_{med} é a função energia de erro média e $\Delta_{ij}^{(t-1)}$ é a taxa anterior de atualização dos pesos.

Durante o processo de treinamento, uma mudança no sinal dos gradientes $\frac{\partial \xi_{med}^{(t)}}{\partial w_{ji}}$ de uma interação para outra, indica que a última adaptação dos pesos e polarizações foi suficiente para que o algoritmo saltasse sobre um ponto extremo da função custo ξ_{med} . Deste modo, a configuração anterior a última adaptação é retomada, a variável Δ_{ij} é diminuída por um fator η^- e o valor do ponto extremo é analisado segundo os critérios de parada do algoritmo. Caso o sinal do gradiente seja mantido, a variável é incrementada por um fator η^+ de modo a acelerar a convergência do algoritmo.

Os pesos são ajustados pelo modo *batch*, onde o reajuste destes é calculado do seguinte modo:

$$\Delta w_{ji}^{(t)} = \begin{cases} + \Delta_{ji}^{(t)}, & \text{se } \frac{\partial \xi_{med}^{(t)}}{\partial w_{ji}} > 0 \\ - \Delta_{ji}^{(t)}, & \text{se } \frac{\partial \xi_{med}^{(t)}}{\partial w_{ji}} < 0 \\ 0, & \text{caso contrário.} \end{cases} \quad (3.10)$$

Além de acelerar o processo de aprendizado permitindo o tratamento de grandes massas de dados, para a maioria dos problemas não é necessário fazer alterações nos parâmetros do algoritmo para a obtenção da convergência ótima.

3.2.3 Algoritmo de Treinamento Levenberg-Marquardt

O algoritmo Levenberg-Marquardt representa uma aproximação do método de Newton (Hagan and Menhaj, 1994), que é obtida introduzindo-se o parâmetro μ na equação original. De forma resumida, a equação de correção de pesos da rede neural pode ser escrita como:

$$\Delta W = [J^T(w)J(w) + \mu I]^{-1} J^T(w)e(w), \quad (3.11)$$

sendo I a matriz identidade, J a matriz Jacobiana e $e(x)$ o erro. O parâmetro μ é multiplicado por um fator β sempre que o ajuste dos pesos provocar um aumento da função de custo, e é dividido por β quando há uma redução. Portanto, o parâmetro μ tem a função de estabilizar o treinamento, ajustando a aproximação, de forma a utilizar a rápida convergência do método de Newton e evitar passos muito grandes que possam levar a um erro de convergência.

O ponto principal do método Levenberg-Marquardt para o treinamento de redes neurais MLP's é o cálculo da matriz Jacobiana, que é realizado a partir de uma simples modificação do algoritmo *backpropagation*. Neste último, o reajuste dos pesos é calculado a partir do gradiente da *função energia de erro*:

$$\frac{\partial \xi(n)}{\partial w_{ji}^k} = \frac{\partial \sum_{q=1}^Q e_q^2(n)}{\partial w_{ji}^k} \quad (3.12)$$

Sabendo-se que a matriz Jacobiana é composta pelos seguintes elementos:

$$J(w) = \begin{bmatrix} \frac{\partial e_1(w)}{\partial w_1} & \frac{\partial e_1(w)}{\partial w_2} & \dots & \frac{\partial e_1(w)}{\partial w_L} \\ \frac{\partial e_2(w)}{\partial w_1} & \frac{\partial e_2(w)}{\partial w_2} & \dots & \frac{\partial e_2(w)}{\partial w_L} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial e_Q(w)}{\partial w_1} & \frac{\partial e_Q(w)}{\partial w_2} & \dots & \frac{\partial e_Q(w)}{\partial w_L} \end{bmatrix}, \quad (3.13)$$

sendo L o número de ligações sinápticas da rede e Q , o número de padrões de treinamento em uma época de treinamento. Estes elementos são calculados através do algoritmo de retropropagação, modificando o cálculo do gradiente local da camada final:

$$\delta_j^k = \phi_j^k, \quad (3.14)$$

Logo, as equações de treinamento do algoritmo *backpropagation* são utilizadas no método de Levenberg-Marquardt para o cálculo da matriz Jacobiana, onde os pesos da rede são reajustados segundo a equação (3.11).

3.3 Sistemas Fuzzy

A subjetividade inerente aos seres humanos os torna capazes de lidar com processos bastante complexos, baseadas em informações imprecisas ou aproximadas, que podem ser transmitidas e compreendidas linguisticamente. A teoria de conjuntos difusos (lógica fuzzy), desenvolvida pelo iraniano Lotfi Asker Zadeh (Zadeh, 1965), torna possível o tratamento matemático dessas variáveis linguísticas com a finalidade de permitir o cálculo e a tomada de decisões ótimas em situações compostas por incertezas.

A lógica fuzzy se baseia na teoria clássica dos conjuntos, segundo a qual cada elemento pertence – ou não – a um conjunto, que é representado por uma função conhecida como função de pertinência. Os elementos desse conjunto possuem graus de existência, o que não é possível representar pela teoria clássica.

Os sistemas fuzzy realizam um mapeamento das variáveis de entrada em variáveis de saída, através de um processo de inferência baseado na lógica fuzzy.

No sistema fuzzy da Figura 3.4, as entradas constituem os dados não-fuzzy resultantes de medições ou observações. Na etapa de fuzzificação é realizado um mapeamento desses dados para os conjuntos fuzzy de entrada. As regras podem ser fornecidas por especialistas, em forma de sentenças linguísticas. Elas definem o fundamento da estrutura de conhecimento de um Sistema Fuzzy. No estágio de inferência ocorrem as operações com os conjuntos fuzzy propriamente ditas: combinação dos antecedentes das regras, implicação e obtenção do conjunto fuzzy de saída.

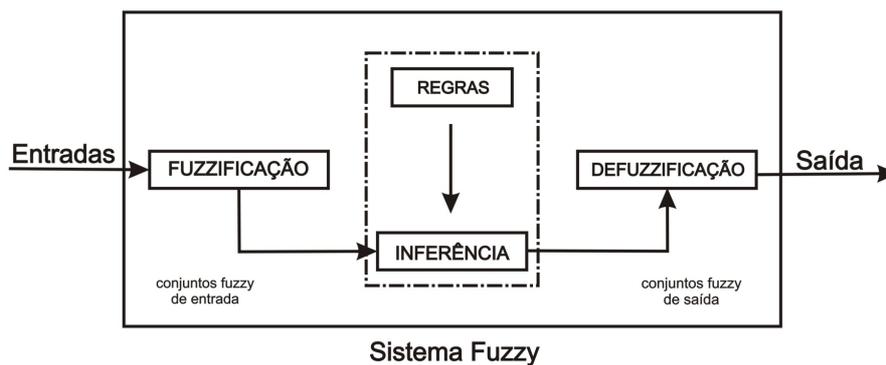


Figura 3.4 – Sistema Fuzzy.

Após a realização das análises das regras aplicadas, é obtido o resultado final através da defuzzificação, a qual converte o conjunto fuzzy de saída em um número real.

3.4 Sistema Neuro-Fuzzy (ANFIS)

A finalidade de um sistema Neuro-Fuzzy é aproveitar ao máximo os benefícios propostos individualmente, como a capacidade de aprendizagem das redes neurais e o alto nível de raciocínio dos Sistemas Fuzzy.

O Sistema Neuro-Fuzzy ANFIS (*Adaptive Neuro-Fuzzy Inference System*) apresentado na Figura 3.5 (Jang, 1993), possui duas variáveis de entrada x e y , uma variável de saída z , assim como duas regras *If-then* do tipo Takagi-Sugeno.

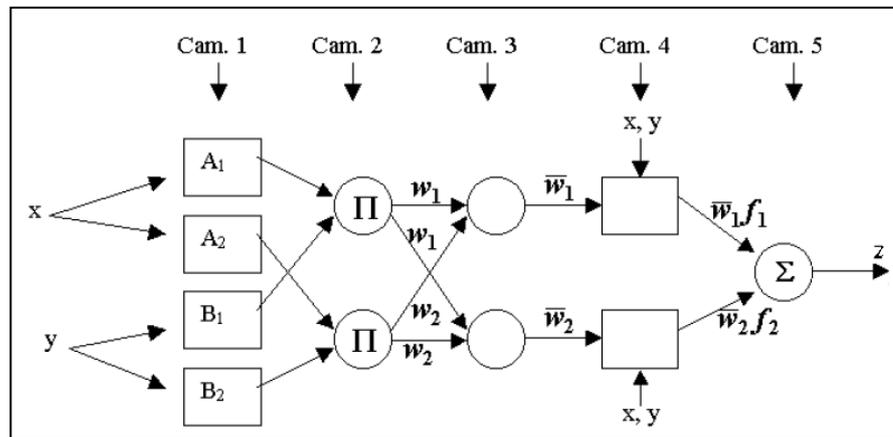


Figura 3.5 - Arquitetura ANFIS.

As diversas camadas apresentam as seguintes funcionalidades:

Camada 1: Cada nó i desta camada terá seus parâmetros treinados por um algoritmo de aprendizagem, determinando o grau de pertinência para o qual as variáveis de entrada (x , y) satisfazem a função de pertinência. O valor que especifica o grau de pertinência é equacionado por:

$$O_i^1 = \mu_{A_i}(x), \tag{3.15}$$

em que i representa o nó, μ_{A_i} a função de pertinência e x uma entrada do sistema. Os parâmetros desta camada são conhecidos como parâmetros da premissa.

Camada 2: Os nós desta camada não sofrerão treinamento. Cada nó calcula o grau de ativação da regra correspondente multiplicando os sinais de entrada enviando o produto para a saída:

$$w_i = \mu_{A_i}(x) \times \mu_{B_i}(y), \quad i = 1, 2. \tag{3.16}$$

Camada 3: É realizada uma normalização, onde o i -ésimo nó calcula a razão entre o grau de ativação da i -ésima regra e a soma dos graus de ativação de todas as regras. Essa normalização é feita da seguinte forma:

$$\bar{w}_i = w_i / (w_1 + w_2), \quad i = 1, 2. \quad (3.17)$$

Camada 4: Os nós desta camada terão seus parâmetros treinados. Estes são descritos segundo a seguinte equação:

$$O_i^4 = \bar{w}_i f_i = \bar{w}_i (p_i x + q_i y + r_i), \quad (3.18)$$

em que \bar{w}_i representa a saída da camada três.

Camada 5: Esta camada contém apenas um nó que calcula a saída do sistema através de um somatório de todos os sinais de entrada:

$$O_i^5 = \sum_i \bar{w}_i f_i = \frac{\sum_i w_i f_i}{\sum_i w_i}. \quad (3.19)$$

3.5 Sistema Híbrido RPROP

Aproveitando as particularidades das abordagens neural e fuzzy, onde o poder de compressão de uma grande massa de dados é facilitado através da rede neural, juntamente com a abordagem fuzzy para a incorporação do conhecimento linguístico dos operadores, foi desenvolvido o sistema híbrido RPROP (Sodré, 2006). Este sistema consiste numa estrutura série de uma rede neural com algoritmo de treinamento RPROP e o sistema neuro-fuzzy ANFIS (Figura 3.6).

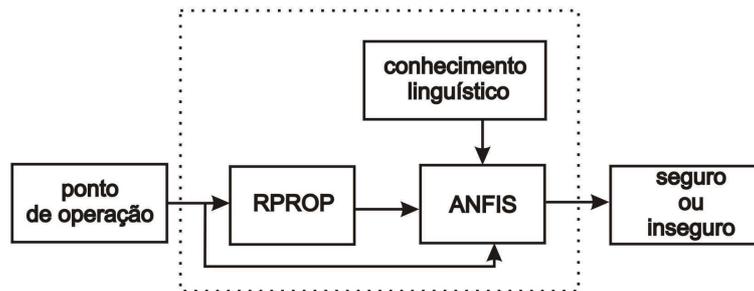


Figura 3.6 – Sistema Híbrido RPROP.

Nesse classificador, o ponto de operação é primeiramente avaliado pelo sistema RPROP da estrutura série, em seguida, o resultado é avaliado pelo sistema neuro-fuzzy ANFIS, gerando a saída do classificador.

Na parte superior do classificador temos a entrada do conhecimento linguístico, função esta característica dos sistemas fuzzy em geral, que tem o objetivo de incorporar ao sistema, o conhecimento dos operadores para elevar a capacidade de generalização do sistema classificador. O conhecimento linguístico é acrescentado através de regras *if-then*, as quais podem ser aplicadas de forma aleatória, pois as regras fuzzy são interpretadas paralelamente.

Capítulo 4

Método Proposto e Base de Dados

4.1 Introdução

Neste capítulo será apresentado o método proposto, com base nas técnicas IA apresentadas no capítulo 3. Onde seu objetivo é apresentar as condições de segurança de tensão dos sistemas elétricos de potência de forma eficiente.

Para testar o desempenho do método proposto, e dos demais sistemas classificadores utilizados neste trabalho foram utilizadas bases de dados contendo as características da Área Leste do subsistema Nordeste, onde alguns pontos relevantes para a construção destas bases de dados serão destacados nas próximas seções.

4.2 Método Proposto: Sistema Híbrido LM

O sistema Híbrido LM constitui um arranjo híbrido de uma rede neural RPROP em série com uma rede neural Levenberg-Marquardt. A primeira é uma rede neural com algoritmo de treinamento de alta eficiência no processo de aprendizado para grandes quantidades de dados e de elevada robustez com relação à escolha dos parâmetros iniciais. A segunda rede neural é de alta precisão para poucas centenas de pesos a otimizar. Tal sistema é descrito na Figura 4.1.

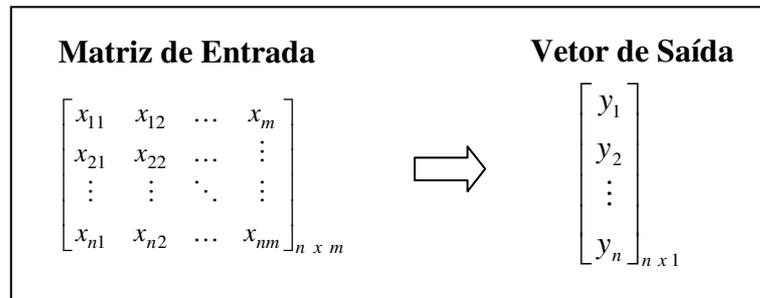


Figura 4.1 - Sistema Classificador Híbrido LM.

Primeiramente, o ponto de operação é apresentado à rede neural RPROP que trata a massa de dados para que seja apresentada em seguida, de forma reduzida, a rede neural Levenberg-Marquardt, viabilizando o uso deste último algoritmo, que apresenta um desempenho superior ao se aproximar do erro mínimo global, e por fim é

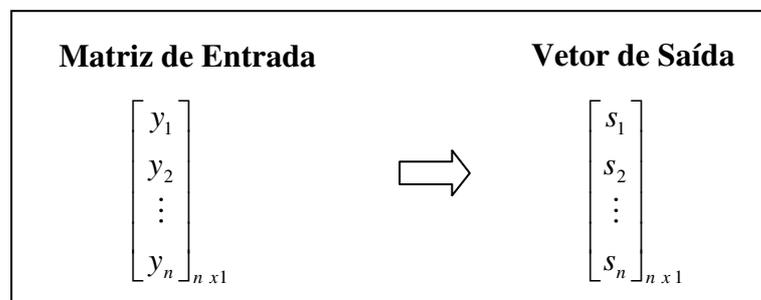
apresentado o resultado final do sistema de reconhecimento de padrões, ou seja, se o sistema elétrico de potência em análise se encontra em estado seguro ou inseguro em relação à estabilidade de tensão.

Os padrões de entrada para o primeiro bloco do diagrama da Figura 4.1 são representados da seguinte forma:



sendo n o número de padrões e m o número de entradas de cada padrão. Logo, cada linha da matriz de entrada corresponde a um elemento do vetor de saída sendo necessário uma rede neural RPROP contendo **$(m+2) \times (\text{n}^\circ \text{ de neurônios na camada oculta}) + 1$** parâmetros a serem otimizados.

Já os padrões que serão apresentados ao segundo bloco do diagrama da Figura 4.1 são representados a seguir:



Onde a entrada deste segundo bloco será um vetor de n elementos correspondentes aos n elementos de saída do bloco anterior. Sendo necessário uma rede neural Levenberg-Marquardt contendo **$3 \times (\text{n}^\circ \text{ de neurônios na camada oculta}) + 1$** pesos a serem otimizados. Há de se observar que para o tema em questão, e para um número fixo de neurônios de cada camada, a rede neural Levenberg-Marquardt terá sempre um número de pesos a ser otimizados inferior ao da rede RPROP.

Para o treinamento do Sistema Híbrido LM, os vetores padrão de uma base de dados são utilizados no treinamento da rede RPROP, em seguida, com esta rede treinada são propagados todos os vetores padrões do treinamento e obtidas as respostas da rede.

Então, estas respostas são utilizadas para compor a entrada dos vetores padrões de treinamento da rede Levenberg-Marquardt, onde a saída destes corresponde às saídas dos vetores padrões de treinamento da rede RPROP.

Com a utilização do sistema proposto pretende-se elevar o grau de aprendizagem da técnica de inteligência artificial RPROP atuando de forma singular, visando o desenvolvimento de um *software* para avaliação da estabilidade de tensão.

4.3 Base de Dados

O Sistema Norte-Nordeste da rede básica do SIN – Sistema Interligado Nacional, consiste de 482 barras operando nos níveis de tensão de 500, 230, 138, 69 e 13,8 kV, com 14 usinas hidrelétricas, 7 térmicas e 10 parques eólicos. A Figura 4.2 representa os principais troncos de 500kV desse sistema.

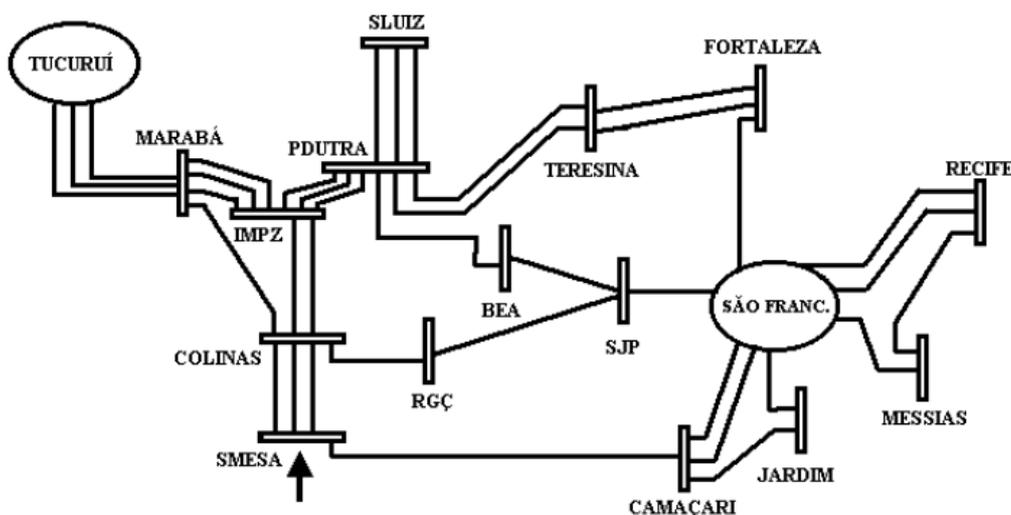


Figura 4.2 - Principais Troncos de 500kV do Sistema Norte-Nordeste ano 2010.

Foram utilizados oito pontos de operação para esse sistema operando em carga pesada no ano de 2010. A diferença entre estes está nos valores de intercâmbios de potência dentro dos limites de importação do sistema Sudeste e de geração do Complexo Hidroelétrico do São Francisco e da Hidroelétrica de Tucuruí, de acordo com o PAR 2006-2008 (2005).

Para a análise do Sistema Norte-Nordeste, considerado este de grande porte, utilizou-se a estratégia de separar o sistema em áreas (Mendes, 1999), analisando-se o máximo carregamento através da curva PV para um dado conjunto de barras.

Identificada uma área, escolhem-se apenas algumas barras mais sensíveis com o intuito de melhorar o desempenho dos sistemas classificadores, visto que o vetor padrão será de tamanho reduzido (Sodré, 2006). Deste modo, é necessário um sistema classificador para cada área do sistema de potência (Figura 4.3), de tal forma que: se apenas uma área é considerada insegura todo sistema também é considerado inseguro. A grande vantagem desta metodologia é que o operador já terá informações mais precisas de qual área requer uma ação preventiva.

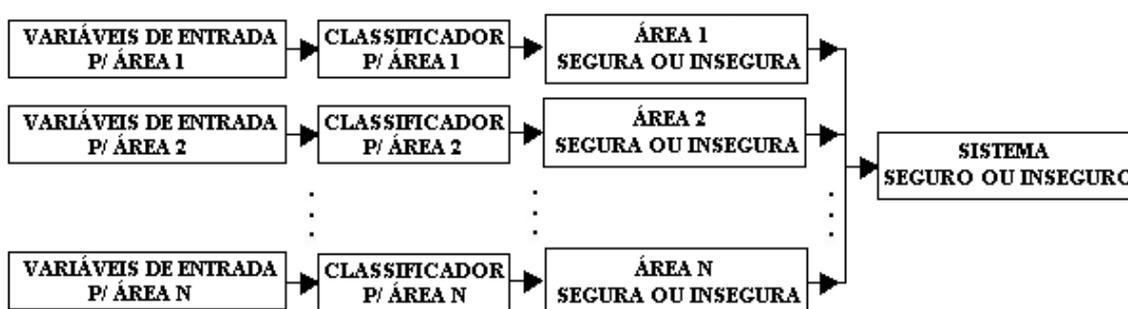


Figura 4.3 - Sistema de Avaliação da Estabilidade de Tensão por Áreas.

Para a avaliação das técnicas de IA, a área Leste do Subsistema Nordeste composta por 82 barras que compreende as áreas de Campina Grande, João Pessoa, Natal, Recife e Maceió foi utilizada para a confecção de uma base de dados. Onde, uma lista das contingências, consideradas severas, foi levantada para o sistema em análise.

Algumas contingências consideradas para a Área Leste são: saída da linha de transmissão que liga a barra Xingó – 500 kV à barra Messias – 500 kV, Ribeiro Gonçalves – 500 kV à barra Colinas – 500 kV, P. Dutra – 500 kV à barra Boa Esperança – 500 kV, saída de um compensador síncrono de Recife II, entre outras. Logo, dado um ponto de operação, aplicaram-se todas as contingências da lista e realizou-se uma avaliação do índice margem do sistema para verificar se o sistema é seguro ou inseguro de acordo com os critérios de segurança estabelecidos pelo ONS e WECC. Se apenas uma contingência da lista implicar em um máximo carregamento abaixo do limite especificado, então o ponto em análise é considerado inseguro, caso contrário o ponto de operação é considerado seguro.

Para não gerar vetores padrão para todas as 82 barras da Área Leste, foi feita uma análise para a determinação das barras críticas, através da monitoração da variação da magnitude das tensões das barras em função do seu carregamento durante a resolução dos fluxos de potência. Deste modo, as 5, 17 e 41 barras que apresentaram

maiores variações de tensão foram selecionadas e, destas extraídos os quatro elementos do vetor padrão: tensão, ângulo, injeção de potência ativa e injeção de potência reativa. Vale ressaltar que foi necessário realizar uma normalização dos dados, dividindo todos os elementos de cada vetor padrão pelo máximo valor registrado, de acordo com a grandeza elétrica que cada elemento descreve.

De posse dos oito pontos de operação, geraram-se bases de dados compostas por vetores padrão com variações aleatórias de 5%, 20%, 60% e 90%, ou seja, para cada elemento do vetor padrão é gerado um número aleatório cujo valor esteja, por exemplo, entre $-0,2 < \text{rand} > 0,2$ (variação aleatória de 20%). Donde estes novos pontos originados aleatoriamente seguem a mesma classificação do ponto inicial.

Para cada ponto de operação foram obtidos de forma aleatória 200 vetores padrão resultando em 1600 vetores padrão para cada base de dados, onde 1120 vetores foram usados no processo de treinamento dos sistemas classificadores e os 480 vetores restantes para o teste destes.

O programa de Análise de Redes – ANAREDE[®] foi utilizado para o levantamento das curvas PV's, mediante aplicativo denominado *Fluxo de Potência Continuado*, que processa seqüencialmente uma série de fluxo de potência, incrementando a carga de um conjunto de barras de acordo com uma direção específica. Logo, quando o fluxo de potência não converge (diverge), o último caso é restabelecido e um novo incremento de carga reduzido é utilizado, repetindo-se o procedimento até que o sistema atinja seu máximo carregamento. Ainda, utilizando-se o *Fluxo de Potência Continuado*, também é possível monitorar a variação dos perfis de tensão de acordo com o crescimento da demanda através do vetor tangente (dP/dV), o qual foi utilizado para a identificação das barras críticas do sistema.

Com as bases de dados montadas, estas foram utilizadas para a comparação dos desempenhos dos classificadores. Na seção seguinte, será apresentado um exemplo de avaliação da estabilidade de tensão para a classificação de um ponto de operação diante da aplicação de uma das contingências selecionadas para o sistema em estudo.

4.3.1 Exemplo Prático de Avaliação da Estabilidade de Tensão

Como exemplo prático de análise de estabilidade de tensão através de curvas PV, para a classificação da segurança de tensão de um ponto de operação, objetivando o

levantamento de uma base de dados, foi efetuada a desenergização da linha de transmissão de 500 kV Xingó – Messias do Sistema Norte-Nordeste do SIN. O trecho do sistema em análise é apresentado na Figura 4.4.

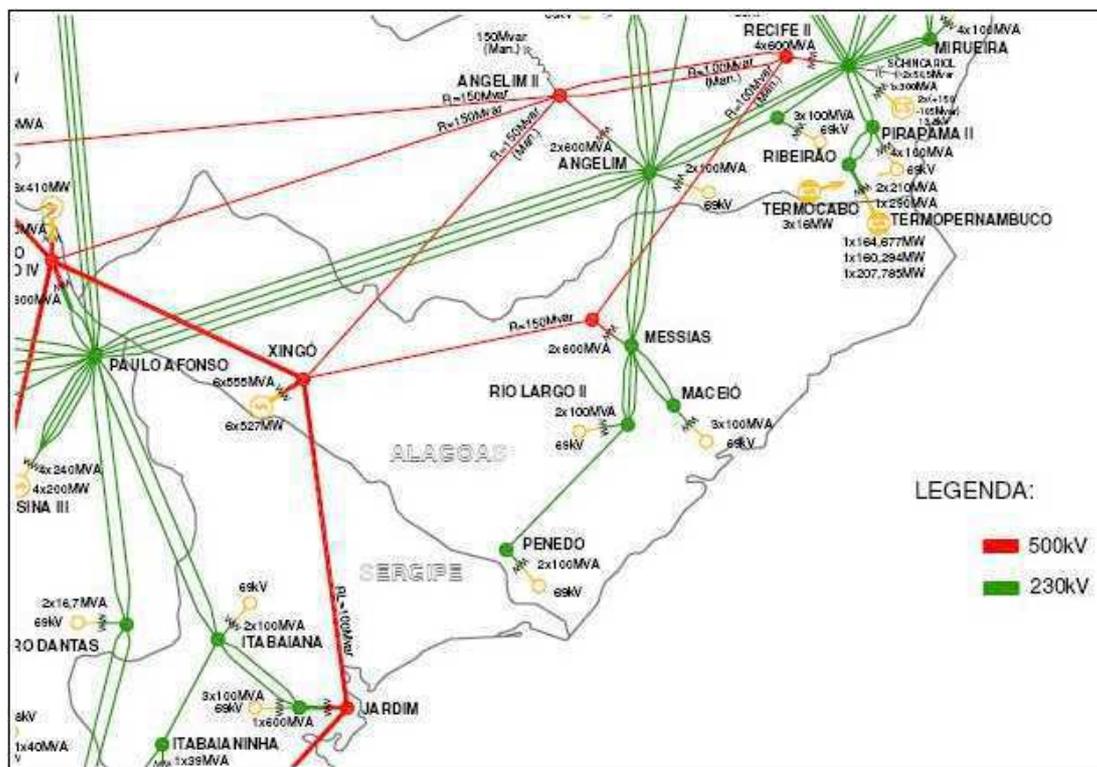


Figura 4.4 - Trecho do Sistema Norte-Nordeste.

Com o objetivo de realizar uma análise de estabilidade de tensão precisa, foi utilizado o programa de Fluxo de Potência Continuo do ANAREDE[®] para o levantamento das curvas PV's das barras críticas diante da aplicação da contingência.

Há de se observar que no levantamento da curva PV deve-se considerar o controle de tensão por variação automática de tap dos transformadores e o controle de tensão por injeção remota de potência reativa dentro dos limites mínimos e máximos, tornando os resultados mais realistas.

Para um fluxo de carga continuado com incremento de carga de 2% em todas as barras de carga da área que compreende as barras monitoradas mais sensíveis diante da aplicação da contingência, foram obtidas as curvas PV's para a barra Penedo 230 kV pré-contingência e pós-contingência, exibidas nas figuras 4.5 e 4.6, respectivamente.

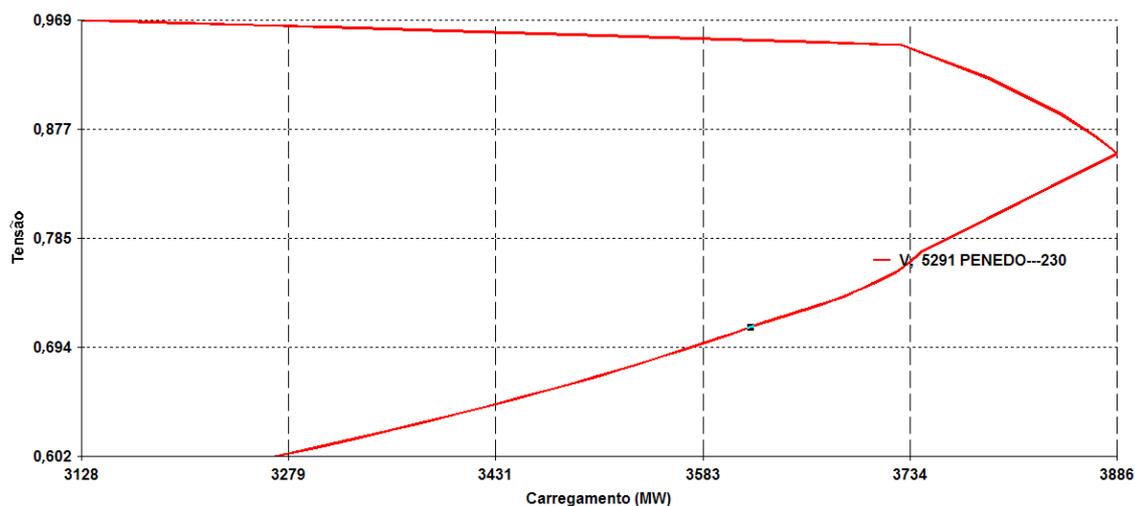


Figura 4.5 - Curva PV da Barra Penedo 230 kV Pré-Contingência.

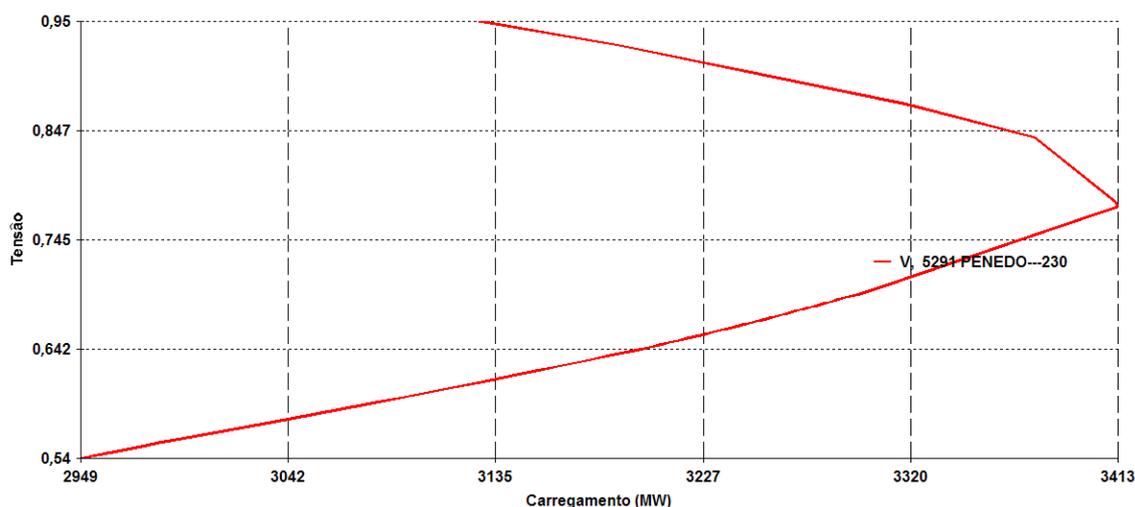


Figura 4.6 - Curva PV da Barra Penedo 230 kV Pós-Contingência.

Os resultados mostram que a margem de estabilidade de tensão – MET da área do sistema operando em condições normais é de 24,2% e que, após a contingência, a mesma é reduzida para 15,7%. Apesar da redução considerável da MET, a área do sistema ainda permanece dentro dos critérios de segurança estabelecidos pelo ONS e WECC. O fato de que, diante da aplicação da contingência severa o sistema se manter seguro em relação à estabilidade de tensão é justificada por conta da área afetada fazer parte de uma malha redundante que oferece caminhos alternativos ao fluxo de potência com reservas de potência reativa suficientes para o sistema operar de forma segura.

Para a contingência aplicada o sistema se manteve em estado de segurança de tensão. Porém, este fato não implica que o ponto de operação em questão seja classificado como seguro. O estado de segurança correspondente a este ponto de

operação será determinado seguro se, e somente se, para as demais contingências aplicadas o sistema se manter estável em relação à estabilidade de tensão.

Capítulo 5

Avaliação das Técnicas de Inteligência Artificial

5.1 Introdução

O objetivo dos sistemas inteligentes é classificar o ponto de operação do sistema entre seguro ou alerta. Para a avaliação das técnicas de IA foram utilizadas bases de dados contendo as características da Área Leste do subsistema Nordeste.

Neste capítulo, são apresentados os resultados da comparação dos sistemas de IA com o intuito de seleção da técnica mais adequada para o desenvolvimento do sistema computacional para a avaliação da estabilidade de tensão. Onde os recursos computacionais *Neural Network Toolbox* e *Fuzzy Logic Toolbox* do MATLAB® foram utilizados para a realização das simulações.

Os sistemas de IA utilizados para comparação foram:

- RNA RPROP;
- Sistema Híbrido RPROP;
- Sistema Híbrido LM.

Ao final deste capítulo é apresentada a ferramenta desenvolvida implementando o sistema de IA escolhido.

5.2 Resultados dos Sistemas Classificadores

Nesta seção são apresentados os resultados obtidos na classificação da segurança da Área Leste do Subsistema Nordeste em relação à estabilidade de tensão, mediante a aplicação das técnicas de IA. Consideraram-se três conjuntos de bases de dados formadas a partir de: 5, 17 e 41 barras críticas.

Também é apresentado o número de casos considerados seguros pelo classificador ao tempo que o sistema não se encontrava em estado de segurança (Falso Seguro) e, o número de casos considerados inseguros ao tempo que o sistema se encontra em estado de segurança (Falso Inseguro). As classificações Falso Seguro são

bastante preocupantes em relação à avaliação de segurança, pois diante deste caso, o operador não teria premissas para a tomada de medidas de segurança. Já as classificações Falso Inseguro levariam os operadores ao estado de alerta, induzindo-os naquele instante a uma análise desnecessária do sistema.

A RNA com algoritmo de treinamento RPROP utilizada é composta por uma camada oculta com 10 neurônios e um único neurônio na camada de saída. O Sistema Híbrido RPROP é composto por uma rede RPROP com a mesma configuração descrita acima e, de um sistema neuro-fuzzy ANFIS. Já o Sistema Híbrido LM é composto pela rede RPROP com a mesma configuração dos sistemas de IA acima descritos e de uma rede Levenberg-Marquardt com 5 neurônios na camada oculta e um neurônio na camada de saída. As simulações foram realizadas num microcomputador com processador Pentium D de 3GHz.

Para a avaliação dos resultados, levou-se em consideração que o critério de maior relevância para a escolha da técnica de IA foi a taxa de acerto do sistema, e, em seguida, o número de casos falso seguro, o número de casos falso inseguro, finalizando com o tempo de treinamento.

Para o caso de 5 barras, em todas as bases de dados (5%, 20%, 60%, 90%), o Sistema Híbrido RPROP apresentou taxa de acerto maior ou igual, em relação a rede neural RPROP atuando singularmente. No entanto, o Sistema Híbrido LM apresentou o melhor resultado para a taxa de acerto e, conseqüentemente, um menor número de falsas indicações de segurança. A Tabela 5.1 apresenta os resultados para a classificação da segurança da Área Leste considerando 5 barras críticas.

Tabela 5.1 - RESULTADOS CONSIDERANDO 5 BARRAS CRÍTICAS.

N° de Barras	Variação Aleatória	Classificador	Tempo de Treinamento (s)	Taxa de Acerto (%)	Falso Seguro	Falso Inseguro
05	5%	RPROP	9,52	100	0	0
		HÍBRIDO RPROP	9,64	100	0	0
		HÍBRIDO LM	9,81	100	0	0
	20%	RPROP	89,47	99,54	6	1
		HÍBRIDO RPROP	89,63	99,54	6	1
		HÍBRIDO LM	89,80	99,58	4	1
	60%	RPROP	247,66	91,04	24	19
		HÍBRIDO RPROP	261,83	91,87	18	21
		HÍBRIDO LM	253,77	92,08	18	20
	90%	RPROP	225,09	84,38	39	36
		HÍBRIDO RPROP	239,62	84,79	59	14
		HÍBRIDO LM	227,09	85,21	53	18

No segundo conjunto de resultados – apresentados na Tabela 5.2, são consideradas 17 barras críticas. Para as bases de dados aleatórias com variações de 5% e 20%, observar-se que a taxa de acerto foi de 100% para todos os sistemas testados, pois esses casos exigem menos esforço para o reconhecimento de padrões, diferentemente dos casos com variações de 60% e 90%, que obtiveram taxas de acerto abaixo dos 100%, prevalecendo as maiores taxas de acerto para o sistema Híbrido LM.

O sistema Híbrido LM apresentou um número de casos falso seguro e inseguro, igual ou inferior aos demais sistemas. No entanto, seu tempo de treinamento foi superior para os casos com variações de 5%, 20% e 60%.

Tabela 5.2. RESULTADOS CONSIDERANDO 17 BARRAS CRÍTICAS.

N° de Barras	Variação Aleatória	Classificador	Tempo de Treinamento (s)	Taxa de Acerto (%)	Falso Seguro	Falso Inseguro
17	5%	RPROP	3,34	100	0	0
		HÍBRIDO RPROP	3,50	100	0	0
		HÍBRIDO LM	3,62	100	0	0
	20%	RPROP	5,72	100	0	0
		HÍBRIDO RPROP	5,84	100	0	0
		HÍBRIDO LM	6,00	100	0	0
	60%	RPROP	56,78	97,91	3	7
		HÍBRIDO RPROP	56,92	98,12	2	7
		HÍBRIDO LM	57,09	98,33	1	7
	90%	RPROP	300,22	95,20	11	12
		HÍBRIDO RPROP	334,00	95,62	10	11
		HÍBRIDO LM	305,87	95,83	10	8

No conjunto de resultados oriundos da utilização de 41 barras críticas para a construção da base de dados (Tabela 5.3), temos que o Sistema Híbrido LM, não diferente dos casos anteriores, apresentou os melhores resultados, com a exceção do tempo de treinamento.

Tabela 5.3. RESULTADOS CONSIDERANDO 41 BARRAS CRÍTICAS.

N° de Barras	Variação Aleatória	Classificador	Tempo de Treinamento (s)	Taxa de Acerto (%)	Falso Seguro	Falso Inseguro
41	5%	RPROP	2,50	100	0	0
		HÍBRIDO RPROP	2,61	100	0	0
		HÍBRIDO LM	2,79	100	0	0
	20%	RPROP	2,92	100	0	0
		HÍBRIDO RPROP	3,04	100	0	0
		HÍBRIDO LM	3,21	100	0	0
	60%	RPROP	5,25	98,12	3	6
		HÍBRIDO RPROP	5,37	98,12	3	6
		HÍBRIDO LM	5,69	98,33	2	6
	90%	RPROP	16,61	91,45	20	21
		HÍBRIDO RPROP	16,80	91,45	20	21
		HÍBRIDO LM	18,59	91,87	19	20

5.4 Conclusões dos Resultados

Observa-se dos resultados obtidos que para um número maior de barras consideradas para a formação da base de dados, obtém-se, em geral, um tempo de treinamento menor, apesar de o número de parâmetros a serem otimizados ser maior. Isso se justifica pelo fato de a base de dados com maior número de barras consideradas possuir uma melhor representação do sistema, facilitando a convergência do classificador para um erro de treinamento mínimo pré-estabelecido.

Também, há de se observar que quanto maior a variação aleatória da base de dados, maior a exigência computacional do sistema classificador e menor a taxa de acerto, visto que, à medida que a variação aleatória é elevada, as características dos pontos de operação a serem classificados tendem a se aproximarem, dificultando a distinção dos mesmos por parte dos sistemas classificadores.

Os resultados obtidos para a base de dados constituída de vetores padrão com 17 e 41 barras críticas apresentaram resultados semelhantes e superiores ao do caso de 5 barras críticas. Entretanto, apesar de o tempo de treinamento para o caso de 41 barras

ser inferior, as taxas de acerto para o caso de 17 barras se mostraram superiores. Pois, a partir deste caso há um aumento dos dados de entrada dos classificadores e, conseqüentemente, o desempenho destes tende a reduzir. Portanto, a base de dados obtida por meio dos vetores padrão extraídos de 17 barras críticas é considerada suficiente para a avaliação da estabilidade de tensão através das técnicas de inteligência artificial para o sistema em análise - Área Leste do Subsistema Nordeste.

A análise de segurança de tensão do sistema de potência utilizado, mediante os sistemas híbridos apresentaram taxas de acertos superiores, sobretudo o Sistema Híbrido LM que apresentou a melhor capacidade de solução dentre os classificadores pesquisados, embora tenha requerido um tempo de treinamento levemente superior em alguns casos. No entanto, o tempo de treinamento não constitui o fator determinante para o desenvolvimento do *software*, e sim sua confiabilidade e precisão deduzidas segundo a taxa de acerto e o número de casos falsos. Logo, o Sistema Híbrido LM foi escolhido para fazer parte da versão definitiva do *software* de análise de estabilidade de tensão de sistemas de potência.

5.5 Desenvolvimento do Software

Foi desenvolvido um *software* em linguagem de programação C++ capaz de analisar eficazmente a seguridade de um sistema elétrico com relação à estabilidade de tensão. Para tanto, foi implementado o sistema proposto no capítulo 4 – Sistema Híbrido LM, que se utiliza de uma rede neural artificial RPROP em série com uma rede neural artificial Levenberg-Marquardt. Os bancos de dados apresentados no capítulo 4 foram utilizados para o teste do *software* desenvolvido.

A ferramenta desenvolvida é composta por dois *softwares*:

- *Software* de Treinamento: TreinaRNA.exe;
- *Software* de Execução: ExecutaRNA.exe;

Para o *software* de treinamento *TreinaRNA.exe*, são apresentados os padrões de treinamento, validação e teste. Durante a execução deste arquivo é impresso na tela o desempenho do treinamento, validação e teste das redes de neurais e, concluído o treinamento, são gerados dois arquivos de saída - melhorRedeRPROP.rna e

melhorRedeLM.rna, contendo as características das redes neurais RPROP e Levenberg-Marquardt (Figura 5.1). Estas características incluem os seguintes itens:

- Número de camadas das redes neurais;
- Número de neurônios de cada camada;
- Tipo de função de ativação de cada camada;
- Matriz dos pesos sinápticos otimizados;
- Vetor das polarizações otimizadas.

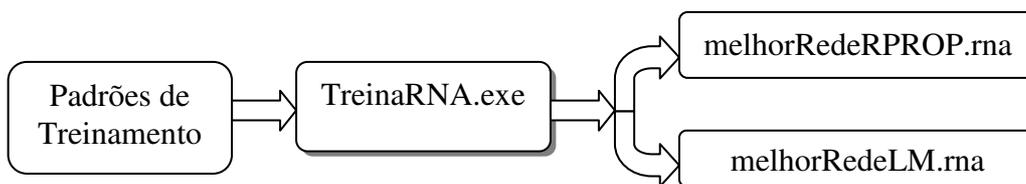


Figura 5.1 – Treinamento do Sistema Híbrido LM via *software* TreinaRNA.exe.

De posse dos arquivos de características das redes neurais, o segundo *software* - *ExecutaRNA.exe*, deverá extrair as configurações de topologia das redes e os valores de todos os pesos otimizados. Desta forma, ao apresentar um arquivo de entrada para a classificação da segurança de tensão do sistema, este *software* irá extrair as características das duas redes neurais treinadas e propagar os dados de entrada exibindo, como resultado, o estado de segurança do sistema, ou seja, se o sistema em questão se encontra seguro ou inseguro em relação à estabilidade de tensão (Figura 5.2).

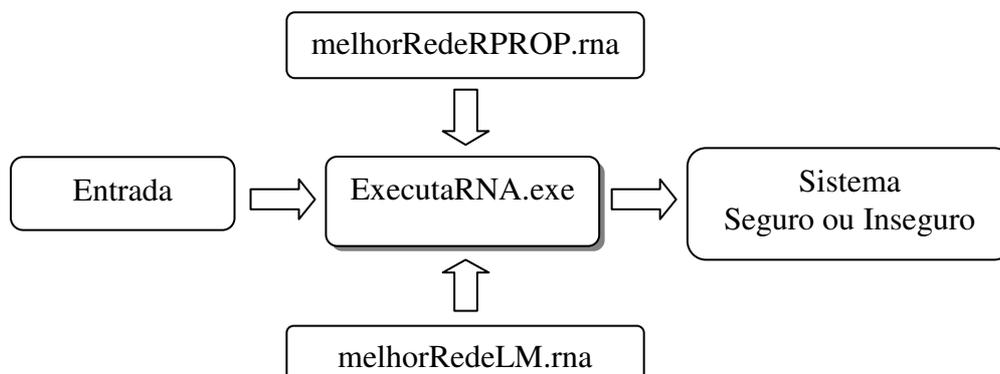


Figura 5.2 – Classificação do Sistema de Potência via *software* ExecutaRNA.exe.

Capítulo 6

Conclusões

Um método baseado em técnicas de IA, denominado Sistema Híbrido LM, foi proposto com o objetivo de integrar um sistema computacional para a avaliação da estabilidade de tensão dos sistemas de potência. Seu desempenho foi comparado com uma rede neural RPROP e um sistema híbrido baseado em redes neurais e lógica fuzzy – Sistema Híbrido RPROP.

A principal contribuição do método proposto está relacionada ao maior grau de confiabilidade e eficiência do sistema de reconhecimento de padrões, visto que a análise de segurança de tensão de um sistema de potência demanda uma grande acurácia.

Foi demonstrada neste trabalho a utilização do Índice Margem baseado na curva PV, pelas empresas do setor para identificação do estado de operação do sistema elétrico em seguro ou inseguro, quanto à estabilidade de tensão. Este critério foi utilizado para a construção das bases de dados para o treinamento e teste dos classificadores.

O bom desempenho de um sistema classificador baseado em técnicas de IA depende fundamentalmente do processo de construção da base de dados, o qual levou em consideração a extração apenas das características relevantes do sistema de potência, de forma a obter a maior representatividade possível do sistema em análise com o menor esforço computacional. Deve-se ressaltar que neste trabalho foi utilizada uma metodologia para a geração dos vetores padrão, dividindo-se o sistema de potência em áreas e utilizando-se um número reduzido de barras, sendo estas, as barras críticas do sistema.

Percebeu-se que, quanto maior o número de barras críticas utilizadas na construção da base de dados, melhores foram os resultados obtidos para os classificadores. Em contrapartida, sabe-se que à medida que o número de barras críticas consideradas é elevado, a eficiência dos classificadores é reduzida devido ao aumento dos parâmetros a serem otimizados. Há de se destacar também o tratamento dos dados efetuado através da normalização dos vetores padrões, para a melhoria dos resultados obtidos.

Um *software* implementando o método proposto - Sistema Híbrido LM - foi desenvolvido em linguagem de programação C++ para sua utilização em estudos *off-line* com aplicação no sistema CHESF.

Sabendo-se que a ferramenta desenvolvida possui capacidade para utilização em tempo real, é proposto como trabalho futuro a integração do *software* desenvolvido a um sistema SCADA - *Supervision Control And Data Acquisition Station*, presente nos centros de controle das empresas de energia elétrica, com o objetivo de extrair as informações do sistema e, em seguida, informar o estado de segurança de tensão ao operador.

Como o *software* desenvolvido abrange apenas a análise de uma área por vez de um sistema de grande porte e, sabendo-se que na construção de uma base de dados para o subsistema Norte-Nordeste completo, muitas barras críticas deveriam ser selecionadas para extrair suas características implicando na inviabilidade do uso do método proposto. Como proposta para trabalho futuro, seria de se pensar na ampliação da capacidade da ferramenta desenvolvida para realizar uma análise simultânea de *n-áreas* para um sistema de grande porte - Figura 6.1, identificando quais regiões do sistema necessitariam de ações corretivas, resultando em apenas uma classificação final do sistema, tendo em vista que se apenas uma área do sistema for considerada insegura o sistema também será considerado desta forma.

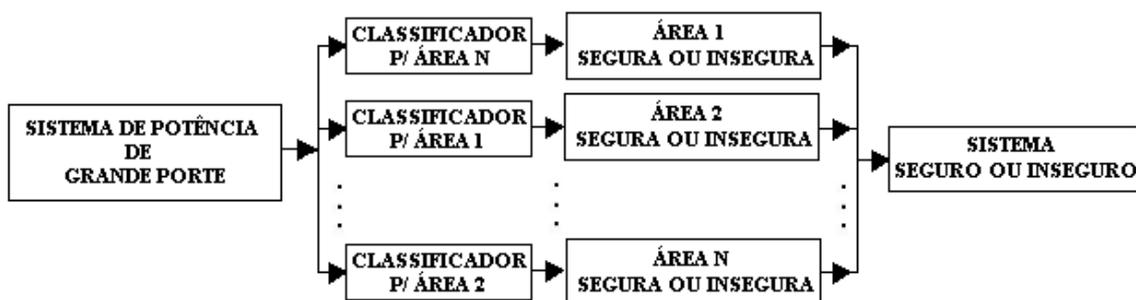


Figura 6.1 – *Software* para Análise de Segurança de Tensão em Sistemas de Grande Porte.

Por fim, novas técnicas de inteligência artificial vêm sendo apresentadas superando deficiências de técnicas mais antigas, a exemplo da rede neural recorrente *Echo State Network – ESN* que vem sendo utilizada em sistemas elétricos. Sua principal característica é a habilidade de modelar sistemas sem a necessidade de treinar os pesos recorrentes, treinando apenas os pesos da camada de saída da rede, reduzindo o esforço computacional deste processo. Portanto, um estudo comparativo destas técnicas com as

utilizadas neste trabalho, com objetivo de identificar um algoritmo mais eficiente para a avaliação *on-line* de segurança de tensão, pode ser realizado em um trabalho futuro.

REFERÊNCIAS

- Ajjarapu, V., and Christy, C., (1992). “The continuation power flow: A tool for steady state voltage stability analysis”, *IEEE Transactions on Power Systems*, Vol. 7 (1) , pp. 416_423, February.
- Amjady, N., and Ehsan, M., (1999). “Evaluation of power system reliability by an artificial neural network”, *IEEE trans. Power Syst.* Vol. 14 (1), pp. 287 – 292, Feb. 1999.
- Amjady, N., (2003). “Dynamic voltage security assessment by a neural network based method”, *Electric Power Systems Research*, Vol. 66, pp. 215-226.
- Andrade, A. C., Marciel Barbosa, F. P., (2005). “Detection of the point of voltage collapse using the FSQV method”, *Power Tech, 2005 IEEE Russia*, 27 – 30 June, St. Petersburg, Russia.
- Andrade, A. C., Marciel Barbosa, F. P., Fidalgo, J. N. and Ferreir, J. R., (2006). “Voltage stability assessment using a new FSQV method and artificial neural networks”, *Electrotechnical Conference, MELECON 2006, IEEE Mediterranean*, 16 – 19 May, Malaga, Spain.
- Begovic, M. M. and Phadke, A. G., (1992). “Control of Voltage stability Using Sensitivity Analysis”, *IEEE Trans. On Power System*, Vol. 7, No. 1, February.
- Bihain, A.; et. Al., (2003). “OMASES: A Dynamic Security Assessment Tool for the New Market Environment”, *IEEE Bologna Power Tech Conference*, 23 – 26 June, Bologna, Italy.
- Cañizares, C. A., and Alvarado, F. L. (1993). “Point of collapse and continuation methods for large ac/dc systems”, *IEEE Transactions on Power Systems*, 8:1-8, February.
- Cañizares, C. A., de Souza, A. C. Z. and Quintana, V. H. (1996). “Comparison of performance indices for detection of proximity to voltage collapse”, *IEEE Trans. Power Syst.*, Vol. 11, pp. 1441 – 1450, Aug.

- Chakrabarti, S. and Jeyasurya, B., (2004). “On-line voltage stability monitoring using artificial neural network”, Large Engineering Systems Conference – LESCOPE-04, 28 - 30 July, pp. 71 – 75.
- Dinavahi, V. R. and Srivastava, S. C., (2001). “ANN based voltage stability margin prediction”, Power Engineering Society Summer Meeting, IEEE, Vol. 2, 15-19 July, pp. 1275 – 1280.
- Franchi, L., Gambelungho, A., Salvati, R. and Sforza, M., (2003). “Online Dynamic Security Assessment at the Italian System Operator”, *IEEE Bologna Power Tech Conference*, 23 – 26 June, Bologna, Italy.
- Hagan, M. T., and Menhaj, M. B. (1994). “Training Feedforward Networks with the Marquardt Algorithm”, *IEEE Trans. on Neural Networks*, Vol. 6, no. 6, pp. 160-168.
- Haykin, S. (1994). “Neural Networks: a comprehensive foundation”, Macmillan College Publishing Company, New York.
- Haykin, S. (2001). “Redes Neurais: Princípios e prática”, trad. Paulo Martins Engel 2ª Edição – Porto Alegre: Bookman.
- Jang, J.-S. R. (1993). “ANFIS: Adaptive-Network-Based Fuzzy Inference System”, *IEEE Transactions on Systems, Man, and Cybernetics*, Vol. 23, No.3, pp. 665-685.
- Jardim, J. L., Neto, C. A., Groetaers, M. e Gomes, P. (2004). “Design Features of a Dynamic Security Assessment System” IX SEPOPE – Simpósio de Especialistas em Planejamento da Operação e Expansão Elétrica, 23 a 27 de maio, Rio de Janeiro (RJ), Brasil.
- Jeyasurya, B., (2000). “Artificial neural networks for on-line voltage stability assessment”, Power Engineering Society Summer Meeting, 2000. IEEE, Vol. 4, 16 - 20 July, pp. 2014 – 2018.
- Jesan, J. P., (2005). “The neural approach to pattern recognition”, *Ubiquity: An ACM IT Magazine and forum* – http://www.acm.org/ubiquity/views/v5i7_jesan.html - acessado em agosto de 2008.
- Kundur, P. (1994). *Power System Stability and Control*, McGraw-Hill, Inc.

- Kundur, P. and Morison, K., (1998). “On-line Dynamic Security Assessment of Power Systems”, SEPOPE – Simpósio de Especialistas em Planejamento da Operação e Expansão Elétrica, Salvador (BA), Brasil.
- Mendes, P. P. de C., (1999). “Aplicação de Redes Neurais Artificiais na Análise em Tempo Real da Estabilidade de Tensão de Regime Permanente de Sistemas Elétricos de Potências”, Julho, Tese de Doutorado, Coordenação dos Programas de Pós-Graduação em Engenharia – COPPE, UFRJ.
- Mendes, P. P. de C., Falcão, D. M. e da Silva, A. P. A., (2000b). “Extração de Características de um Sistema Elétrico de Potência para Avaliação da Estabilidade de Tensão via Redes Neurais Artificiais”, XIII Congresso Brasileiro de Automática – CBA, 11 a 14 de setembro – Florianópolis – SC – Brasil.
- Modi, P. K., Singh, S. P., Sharma, J. D., (2008). “Fuzzy neural network based voltage stability evaluation of power systems with SVC”, ELSEVIER B. V., Vol. 8 (1), pp. 657 – 665, January.
- Ni, M., McCalley, J. D., Vittal, V. and Tayyib, T., (2003). “Online Risk-Based Security Assessment”, *IEEE Transactions on Power Systems*, Vol. 18, No. 1, Feb.
- ONS (2005). Plano de Ampliações e Reforços na Rede Básica – Período 2006 a 2008 – Sumário Executivo. <http://www.ons.org.br>
- ONS (2007). Procedimentos de Rede, Submódulo 23.3, Diretrizes e Critérios para Estudos Elétricos - 2ª Revisão. <http://www.ons.org.br>
- Riedmiller, M., and Braun, H. (1993). “A direct adaptive method for faster backpropagation learning: The RPROP algorithm.” *Proceedings of the IEEE International Conference on Neural Networks, San Francisco.*
- Sodré, E., Almeida, K. C. e Salgado, R. (1997). “Avaliação Estática da Estabilidade de Tensão via Método da Continuação”, XIV SNPTEE, Belém-PA.
- Sodré, E. e Mota, W. S. (2000). “Um Sistema Neuro-Fuzzy para Análise de Segurança da Estabilidade de Tensão”, CBA 2000 – Congresso Brasileiro de Automática, 11 a 14 de setembro, Florianópolis, SC.
- Sodré, E., (2006). “Avaliação da Estabilidade de Tensão através das Técnicas de Inteligência Artificial”, Tese de Doutorado – UFCG, Campina Grande – PB, Abril de 2006.

- de Souza, A. C. Z., de Souza, J. C. S. and Silva, A. M. L., (2000) “On-Line Voltage Stability Monitoring”, IEEE Transactions on Power Systems, vol. 15, No. 4, Nov.
- Suthar, B. and Balasubramanian, R., (2007). “A Novel ANN Based Method for Online Voltage Stability Assessment”, International Conference on ISAP – Intelligent Systems Applications to Power Systems, 5 – 8 November, pp. 1 – 6.
- Taylor, C. W. (1994). Power System Voltage Stability, McGraw-Hill, Inc.
- Teng, J. H., (2005). “Power Flow and Loss Allocation for Deregulated transmission systems”, Electrical Power and Energy Systems, Vol 27 no 4, pp. 327-333, January.
- WECC Reactive Power Reserve Work Group (1998). Final Report: Voltage Stability Criteria, Undervoltage Load Shedding Strategy, and Reactive Power Reserve Monitoring Methodology. <http://www.wecc.biz>.
- Van Cutsem, T., Vournas, C., (1998). “Voltage Stability of Electric Power Systems”, Kluwer Academic Publishers (Power Electronics and Power Systems Series).
- Vaahedi, E., Fuch, C., Xu, W., Mansour, Y. Hamadanizadeh, H. and Morrison, G. K., (1999). “Voltage Stability Contingency Screening and Ranking”, IEEE Trans. on Power System, Vol. 14, No. 1, February.
- Van Cutsem, T. (2000). “Voltage Instability: Phenomena, Countermeasures, and Analysis Methods”, Proceedings of the IEEE, Vol. 88, No. 2, February.
- Van Cutsem, T; Kabouris J.; Christoforidis G.; Vournas C. D., (2004). Application of real-time voltage security assessment to the Hellenic interconnected system. *IEEE, Proc.-Gener. Transm. Distrib.*, vol. 152, no. 1, Jan. 2005.
- U.S. – Canada Power System Outage Task Force (2004). Final Report on the August 14, 2003 Blackout in the United State and Canada: Causes and Recommendations. <http://www.iwar.org.uk/cip/resources/blackout-03/>.
- Zadeh, L. A., “Fuzzy sets”, *Inf. Contr.*, vol. 8, pp. 338–353, 1965.
- Zhang, Y. and Zhou, Z., (2002). “Online voltage stability contingency selection using improved RSI method based on ANN solution”, Power Engineering Society Winter Meeting, IEEE, Vol. 2, Pag.: 888 – 892, Jan. 2002.