



Universidade Federal de Campina Grande
Coordenação dos Cursos de Pós-Graduação em Engenharia Elétrica

Avaliação da Estabilidade de Tensão através das Técnicas de Inteligência Artificial

Eduardo de Aguiar Sodré

Tese de Doutorado submetida à Coordenação dos Cursos de Pós-Graduação em Engenharia Elétrica da Universidade Federal de Campina Grande, como parte dos requisitos necessários para obtenção do Grau de Doutor em Ciências no domínio da Engenharia Elétrica.

Área de Concentração: Sistemas Elétricos

Wellington Santos Mota, Ph.D.
Orientador

Campina Grande, Paraíba, Brasil
© Eduardo de Aguiar Sodré, Abril de 2006

UFCG - BIBLIOTECA - CAMPUS I	
562	09-03-07

FICHA CATALOGRÁFICA ELABORADA PELA BIBLIOTECA CENTRAL DA UFCG

S679a Sodré, Eduardo de Aguiar
 2006 Avaliação da estabilidade de tensão através das técnicas de inteligência artificial/ Eduardo de Aguiar Sodré. Campina Grande, 2006. 151.;il.

Referências.

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

Orientadores: Wellington Santos Mota.

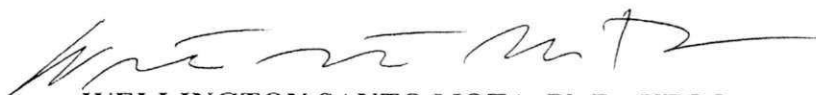
1 Inteligência Artificial 2 Engenharia Elétrica 3 Sistemas de Potência I
 Título

CDU 004.8

**AVALIAÇÃO DA ESTABILIDADE DE TENSÃO ATRAVÉS DAS TÉCNICAS DE
INTELIGÊNCIA ARTIFICIAL**

EDUARDO DE AGUIAR SODRÉ

Tese Aprovada em 07.04.2006

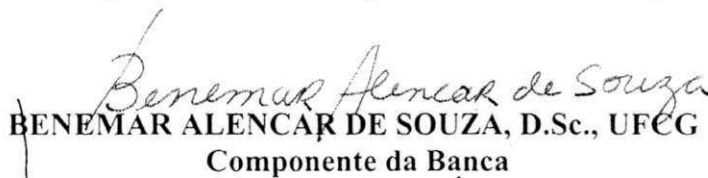


WELLINGTON SANTO MOTA, Ph.D., UFCG
Orientador

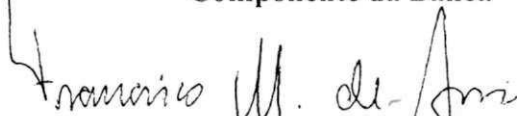


ANTONIO CARLOS ZAMBRONI DE SOUZA, Dr., UNIFEI
Componente da Banca

ROBERTO DE SOUZA SALGADO, Ph.D., UFSC
Componente da Banca (Ausência Justificada)



BENEMAR ALENCAR DE SOUZA, D.Sc., UFCG
Componente da Banca



FRANCISCO MARCOS DE ASSIS, Dr., UFCG
Componente da Banca

CAMPINA GRANDE – PB
ABRIL - 2006

Agradecimentos

Nenhum trabalho, empresa ou empreendimento é o resultado do esforço de um homem só. Cada produto, idéia ou desenvolvimento só é possível porque vários outros contribuíram para essa realização. Nenhuma colheita é fruto de esforço único. Há o tempo, o vento e as pessoas, que direta ou indiretamente, tornaram possível a sementeira e a colheita. Mesmo os empecilhos e os obstáculos têm sua parcela de responsabilidade, de um modo ou de outro fazem com que amadureçamos e fazem com que cheguemos até aqui.

Agradeço de modo particular ao Prof. Wellington Santos Mota por sua total e irrestrita confiança de que seria capaz de realizar o trabalho. Nunca ouvi ou pressenti qualquer movimento, suspeita ou esgar que indicasse que não seria possível. Essa foi a sua maior contribuição. Agradeço todas as outras também, que não foram pequenas nem dispensáveis.

Agradeço também aos Prof.(s) Roberto Salgado e Benemar Alencar de Souza, não só pela paciência, presteza e conhecimento técnico, mas principalmente pelas valiosas lições que me deram sem que percebesse e que só hoje agradeço e valorizo.

Agradeço a todos os profissionais das empresas e das Universidades por onde passei, que fizeram com que eu conhecesse melhor a espécie humana e a mim também. Em particular aos formidáveis seres humanos da CHESF, essa empresa tão espetacularmente idiossincrática, nas pessoas dos Engenheiros Valdson Simões de Jesus, Murilo Sérgio Lucena Pinto e Fernando Rodrigues Alves.

E também aos amigos, colaboradores e parceiros do Dept. de Engenharia Elétrica da UFCG. Que vosso exemplo de seriedade técnica seja sempre uma bandeira desfraldada acima dos mesquinhos interesses pessoais, e que permaneça para todo o sempre servindo de referência aos que respeitam e gostam da Engenharia.

Agradeço à Família, que significa o início e o fim, o próprio Caminho e o exercício da caminhada. Todos os agradecimentos são poucos para essa instituição gratificadora da alma

humana. As vicissitudes da Vida são ensinamentos que absorvemos acalentados pelo calor de meigos olhares e ombros amigos que só existem na Família. Que o meu filho(s) aproveite isto da mesma forma que me completa. Agradeço a ele também.

Agradeço em particular à minha esposa e companheira, Flávia Maria Cavalcanti Ferreira, exemplo de luta, seriedade, disposição, amor fraterno e busca contínua às verdadeiras virtudes. Toda gratidão é pouca, tantas são e foram as batalhas e tamanha foi a satisfação em vivê-las juntamente com você. Que muitos anos ainda venham, da mesma forma e com a mesma essência, para que continuemos a plantar e a colher: nosso filho e nossa casa, nossas lutas e vitórias, nossa responsabilidade pelo mundo e pelos outros. Obrigado.

Agradeço por esta Vida, por esta oportunidade, pela contemplação do espaço, do tempo e da divindade, pela permanência e pela transitoriedade.

Agradeço a Deus.

Se

Se és capaz de manter a tua calma quando
Todo o mundo ao teu redor já a perdeu e te culpa;
De crer em ti quando estão todos duvidando,
E para esses no entanto achar uma desculpa;
Se és capaz de esperar sem te desesperares,
Ou, enganado, não mentir ao mentiroso,
Ou, sendo odiado, sempre ao ódio te esquivares,
E não parecer bom demais, nem pretensioso;

Se és capaz de sonhar — sem que eles tornem-se teus senhores;
Se és capaz de pensar — sem que a isso só te atires;
Se encontrando a desgraça e o triunfo conseguires
Tratar da mesma forma a esses dois impostores;
Se és capaz de sofrer a dor de ver mudadas
Em armadilhas as verdades que disseste,
E as coisas, por que deste a vida, estraçalhadas,
E refazê-las com o bem pouco que te reste;

Se és capaz de arriscar numa única parada
Tudo quanto ganhaste em toda a tua vida,
E perder e, ao perder, sem nunca dizer nada,
Resignado, tornar ao ponto de partida;
De forçar coração, nervos, músculos, tudo,
A dar seja o que for que neles ainda existe
E a persistir, mesmo quando exaustos e contudo
Só restar a Vontade em ti que ainda ordena: "Persiste!";

Se és capaz de, entre a plebe, não te corromperes
E, entre reis, não perder a naturalidade,
E de amigos, quer bons, quer maus, te defenderes;
Se a todos podes ser de alguma utilidade;
E se és capaz de dar, segundo por segundo,
Ao minuto inesquecível todo o valor e brilho,
Tua é a terra com tudo o que existe no mundo
E - o que é mais - tu serás um Homem, meu filho!

Rudyard Kipling

À Flávia Maria Cavalcanti Ferreira

ÍNDICE

LISTA DE FIGURAS	iii
LISTA DE TABELAS	iv
RESUMO	v
1 – INTRODUÇÃO	1
1.1 – Justificativa e Relevância da Tese	1
1.2 – Revisão Bibliográfica	3
1.2.1 – Grupo de Análise Rápida	4
1.2.2 – Grupo de Simulação <i>Quasi</i> -Estática	8
1.2.3 – Grupo de Inteligência Artificial	10
1.3 – Organização da Tese e Principais Contribuições	17
2 - TÉCNICAS DE INTELIGÊNCIA ARTIFICIAL	20
2.1 – Introdução	20
2.2 - Redes Neurais Artificiais	21
2.2.1 - Reconhecimento de Padrões	21
2.2.2 - As Redes Neurais e o Perceptron	25
2.2.3 - Multilayer Perceptron	36
2.2.4 – RPROP	42
2.2.5 - RBF – DDA	45
2.2.6 - Combinador de Redes Neurais	47
2.2.7 - Aplicações em Sistemas de Potência	49
2.3 - Sistemas Fuzzy	51
2.3.1 - Visão Geral dos Sistemas Fuzzy	52
2.3.2 - Fundamentos da Lógica Fuzzy	56
2.3.3 - Sistemas Fuzzy	63
2.3.4 - Um Pouco da História	67
2.3.5 - Aplicações em Sistemas de Potência	69
2.4 - Sistemas Neuro-Fuzzy	72
2.5 – Conclusões	76
3 – ESTABILIDADE DE TENSÃO: CONCEITOS E CRITÉRIOS	77
3.1 – Introdução	77
3.2 - O Estudo da Estabilidade de Tensão	79
3.2.1 - Conceitos e Definições Básicas	80
3.2.2 - Critérios de Desempenho	82
3.2.3 - Diretrizes e Critérios para Estudos	85
3.3 - Método da Continuação	89
3.3.1 - Reformulação das Equações do Fluxo de Potência	90
3.3.2 - Etapa de Previsão	92
3.3.3 - Etapa de Correção	94
3.4 - Resultados	98
3.4.1 - Configuração	99
3.4.2 - Critério para Definição do Limite de Transmissão	100
3.5 - Conclusões	103
4 - RESULTADOS	104
4.1 – Introdução	104
4.2 – Análise da Segurança	104
4.2.1 - Avaliação da Estabilidade de Tensão <i>on-line</i>	105
4.2.2 - Requisitos Funcionais do Módulo <i>on-line</i>	110
4.3 – Resultados Sistema Sul-Sudeste	114
4.3.1 - Pontos de Operação e Contingência	115
4.3.2 - Resultados do Combinador	119
4.3.3 - Resultados do Sistema Neuro-Fuzzy	121
4.4 – Resultados Sistema Norte-Nordeste	122
4.4.1 - Pontos de Operação e Contingência	123
4.4.2 - Resultados do Sistema Híbrido	133
4.5 - Conclusões	138
5 – CONCLUSÕES E TRABALHOS FUTUROS	140
REFERÊNCIAS	143

Lista de Figuras

Figura 1.1 – Grupos de Soluções para a Avaliação da Estabilidade de Tensão	3
Figura 2.1 – Espaço de Características	23
Figura 2.2 – 1ª classificação do kNN	25
Figura 2.3 – 2ª classificação do kNN	25
Figura 2.4 - Esquema de um neurônio	26
Figura 2.5 - Modelo de neurônio contínuo	29
Figura 2.6 – Sistema Classificador com uma fronteira de decisão linear	31
Figura 2.7 - Região de decisão: Função AND	32
Figura 2.8 - Porta lógica AND implementada no Perceptron	32
Figura 2.9 – MLP 2 camadas	36
Figura 2.10 – Área de Conflito	46
Figura 2.11 – Combinador SMPM	49
Figura 2.12 – Mapeamento Entrada-Saída	52
Figura 2.13 – Mapeamento Entrada-Saída Linear	54
Figura 2.14 – Mapeamento Entrada-Saída Linear por Partes	55
Figura 2.15 – Mapeamento Entrada-Saída Fuzzy	57
Figura 2.16 – Função de Pertinência	59
Figura 2.17 – Teoria Clássica dos Conjuntos	60
Figura 2.18 – Método de Implicação <i>min</i>	63
Figura 2.19 – Estrutura Básica do Sistema Fuzzy	64
Figura 2.20 – Agregação de Todas as Saídas	66
Figura 2.21 – Defuzzificação	66
Figura 2.22 – Sistema Fuzzy Tipo Takagi-Sugeno	73
Figura 2.23 – Arquitetura ANFIS	73
Figura 3.1 – Curva P-V	83
Figura 3.2 – Curva P-V	85
Figura 3.3 - Ilustração do esquema de previsão-correção do Método da Continuação	90
Figura 3.4 - Sistema para exemplo do Método de Continuação	95
Figura 3.5 – Configuração Básica	100
Figura 3.6 - Curvas de Estabilidade Estática	103
Figura 4.1 – Módulo <i>AET on-line</i>	111
Figura 4.2 - Sistema Sul-Sudeste	116
Figura 4.3 - Curvas P-V	117
Figura 4.4 – Combinador SMPM	120
Figura 4.5 - Sistema Norte-Nordeste ano 2010 – Principais Troncos de 500 kV	122
Figura 4.6 – Pontos de operação para o Sistema Norte-Nordeste	125
Figura 4.7 – Avaliação de Estabilidade para o Sistema Sul-Sudeste	127
Figura 4.8 – Avaliação de Estabilidade para o Sistema Norte-Nordeste	127
Figura 4.9 – Sistema de Avaliação de Estabilidade por Áreas	128
Figura 4.10 – Variações para as 164 variáveis de um vetor padrão	131
Figura 4.11 – Sistema Classificador Híbrido RPROP	135
Figura 4.12 – Sistema Classificador Híbrido kNN	135

Lista de Tabelas

Tabela 2.1 – Características dos Problemas em Sistemas de Potência.	50
Tabela 2.2 – Aplicações Práticas de Redes Neurais.	51
Tabela 2.3 - Tabela Verdade das Funções Lógicas Booleanas.	60
Tabela 2.4 - Tabela Verdade das Funções Lógicas Fuzzy.	61
Tabela 3.1 – Limites de suprimento de carga na área Norte da CHESF, durante a liberação da barra principal de 230 kV da SE Bom Nome	101
Tabela 4.1 - Critérios WSCC.	108
Tabela 4.2 - Primeiro Conjunto de Resultados	120
Tabela 4.3 - Segundo Conjunto de Resultados	122
Tabela 4.4 – Lista de Contingências para a Área Leste do Subsistema Nordeste	129
Tabela 4.5 – Classificação dos Pontos de Operação	130
Tabela 4.6 – Barras críticas da Área Leste	131
Tabela 4.7 – Análise de número de barras para formação do vetor padrão	132
Tabela 4.8 – Resultados considerando MLP convencional	134
Tabela 4.9 – Resultados com vetor padrão de 17 barras e Bases de Dados de 5%, 20%, 60% e 90%	136
Tabela 4.10 – Resultados com vetor padrão de 41 barras e Bases de Dados de 5%, 20%, 60% e 90%	138

Resumo

Nesta Tese são apresentados os resultados obtidos na avaliação da segurança dos sistemas de potência em relação à instabilidade de tensão utilizando a rede neural RPROP e o sistema neuro-fuzzy ANFIS (Adaptive Neuro-Fuzzy Inference System) combinados num arranjo híbrido. Este arranjo híbrido tem seu desempenho comparado com os desempenhos apresentados pela rede neural Multilayer Perceptron (MLP), pelo RPROP, kNN (k - Nearest Neighbour) e pelo sistema neuro-fuzzy ANFIS.

São apresentados também os resultados utilizando um combinador de redes neurais através dois classificadores (RBF-DDA e kNN). Estes classificadores foram combinados utilizando um método denominado Soma Máxima Ponderada Modificada (SMPM). Estes resultados são comparados com os desempenhos apresentados pelas redes neurais MLP e RBF-DDA atuando sozinhas e pelo kNN.

Os classificadores foram treinados para dar como saída, de um conjunto de variáveis de entrada (ponto de operação da rede elétrica), a condição de segurança do sistema entre uma de duas, quais sejam, seguro ou alerta. Estas condições foram obtidas em função do Índice Margem calculado através do Método da Continuação.

É ressaltada a importância fundamental da correta formação dos conjuntos de padrões de treinamento e teste, e também a importância da estratégia da divisão do sistema de potência em conjuntos de barras (áreas) para aumentar o desempenho do sistema de avaliação de segurança. A eficiência da abordagem proposta foi avaliada através dos resultados obtidos com dois sistemas de potências reais: o sistema Sul-Sudeste de 77 barras; e o sistema Norte-Nordeste de 482 barras.

Abstract

In this Thesis the results obtained in the evaluation of the security of power systems in relation to the voltage instability using the neural network RPROP and the neuro-fuzzy system ANFIS (Adaptive Neuro-Fuzzy Inference System), combined in a hybrid arrangement are presented. This hybrid arrangement has its performance compared with the results presented by the neural network Multilayer Perceptron (MLP), RPROP, kNN (k - Nearest Neighbour) and ANFIS.

It is also presented the results using a combination of neural networks made by two classifiers (RBF-DDA and kNN). These classifiers were combined using a method denominated Modified Weighted Maxim Sum (MWMS). These results are compared with the results presented by the neural networks MLP and RBF-DDA acting alone, and for the kNN.

The classifiers were trained to give as exit, of a group of input variables (operation point of electric system), the condition of security of the system among one of two: secure or alert. These conditions had been obtained by the Margin Index calculated through the Continuation Method.

It is important to stand out the right formation of the sets of training and test data that had been presented to the Classifiers, and also the importance of the strategy of the division of the power system in groups of bars (areas) to increase the performance of the security assessment. The efficiency of the approach was evaluated through the results gotten with two real systems: the South-Southeast Brazilian system of 77 bus; and North-Northeast system of 482 bus.

Capítulo 1

Introdução

1.1 – JUSTIFICATIVA E RELEVÂNCIA DA TESE

Modificações estruturais no setor elétrico, tais como aquelas causadas por privatizações e desregulamentação, assim como a disponibilidade de dispositivos rápidos de compensação de reativos e restrições ambientais, têm levado os sistemas de potência a operar próximos à sua capacidade máxima de transmissão. Em decorrência dessa prática operativa, a estabilidade de tensão tornou-se um aspecto importante, senão decisivo, na determinação dos limites máximos de transferência de potência, suplantando em muitos casos aqueles impostos pela estabilidade angular do sistema (Taylor,1994), (Kundur, 1994), (IEEE/PES, 2002), (Van Cutsem, 2000).

A estabilidade de tensão está associada à capacidade do sistema em manter um perfil de tensões adequado, tanto em condições normais de operação, quanto no caso de ocorrência de perturbações severas. Caso essa condição não seja satisfeita, ocorrerá o fenômeno da *instabilidade de tensão*, caracterizado por uma redução progressiva da magnitude da tensão em uma ou mais barras do sistema (ou aumento). Podendo, caso não sejam tomadas medidas corretivas, estender-se a regiões vizinhas, resultando em um colapso parcial ou total do sistema.

As estratégias tradicionais para a solução de problemas em sistemas de potência são caracterizadas pelo desenvolvimento de modelos matemáticos tratados através de algoritmos computacionais envolvendo técnicas de simulação, soluções numéricas, programação matemática, etc. Estas revelam-se demoradas e trabalhosas em alguns casos, e em outros casos totalmente inviáveis.

A mais nova abordagem dos problemas relacionados à operação e ao planejamento da expansão dos sistemas elétricos faz uso das novas técnicas conhecidas como inteligência artificial (IA). O potencial de utilização da IA em sistemas de potência inclui: previsão de carga, análise de segurança, diagnóstico de falhas, estimação de estado, projetos de estabilizadores, comissionamento de unidades geradoras, controle, etc. (Momoh, Ma and Tomsovic, 1995), (Schiling *et al.*, 1996), (Tomsovic and Chow, 2000).

Neste trabalho procura-se determinar a viabilidade da aplicação das tecnologias das redes neurais e da lógica fuzzy para a análise da segurança em relação à estabilidade de tensão. O objetivo é determinar um sistema baseado em inteligência artificial que possa resolver de forma satisfatória e segura a avaliação da estabilidade de tensão. Existem outras formas de solução desse problema, mas a contribuição do trabalho é demonstrar que as técnicas de IA são suficientemente seguras e robustas, os que as tornam de uso praticamente indispensável em conjunto com as técnicas tradicionais resultando na melhor combinação para os engenheiros de análise de sistemas de potência.

Basicamente, o ponto de operação de um sistema de potência pode ser classificado de duas formas: seguro e inseguro. O problema do colapso de tensão não deve ser confundido com os problemas normais de queda de tensão que acontecem durante a operação diária do sistema quando submetido à contingências.

Apesar do sistema poder apresentar instabilidade de tensão sem se caracterizar o colapso, desejável seria que o estado pós-distúrbio equilibrado do sistema apresentasse um perfil de tensões com valores dentro de limites aceitáveis. Ou seja, neste caso o sistema permaneceria estável depois que se seguisse uma contingência significativa ou um aumento exagerado de carga. o que caracteriza uma condição de operação que pode ser denominada **segura em relação à tensão**.

Em função desta classificação entre condições de operação seguras ou inseguras pode-se elaborar um sistema de reconhecimento de padrões utilizando-se as vantagens combinadas dos sistemas neural e fuzzy. A Tese defendida neste trabalho é a utilização de

um sistema híbrido resultante do “casamento” entre as técnicas de redes neurais artificiais e sistemas fuzzy.

Vale lembrar que a determinação de um ponto de operação em seguro ou inseguro é devido ao índice margem da curva P-V, sendo esta uma das mais importantes indicações da segurança de tensão ou robustez do sistema em relação à instabilidade de tensão de longo termo envolvendo grandes distúrbios (Taylor, 1994, 1996).

1.2 – REVISÃO BIBLIOGRÁFICA

As soluções para o problema da avaliação da estabilidade de tensão podem ser divididas em seis grandes grupos, conforme Figura 1.1. Os três primeiros grupos (Análise em Regime, Pequenos Sinais e Simulação no Tempo) são as técnicas que foram primeiramente utilizadas e/ou desenvolvidas para o entendimento e a solução do problema da estabilidade de tensão (Ajjarapu and Lee, 1998), (Cañizares, de Souza and Quintana, 1996). Os três últimos grupos (Análise Rápida, Simulação Rápida no Tempo e Inteligência Artificial) são as técnicas que tem como objetivo solucionar o problema em curto espaço de tempo e de forma eficiente, e são mais comumente utilizadas para avaliação de segurança em tempo real.

Por este motivo a seleção dos trabalhos e artigos dos vários pesquisadores ao redor do mundo para revisão bibliográfica foi escolhida de forma a privilegiar os três últimos grupos da Figura 1.1.



Figura 1.1 – Grupos de Soluções para a Avaliação da Estabilidade de Tensão.

O grupo da *Análise Rápida* é formado por vários métodos extremamente diferentes entre si, mas com uma característica comum a todos, que é a aplicação das tradicionais técnicas de análise em regime permanente ou de transitório eletromecânico, ou até mesmo com cálculo de determinantes e autovalores/autovetores. Muitos dos trabalhos deste grupo também utilizam uma aproximação das técnicas com o objetivo de tornar o cálculo dos índices mais rápidos.

Pode-se tomar como exemplo de trabalho deste grupo o artigo apresentado por J. L. Jardim no SEPOPE 2004 (Jardim, *et al.*, 2004). Um outro tipo de trabalho bastante característico deste grupo é o publicado pelo Zambroni (de Souza, *et al.*, 2000), pode-se citar também o trabalho da ERCOT (Avila-Rosales, *et al.*, 2003) e o trabalho do Lixin Bao (Bao, Huang and Xu, 2003).

O grupo de *Simulação Rápida no Domínio do Tempo* inclui os trabalhos que utilizam um algoritmo de simulação quasi-estática. Este algoritmo de simulação é extremamente rápido, pois só considera a dinâmica de longo termo dos componentes de controle do sistema de potência. Como exemplos pode-se citar: (Franchi, *et al.*, 2003), (Bihain, *et al.*, 2003), (Kundur and Morison, 1998), (Nativel, *et al.*, 2000).

O terceiro grupo utiliza as técnicas de *Inteligência Artificial*, tais como, redes neurais, lógica fuzzy, etc.

1.2.1 – GRUPO DE ANÁLISE RÁPIDA

Neste grupo, como já citado anteriormente, estão incluídas as metodologias que se utilizam das técnicas tradicionais. Um trabalho bastante característico deste grupo é o trabalho do Zambroni (de Souza, *et al.*, 2000). Este trabalho conta com um estimador de estados para ajudar na tarefa de avaliar em tempo real a estabilidade de tensão. A avaliação da estabilidade de tensão é efetuada através da técnica de extrapolação do vetor tangente do método da continuação. A função do estimador de estados é predizer uma condição futura de operação do sistema de potência baseado numa previsão de carga a curto prazo. A idéia subjacente na utilização do vetor tangente é aproximar o comportamento do vetor

tangente por uma quadrática e então obter a margem de carregamento do sistema, seguindo a idéia da referência (Ejebe *et al.*, 1996). Os testes foram realizados no sistema IEEE-14 barras.

O trabalho do Ming Ni (Ni, *et al.*, 2003) propõe uma abordagem baseada em risco para a avaliação da segurança do sistema de potência. Basicamente há o cálculo de índices de risco para cada contingência de interesse. Estes índices de risco são computados como uma soma da probabilidade de ocorrência da contingência analisada multiplicada pela “severidade” que a contingência impõe ao sistema. Esta severidade é computada como uma diferença da condição de operação do sistema sob a contingência para os limites de tensão e carregamento permitidos. Este artigo considera para o cálculo dos índices de risco a solução do fluxo de carga.

O artigo do Rene Avila-Rosales (Avila-Rosales, *et al.*, 2003) descreve em detalhe a integração da avaliação da segurança dinâmica no sistema de gerenciamento da energia da ERCOT (Electric Reliability Council of Texas). As principais características deste esforço de integração são a ferramenta de Avaliação da Segurança da Estabilidade de Tensão (ASE) e a ferramenta da Avaliação da Segurança Transitória (AST). A arquitetura do sistema computacional que suporta o sistema de gerenciamento da energia teve um papel preponderante para a implementação da avaliação da segurança dinâmica no caso da ERCOT, pois a ASE e a AST foram configuradas para permitir uma computação distribuída de qualquer número de casos baseado em qualquer número de CPU’s.

Jardim, no artigo (Jardim, *et al.*, 2004), apresenta as principais características adotadas para um sistema de avaliação da segurança dinâmica que tem sido satisfatoriamente implementado no ambiente de planejamento e no ambiente de tempo real do ONS (Operador Nacional do Sistema Elétrico Brasileiro). Este sistema é basicamente uma automação dos procedimentos tradicionais para a avaliação da segurança, que consiste de uma computação sistemática de soluções de fluxo de carga e transitórios eletromecânicos para várias condições de rede/geração/carga. Os dois elementos chaves para o sucesso do sistema proposto são o uso de computadores de alto desempenho e a disponibilidade de mecanismos para avaliar as simulações no domínio do tempo sem a

necessidade de inspeção visual. Estes mecanismos são relativamente triviais para a análise de condições em regime, mas um pouco complicados para a análise de condições transitórias. Funções energia e análises de sinais são usadas para este propósito.

Apesar dos autores não serem favoráveis ao uso de simplificações na modelagem dinâmica dos componentes do sistema de modo a se obter uma simulação rápida no domínio do tempo, eles indicam ao final do artigo que as técnicas de inteligência artificial podem melhorar de forma significativa o desempenho deste trabalho. Na palavra dos autores: “*...O automatismo da avaliação da segurança pode gerar uma enorme quantidade de resultados para diferentes cenários, que são particularmente úteis para o treinamento de redes neurais, por exemplo.*”.

Vale citar também a seguinte referência (Jardim, 2000) em que estão explicitadas os benefícios e as vantagens do uso da inteligência artificial na avaliação da segurança em tempo real.

O artigo do Ricardo Prada (Prada, *et al*, 2002) está baseado no cálculo do determinante de uma submatriz derivada do Jacobiano. Os autores demonstram, através de suposições fundamentadas, que este cálculo para cada barra do sistema e para cada contingência considerada é bastante rápido para ser utilizado num ambiente de tempo real, incluindo análise de contingências. O cálculo do determinante para todas as 1758 barras do Sistema Sul/Sudeste Brasileiro levou 3.98 segundos em um Pentium II de 300 MHz.

No trabalho do Lixin Bao (Bao, Huang and Xu, 2003) o principal objetivo é apresentar um método sistemático e prático para avaliação da estabilidade de tensão. O método está baseado no nível de reserva de reativo como indicação para a estabilidade de tensão de um sistema de potência. Este entendimento por parte de vários pesquisadores ao redor do mundo conduziu a vários esforços de pesquisa nesta matéria. Por exemplo, (Avramovic and Fink, 1992) mostrou que o impacto das reservas de reativo na estabilidade de tensão é dependente da área de influência da geração. A referência (Lachs and Sutanto, 1995) propõem o uso do nível de aquecimento do rotor do gerador como um indicador da estabilidade de tensão do sistema e a BPA desenvolveu um sistema que monitora alguns

geradores chaves (Taylor and Ramanathan, 1998). O trabalho da BPA introduz um índice que mede o nível de reserva total de um sistema. Um pequeno valor para o índice significa que o sistema está próximo ao colapso de tensão. Conforme referenciado esta foi a primeira implementação real de um sistema de avaliação on-line da estabilidade de tensão.

Em (Bao, Huang and Xu, 2003) é assumido que a margem de estabilidade de tensão do sistema é linearmente relacionada à uma reserva “equivalente” de reativo, através da seguinte equação:

$$M = kQ_{rt} + b$$

onde Q_{rt} é a reserva “equivalente” de reativo do sistema, k e b são os parâmetros da função linear, que relaciona Q_{rt} e a margem de estabilidade de tensão M .

Assume-se ainda que a reserva “equivalente” de reativo é determinada por uma função linear onde cada fonte de reativo do sistema contribui para a reserva equivalente através de uma soma ponderada. Por exemplo, para certos cenários a reserva do gerador G1 é importante enquanto para outros cenários a reserva de G4 é mais importante. Estes vários cenários estão relacionados à existência de contingências em áreas diferentes do sistema e crescimentos de carga também. Vale ressaltar que na proposta apresentada sempre que há uma mudança no sistema, como por exemplo, uma entrada de uma nova geração ou de uma nova linha de transmissão os parâmetros das duas funções lineares, apresentadas anteriormente, precisam ser recalculados.

A validade da proposta foi testada em dois grandes sistemas reais. O sistema de 1000 barras da BC Hydro e o sistema de 1800 barras de Alberta no Canadá.

É necessário citar que os autores na conclusão do artigo relacionam alguns tópicos em que uma maior pesquisa pode resultar em melhorias para a proposta: *“...Métodos alternativos para capturar a correlação entre a margem de estabilidade e a reserva de reativo poderiam ser explorados. Por exemplo, equações não-lineares poderiam ser utilizadas para modelar a correlação margem-reserva. Ferramentas de “data mining” poderiam ser usadas para obter diferentes maneiras de representar a correlação....”*

1.2.2 – GRUPO DE SIMULAÇÃO QUASI-ESTÁTICA

O segundo grupo inclui os trabalhos de simulação no domínio do tempo utilizando um algoritmo de *simulação quasi-estática*. Franchi (Franchi, *et al.*, 2003) ilustra o desenvolvimento para o GRTN – Itália (Gestore della Rete di Trasmissione Nazionale) de um sistema de avaliação on-line denominado Sistema Xdsa-Web, correntemente no estágio de teste. O Sistema Xdsa-Web, gera uma avaliação do status do sistema de potência em intervalos de 15 minutos, provendo os especialistas e o centro de controle com informações úteis sobre a segurança. No futuro o intervalo pode ser reduzido para menos de 5 minutos com o objetivo de prover relatórios mais realísticos.

Este sistema foi desenvolvido pelos próprios técnicos da GRTN utilizando os programas de fluxo de carga e de cálculo de transitórios eletromecânicos desenvolvidos anteriormente pelo CESI, e que tem os códigos abertos, respectivamente o CRESO e o SICRE.

O sistema funciona da seguinte maneira: os operadores são informados das conseqüências que cada saída poderia ter tido 15 minutos atrás, podendo avaliar como necessária alguma medida preventiva. O Xdsa-Web dos italianos também indica os controles preventivos mais apropriados. Correntemente só indica controle preventivo de corte de carga. As funções on-line são efetuadas através de simulação rápida no domínio do tempo.

Igual tratamento para a avaliação da segurança dinâmica on-line pode ser vista em (Bihain, *et al.*, 2003). Nesta referência são apresentados a estrutura global e os resultados parciais de um Projeto de Pesquisa parcialmente suportado pela União Européia, o projeto OMASES – *Open Market Access and Security Assessment System*. O consórcio OMASES inclui Indústrias, Centros de Pesquisa, Universidades e Operadores de Sistemas Elétricos, totalizando 31 pessoas e 8 instituições de vários países.

O objetivo do OMASES é prover os SGE's (Sistema de Gerenciamento de Energia) com uma ferramenta de ASD (Avaliação da Segurança Dinâmica) para ser usada em tempo

real durante o ciclo normal da operação, podendo também ser usada no planejamento da operação e como um simulador de treinamento de operadores incluindo uma simulação do ambiente de mercado desregulado.

As duas mais importantes aplicações do OMASES são: a AST – Avaliação da Estabilidade Transitória; e a AET – Avaliação da Estabilidade de Tensão.

A AST é realizada através da metodologia usada no método SIME (Zhang, *et al.*, 1997), uma ferramenta desenvolvida na Universidade de Liege. SIME é um método de estabilidade transitória híbrido que pode usar modelos detalhados dos componentes e dos controles dos sistemas de potência. Índices de estabilidade (tais como, tempo crítico de abertura) são computados usando o princípio do critério da igualdade das áreas através da redução da dinâmica global do sistema multi-máquinas para a dinâmica do sistema máquina-barras infinita (OMIB).

Dentro da função AST do OMASES o SIME pode também prover diretrizes para estabilizar casos instáveis através do cálculo do excesso de potência em máquinas críticas e redirecionar o compartilhamento entre aquelas máquinas que são não-críticas. É esperado também que seja provido insights na solução do gerenciamento dos congestionamentos.

Para atender o objetivo de tempo real do OMASES a AET é baseada numa abordagem “*quasi steady state*” (QSS) para simulações não-lineares rápidas, juntamente com ferramentas baseadas em linearização para diagnósticos (Van Cutsem and Vournas, 1998), (Van Cutsem, *et al.*, 2000). Para testar e validar a plataforma OMASES dois sistemas experimentais foram disponibilizados, um pelo Operador do Sistema de Transmissão Helênico (HTSO) (Vournas, *et al.*, 2003) e outro pelo CESI. Até o momento OMASES-AET ainda não foi instalado no HTSO.

Na abordagem do trabalho de Kundur e Morison (Kundur and Morison, 1998) a estabilidade do sistema para um ponto de operação é calculada com velocidade suficiente para permitir que o operador empreenda alguma ação se uma contingência analisada se mostrar potencialmente insegura. O trabalho descreve o desenvolvimento dos dois

principais aspectos da avaliação da segurança dinâmica on-line, que são: a avaliação da estabilidade de tensão e a avaliação da estabilidade transitória. Em relação especificamente à avaliação da estabilidade de tensão a estrutura do pacote on-line VSA (Voltage Stability Assessment) proposto pelos autores conta com um módulo de simulação rápida no domínio do tempo. Este módulo simula em detalhe uma seqüência de eventos determinada por uma falta e permite simulações de 200 a 1000 vezes mais rápidas em relação à simulação convencional.

A ferramenta de avaliação da segurança de tensão da EDF está baseada numa simulação rápida no domínio do tempo (Nativel, *et al.*, 2000). Suas principais características são a simulação da dinâmica lenta e do fenômeno da estabilidade de tensão, a computação de diferentes espécies de margens de segurança e a sugestão e a validação de ações corretivas. Esta ferramenta está sendo experimentada no Centro de Controle Nacional da França, onde o objetivo é preparar a operação do sistema um dia à frente, como também a operação em tempo real.

1.2.3 – GRUPO DE INTELIGÊNCIA ARTIFICIAL

Neste terceiro grupo são utilizadas as técnicas de *inteligência artificial*, preponderantemente as redes neurais e os sistemas fuzzy.

Dinavahi em seu trabalho de 2001 (Dinavahi and Srivastava, 2001) utiliza um sistema exemplo de 5 barras, calculando o índice de estabilidade de tensão baseado na metodologia da função energia. A rede neural utilizada para a determinação da margem de energia, foi uma MLP com 30 neurônios escondidos. A entrada para a rede neural consiste das injeções de potência ativa e reativa de todas as barras do sistema para uma dada condição particular de carregamento. A saída da rede neural é a margem de energia. Durante a fase de treinamento foram utilizadas 200 condições de carregamento.

No artigo do Hatziargyriou (Hatziargyriou, *et al.*, 2001) são apresentados os resultados preliminares do Projeto Europeu de P&D MORE CARE, que conta com 18 pesquisadores de mais de 5 países. Este projeto tem como principal objetivo o

desenvolvimento de um avançado sistema de controle para otimizar o desempenho global de sistemas isolados ou fracos, incrementando o compartilhamento da energia eólica e outras fontes renováveis. Este sistema inclui avançadas funções de segurança on-line em ambos os modos preventivo e corretivo. As análises dinâmicas on-line do comportamento do sistema para um número de distúrbios pré-especificados faz uso das técnicas de inteligência artificial, como por exemplo, sistemas especialistas ou redes neurais artificiais. Estas técnicas são utilizadas para prover uma avaliação rápida e acurada da estabilidade do sistema através da definição de regras e funções de segurança. Estas regras necessitam ser extraídas de um “conjunto de aprendizado” e podem ser usadas para monitoração on-line de uma margem de segurança definida apropriadamente. As redes neurais utilizadas neste projeto para a avaliação dinâmica são as tradicionais MLP's.

O trabalho de Yi Zhang e Zheng Zhou (Zhang and Zhou, 2002) propõe uma metodologia eficiente para a seleção de contingências relacionadas à estabilidade de tensão, denominada Método RSI Melhorado baseado em redes neurais artificiais. Neste artigo é adotada a idéia básica do Método RSI enquanto a solução de redes neurais é empregada para tratar a relação não-linear entre o índice RSI e a variação da margem de estabilidade de tensão. O método RSI é baseado no fato de que contingências severas tendem a causar grandes variações de geração de potência reativa em todo o sistema. Esta idéia foi apontada por (Begovic and Phadke, 1992) e utilizada por (Vaahedi, *et al.*, 1999) para implementar uma seleção de contingências introduzindo o somatório da mudança da geração de potência reativa ΔQ_{gi} de todos os geradores como um índice. A metodologia proposta neste artigo combina as vantagens de conceituação física do RSI e a acurácia e velocidade de uma rede neural MLP de duas camadas, com o algoritmo de treinamento backpropagation Levenberg-Marquardt, utilizando para a etapa de treinamento 90 exemplos. Este método foi testado num sistema de 39 barras do IEEE.

No artigo do Amjady (Amjady, 2003) foi apresentado um combinador de redes neurais para a avaliação da segurança de tensão. A validade da proposta foi testada numa porção do Sistema de Transmissão Sudoeste Iraniano. Os vetores padrões para treinamento e teste foram gerados através de simulações dinâmicas. Para a fase de treinamento da rede

neural foram utilizados 300 exemplos e para a fase de teste foram utilizados 65 exemplos. O combinador de redes neurais consiste numa combinação em paralelo de redes MLP's.

O objetivo do trabalho de Repo e Jarventausta (Repo and Jarventausta, 2003) foi discutir as questões de implementação de redes neurais artificiais na avaliação on-line da estabilidade de tensão. Um exemplo a partir da Rede de Transmissão Nórdica foi apresentado. A rede neural MLP foi determinada como a melhor entre as redes neurais estudadas. A melhor estrutura de MLP era a que incluía 8 neurônios na camada escondida. Os autores chamam a atenção na conclusão, que uma das principais desvantagens do uso das redes neurais é o enorme tempo dispendido nas etapas de geração dos dados para o treinamento das redes neurais, na própria etapa de treinamento e na etapa de atualização do modelo. Vale ressaltar que estas desvantagens são próprias do modelo MLP utilizado pelos autores, como será visto posteriormente em resultados dessa proposta de Tese, grande parte destas desvantagens podem ser superadas através do uso dos sistemas neuro fuzzy.

O trabalho do Prof. Paulo Mendes (Mendes, Falcão e da Silva, 2000a) propõe a aplicação de redes neurais artificiais como uma ferramenta auxiliar para a avaliação da estabilidade de tensão em tempo real. Uma rede de MLP's foi treinada com dados correspondendo à diferentes condições de operação. Os dados para treinamento foram obtidos através de muitas avaliações executadas usando a decomposição em valor singular que incorpora os modelos dinâmicos dos mais importantes componentes do sistema.

A abordagem proposta definiu um conjunto de redes neurais para diferentes níveis de carga, configurações (caso base e contingências), e para subredes do sistema, ou seja, cada característica particular tem sua própria rede neural, constituindo assim um conjunto de redes neurais. Cada rede neural é uma MLP (MultiLayer Perceptron) com uma camada escondida de 8 neurônios e um neurônio na camada de saída para estimar a margem de segurança do sistema em MW. O algoritmo de treinamento utilizado não foi o BackPropagation mas sim o OET 2 (Optimal Estimate Training 2). Os autores não explicitam o tamanho dos conjuntos de treinamento e teste. Neste artigo a proposta foi testada num sistema de 73 barras retirado do Sistema Interligado Nacional.

Em outro artigo o Prof. Mendes (Mendes, Falcão e da Silva, 2000b) propôs um modelo contendo 72 MLP's com os vetores padrões de entrada contendo de 9 a 13 variáveis e a camada escondida com o número de neurônios igual ao vetor de entrada. Esta proposta foi testada no Sistema New England de 39 barras.

Neste artigo (Maiorano and Trovato, 1998) é proposta uma rede neural para prover estratégias de controle preventivo on-line capazes de restituir um sistema de potência para um ponto de operação seguro quando uma condição de instabilidade de tensão está para ser alcançada. Estas estratégias estão baseadas em ações de controle de potência reativa, controle de geração e ações de corte de carga. Depois de decompor o sistema em um número apropriado de áreas são treinadas uma MLP para cada área, dando como saída para um conjunto definido de entradas, um índice de estabilidade de tensão (margem de carregamento da área). Para treinar as redes neurais são criados vários pontos de operação e calculados a sua margem de carregamento através da análise de autovalores a pequenos sinais (La Scala, Trovato and Torelli, 1996). São utilizados aproximadamente 434 padrões para a etapa de treinamento.

A estabilidade de tensão do sistema global é caracterizada pelo valor mínimo entre os índices das áreas. Então, para uma dada condição de operação, a área mais crítica é identificada e ações de controle são consideradas, somente para uma região restrita do sistema. É demonstrado neste trabalho que usando a própria arquitetura das redes neurais podem ser desenvolvidos algoritmos apropriados para determinar estratégias de controle preventivo baseado nos tipos de ações de controle mencionados acima. A proposta é testada num Sistema de 118 barras, 19 máquinas do IEEE.

Este trabalho (Marannino, *et al*, 2002) aplica um sistema neuro-fuzzy para prover aos operadores do sistema um índice de estabilidade de tensão diretamente relacionado com a distância ao colapso de tensão (margem de carregamento). O sistema neuro-fuzzy recebe como entrada um conjunto de variáveis numéricas, que representam de forma quantitativa um ponto de operação do sistema de potência. Estes dados (níveis de tensões, margens de reativo, perdas de reativo, etc.) são manipulações algébricas obtidas através das soluções do fluxo de carga. Como resultado final, o sistema neuro-fuzzy rende uma

medida de degradação do nível de segurança em relação ao risco do colapso de tensão (Margem de MVAr). Na análise do desempenho do sistema neuro-fuzzy proposto os resultados são comparados com os resultados obtidos através da ferramenta convencional COLLAS. O procedimento COLLAS está baseado em estudos de regime permanente e está disponível no CESI (Centro Elettrotecnico Sperimentale Italiano) e no GRTN (o Operador do Sistema Elétrico Italiano). Este sistema neuro-fuzzy foi escrito no MATLAB utilizando o Toolbox de Lógica Fuzzy.

O trabalho (Liu, Chang and Su, 1998) propõe uma nova rede neuro-fuzzy, a Fuzzy Hyperrectangular Composite Neural Network (FHRCNN), para a monitoração da segurança da tensão, usando como dados de entrada somente tensões e ângulos das barras do sistema de potência. O FHRCNN foi testado com 3000 padrões gerados aleatoriamente a partir de condições de operação extraídas de um sistema IEEE de 30 barras. O programa foi desenvolvido numa estação SUN SPARC II em C++ e MATLAB. O FHRCNN sempre apresentou um desempenho superior a 97% de taxa de acerto. Comparando-o com uma MLP tradicional esta não conseguiu em nenhum dos casos atingir uma taxa de acerto superior a 90%.

O objetivo da rede neural no trabalho do Jeyasurya (Jeyasurya, 2000) é mapear a relação entre a condição de operação de um sistema de potência e a sua correspondente margem de estabilidade de tensão. A rede neural MLP projetada possui apenas uma camada escondida. Os dados de treinamento utilizados são compostos com as tensões das barras, cargas ativas e reativas e gerações de potência ativa e reativa. Entretanto para reduzir a dimensão dos padrões de entrada foi utilizada a transformação PCA (Principal Component Analysis) (Haykin, 1994). As entradas e as saídas da rede neural são normalizadas de forma que elas possuam uma média zero e um desvio padrão unitário. O treinamento é baseado no algoritmo de Levenberg-Marquadt tendo sido todo o trabalho desenvolvido usando o MATLAB Neural Network Toolbox. O autor não informa o tamanho dos conjuntos de treinamento e teste. O método proposto foi utilizado para a estimação da estabilidade de tensão do sistema IEEE 118 barras.

A rede neural utilizada neste trabalho (El-Keib and Ma, 1995) foi uma MLP possuindo apenas uma camada escondida com cinco neurônios. Os dados de treinamento utilizados são compostos das cargas ativas e reativas e gerações de potência ativa e reativa. Para reduzir a dimensão dos padrões de entrada foi utilizada a uma análise de sensibilidade que determinou quais as cargas e as gerações que mais influenciavam o índice de estabilidade. O método proposto foi utilizado para a estimação da estabilidade de tensão de vários sistemas IEEE: 5, 14, 30, 31, 76 e 118 barras. Os autores descobriram também que utilizando três redes MLP's, uma para cada condição de carregamento, obtinha-se um melhor desempenho da técnica utilizada. Então para cada sistema de potência foram utilizadas três redes neurais, sendo uma para a condição de carga leve, uma para a condição de carga média e uma para a condição de carga pesada.

Como uma continuação do trabalho apresentado no VII SEPOPE (Taylor, Venkatasubramanian and Chen, 2000), Taylor descreve neste artigo (Taylor and Wilson, 2004) os últimos avanços obtidos no sistema de controle de tensão e de estabilidade (WACS-Wide-Area Stability and Voltage Control System) implantado na BPA.

O Sistema WACS provê uma plataforma flexível para uma rápida implementação de corte de geração e chaveamento de compensação reativa para a manutenção da estabilidade transitória e para o suporte de tensão de grandes sistemas de potência. As características principais do Sistema WACS incluem medições fasoriais de seqüência positiva, comunicações digitais em fibra ótica, computadores para controle em tempo real, e saída de comunicações para corte de geração e chaveamento de capacitores/reatores de 500 kV. O software incluído no Sistema WACS possui subsistemas rápidos e lentos rodando em ambientes paralelos. O subsistema de controle rápido para a manutenção da estabilidade transitória entre áreas do sistema opera em centenas de milisegundos baseado em medições de tensões de seis subestações, e o subsistema lento que garante o suporte de tensão opera em alguns segundos ou dezenas de segundos baseado em medições de tensões e de potência reativa que são combinadas utilizando lógica fuzzy.

Esta proposta do Carson Taylor é muito diferente do que foi apresentado até o momento nesta revisão bibliográfica, porque o que está implementado na BPA é um

controle, e não simplesmente uma avaliação para saber se uma determinada condição de operação é segura ou não. A proposta da BPA é colocar em operação um sistema que esteja medindo de forma on-line algumas grandezas elétricas do sistema, tais como, tensões e gerações de reativo, e a partir destas medições tomar algumas ações de controle corretivo. Vale ressaltar que as ações para o suporte de tensão são determinadas através de um sistema fuzzy.

O trabalho realizado no PSERC- Power System Engineering Research Center (Tomsovic, *et al.*, 2001) analisou várias maneiras de melhorar os procedimentos de operação com particular ênfase na estimação da margem de estabilidade de tensão baseado em esquemas de reconhecimento de padrões.

Duas espécies de redes neurais foram investigadas: Kohonen e MLP. A MLP mostrou-se mais adequada para a solução deste tipo de problema, conforme resultado dos autores. A seleção de características dos vetores padrões foi baseada em sensibilidade e correlação estatística utilizando PCA (Principle Component Analysis) para reduzir o tamanho dos vetores padrões e melhorar o pré-processamento dos dados. Para aumentar a robustez do sistema proposto são utilizadas múltiplas MLP's, com a solução final baseada numa média da saída das MLP's.

Diferentes condições de operação do sistema (verão, inverno), diferentes níveis de carregamento e contingências são utilizados para gerar os conjuntos de treinamento e teste. Os dados gerados são calculados utilizando as tradicionais curvas VQ's. Para o sistema utilizado para os testes, o sistema da WSCC (5000 barras), existem cinco conjuntos de dados. Cada conjunto possui o caso base e para cada caso base são determinados os pontos de operação de todas as n-1 contingências de todas as linhas de transmissão acima de 345 kV e de algumas linhas de 230 kV (354 contingências), totalizando então um número de 1775 casos de estudo. Os resultados obtidos estabelecem que usando um sistema de múltiplas MLP's pode-se estimar de forma acurada as margens de segurança em aplicações on-line.

Neste artigo (Yabe, *et al.*, 1996) é apresentado um sistema hierárquico envolvendo sistema neuro-fuzzy (Jang, 1993) para a predição das margens de estabilidade de tensão. Um novo conceito de modelagem de uma superfície P-Q-V foi introduzido. A viabilidade da proposta foi comprovada através de análises utilizando um sistema de 91 barras e 25 máquinas.

1.3 – ORGANIZAÇÃO DA TESE E PRINCIPAIS CONTRIBUIÇÕES

A contribuição da Tese é incrementar a eficiência das técnicas de IA para torná-las aplicáveis a sistemas de potência de grande porte. Isto será alcançado mediante as seguintes etapas:

1. – Entendimento do fenômeno da estabilidade de tensão e suas formas de avaliação.
2. – Entendimento das técnicas de IA.
3. – Revisão bibliográfica.
4. – Utilização de sistemas de potência de grande porte e reais.
5. – Verificação da viabilidade das técnicas de IA para a solução do problema da avaliação da estabilidade de tensão.

As contribuições da Tese para o estado da arte são:

1. - Uma metodologia geral de divisão do sistema de potência em áreas, para que possa ser implementada de forma prática a análise de segurança. Provando de forma definitiva a viabilidade da aplicação da técnica em redes elétricas de grande porte.
2. – Proposição do Sistema Híbrido RPROP, que demonstrou ter o melhor desempenho.

As principais contribuições da Tese de forma geral, em relação a área de análise de sistemas de potência, podem ser sintetizadas nos seguintes pontos:

1. – Algoritmo detalhado das principais redes neurais e sistemas fuzzy utilizados, para que possam ser implementados em qualquer plataforma de programação.
2. – Caracterização dos procedimentos de avaliação da estabilidade de tensão como atualmente utilizados pelas empresas de energia elétrica no Brasil e no mundo.
3. – Explicação detalhada do Método da Continuação.
4. – Resultados de reconhecimento de padrão utilizando-se redes neurais supervisionadas e construtivas, utilizando-se também técnicas tradicionais como o kNN, e não tradicionais como um combinador neural, um sistema neuro-fuzzy e um sistema híbrido.
5. – Metodologia para construção dos vetores padrão que compõem os conjuntos de treinamento e teste, considerando as particularidades do fenômeno da estabilidade de tensão nos sistemas de potência, levando em consideração a divisão do sistema em áreas.
6. – Apresentação de resultados obtidos com a aplicação das técnicas de IA num sistema real de 77 barras da região sul do Brasil, o sistema Sul-Sudeste.
7. – Apresentação de resultados obtidos com a aplicação das técnicas de IA num sistema real de 402 barras das regiões Norte e Nordeste do Brasil.

Esta Proposta de Tese está organizada de acordo com a seguinte estrutura:

No capítulo 2 são apresentados os principais métodos de reconhecimento de padrão que fazem uso da inteligência artificial para aplicação em análise de segurança de sistemas de potência. Sendo apresentadas em detalhe as técnicas de inteligência artificial utilizadas inicialmente para o trabalho de Doutorado, basicamente as técnicas de redes neurais artificiais e sistemas neuro-fuzzy.

Os conceitos básicos do problema de estabilidade de tensão conforme necessários para a análise de segurança são apresentados no capítulo 3. Neste capítulo o equacionamento do Método da Continuação é demonstrado, pois seu conhecimento é

fundamental, sendo dele extraído o Índice Margem, que defini a condição de operação do sistema. Neste capítulo é realizada também uma análise real de como o índice margem da curva P-V é utilizado para determinação da segurança do ponto de operação, através de um estudo para perda de um barramento de 230 kV do Sistema Nordeste de Transmissão.

No capítulo 4 são apresentados os principais requisitos para um módulo de avaliação em tempo real da estabilidade de tensão nos sistemas de gerenciamento de energia atualmente empregados nas companhias de eletricidade ao redor do mundo. Sendo dada ênfase ao aspecto dos métodos de avaliação da segurança de tensão. Neste capítulo estão apresentados também os resultados obtidos com a aplicação da técnica em sistemas reais. No Capítulo 5 estão relacionadas as principais conclusões dos levantamentos feitos neste Projeto de Pesquisa.

Capítulo 2

Técnicas de Inteligência Artificial

2.1 - INTRODUÇÃO

Este capítulo tem como objetivo a revisão dos principais conceitos das redes neurais artificiais, dos sistemas fuzzy e dos sistemas neuro-fuzzy, tendo como preocupação principal uma abordagem geral da teoria, do funcionamento e das aplicações destes sistemas, assim como a caracterização das vantagens e desvantagens destes em relação à abordagem convencional na solução dos mesmos problemas.

Importantes avanços na área de sistemas de potência visando solucionar problemas de estabilidade estão sendo alcançados através da utilização das novas tecnologias de IA. Existe uma grande oportunidade de sinergia entre estas áreas. O ganho na transferência de tecnologia entre disciplinas, tais como, controle automático, inteligência artificial e processamento de sinal em sistemas de potência pode ser considerável (Taylor, 1998), (Gupta and Sinha, 1996), (Huang, 1994).

Sistemas fuzzy e redes neurais tem atraído atenção crescente de pesquisadores, cientistas, engenheiros, praticantes e estudantes de várias áreas da engenharia e da ciência. O número e a variedade das aplicações dos sistemas fuzzy e das redes neurais tem aumentado substancialmente. Desde que as primeiras aplicações de redes neurais, em produtos comerciais, apareceram no início dos anos 90, uma grande quantidade de aplicações comerciais vieram à tona. Assim como os sistemas fuzzy, as aplicações de redes neurais tem se tornado mais promissoras em problemas com sabor de mundo real, tais

como, reconhecimento de fala, controle de processos industriais, conversão fala-texto, processamento de imagens, aplicações médicas, reconhecimento de assinaturas, reconhecimento ótico de caracteres (OCR), análise de decisão, etc (Yen, Langari and Zadeh, 1995).

2.2 - REDES NEURAIIS ARTIFICIAIS

As redes neurais artificiais (RNA's) são modelos abstratos, elaborados através de investigações sobre o funcionamento e a forma de processamento de informações dos sistemas neurais biológicos, os quais compreendem as células nervosas, também denominadas neurônios, e o cérebro humano. São compostas por um conjunto de unidades básicas de processamento, os neurônios artificiais, que retém algumas propriedades do neurônio biológico. E levam em consideração, assim como o sistema cerebral, a capacidade de aprendizagem.

2.2.1 - RECONHECIMENTO DE PADRÕES

Esta é uma grande área de pesquisa que conta com muitas ferramentas e métodos matemáticos para soluções dos problemas de reconhecimento de padrões. Uma destas ferramentas são as técnicas de inteligência artificial, predominantemente as redes neurais. O entendimento básico do problema de reconhecimento de padrões ajudará a compreender a que se propõem as redes neurais artificiais.

Para determinar o que seja o problema de reconhecimento de padrões pode-se considerar uma tarefa que é extremamente básica para a maioria dos seres humanos: **ler**. A parte mais significativa das informações que o ser humano absorve é lhe apresentada em símbolos padronizados. O texto que você está lendo agora é apresentado em formas de padrões complexos e variados. Antes de se considerar as questões cognitivas relativas ao processamento da linguagem, o sistema visual deve primeiro resolver o problema do

reconhecimento de padrões. Isto é, reconhecer as cadeias de símbolos como caracteres alfabéticos.

O fato de que o sistema visual resolve esta questão quase sem esforço, faz com que não se considere devidamente a complexidade desta imensa tarefa. Entretanto, se esta tarefa for apresentada a um computador, logo vê-se a enorme dificuldade de se implementar uma solução efetiva para este problema. Uma solução computacional para este problema seria utilizar a técnica de casamento de medidas.

Nesta técnica cada letra é armazenada numa estrutura matricial fixa e então estes padrões armazenados são um a um comparados com o símbolo que se quer descobrir. Esta é a solução usada em aplicações simples, por exemplo numa linha de produção de uma fábrica, onde é fácil armazenar todas as possíveis formas e tamanhos dos produtos de uma linha de montagem. Considere entretanto o que aconteceria com a técnica de casamento de medidas se em um texto fossem encontradas letras com tamanhos diferentes daquele que foi armazenado numa estrutura matricial fixa. A menos que se tivesse uma segunda estrutura, do tamanho correto, o desempenho do sistema seria, para esta tarefa de classificação, extremamente miserável.

Considere então a implementação de um sistema computacional que reconheça textos manuscritos. Seria praticamente inviável o armazenamento de muitas estruturas matriciais fixas correspondendo aos vários tamanhos de textos manuscritos encontráveis.

O processamento de textos é apenas um dos exemplos dos problemas que as técnicas de reconhecimento de padrões tem como objetivo resolver. As dificuldades descritas acima se tornam mais complicadas se forem considerados o processamento de imagens, o reconhecimento da fala e a previsão das tendências do mercado financeiro.

DEFINIÇÕES

O objetivo fundamental no reconhecimento de padrões é a classificação. Dado um vetor cujos elementos representam medidas de um determinado objeto, o sistema

classificador deveria dar como saída a indicação da classe a que pertence aquele objeto. Os classificadores convencionais comumente se utilizam das técnicas de "distâncias métricas" e da teoria da probabilidade.

A classificação é raramente executada utilizando-se somente uma simples medida, ou característica, do padrão de entrada. Usualmente muitas medidas são necessárias para que os padrões possam ser adequadamente distinguidos, ou categorizados. Sendo feitas n medidas em um objeto (que se deseja classificar), e sendo cada uma destas medidas uma característica única, então pode ser criado um vetor de características de dimensão n , que será a entrada do classificador. Este vetor visualizado num espaço de dimensão n , determina o que se chama o espaço de características.

A maneira mais simples de demonstrar o que seja o espaço de características é considerar um problema de duas dimensões. Ou seja, serão consideradas apenas duas medidas em relação aos objetos que se quer classificar. O problema será distinguir entre dois grupos profissionais aquelas pessoas que pertencem ao grupo dos dançarinos de ballet e as que pertencem ao grupo de jogadores de futebol. As duas medidas que serão tomadas serão o peso e a altura. Depois de feitas as medidas o espaço de características fica como na Figura 2.1.




Figura 2.1 – Espaço de Características.

TÉCNICAS DE CLASSIFICAÇÃO

As técnicas de reconhecimento de padrões podem ser divididas em dois grandes grupos: os numéricos e os não numéricos. As técnicas numéricas incluem medidas estatísticas e determinísticas. As técnicas não numéricas são aquelas que levam a termo o processamento simbólico e métodos tais como a lógica fuzzy.

Uma das técnicas numéricas de reconhecimento de padrões muito utilizada é conhecida como k-Vizinhos mais Próximos (k-Nearest Neighbour - kNN). Esta é uma das técnicas de classificação cujo desempenho é geralmente comparado às redes neurais artificiais.

A técnica dos k-Vizinhos mais Próximos (k-Nearest Neighbour - kNN) toma a decisão de classificação baseada nas classes a que pertencem os k exemplos mais próximos do padrão de teste. A decisão define que o padrão de teste de entrada pertence à classe que possui mais exemplos entre os k primeiros que têm menor distância a ele (Beale and Jackson, 1990).

Considerando por exemplo, duas classes representadas no espaço de características e que se quer classificar um padrão de entrada X, ou seja, descobrir a que classe ele pertence, a técnica dos k-Vizinhos mais Próximos toma uma decisão baseada na menor distância. A pergunta que precisa ser respondida é a seguinte: o padrão que se quer classificar (X) está mais próximo a que padrão? A classe a qual pertencer o padrão mais próximo de X será então a resposta do classificador. Pela Figura 2.2 vê-se que o padrão X pertence à Classe 2.




Figura 2.2 – 1ª classificação do kNN.

Considerando a nova situação apresentada pela Figura 2.3 se for considerado apenas o primeiro vizinho mais próximo o padrão X seria classificado como pertencente à classe 2, o que seria um erro, pois claramente, na Figura 2.3 o padrão X pertence à classe 1. Mas se for considerado talvez o cinco vizinhos mais próximos, entre estes cinco teríamos 4 deles pertencentes à classe 1, o que faria com que o padrão X fosse classificado corretamente como pertencente à classe 1.




Figura 2.3 – 2ª classificação do kNN.

2.2.2 – AS REDES NEURAIS E O PERCEPTRON

A estrutura dos neurônios e sua descoberta como as unidades constituintes do cérebro foram feitas em 1911 através do trabalho pioneiro do fisiologista Ramón y Cajál. O neurônio possui entradas - *muitas entradas* -, e uma saída (Figura 2.4). As entradas

ocorrem através das *conexões sinápticas*, que conectam a árvore dendrital aos axônios de outras células nervosas. As conexões sinápticas podem ser *excitatória* ou *inibitória*. Uma conexão excitatória provoca uma alteração no potencial da membrana que contribui para a formação de um impulso nervoso no axônio de saída enquanto que uma conexão inibitória age no sentido oposto. Os sinais que chegam pelas conexões sinápticas são pulsos elétricos (*impulsos nervosos* ou *potenciais de ação*), e constituem a *informação* que o neurônio processará, de alguma forma, para produzir como saída um impulso nervoso no seu axônio.

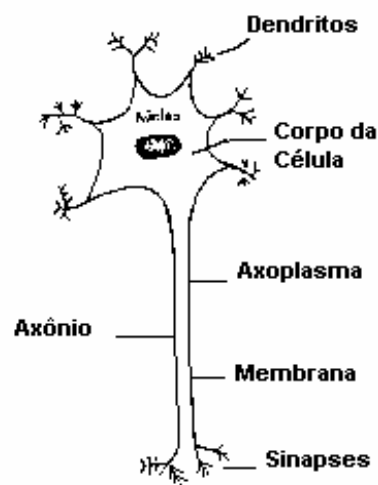


Figura 2.4 - Esquema de um neurônio.

A idéia básica em redes neurais é que unidades de processamento simples computando certas funções matemáticas, dispostas em uma ou mais camadas, e interligadas pôr um grande número de conexões, apresentam um elevado poder computacional. Às unidades se atribui o nome de *neurônios* e à estrutura de interconexão entre elas, o nome de *rede neural*.

A função básica de um neurônio é de somar ponderadamente os vários estímulos e produzir uma saída se tal soma for maior que o valor limiar de ativação. O comportamento de uma *unidade de referência funcional* está sempre determinado pela ocorrência de um estímulo ou padrão de informação apresentado como entrada para o neurônio, pela computação de um estado de ativação em função do estímulo de entrada e da informação

armazenada nas conexões do neurônio (sinapses) e pela computação de uma resposta em função da ativação alcançada.

Geralmente estas conexões estão associadas a pesos, os quais armazenam o conhecimento representado no modelo e servem para ponderar a entrada recebida por cada neurônio da rede. Em particular, a semelhança que as redes neurais artificiais apresentam em relação ao cérebro humano pode ser fundamentalmente associada com as seguintes colocações:

1 - *O conhecimento é adquirido em uma rede neural através de um processo de aprendizagem.*

A etapa de aprendizagem consiste num processo iterativo de ajuste dos parâmetros da rede, os pesos das conexões entre as unidades de processamento, que guardam ao final do processo o conhecimento que rede aprendeu do ambiente em que está operando.

2 - *O conhecimento é armazenado em conexões (sinapses) existentes entre os elementos da rede, representadas através de pesos.*

Um modelo de rede neural artificial pode ser compreendido a nível de neurônio, arquitetura e processo de aprendizagem.

MODELO COMPUTACIONAL DO NEURÔNIO

Em 1943, Warren McCulloch juntamente com o fisiologista Walter Pitts lançaram as bases do modelo matemático do funcionamento do neurônio. O neurônio de McCulloch era um dispositivo binário: a sua saída poderia ser *pulso* ou *não pulso*, e suas várias entradas tinham ganho arbitrário e poderiam ser excitatórias ou inibitórias. Para determinar a saída do neurônio, calculava-se a soma ponderada das entradas com os respectivos ganhos como fatores de ponderação, positivos nos casos excitatórios e negativos nos casos inibitórios. Se este resultado fosse maior ou igual a um certo limiar então a saída do neurônio era *pulso*, e caso contrário era *não pulso*.

Em termos matemáticos a definição da unidade fundamental é realizada por uma regra de propagação (*estado de ativação*) definida pela equação (2.1) e por uma função de ativação definida pela equação (2.2).

$$net_j = \sum_{i=1}^n w_{ji} x_i \quad (2.1)$$

Onde w_{j1} , w_{j2} , ..., w_{jn} corresponde aos pesos das conexões e x_1 , x_2 , ..., x_n os valores de entrada para a unidade de processamento j . Especificamente um sinal x_i na entrada da sinapse conectado ao neurônio j é multiplicado pelo peso sináptico w_{ji} . É importante notar a maneira nas quais os subscritos dos pesos sinápticos são escritos w_{ji} . O primeiro refere-se ao neurônio em questão (j) e o segundo refere - se ao terminal de entrada (i).

Como visto, o valor net_j determina a soma ponderada (o produto interno) entre os valores fornecidos como entrada e os valores dos pesos representados nas conexões de entrada da unidade de processamento; o que caracteriza uma combinação linear.

A função de ativação é definida matematicamente através da equação (2.2), como função do valor net_j obtido e de outra variável θ_j , chamada de limiar de ativação. Uma forma simples e conveniente de entender o limiar θ_j é interpretá-lo como um valor adicionado negativamente às entradas do neurônio, a partir do qual o neurônio dispara (é ativado com valor positivo) e, abaixo do qual, permanece em estado de inércia.

$$o_j = f_j(net_j - \theta_j) \quad (2.2)$$

Nos vários modelos de neurônios artificiais propostos a função de ativação f_j tem sido aproximada por uma variedade de funções que tem como principais características o comportamento monotônico sobre uma faixa do argumento $net_j - \theta_j$, conhecida como

faixa dinâmica, e a *saturação* fora desta faixa. No neurônio de McCulloch a aproximação é através de um degrau unitário onde apenas a *saturação* é preservada.

$$o_j = \begin{cases} 1 & \Rightarrow f_j(\text{net}_j - \theta_j) > 0 \\ 0 & \Rightarrow f_j(\text{net}_j - \theta_j) < 0 \end{cases} \quad (2.3)$$

Conclui-se então que o neurônio de McCulloch pode ser modelado por um caso particular de *discriminador linear* cujas entradas são binárias. A expressão 2.2 representa um hiperplano que divide o espaço euclidiano \mathfrak{R}^n , de dimensão n , em duas regiões A e B. Assim, um vetor \vec{x} de componentes $\{x_1, x_2, \dots, x_n\}$ estará em uma destas regiões na medida em que se verificar:

$$\begin{cases} \vec{x} \in A \Rightarrow f_j(\text{net}_j - \theta_j) > 0 \\ \vec{x} \in B \Rightarrow f_j(\text{net}_j - \theta_j) < 0 \end{cases} \quad (2.4)$$

enquanto o valor da saída o_j será:

$$o_j = 1 \text{ se } \vec{x} \in A \text{ e } o_j = 0 \text{ se } \vec{x} \in B$$

O resultado da combinação das duas variáveis, a regra de propagação e a função de ativação, determina o comportamento da unidade de processamento cuja representação pode ser ilustrada através do diagrama de blocos da Figura 2.5.




Figura 2.5 - Modelo de neurônio contínuo.

Uma característica interessante das RNA's é sua capacidade de *generalização*, ou seja, elas conseguem interpolar, a partir dos exemplos usados no treinamento, uma relação mais geral que contém o relacionamento definido pelos dados dos exemplos. Trabalhando em um domínio em que entradas semelhantes são mapeadas para saídas semelhantes, a RNA com seu algoritmo de treinamento interpolará quando receber entradas que nunca tenha visto antes. A *generalização* ajudará a superar ruídos indesejáveis na entrada. As RNA's podem manipular dados incompletos e imperfeitos, sendo tal capacidade bastante importante uma vez que, no mundo real, a informação se encontra impregnada de ruído.

PERCEPTRONS

O pioneiro na simulação das redes neurais artificiais em computadores digitais foi Frank Rosenblatt (1962). Rosenblatt em seu livro *Principles of Neurodynamics*, forneceu várias idéias a respeito dos Perceptrons. Este modelo foi proposto para ser empregado em tarefas de reconhecimento de padrões e teve uma grande influência no desenvolvimento histórico da área.

O Perceptron em si consiste nos pesos, no processador de soma e no processador de limite ajustável. A operação do Perceptron é descrita conforme o neurônio do tipo proposto por McCulloch - Pitts. Uma combinação linear das suas entradas aplicadas aos pesos das suas conexões ($net_j = \sum_i w_{ji}x_i$), seguida de uma função limiar:

$$o_j = f_j(net_j - \theta_j)$$

O objetivo do neurônio é classificar o estímulo de entrada em uma entre duas classes C_1 e C_2 dependendo do valor da soma ponderada das suas entradas. Se o_j é positivo então a entrada é classificada como pertencente à classe C_1 e o neurônio produz uma saída igual a + 1. Se net_j é negativo então pertence à classe C_2 e a resposta do neurônio é 0.

O aspecto mais importante sobre a operação do Perceptron é como os conjuntos de pesos são encontrados. Uma linha que separa corretamente as instâncias de treinamento corresponde a um Perceptron de funcionamento perfeito (Figura 2.6).

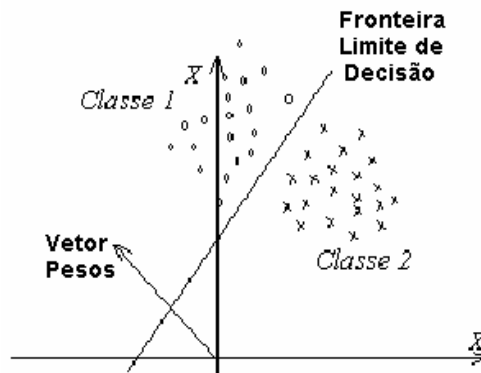


Figura 2.6 – Sistema Classificador com uma fronteira de decisão linear.

A superfície de decisão é definida através da função de ativação net_j , ou seja, é definida pelo produto interno entre o vetor de entrada e o vetor peso. O produto interno de dois vetores é um número real e sendo ϕ o ângulo entre os vetores \vec{x} e \vec{w} , $\vec{x} \neq 0$ e $\vec{w} \neq 0$ tem-se:

- Produto interno entre \vec{x} e $\vec{w} > 0 \Leftrightarrow 0^\circ \leq \phi < 90^\circ$
- Produto interno entre \vec{x} e $\vec{w} < 0 \Leftrightarrow 90^\circ \leq \phi < 180^\circ$
- Produto interno entre \vec{x} e $\vec{w} = 0 \Leftrightarrow \phi = 90^\circ$

onde \vec{x} é o padrão e \vec{w} é o vetor pesos.

O $\cos \phi$ varia entre ± 1 , logo qualquer alteração de ϕ entre 90° modificará o sinal de saída de net_j . Então a superfície de decisão é normal ao vetor peso, logo, todo conjunto de pesos especifica alguma superfície de decisão.

O problema de aprendizado do Perceptron, recai numa localização da superfície de decisão, ou seja, de colocar um sistema em posição onde ele possa solucionar melhor os problemas.

Como exemplo será demonstrada a implementação da função lógica binária AND no Perceptron.

- Função AND:

Tabela da Verdade

x_1	x_2	Z
0	0	0
1	0	0
0	1	0
1	1	1




Figura 2.7 - Região de decisão: Função AND.

Dados valores para x_1 e x_2 , quer-se treinar um Perceptron para produzir 1 se ele achar que a entrada pertencente à classe dos pontos brancos (classe 1) e 0 se ele achar que a entrada pertence à classe dos pontos pretos (classe 2). Pode-se modelar o Perceptron conforme a Figura 2.8 para a classificação dos padrões apresentados.




Figura 2.8 - Porta lógica AND implementada no Perceptron.

Para casos simples como a implementação das funções booleanas AND e OR de duas variáveis é relativamente trivial escolher os ganhos sinápticos e o valor do limiar,

conforme já mostrado acima. Porém, para a implementação de uma função discriminatória arbitrária esta escolha é não trivial e, dependendo do número de variáveis envolvidas, sem a existência de algum *método*, beira o impossível.

Sistemas nervosos biológicos possuem a essencial propriedade de serem capazes de *aprender* uma função. Poderia-se portanto imaginar uma maneira de *ensinar* a rede artificial até que esta *aprendesse* a função desejada. Tal problema, Rosenblatt propôs resolver, definindo *um método de aprendizagem* para o Perceptron.

Por este método, são apresentados exemplos de comportamento à rede, isto é, para um estímulo (padrão \bar{x}_p) a saída deve ser t_p . Os exemplos são repassados até que a rede aprenda o comportamento correto, ou seja, até que implemente corretamente a função $t_p = f(\bar{x}_p)$ para todos os exemplos. O discriminador linear é inicializado com parâmetros arbitrários $\{\bar{w}_0, \bar{\theta}_0\}$ e os vetores dos exemplos de treinamento são aplicados seqüencialmente à sua entrada. Utilizando-se o algoritmo de aprendizado para ajuste dos parâmetros $\{\bar{w}, \bar{\theta}\}$ procura-se convergir para valores $\{\bar{w}^*, \bar{\theta}^*\}$ tais que as saídas do discriminador coincidam com as saídas especificadas no conjunto de treinamento para todos os exemplos.

ALGORITMO DE APRENDIZAGEM

Dada uma amostra de padrões de treinamento das classes C_1 e C_2 apresentados ao Perceptron, o algoritmo ajusta os pesos da rede iterativamente depois da apresentação de cada padrão. Se um padrão denotado por \bar{x}_p é corretamente classificado então não há correção a ser feita. Neste caso, os pesos das conexões no passo $t + 1$ permanecem:

$$\bar{w}(t + 1) = \bar{w}(t) \quad (2.5)$$

Se, entretanto, um padrão é incorretamente classificado como pertencente a uma das duas classes então é necessária uma correção dos pesos. Se o Perceptron dispara

quando não deve disparar, diminua de cada w_i um número proporcional a x_i - Eq. (2.6). Se o Perceptron deixa de disparar quando deveria, aumente um número semelhante em cada w_i - Eq. (2.7).

$$\bar{w}(t + 1) = \bar{w}(t) - \eta \bar{x}_p \quad (2.6)$$

$$\bar{w}(t + 1) = \bar{w}(t) + \eta \bar{x}_p \quad (2.7)$$

onde o termo η controla a taxa de aprendizagem.

O *teorema da convergência de Perceptrons*, provado por Rosenblatt (1962), garante que o Perceptron encontrará um estado de solução, isto é, ele aprenderá a classificar qualquer conjunto de entradas separáveis linearmente em um número finito de interações. Em outras palavras, o teorema mostra que, em um espaço de pesos, não há mínimos locais que não correspondem ao mínimo global. Entretanto, existe um aspecto extremamente limitante à respeito da capacidade do Perceptron em resolver tarefas. Este diz respeito à observação de que este tipo de modelo só consegue representar associações de padrões de entrada - saída linearmente separáveis.

Observe que a deficiência aqui não está no algoritmo de aprendizagem por Perceptrons, mas no modo como o Perceptron representa o conhecimento. Esta desvantagem do modelo, demonstrada por Minsky e Papert em 1969 em seu clássico livro *Perceptrons*, pode ser apontada como um dos fatos responsáveis pelo grande pessimismo quanto ao futuro da área das redes neurais nos anos 70. Embora fosse entendido naquela época que redes Perceptron com mais de uma camada poderiam resolver o problema, não se conhecia ou não se via até então a possibilidade de um algoritmo de aprendizagem capaz de treinar a rede com mais de uma camada de neurônios.

ADALINE E MADALINE

Na mesma época em que Rosenblatt trabalhava no Perceptron, Widrow na Universidade de Standford desenvolveu um modelo neural linear, muito simples

conceitualmente, que ele batizou de ADALINE e mais tarde a sua generalização multidimensional, o MADALINE. A contribuição realmente importante do trabalho de Widrow foi a invenção de um princípio de treinamento extremamente poderoso para as redes de Adalines conhecido como a *Regra Delta*, que foi mais tarde generalizado para redes com modelos neurais mais elaborados.

O Adaline é um elemento linear cuja saída é simplesmente uma combinação linear das componentes do vetor de entrada ($o_p = \vec{w}^t \vec{x}_p$). A proposta de Widrow foi de, dado um conjunto de padrões de entrada e as respostas desejadas $\Psi = \{ \vec{x}_p; t_p \}$, determinar um conjunto ótimo de pesos sinápticos \vec{w}^* , e a função “*Threshold*”, de modo a minimizar a diferença entre a resposta desejada t_p e a saída do sistema o_p . Como medida de performance ou função de custo introduz-se o erro médio quadrático definido como: $E_p = \frac{1}{2} (t_p - o_p)^2$.

A condição necessária para que \vec{w}^* seja um ponto de mínimo interno é de que ali o gradiente da função $E(\vec{w}^*)$ seja nulo. Pelo método do gradiente, partindo-se de um ponto arbitrário \vec{w}_0 , pode-se caminhar pela superfície $E(\vec{w})$ em direção ao ponto de mínimo, bastando para isto evoluir sempre no sentido oposto ao do gradiente naquele ponto. Isso pode ser traduzido no seguinte algoritmo iterativo para o cálculo de valores $\vec{w}(t)$ sucessivamente mais próximos do ponto de mínimo: dado $\vec{w}(t)$ obtém-se $\vec{w}(t+1)$ por: *O valor atualizado do t-ésimo peso é igual ao valor atual do peso mais correção, a qual é proporcional ao gradiente negativo do erro de superfície com respeito àquele peso particular.*

$$\vec{w}(t+1) = \vec{w}(t) - \eta \text{grad}(E(\vec{w}(t))), \text{ ou}$$

$$\vec{w}(t+1) = \vec{w}(t) - \eta \frac{d}{dw} E(\vec{w}(t)) \quad (2.8)$$

onde o parâmetro η determina o tamanho do *passo* que se dará naquela direção.

O método do gradiente aplicado ao problema de se determinar a melhor aproximação linear a um conjunto de dados, conhecido como regra delta, não passaria de um exercício acadêmico de otimização em espaços lineares, não tivesse preparado o terreno para a introdução mais tarde, por Werbos em seu trabalho de doutorado nos idos de 1971, de um poderoso procedimento para o treinamento de redes neurais, que foi popularizado principalmente por Rummelhart, Hinton e Willians: o método da *retropropagação do erro* (em inglês: *error backpropagation*).

2.2.3 – MULTILAYER PERCEPTRON

Esta rede possui sentido único de informação, que se dá na direção da camada de entrada até a camada de saída. De maneira geral, a MLP possui uma camada de entrada (*input layer*), uma camada de saída (*output layer*) e uma ou mais camadas escondidas (*hidden layer*). Cada camada terá uma ou mais unidades de processamento (*neurônios*). Cada unidade recebe entradas através de conexões ponderadas. A soma das entradas, multiplicadas pelos seus respectivos pesos, representam a entrada total do neurônio. A este valor aplica-se geralmente a função sigmóide, de modo a obter-se o valor de ativação da unidade, que corresponde à saída do neurônio. Uma MLP é simplesmente uma interconexão de camadas formadas por estas unidades de processamento, cujas características de funcionamento foram colocadas acima (Figura 2.9).




Figura 2.9 – MLP 2 camadas

A impotência das redes Perceptron na resolução do problema de associação de padrões para um conjunto de padrões não-lineares foi eliminada por Rumelhart, Hinton e Willians em 1986. A solução encontrada foi a *Generalized Delta Rule* ou mais conhecida como *Backpropagation Error Correction Algorithm*, para redes Perceptron de multi-camadas. As funções de ativação são contínuas e diferenciáveis, conforme exigência do algoritmo.

O algoritmo *Backpropagation* compreende um dos algoritmos mais representativos do paradigma supervisionado e é dividido em duas fases distintas. A primeira correspondente à etapa de apresentação de um estímulo na camada de entrada da rede e propagação da resposta dos neurônios até a camada de saída. A segunda refere-se a um passo inverso de retropropagação da camada de saída para as camadas anteriores de um sinal de erro, computado entre a resposta corrente e a resposta desejada para o dado estímulo.

Este algoritmo é na verdade um método para implementar o processo do **gradiente descendente** no espaço dos pesos para o treinamento da rede. *O gradiente de uma função vetorial dá a direção ao longo da qual uma pequena variação rende a maior variação da função.* Para um problema de minimização a direção deve ser contrária ao gradiente.

Então o objetivo do método é a computação eficiente das derivadas parciais de uma certa função $F(\vec{w}; \vec{x}_p)$ implementada pela rede com respeito aos componentes do vetor peso \vec{w} para um dado vetor de entrada \vec{x}_p . O emprego dessas derivadas $(\frac{\partial E_p}{\partial w_{ji}})$ para o ajuste dos pesos garante a minimização do erro na camada de saída .

Com a determinação da rede e de sua arquitetura inicial, que apresenta-se como melhor solução para o problema, aplicamos o algoritmo de aprendizagem. Para o caso do *perceptron multi-camadas (Multilayer Perceptrons - MLP)* o algoritmo de aprendizado é o *Backpropagation Error Correction Algorithm*.

Os passos realizados referentes ao algoritmo podem ser descritos da seguinte forma:

1. Apresenta-se um padrão \vec{x}_p na camada de entrada da rede.
2. Em seguida computa-se a partir da primeira camada intermediária até a camada de saída, as respostas fornecidas pelas unidades de processamento da rede.
3. Calcula-se na camada de saída o erro cometido, correspondendo à diferença entre a resposta desejada t_p e a resposta fornecida, através de uma determinada *função custo* E_p . Se o valor de E_p em um dado instante é menor que um certo valor mínimo ϵ estabelecido, o processo de aprendizagem é finalizado e o algoritmo pula para o passo 5. Caso contrário, segue-se para o passo 4. Diferentes tipos de função custo podem ser empregadas, sendo entretanto a mais comum a utilização do mínimo erro quadrado dado pela equação abaixo.

$$E_p = \frac{1}{2} \sum_{j=1}^n (t_{pj} - o_{pj})^2 \quad (2.9)$$

4. O passo seguinte corresponde a atualização dos pesos das conexões de acordo com a taxa de aprendizado. O processo ocorre da camada de saída em direção a camada de entrada, passando pelas camadas intermediárias. Após os ajustes, retorne ao *passo 1*
5. Fim do algoritmo.

Como vê-se o algoritmo é dividido em duas fases distintas, sendo a primeira correspondente à etapa de apresentação de um estímulo na camada de entrada da rede e propagação da resposta dos neurônios até a camada de saída e a segunda referente a um passo inverso de retropropagação, da camada de saída para as camadas anteriores. É nesta

segunda fase que se configura de fato o ajuste dos parâmetros da rede como resultado do estímulo sofrido do ambiente. A matemática deste algoritmo será apresentada a seguir.

MATEMÁTICA

Notações:

E_p → Função erro para um padrão p .

t_{pj} → Resposta desejada na unidade j para um padrão p .

o_{pj} → Resposta obtida na unidade j para um padrão p .

w_{ji} → Peso das conexões entre as unidades i e j .

A função erro é definida por:

$$E_p = \frac{1}{2} \sum_j (t_{pj} - o_{pj})^2$$

A regra de propagação de cada unidade j , para o padrão p , é dada pela função net_{pj} .

$$net_{pj} = \sum_i w_{ji} o_{pi}$$

E a função de ativação é dada pela função sigmoid ($f(x) = 1/(1 + e^{-net})$), que é contínua e diferenciável, conforme exigência do algoritmo.

$$o_{pj} = f_j(net_{pj})$$

O passo seguinte corresponde à atualização dos pesos das conexões.

$$\frac{\partial E_p}{\partial w_{ji}} = \frac{\partial E_p}{\partial net_{pj}} \frac{\partial net_{pj}}{\partial w_{ji}}$$

$$\frac{\partial net_{pj}}{\partial w_{ji}} = \frac{\partial}{\partial w_{ji}} \sum_k w_{jk} o_{pk} = \sum_k \frac{\partial w_{jk}}{\partial w_{ji}} o_{pk}$$

Onde $\frac{\partial w_{jk}}{\partial w_{ji}} = 0$ exceto quando $k = i$

$$\frac{\partial net_{pj}}{\partial w_{ji}} = o_{pi}$$

Pode-se definir δ_{pj} como sendo o erro cometido entre a resposta desejada e a fornecida pela unidade j .

$$\delta_{pj} = - \frac{\partial E_p}{\partial net_{pj}}$$

Então têm-se:

$$- \frac{\partial E_p}{\partial w_{ji}} = \delta_{pj} o_{pi}$$

O ajuste dos pesos ocorre da camada de saída em direção à camada de entrada, passando pelas camadas intermediárias, sendo efetuado pela equação abaixo:

$$\Delta w_{ji} = \eta \delta_{pj} o_{pi}$$

Calculam-se os δ_{pj} para cada unidade.

$$\delta_{pj} = -\frac{\partial E_p}{\partial net_{pj}} = -\frac{\partial E_p}{\partial o_{pj}} \frac{\partial o_{pj}}{\partial net_{pj}}$$

Considerando o segundo termo:

$$\frac{\partial o_{pj}}{\partial net_{pj}} = f'_j(net_{pj})$$

Considerando o primeiro termo:

$$\frac{\partial E_p}{\partial o_{pj}} = -(t_{pj} - o_{pj})$$

No caso em que j é uma unidade de saída obtêm-se:

$$\delta_{pj} = f'_j(net_{pj})(t_{pj} - o_{pj})$$

Quando a função de ativação f_j utilizada é a função sigmoid obtêm-se:

$$\delta_{pj} = o_{pj}(t_{pj} - o_{pj})(1 - o_{pj})$$

Para as unidades j nas camadas intermediárias, não há como computar diretamente os ajustes em função do erro $(t_{pj} - o_{pj})$ e, portanto, os mesmos são calculados em função dos erros δ_k observados nas unidades das camadas subsequentes, da seguinte forma:

$$\begin{aligned}
\frac{\partial E_p}{\partial o_{pj}} &= \sum_k \frac{\partial E_p}{\partial net_{pk}} \frac{\partial net_{pk}}{\partial o_{pj}} \\
&= \sum_k \frac{\partial E_p}{\partial net_{pk}} \frac{\partial}{\partial o_{pj}} \sum_i w_{ki} o_{pi} \\
&= - \sum_k \delta_{pk} w_{jk} \\
&\quad \text{então} \\
\delta_{pj} &= f'_j(net_{pj}) \sum_k w_{jk} \delta_{pk}
\end{aligned}$$

onde os δ_k 's do somatório são da camada posterior, que já foram calculados. Devido a isto é que o algoritmo leva o seu nome.

A regra de aprendizado *Backpropagation* é a mais importante contribuição que impulsionou decisivamente a divulgação das redes neurais artificiais. Embora esta regra de aprendizado tenha sido formulada em 1971 por Werbos, foi redescoberta e tornou-se largamente conhecida em 1986 através de Rumelhart, Hinton e Williams. *Backpropagation* é ainda o mais comumente utilizado algoritmo de aprendizado para treinamento supervisionado. Redes neurais artificiais treinadas via algoritmo *Backpropagation* são também designadas como redes *Backpropagation*, razão pela qual este termo é praticamente sinônimo do mais difundido tipo de rede, as redes *Multilayer Perceptrons* (MLP).

2.2.4 – RPROP

RPROP, que segue de “resilient propagation”, (Riedmiller and Braun, 1993) é um algoritmo de aprendizado extremamente eficiente que executa o cálculo do Δw_{ji} de forma direta, baseado em informações locais do gradiente e não baseado na “dimensão” do gradiente.

Sendo as derivadas parciais de cada peso de um neurônio conhecidas, o objetivo de minimização da função erro E é obtida executando o gradiente descendente.

$$w_{ji}(t+1) = w_{ji}(t) + \Delta w_{ji}(t)$$

$$\Delta w_{ji} = -\eta \frac{\partial E(t)}{\partial w_{ji}}$$

Obviamente, a escolha da taxa de aprendizado η , que determina o tamanho do passo na direção contrária ao gradiente da função erro tem um importante efeito no tempo despendido até que a convergência seja alcançada (tempo de treinamento). Se a taxa de aprendizado é pequena, são necessários muitos passos até que um valor aceitável da função erro seja alcançado, de modo contrário se a taxa de aprendizagem é escolhida como sendo muito grande, provavelmente será apresentada uma oscilação da função erro E , não permitindo que seja atingido o valor desejado.

Para obter este algoritmo deve-se introduzir a variável Δ_{ji} que é denominada de “valor atualizado”. Cada peso Δw_{ji} tem sua variável Δ_{ji} , e ela determina de forma exclusiva o tamanho da variável Δw_{ji} .

A variável segue a seguinte regra de aprendizagem

$$\Delta_{ji}(t) = \begin{cases} \eta^+ * \Delta_{ji}(t-1) & \text{if } \frac{\partial E(t-1)}{\partial w_{ji}} * \frac{\partial E(t)}{\partial w_{ji}} > 0 \\ \eta^- * \Delta_{ji}(t-1) & \text{if } \frac{\partial E(t-1)}{\partial w_{ji}} * \frac{\partial E(t)}{\partial w_{ji}} < 0 \\ \Delta_{ji}(t-1) & \text{else} \end{cases}$$

onde $0 < \eta^- < 1 < \eta^+$

Toda vez que a derivada parcial do correspondente peso muda de sinal, o que indica que a última atualização foi muito grande e o algoritmo pulou um mínimo local, a variável Δ_{ji} é diminuída por um fator η^- . Se a derivada mantém seu sinal, a variável é levemente incrementada de modo a acelerar a convergência em regiões de planície.

Então a atualização da variável Δw_{ji} é realizada de acordo com a seguinte regra bastante simples: Se a derivada parcial é positiva (função erro aumentando de valor), o peso w_{ji} é diminuído pela sua variável Δ_{ji} . Se a derivada é negativa, o Δ_{ji} é adicionado.

$$\Delta w_{ji}(t) = \begin{cases} -\Delta_{ji}(t) & \text{if } \frac{\partial E(t)}{\partial w_{ji}} > 0 \\ +\Delta_{ji}(t) & \text{if } \frac{\partial E(t)}{\partial w_{ji}} < 0 \\ 0 & \text{else} \end{cases}$$

$$w_{ji}(t+1) = w_{ji}(t) + \Delta w_{ji}(t)$$

Entretanto existe uma exceção: Se a derivada parcial muda de sinal, isto é, o passo anterior foi muito grande e o ponto de mínimo foi perdido, a atualização do peso é revertida:

$$\Delta w_{ji}(t) = -\Delta w_{ji}(t-1), \quad \text{if } \frac{\partial E(t-1)}{\partial w_{ji}} * \frac{\partial E(t)}{\partial w_{ji}} < 0$$

Devido ao “backtracking” acima, a derivada pode mudar de sinal novamente no passo seguinte. Para evitar uma punição dupla da variável Δ_{ji} , deve-se não atualizá-la no passo seguinte. Na prática isto pode ser feito declarando $\frac{\partial E(t-1)}{\partial w_{ji}} := 0$ na regra de adaptação da variável Δ_{ji} .

As variáveis Δ_{ji} e os pesos w_{ji} são atualizados uma vez por época (uma época significa que todos os padrões do conjunto de treinamento são apresentados uma vez).

Em relação à todos os outros algoritmos de treinamento rápido para a MLP, o RPROP toma somente o sinal da derivada parcial para executar o aprendizado da rede neural. Esta característica conduz à um processo de adaptação transparente e extremamente poderoso, muito eficiente em relação ao tempo de processamento e memória computacional utilizados.

2.2.5 – RBF-DDA

O algoritmo de treinamento aqui apresentado é o *Dynamic Decay Adjustment* para RBF's (RBF-DDA) do simulador *Stuttgart Neural Network Simulator* (SNNS, 1995), (Sodré, *et. al.*, 1998). Este algoritmo consiste de uma Metodologia Construtiva aplicada às tradicionalmente conhecidas Radial Basis Functions (RBF), cujo treinamento é bastante rápido.

A camada escondida construtiva, cujas unidades RBF são adicionadas durante o treinamento, está completamente conectada à de entrada. Cada unidade da camada de saída representa uma possível classe, isto é, o número de unidades de saída é igual ao número de classes do problema em questão. Para a classificação a unidade de saída com a mais alta ativação determina a classe. Cada unidade RBF escondida é conectada a uma e somente uma unidade de saída.

A camada de saída calcula a resposta de cada unidade da seguinte forma:

$$f(\vec{x}) = \sum_{i=1}^m A_i * R_i(\vec{x})$$

onde m indica o número de unidades RBF pertencentes à classe correspondente, $R_i(\vec{x})$ representa a sua saída e A_i indica o peso para cada unidade RBF.

Cada unidade de saída simplesmente calcula a soma ponderada de todas as ativações das unidades RBF pertencente à classe correspondente.

O algoritmo DDA introduz a idéia de vizinhanças *casadas* e *conflitantes* em uma *área de conflito*. Dois limites θ^+ e θ^- são introduzidos, como ilustrado na Figura 2.10.

Os dois *limites* são usados para definir uma *área de conflito* onde nenhum outro padrão de uma classe conflitante é permitido existir. Cada padrão de treinamento tem que estar no círculo interno de pelo menos uma unidade RBF da mesma classe.

Usando estes limites, o algoritmo constrói dinamicamente a rede e ajusta o espalhamento da Função Gaussiana individualmente. São necessárias em torno de cinco épocas, além das quais o erro não é usualmente reduzido, para completar o treinamento, devido à natureza construtiva do algoritmo.

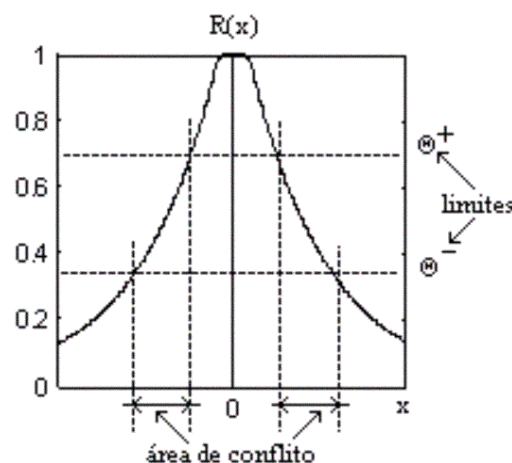


Figura 2.10 – Área de Conflito

O algoritmo DDA é baseado em dois passos:

1º Passo - Classificação de Padrão: durante o treinamento, quando quer que um padrão seja classificado errado, toma-se a seguinte ação: uma nova unidade RBF com o espalhamento igual a 1 é criada; ou o espalhamento de uma unidade RBF existente (que cobre o novo padrão) é incrementado.

2º Passo – Redução do Espalhamento: em ambos os casos o espalhamento das unidades RBF conflitantes (unidades pertencentes às outras classes) é reduzido. Isto garante que cada padrão dos dados de treinamento seja coberto por uma unidade RBF da classe correta e nenhuma outra unidade RBF das classes conflitantes tenha uma resposta não apropriada.

Para criar uma nova unidade RBF nenhuma das unidades RBF existentes da classe correta tem uma ativação acima de θ^+ e durante a redução do espalhamento das unidades RBF das classes conflitantes a nenhuma unidade é permitido ter uma ativação acima de θ^- .

Durante o treinamento de um padrão são incrementados os pesos entre a unidade RBF da classe correta cobrindo aquele padrão e sua correspondente unidade de saída. É importante que os dados sejam normalizados. Usualmente a normalização entre [0,1] é empregada.

2.2.6 – COMBINADOR DE REDES NEURAIIS

A combinação de várias redes neurais para implementação de um processo de reconhecimento de padrões já é uma atividade bastante desenvolvida na área de Reconhecimento Automático de Alvos, podendo naturalmente ser aplicada em qualquer área que faça uso da tecnologia das redes neurais (Prampero, 1998), (Vasconcelos, *et. al.*, 1999). Neste trabalho foi proposta uma nova forma de combinação, a qual denominou-se SMPM (Soma Máxima Ponderada Modificada) (Sodré, Neto e Carvalho Jr., 1999).

Os classificadores utilizados para a combinação foram a RBF-DDA (Radial Basis Function – Dynamic Decay Adjustment) e o kNN (k-Nearest Neighbour), cujo desempenho foi comparado com a atuação de uma MLP (Multilayer Perceptron).

As vantagens de se combinarem as saídas de redes neurais são bastante óbvias, dado que podem ser exploradas as características específicas de várias redes. Sendo importante observar que a combinação deve se dar entre redes neurais que apresentem

desempenhos diferentes quando aplicadas sozinhas na solução do problema considerado, porque assim poderão ser melhor aproveitadas as discrepâncias de classificação (Prampero, 1998). Vários modelos são propostos na literatura, tais como, em paralelo, cascata ou hierárquico. Nos modelos em paralelo a decisão de combinação pode ser formulada como, 1) pela Maioria, 2) pela Maioria Ponderada, 3) uma Rede Neural, etc.

O modelo de combinação proposto neste trabalho é o SMPM (Soma Máxima Ponderada Modificada), onde as redes neurais consideradas, alimentam em paralelo um somador que dará como resposta a classificação do ponto de operação elétrico do sistema, entre seguro e alerta (Figura 2.11).

A SMPM foi a forma encontrada para que a margem de acerto da combinação fosse a melhor possível. A combinação é feita tal que a saída final seja a soma ponderada das saídas da RBF_DDA e do kNN. Desde que uma regra IF-THEN seja satisfeita, conforme:

IF (rand = = 10 %) THEN

$$S_1 = \beta_{11}R_1 + k_1$$

$$S_2 = \beta_{21}R_2 + k_2$$

ELSE

$$S_1 = k_1$$

$$S_2 = k_2$$

onde, S_1 e S_2 são a saída do combinador; β_1 e β_2 são os pesos que atuam somente na saída da RBF-DDA; a saída da RBF-DDA são R_1 e R_2 ; e a saída do kNN são k_1 e k_2 .

A condição IF que precisa ser satisfeita é um artifício que pode garantir, com uma probabilidade de 10%, que para cada padrão apresentado a combinação renda o maior acerto possível, sendo importante observar que esta combinação proposta é específica para o caso em questão. Nada justifica a aplicação geral do SMPM.




Figura 2.11 – Combinador SMPM

2.2.7 – APLICAÇÕES EM SISTEMAS DE POTÊNCIA

Na área de sistemas de potência, os problemas podem ser expressos de diferentes maneiras, dependendo da natureza do estudo desejado. A formulação do problema pode ser expresso em termos de sistemas complexos, não lineares, dinâmicos, discretos, estocásticos, quase periódicos, sistemas com parâmetros variando no tempo, etc. Entre estes fatores, as não linearidades e a grande dimensão dos sistemas de potência fazem com que seja muito difícil tratar matematicamente a operação destes.

Fora as técnicas de sistemas lineares, nenhuma suficientemente boa tecnologia analítica está disponível para problemas complicados. As redes neurais são candidatas promissoras para tratar com estes tipos de problemas. Desde o trabalho de Sobajic e Pao (Sobajic and Pao, 1989), uma grande quantidade de estudos de aplicações de redes neurais em sistemas de potência tem sido publicado.

Esta seção descreve um panorama das redes neurais aplicadas a sistemas de potência. Aproximadamente 400 artigos foram investigados. A MLP é a principal rede utilizada nos trabalhos. A MLP contabiliza uma porcentagem, dentro dos 400 artigos investigados, de 81.19 %, a Hopfield tem 5.41 %, e a Kohonen tem 8.25 % (El-Sharkawi and Niebur, 1996). Os seguintes problemas específicos são os mais solucionados com as técnicas de redes neurais: previsão de carga, avaliação da segurança, e diagnóstico/detecção de falta. A Tabela 2.1 abaixo mostra as características típicas dos problemas. Como visto as aplicações de redes neurais para previsão de carga são de mais fácil implementação do que a avaliação da segurança e o diagnóstico/detecção de falta.

Tabela 2.1 – Características dos Problemas em Sistemas de Potência.

Características	Previsão de Carga	Avaliação da Segurança	Diagnóstico/Deteccção de Falta
Abordagem Analítica	Disponível	Disponível	Não Disponível
Avaliação on-line	Necessária	Altamente necessária	Necessária
Tamanho da RN	Pequena	Pequena	Grande
Implementação direta da RN	Aceitável	Difícil	Difícil

A MLP é usada como uma das principais ferramentas para lidar com a análise da série temporal da carga. Nas aplicações de RN's para previsão de carga a principal preocupação é a previsão de curto-prazo. Uma previsão de alta acurácia melhora a segurança e o custo da geração. Entretanto, o problema da previsão não é tão fácil por causa de fatores complicados que influenciam diretamente o comportamento da carga, tais como, não linearidade e comportamento aleatório da carga e das condições climáticas. Os métodos convencionais, ARIMA, Filtro de Kalman e modelos de regressão múltipla sofrem de pouca adaptabilidade em sua estrutura em casos que eventos inesperados, tais como, aquecimento ou frentes frias, influenciam significativamente as cargas dos sistemas.

A avaliação de segurança dinâmica e estática freqüentemente requer resolução on-line. Entretanto, as técnicas analíticas convencionais são consumidoras de tempo. Nestes casos é freqüentemente utilizada a MLP. O mapeamento não-linear da MLP é utilizado para reduzir o esforço computacional e lidar com as características específicas dos sistemas de potência. As RN's permitem, até mesmo, a implementação on-line das avaliações/monitorações da estabilidade dinâmica e da instabilidade de tensão.

O diagnóstico/deteccção de falta é um dos problemas mais desafiantes em sistemas de potência. As RN's identificam o tipo e o local das faltas dado um conjunto de condições do sistema de potência, medidas, alarmes, etc. De acordo com algumas condições de entrada, as RN's são capazes de selecionar entre soluções candidatas. Entretanto, a

complexidade aumenta significativamente ao aumentar o tamanho do sistema. Logo, técnicas de pré-filtragem sofisticadas tem que ser utilizadas.

Kohonen é aplicado para classificar os padrões faltosos. O diagnóstico dos equipamentos são feitos para julgar que tipos de faltas estes sofreram. O mapeamento dos neurônios da rede de Kohonen deve ser feito de forma apropriada. A rede de Kohonen tem um desempenho inferior à MLP, devido ao processo de aprendizagem não supervisionado.

Finalmente apresentam-se exemplo típicos de sistemas neurais em operação e sistemas que ainda estão em testes de campo. Em anos recentes a implementação de métodos baseados em redes neurais tem sido uma preocupação das empresas de energia elétrica. Através da tabela abaixo pode-se ver que o principal problema atacado é a previsão de carga (El-Sharkawi and Niebur, 1996).

Tabela 2.2 – Aplicações Práticas de Redes Neurais.

Áreas	Status	Empresas
Previsão de Carga	em Operação	Pacific Gas & Electric, USA
	em Teste	Siemens, Alemanha
	em Teste	Fuji Electric, Japão
Processamento de Alarme / Detecção de Falta	em Operação	Hitachi Cable, Japão
	em Teste	TEPCO, Japão

2.3 – SISTEMAS FUZZY

Desde o início dos anos 90 tem sido presenciado um rápido crescimento nas aplicações dos sistemas fuzzy. Estas aplicações vão desde produtos eletrônicos, tais como, câmeras fotográficas, câmeras de vídeo, máquinas de lavar roupa, até controle de processos industriais, instrumentação médica, sistemas de suporte à decisão, etc.

Para entender as razões do rápido crescimento do uso dos sistemas fuzzy é necessário primeiro tornar claro o que seja a lógica fuzzy.

Um sistema fuzzy é uma maneira conveniente de mapear variáveis de entrada (espaço de entrada) numa variável de saída (espaço de saída). Por exemplo: dada a temperatura que pretende-se manter aquecida uma determinada quantidade de água, o sistema lhe mostrará em que posição deve ser colocado o termostato; dada a distância da câmera do objeto a ser fotografado, o sistema posicionará o foco das lentes. Monitorando-se a maneira que a temperatura e a pressão do paciente estão se comportando, o sistema determinará a intervenção anestésica correta.

Muitos dos problemas resolvidos no dia a dia são apenas uma forma apropriada de determinar uma variável de saída dados os valores das variáveis de entrada. A questão crucial é implementar computacionalmente a “caixa preta” da Figura 2.12. Uma das soluções possíveis é o sistema fuzzy.



Figura 2.12 – Mapeamento Entrada-Saída

2.3.1 - VISÃO GERAL DOS SISTEMAS FUZZY

Nesta seção irá ser apresentado um simples exemplo de aplicação de um sistema fuzzy para ajudar a esclarecer os conceitos básicos.

Como exemplo introdutório pode-se supor o Problema da Fábrica de Celulose : Dado um número entre 0 (zero) e 10 (dez), que representa a qualidade da madeira, qual deveria ser a temperatura mantida durante o tempo de cozimento.

Para a solução do problema da Fábrica de Celulose, irá ser empregada simulações baseadas em observações e dados empíricos, e não modelos matemáticos ou químicos, baseados em equações diferenciais.

A qualidade final da celulose depende não somente das propriedades da madeira mas também de muitos outros fatores no processo de produção, tais como, a concentração do ácido durante o cozimento da madeira, o tempo de cozimento, a pressão, a temperatura e o processo de aquecimento gradual da madeira.

Por exemplo, com madeira de baixa qualidade e também com ácido de baixa qualidade a temperatura do cozimento não deve ser tão alta; a mistura deve ser aquecida mais lentamente e tendo sido alcançada a temperatura de 115 °C, a concentração do ácido não pode ser significativamente alterada. Considerando agora a mesma madeira de baixa qualidade mas um ácido de melhor qualidade, isto significa que uma menor quantidade de ácido deve ser usada na mistura numa concentração, durante o processo de cozimento, decrescente, e que a mistura pode ser aquecida mais rapidamente (Höhfeld and Schürmann, 1993).

As declarações acima são bastante inexatas e mesmo em alguns casos contraditórias. As variáveis de entrada, tais como, qualidade da madeira, são difíceis de quantificar e determinar, tornando o controle do processo mais adequado de ser resolvido através dos sistemas fuzzy.

É importante ainda considerar, à título de ilustração, que até que o processo de cozimento tenha sido completado não é possível determinar se a celulose produzida satisfaz as condições desejadas. Sendo necessário portanto um modelo do processo de cozimento que, baseado nos dados disponíveis, possa fazer com que sejam simuladas várias situações e determinado o tempo correto de cozimento. O modelo analítico convencional, baseado em equações cinéticas químicas pode ser substituído por uma modelagem do processo através de redes neurais. Graças a estes sistemas inteligentes (RNA's e sistemas fuzzy) uma fábrica de celulose sediada em Constância/Portugal

conseguiu uma redução de 14% do consumo habitual de energia e atualmente poupa 80% do volume de água anteriormente consumido. No processo de cozedura da celulose, este modelo inteligente permitiu, ainda, reduzir em 30% as variações de qualidade (Höhfeld and Schürmann, 1993).

Vale a pena lembrar também que estes sistemas inteligentes constituem, presentemente, o equipamento-padrão utilizado em unidades de laminagem e contribuem, nesses locais, para poupanças de energia da ordem de 10%.

Considere-se para o exemplo introdutório que baseado em experiências anteriores, tipicamente a temperatura de cozimento fica em torno de 115^oC.

Então uma maneira de implementar a “caixa preta” da Figura 2.14 seria através da relação linear da Figura 2.13.

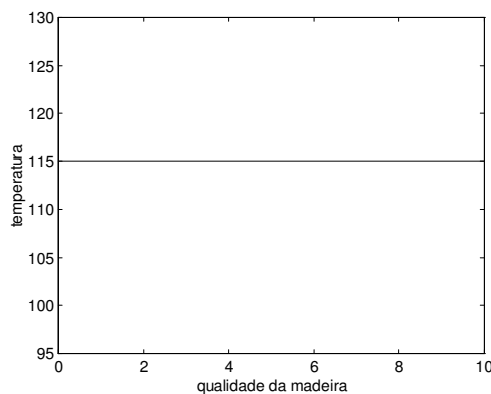


Figura 2.13 – Mapeamento Entrada-Saída Linear

Fica claro que a abordagem linear representa uma solução para o Problema da Fábrica de Celulose, ainda que severamente limitada. Mas ainda pode-se, seguindo uma abordagem linear, construir a figura abaixo onde é levado em consideração que uma madeira de baixa qualidade deve ser cozida a uma temperatura menor e que uma madeira de maior qualidade pode então ser cozida a uma temperatura maior.

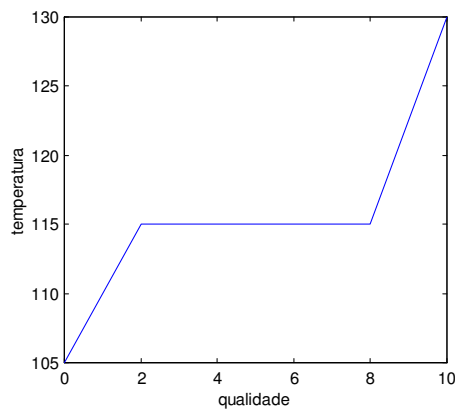


Figura 2.14 – Mapeamento Entrada-Saída Linear por Partes

Agora imagine que se quer incrementar o problema para o Problema da Fábrica de Celulose Estendido, onde deve-se levar em consideração a qualidade do ácido. Poder-se -ia fazer a “caixa preta” ser uma aproximação linear por partes, com duas entrada e uma saída, ou seja, uma superfície de decisão. Claro está que à medida que as variáveis aumentam a abordagem de linearização e de construção de superfícies de decisão se torna proibitiva.

Considerando a abordagem fuzzy para o Problema da Fábrica de Celulose Estendido é suficiente que o sistema para funcionar lance mão somente de apenas algumas regras *If-Then*,

1. ***If*** madeira ***is*** ruim ***Then*** temperatura ***is*** pequena.
2. ***If*** madeira ***is*** boa ***Then*** temperatura ***is*** média.
3. ***If*** madeira ***is*** excelente ***Then*** temperatura ***is*** grande.

A ordem em que as regras são apresentadas aqui é arbitrária. Não importa que regra vem primeiro.

Incluindo o efeito do ácido sobre a temperatura:

4. ***If*** ácido ***is*** ruim ***Then*** temperatura ***is*** grande.
5. ***If*** ácido ***is*** bom ***Then*** temperatura ***is*** pequena.

Pode-se combinar as 5 regras acima numa lista de 3 regras, como abaixo:

1. **If** madeira **is** ruim **or** ácido **is** ruim **Then** temperatura **is** grande.
2. **If** madeira **is** boa **Then** temperatura **is** média.
3. **If** madeira **is** excelente **or** ácido **is** bom **Then** temperatura **is** pequena.

Algumas considerações sobre o exemplo acima devem ser feitas. Uma relação linear por partes resolve o problema, mas vê-se a dificuldade em derivar esta solução para um caso de um espaço de entrada de dimensão alta. Uma vez escrito o código, este não é muito fácil de interpretar ou modificar. O sistema fuzzy utiliza-se de declarações do senso comum. Também vê-se a facilidade de adicionar mais duas regras ao conjunto inicial das três regras, ou seja, as modificações subsequentes são facilmente implementáveis.

A questão central do sistema fuzzy é mapear uma entrada numa saída, e o mecanismo principal para fazer isto é uma lista de regras **If –Then**. Todas as regras são avaliadas de forma paralela e a ordem das regras não é importante. Estas regras determinam como as variáveis de entrada (no caso específico, a qualidade da madeira e do ácido) relacionam-se com a variável de saída (temperatura) e os adjetivos que descrevem ou quantificam estas variáveis.

Antes de ser construído um sistema que interprete estas regras, deve-se definir todas as variáveis que estão sendo usadas e os adjetivos que as descrevem. Ao se querer “medir” quão quente a água está, precisa-se definir o intervalo de temperatura de interesse e para que subintervalos pode-se considerar a água como quente, fria ou morna. A Figura 2.15 mostra o esquema geral do processo de inferência fuzzy.

2.3.2 - FUNDAMENTOS DA LÓGICA FUZZY

Certo está que o desenho do sistema fuzzy acima não tem nada de errado e que as idéias subjacentes de mapear variáveis de entrada numa variável de saída podem resolver o

problema da “caixa preta”. Nesta seção será visto a teoria dos conjuntos difusos e da lógica difusa, que tornam possível a implementação computacional de um sistema fuzzy. Esta teoria foi concebida por Lotfi Zadeh nos idos de 60 como um meio de modelar a incerteza e a imprecisão próprias da linguagem natural.

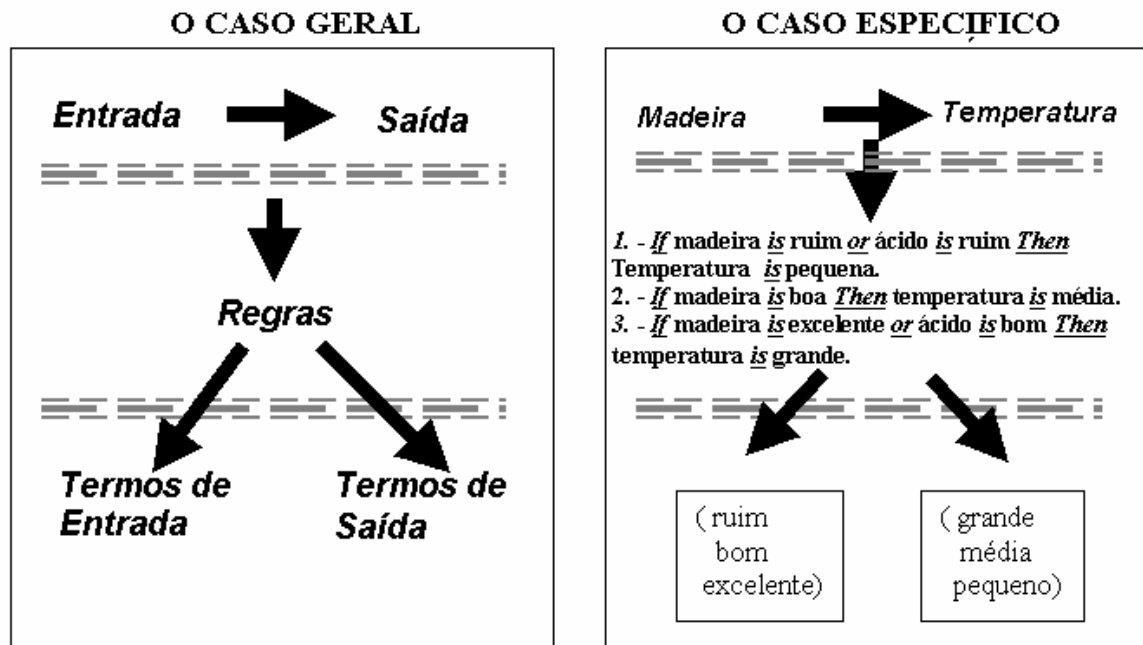


Figura 2.15 – Mapeamento Entrada-Saída Fuzzy

CONJUNTOS FUZZY E FUNÇÕES DE PERTINÊNCIA

A noção de conjunto difuso resulta da observação que alguns elementos são mais membros de um conjunto do que outros elementos, o que introduz graus de pertinência diferenciados entre os elementos de um conjunto.

Cada elemento de um conjunto fuzzy está associado a um valor no intervalo $[0,1]$ que descreve o grau de pertinência do elemento ao conjunto. O valor 0 (zero) representa a não pertinência absoluta, o valor 1 representa a pertinência absoluta, valores entre 0 e 1 representam graus de pertinência intermediários. Assim, alguns elementos podem ser mais membros de um conjunto do que outros elementos.

Na lógica clássica (Booleana), a pertinência intermediária não é definida, ou o elemento pertence (valor = 1) ou não pertence (valor = 0).

Um conjunto difuso A é definido sobre um universo U através de uma *função de pertinência* que assume valores no intervalo [0,1]:

$$\mu_A(x) \in [0,1]$$

O grau de verdade da sentença $X \in A$ é determinado através do valor especificado por $\mu_A(x)$.

$$\mu_A(x) = \begin{cases} 1 \Rightarrow \text{representa a pertinência} \\ \quad \text{absoluta de X ao conjunto A} \\ 0 \Rightarrow \text{representa a não pertinência absoluta} \\ \quad \text{de X ao conjunto A} \\ (0,1) \Rightarrow \text{representa a pertinência} \\ \quad \text{intermediária de X ao conjunto A} \end{cases}$$

Para ilustrar, pode-se considerar o conjunto fuzzy *Alto* cujo universo U corresponde a um conjunto de pessoas. Para definir o conjunto difuso *Alto*, é necessário saber para que grau a estatura de uma certa pessoa X pode ser considerada alta. Para cada pessoa neste universo, deve ser associado um valor no intervalo [0,1] que especifica o grau de pertinência dessa pessoa no conjunto difuso *Alto*. A função de pertinência pode então ser definida da seguinte forma:

$$\mu_{\text{alto}}(x) = \frac{1}{1 + e^{-4,5 \left(\frac{2(\text{altura}(x) - 1,5)}{1,9 - 1,5} - 1 \right)}}$$

onde altura(x) é uma função que especifica a altura de uma determinada pessoa. Dado um conjunto de pessoas e suas respectivas alturas, o grau de pertinência de cada uma das pessoas em relação ao conjunto difuso *Alto* é calculado de forma direta a partir da função de pertinência $\mu_{\text{alto}}(x)$.

Pessoa	Altura(m)	$\mu_{\text{alto}}(\text{pessoa})$
Ana	1,50	0,01
Maria	1,60	0,1
Lúcia	1,70	0,5
Paula	1,80	0,9
Pedro	1,90	0,99
João	2,00	1,00

A função de pertinência $\mu_{\text{ALTO}}(x)$ é exibida graficamente na Figura 2.16.:

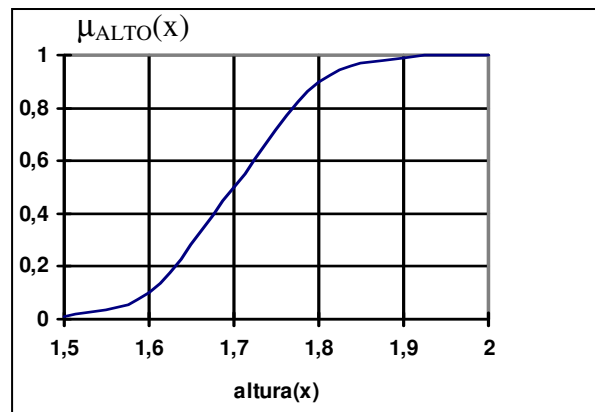


Figura 2.16 – Função de Pertinência

Através do gráfico, pode-se observar que os valores de pertinência crescem gradualmente de 0 até 1 com o aumento do valor da estatura. A definição difusa para o conceito alto é notoriamente superior a qualquer definição baseada na teoria clássica de conjuntos, a qual impõe que somente há duas possibilidades excludentes: um elemento deve pertencer ou não a um conjunto. Isto implica que uma pessoa deve ser alta ou não, existindo um valor específico de estatura que separa abruptamente alto e não-alto. Tal fato pode ser observado na Figura 2.17, onde uma pessoa de estatura 1,69m é considerada não-alta, enquanto uma pessoa de estatura 1,71m é considerada alta. Muitos dos conceitos vagos e imprecisos do mundo real são essencialmente difusos.




Figura 2.17 – Teoria Clássica dos Conjuntos

Funções de pertinência típicas bastante utilizadas para descrever os graus de pertinência de elementos em relação a um conjunto difuso são: funções sigmóides, funções cujos gráficos se assemelham à curva de densidade de probabilidade gaussiana, funções lineares, funções triangulares, funções trapezoidais, entre outras.

OPERAÇÕES LÓGICAS FUZZY

Um dos pontos mais interessantes em relação à lógica fuzzy é que a lógica booleana padrão é um subconjunto da lógica fuzzy. Em outras palavras, se as funções de pertinência fuzzy forem tomadas apenas em seus extremos 0 e 1, completamente falso e completamente verdadeiro respectivamente, as operações da lógica padrão permanecerão válidas. Como um exemplo considere as tabelas verdades abaixo:

Tabela 2.3 - Tabela Verdade das Funções Lógicas Booleanas.

A	B	A and B
0	0	0
0	1	0
1	0	0
1	1	1

AND

A	B	A or B
0	0	0
0	1	1
1	0	1
1	1	1

OR

A	not A
0	1
1	0

NOT

Como foi visto, na lógica fuzzy o valor verdade de uma declaração é um grau de pertinência. Como então os valores de uma determinada tabela verdade podem ser avaliados considerando os equivalentes fuzzy das operações lógicas AND, OR e NOT ? Sabendo que os valores das tabelas podem assumir quaisquer valores entre 0 e 1, que função ou funções preservarão os resultados das tabelas booleanas acima ?

Uma das respostas para estas questões é a função *min*. Esta função avalia dois valores e resulta num valor que é o mínimo entre os dois - $\min(A,B)$. Esta função pode fazer o papel da função AND. Usando o mesmo raciocínio, pode-se definir a função *max* para atuar como a operação lógica fuzzy OR. E para finalizar, a operação NOT A se torna $1-A$. Nota-se que a tabela verdade dada acima permanece inalterada se forem substituídas as operações lógicas padrões pelas operações lógicas fuzzy (Tabela 2.4).

Tabela 2.4 - Tabela Verdade das Funções Lógicas Fuzzy.

A	B	$\min(A,B)$
0	0	0
0	1	0
1	0	0
1	1	1

AND

A	B	$\max(A,B)$
0	0	0
0	1	1
1	0	1
1	1	1

OR

A	$1-A$
0	1
1	0

NOT

Desde que agora tem-se uma função para avaliar uma tabela verdade e não mais apenas a tabela por si só, pode-se considerar valores quaisquer entre 0 e 1. Dada as três funções acima, pode-se resolver qualquer construção lógica que se utiliza de conjuntos fuzzy e dos operadores lógicos fuzzy AND, OR e NOT.

Cabe lembrar ainda que foi definida apenas uma particular correspondência entre a lógica bi-valorada e a lógica fuzzy, mas esta correspondência não é de forma nenhuma a única possível.

REGRAS *If-Then*

Os conjuntos fuzzy e os operadores lógicos fuzzy são os sujeitos e os verbos da lógica fuzzy. Mas para dizer algo útil precisam ser feitas sentenças completas. Declarações condicionais (Regras If-Then) são o que fazem a lógica fuzzy funcionar.

Uma simples regra If-Then tem a seguinte forma:

***If* x is A Then y is B.**

onde A e B são valores lingüísticos (bom, ruim, alto, um pouco quente, etc.) definidos por conjuntos fuzzy nos intervalos x e y, respectivamente. A parte ***If*** da regra “x is A” é chamada o antecedente, enquanto a parte ***Then*** “y is B” é chamada o conseqüente. Um exemplo de uma regra fuzzy pode ser:

***If* madeira is ruim or ácido is ruim Then temperatura is pequena.**

Note que o antecedente é uma interpretação de um valor de entrada que gera um número entre 0 e 1, e posteriormente os operadores lógicos fuzzy geram um valor real. O conseqüente é interpretado de forma a determinar um conjunto fuzzy (função de pertinência) para a variável y.

A interpretação de regras ***If-Then*** envolve partes distintas: avaliação do antecedente (que envolve a fuzzificação da entrada e a aplicação dos operadores fuzzy necessários); e aplicação deste resultado para o conseqüente (processo conhecido como implicação).

Mas, como é o conseqüente afetado pelo resultado lógico fuzzy do antecedente? Uma função de implicação modifica a função de pertinência B de modo a refletir o valor lógico fuzzy resultante do antecedente. A maneira mais comum para modificar o conjunto

fuzzy de saída é a função *min* que trunca a função, onde o conjunto fuzzy é cortado como mostrado abaixo na Figura 2.18.




Figura 2.18 – Método de Implicação *min*.

De forma geral, somente uma única regra fuzzy não realiza trabalho algum. Para um verdadeiro sistema fuzzy funcionar são precisos algumas regras trabalhando conjuntamente. A saída de cada regra é uma função de pertinência, mas a saída do sistema fuzzy é um simples número real. Como todas as funções de pertinência de cada regra são avaliadas para resultar num único número? A próxima seção mostra como todo o processo funciona, como se dá a construção de um verdadeiro sistema fuzzy. Desde a fuzzificação das variáveis de entrada até a agregação de todas as funções de pertinência de cada regra onde o processo de defuzzificação toma forma e é gerado um número real (saída final de todo o processo).

2.3.3 - SISTEMAS FUZZY

Os sistemas fuzzy mapeiam valores numéricos das variáveis de entrada para valores numéricos das variáveis de saída, utilizando-se de um processo de inferência baseado na lógica fuzzy. Este processo envolve todos os tópicos discutidos anteriormente: funções de pertinência, operadores lógicos fuzzy, e regras *If-Then*.

Os sistemas fuzzy tem sido aplicados com sucesso em campos tão variados como, controle automático, classificação de dados, sistemas especialistas, etc. Por causa desta natureza multidisciplinar o sistema fuzzy é conhecido por muitos nomes, tais como,

Sistemas Baseados em Regras Fuzzy, Sistemas Especialistas Fuzzy, Modelo Fuzzy, Controlador Fuzzy, ou simplesmente Sistemas Fuzzy.

Nesta seção será visto como tudo junto trabalha de uma forma específica no problema da fábrica de celulose. A estrutura básica do exemplo é mostrada na Figura 2.19.




Figura 2.19 – Estrutura Básica do Sistema Fuzzy.

FUZZIFICAÇÃO DAS ENTRADAS

O primeiro passo é tomar as entradas e determinar o grau de pertinência de cada uma das entradas devido a cada uma das funções de pertinência. A entrada é sempre um valor numérico real limitado ao universo de discurso das variáveis de entrada (neste caso o intervalo entre 0 e 10) e a saída é um grau de pertinência (sempre entre 0 e 1). O processo de fuzzificação das entradas nada mais é do que uma avaliação de uma função.

APLICAÇÃO DOS OPERADORES FUZZY

Uma vez que as entradas tenham sido fuzzificadas, cada parte do antecedente de uma regra If-Then é então conhecida, logo pode-se aplicar as operações lógicas fuzzy para obter o número que representa o resultado lógico "verdade" do antecedente da regra específica. O resultado lógico "verdade" é um número real.

Como descrito na seção anterior (2.3.2) sobre operações lógicas fuzzy, qualquer método bem definido pode preencher a operação AND ou a operação OR. Os dois métodos apresentados anteriormente são: *min* (minimum) para AND e *max* (maximum) para OR.

Como o operador max funciona? Suponha por exemplo que está sendo avaliado o antecedente da regra 3 do problema da Fábrica de Celulose Estendido:

3. ***If*** madeira ***is*** excelente ***or*** ácido ***is*** bom ***Then*** temperatura ***is*** pequena.

Supondo que as duas diferentes partes do antecedente (madeira ***is*** excelente e ácido ***is*** bom) rendem graus de pertinência 0.0 e 0.7, por exemplo. O operador lógico fuzzy OR seleciona simplesmente o maior valor entre os dois, qual seja, 0.7, e a operação lógica fuzzy para a Regra 3 está completa.

MÉTODO DE IMPLICAÇÃO

O método de implicação consiste em dar uma nova forma à função de pertinência do conseqüente de uma regra devido ao valor numérico resultante do processo de operação da lógica fuzzy sobre os antecedentes da regra. A entrada para o processo de implicação é simplesmente um número real e a saída é uma função de pertinência. O processo de implicação ocorre para cada regra do sistema fuzzy. O método de implicação mais comum utilizado é o método **min**, que trunca a função de pertinência original resultando num novo formato para a função de pertinência (Figura 2.18).

AGREGAÇÃO DE TODAS AS SAÍDAS

A agregação de todas as funções de pertinência resultantes do processo de implicação em cada um das regras gera uma função de pertinência única. Esta função de pertinência única será a entrada para o último passo de cálculo do sistema fuzzy: a defuzzificação. O método de agregação mais comumente utilizado é o método **max**, que junta todas as funções de pertinência (ver Figura 2.20).




Figura 2.20 – Agregação de Todas as Saídas.

DEFUZZIFICAÇÃO

A entrada para o processo de defuzzificação é uma função de pertinência (esta função de pertinência é resultante do processo de agregação) e a saída é um número real. O sistema fuzzy apesar de levar em conta toda a disponibilidade de uma nova ferramenta através da lógica fuzzy tem como entrada números reais e como saída números reais. O mais popular método de defuzzificação é o centróide, que calcula o centro de uma área sob uma curva (Figura 2.21).



Figura 2.21 – Defuzzificação.

2.3.4 - UM POUCO DA HISTÓRIA

A história da aplicação prática da lógica fuzzy passa obrigatoriamente pela história japonesa da lógica fuzzy. Os japoneses foram os primeiros a aplicarem em larga escala os benefícios desta nova ferramenta. O início da história conta-se desde o final dos anos 70 até o início dos anos 80, onde o esforço de alguns grupos universitários de pesquisa de levar a lógica fuzzy até os engenheiros japoneses foi a base indispensável da indústria japonesa da lógica fuzzy. Suas atividades residiam em: buscar cooperação com companhias privadas, publicar livros textos de fácil entendimento escritos em japonês, empreender uma série de seminários sobre tecnologia fuzzy, e fazer arranjos para convidar pesquisadores fuzzy talentosos de toda a parte do mundo para participar destes seminários. Sempre buscando privilegiar a parte prática da aplicação desta nova ferramenta, a qual esperavam poderia ser de grande interesse das companhias japonesas.

Desde meados da década de 80 até o final, foram testadas várias aplicações fuzzy industriais, as duas mais importantes e pioneiras que resultaram em aplicações práticas reais foram os sistemas fuzzy da Hitachi e da Fuji-Electric. O sistema fuzzy da Hitachi era para Operação Automática de Trens (OAT). Onde um OAT-PID foi substituído por um OAT-Fuzzy numa operação real de uma estação do metrô de Sendai em julho de 1987, após vários anos de testes.

O sistema desenvolvido pela Fuji Electric era um sistema de tratamento de água. Usualmente levavam-se 5 anos para um operador novato se tornar experiente na operação do processo de purificação de água. O processo usualmente requer um controle de malha aberta baseado na experiência humana, por não existir nenhum modelo matemático razoável baseado em equações diferenciais para o processo de tratamento de água. A implementação de um sistema de controle automático baseado nas técnicas tradicionais era difícil. Como resultado da implementação prática real deste sistema fuzzy, a Fuji Electric desenvolveu e ofereceu no mercado o primeiro controlador fuzzy japonês para aplicações gerais, denominado FRUITAX, em 1985. Este controlador estava baseado num

computador de 16 bits rodando um software de inferência fuzzy programado em FORTRAN.

Estes dois exemplos serviram como motivação para que outros engenheiros tomassem parte na comunidade fuzzy. No final da década de 80 a Agência de Ciências e Tecnologia do governo japonês começou a estudar a possibilidade de um projeto de pesquisa nacional em lógica fuzzy. Este projeto consistia no aporte de 8,4 milhões de dólares por 5 anos, onde grupos de várias universidades, laboratórios nacionais e companhias privadas ficavam responsáveis por um estudo de um tema particular relativo à lógica fuzzy.

Outro projeto muito importante à nível nacional dentro do Japão foi o LIFE (Laboratory for International Fuzzy Research) que demandou uma quantia de 5,8 milhões de dólares por ano, durante 6 anos, para construção de um prédio de laboratórios na cidade de Yokohama. Foram mandados para o LIFE aproximadamente 30 pesquisadores de várias empresas, tais como, Canon, Hitachi, Fujitsu, IBM – Japonesa, Matsushita, Sharp, Olympus, Toyota, Toshiba, Sony, Mazda, etc.

Em 1990, as principais corporações da Europa começaram a pesquisar e desenvolver atividades em lógica fuzzy porque suas congêneres japonesas estavam ganhando mercado. Exemplos de grandes companhias européias que começaram suas forças tarefas em lógica fuzzy incluem SGS-Thomson da França e da Itália, como também, Siemens e Daimler-Benz da Alemanha.

No Japão a maioria das aplicações práticas da lógica fuzzy foram em controle, ao passo que nos Estados Unidos a maioria das aplicações contam-se na área de suporte à decisão e análise de dados. Uma possível explicação para este fato reside na força e na debilidade do conjunto das indústrias destes países. A força da indústria japonesa são exatamente os produtos eletroeletrônicos para consumidores, tais como, câmeras de vídeo, máquinas fotográficas com auto-focus, carros com sistemas ABS e caixa de marcha automática, etc. Pode-se ainda considerar que a automação dos escritórios japoneses permanece na infância da tecnologia.

Nos Estados Unidos a situação é diferente. O processamento da informação e a automação dos escritórios atingiram altos níveis de sofisticação. Então, muitas das aplicações de lógica fuzzy nos Estados Unidos estão na área de suporte à decisão e análise de dados, tais como, apoio à decisão financeira, detecção de fraude com cartão de crédito, reconhecimento da voz, reconhecimento de texto manuscrito, etc. Considerando também a grande disponibilidade de fontes naturais de energia e matéria prima (óleo e água), comparado ao Japão, não foi criada uma pressão por produtos domésticos altamente otimizados utilizando controle inteligente. Além do mais muito destes produtos (câmeras de vídeo, TV, Som stereo, máquinas fotográficas) são importados. A existência de uma força de trabalho flexível, e de baixo custo tributário não requereu que a automação industrial fosse empurrada até os seus limites.

Na Europa o custo social da força de trabalho é muito maior do que nos Estados Unidos e no Japão. Em adição, devido a leis trabalhistas mais restritivas, a força de trabalho não é flexível. Isto pode explicar porque as aplicações de lógica fuzzy na Europa contam-se em sua maioria na área da automação industrial. Uma outra razão é que na Europa, alguns dos fabricantes de sistemas de automação industrial, tais como Siemens, Telemecanique, AEG-Modicon, ABB e Bosch, adotaram e promoveram soluções fuzzy desde o início (Yen, Langari and Zadeh, 1995).

2.3.5 - APLICAÇÕES EM SISTEMAS DE POTÊNCIA

A teoria dos conjuntos fuzzy, após sua concepção pelo Professor Lotfi Zadeh no início da década de 60, só alcançou a comunidade dos engenheiros de sistemas de potência 30 anos depois. Poucas foram as publicações nesta área durante estes trinta anos.

Com a penetração da teoria fuzzy nas indústrias e nos produtos eletrônicos, aplicações em sistemas de potência estão começando a receber a atenção dos pesquisadores. Conjuntos fuzzy foram introduzidos primeiro na solução de problemas de decisão de longo prazo em sistemas de potência em 1979, entretanto, o interesse em suas aplicações para a área é recente.

Existem soluções analíticas para muitos problemas de controle, planejamento e operação de sistemas de potência. Entretanto, as formulações matemáticas de problemas do mundo real são derivadas sob certas suposições restritivas, e mesmo sob estas suposições, a solução de uma vasta gama de problemas não é trivial. Além disso, em vários problemas de sistemas de potência estão envolvidos consideráveis níveis de incerteza, devido ao comportamento de seus componentes, à sua grandeza, complexidade e ao ambiente no qual o sistema opera. Estes fatos fazem com que seja difícil lidar, de uma maneira efetiva, com alguns problemas através estritamente de uma formulação matemática. O número crescente de publicações de aplicações de fuzzy indica seu potencial na solução dos problemas.

Através de um levantamento bibliográfico, de aproximadamente 250 publicações na área de sistemas de potência (Lambert-Torres, *et al.*, 1998), constatou-se a seguinte distribuição: 20% em planejamento, 37% em operação, 33% em controle e 10% em diagnóstico. Conforme Bansal (Bansal, 2003) verifica-se que o maior número de aplicações em sistemas de potência enquadra-se na área de sinais estabilizadores, seguido pela área de controle de tensão/potência reativa.

Pode-se observar que a aplicação de técnicas fuzzy aos problemas dos sistemas elétricos vem aumentando, inclusive sendo hoje utilizada não mais isoladamente, mas com outras ferramentas clássicas (baseadas em elementos tradicionais da matemática), e em conjunto com outras ferramentas mais modernas (redes neurais, sistemas especialistas e algoritmos genéticos). Esta é uma importante tendência para futuras aplicações.

O que se está buscando na atualidade é a confecção de sistemas híbridos, os quais fundem as diversas teorias, explorando melhor as características de uma teoria e suprimindo sua falta de desempenho por outra. Como exemplo deste tipo de sistema híbrido, pode-se destacar:

- a) As aplicações de previsão de carga, onde redes neurais trabalham em conjunto com sistema especialistas difusos

b) No problema de programação da geração, onde diversos elementos que não eram muito bem modelados através das grandezas usuais e que com a utilização das técnicas difusas podem gerar sistemas mais flexíveis (no caso, fluxos de potência ótimo).

Tendo em vista seus conceitos básicos, a lógica fuzzy pode ser aplicada em três tipos de problemas:

a) onde o volume de dados não é suficiente para que técnicas que têm facilidade em lidar com grandes massas de dados façam o trabalho, como é o caso da teoria das probabilidades e das redes neurais

b) em problemas complexos, onde o modelo matemático é de difícil estruturação, como em certos problemas de modelagem (por exemplo, comportamento futuro da carga) e de controle (por exemplo, auto ajuste de controladores)

c) e em problemas que são mais facilmente descritos através de valores qualitativos/lingüísticos (por exemplo, processos de tomada de decisão).

Em geral, as incertezas ou imprecisões tendem a aumentar em tamanho e complexidade conforme a modelagem do problema se afasta da avaliação em tempo-real. De qualquer forma, existem incertezas a serem caracterizadas já em tempo-real: cargas, medidas/observações, representação externa das redes supervisionadas, etc. No longo-prazo, as variáveis e o tipo de incerteza são obviamente diferentes, usualmente relacionadas a inovações tecnológicas, economia, etc. No planejamento a longo prazo, a utilização de fuzzy seria mais adequada. Entretanto, há exemplos bem formulados de aplicações fuzzy em tempo-real.

Em uma grande maioria dos problemas da área de potência, o objetivo é sempre minimizar custos. Tais custos podem envolver, entre outros, a produção de energia, investimentos, manutenção/interrupção, etc. São classificados de simples e múltiplos; os objetivos múltiplos são em geral conflitantes. Em ambos os casos, tais objetivos podem ser

modelados via fuzzy. No caso específico de múltiplos objetivos, fuzzy é reconhecidamente uma excelente opção para balancear tais conflitos. Por exemplo, considerando um conflito básico da área de planejamento da expansão, se os custos de produção, financeiros e interrupção são considerados na função objetivo, um aumento na capacidade de geração, por novos investimentos, diminui os custos de interrupção. Ao contrário, em estratégias de expansão em que não há investimentos em novas unidades geradoras, o custo de produção e de investimentos diminui, tendo em contra partida um aumento dos custos de interrupção. O balanceamento de tais objetivos pode ser idealizado por ferramentas fuzzy

2.4 – SISTEMA NEURO-FUZZY

Em vista de suas similaridades, os sistemas fuzzy e as redes neurais são adequadas para solução de muitos problemas semelhantes, e suas diferenças têm feito surgir um recente ímpeto de interesse na combinação de um sistema funcional para superar suas fraquezas individuais. Esta idéia inovadora procura integrar os benefícios de ambos os sistemas.

As redes neurais suprem os sistemas fuzzy com capacidade de aprendizagem, e os sistemas fuzzy provêm as redes neurais com uma estrutura de alto nível de raciocínio, através de regras If-Then. Conseqüentemente, as duas tecnologias são complementares, com a rede neural suprindo a força bruta necessária para acomodar e interpretar uma grande massa de dados, e a lógica fuzzy provendo uma estrutura que utiliza e explora estes resultados. A maioria dos produtos neuro-fuzzy são sistemas baseados em regras fuzzy em que as redes neurais são utilizadas para ajustar de modo preciso e automático a resposta do sistema fuzzy (Lin and Lee, 1996).




Figura 2.22 – Sistema Fuzzy Tipo Takagi-Sugeno

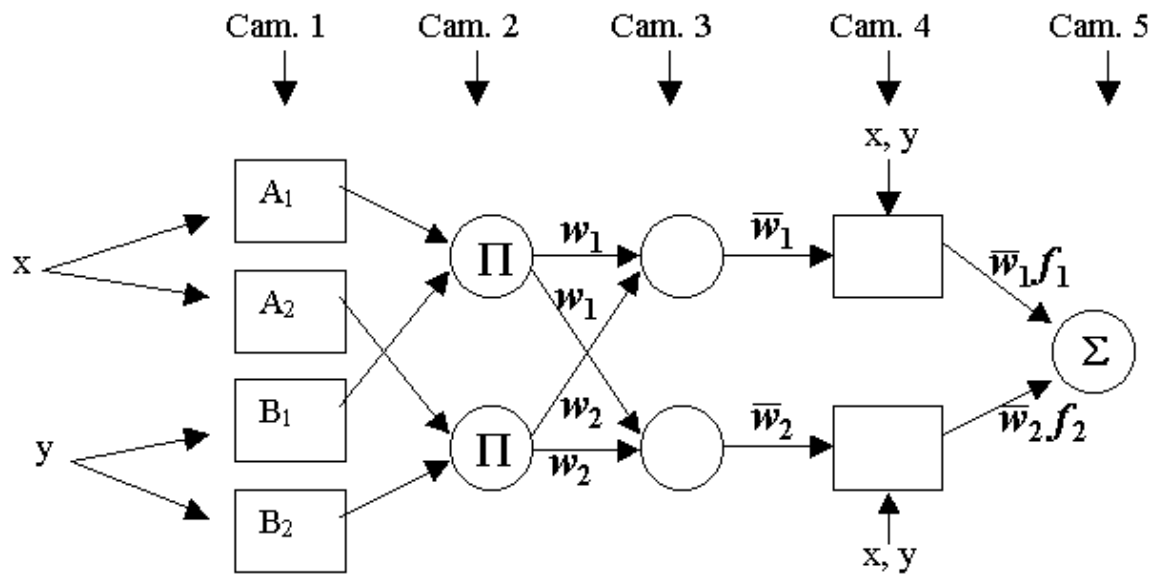


Figura 2.23 – Arquitetura ANFIS

Considerando um sistema fuzzy com duas entradas (x,y) e uma saída (z), por simplificação, e supondo que a base de regras contém duas regras If-Then fuzzy do tipo Takagi-Sugeno tem-se:

Rule 1: If x is A₁ and y is B₁ then f₁ = p₁x + q₁y + r₁

Rule 2: If x is A₂ and y is B₂ then f₂ = p₂x + q₂y + r₂

O sistema fuzzy é apresentado na Figura 2.22 e a arquitetura ANFIS equivalente é apresentada na Figura 2.23 (Jang, 1993). As funções dos nós de cada camada são descritas abaixo:

Camada 1: Cada nó i desta camada terá seus parâmetros treinados por um algoritmo de aprendizagem. Estes nós tem a seguinte função,

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

onde x é a entrada para o nó i , e A_i é a função lingüística (tensão pequena, corrente grande, etc.) associada com a função do nó.

Em outras palavras, O_i^1 é um valor real especificando o grau de pertinência para qual o x dado satisfaz a função de pertinência A_i . Usualmente esta função tem a forma de uma Gaussiana, com o valor máximo igual a 1 e o valor mínimo igual a 0. Tal que,

$$\mu_{A_i}(x) = \frac{1}{1 + \left[\left(\frac{x - c_i}{a_i} \right)^2 \right]^{b_i}}$$

ou

$$\mu_{A_i}(x) = \exp \left\{ - \left(\frac{x - c_i}{a_i} \right)^2 \right\}$$

onde $\{a_i, b_i, c_i\}$ é o conjunto dos parâmetros.

Como os valores destes parâmetros vão mudar pelo treinamento, a forma das funções Gaussianas varia de acordo com a mudança destes parâmetros, exibindo várias formas de funções de pertinência sobre as funções lingüísticas A_i . Estas mudanças é que

serão responsáveis, em parte, pelo ajuste fino da resposta do sistema fuzzy. Os parâmetros desta camada são conhecidos como os parâmetros da premissa.

Camada 2: Todos os nós i desta camada não sofrerão treinamento, e multiplicam os sinais de entrada enviando o produto para a saída. Por exemplo,

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

Cada nó de saída representa a força de disparo de uma regra (de fato, outros operadores que executam a função lógica AND generalizada podem ser usados como a função do nó desta camada).

Camada 3: Os nós i desta camada não sofrerão nenhuma mudança devido ao algoritmo de treinamento, estes nós são fixos. O i -ésimo nó calcula a razão entre a força de disparo da i -ésima regra e a soma das forças de disparo de todas as regras:

$$\bar{w}_i = \frac{w_i}{w_1 + w_2}, \quad i = 1, 2.$$

Camada 4: Todos os nós i desta camada também terão os seus parâmetros treinados. Os nós desta camada tem a seguinte função

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

onde w é a saída da camada 3, e $\{a_i, b_i, c_i\}$ é o conjunto dos parâmetros.

Os parâmetros desta camada são conhecidos como os parâmetros do conseqüente.

Camada 5: Esta camada contém um único nó, que calcula a saída global do sistema como um somatório de todos os sinais de entrada, ou seja,

$$O_i^5 = \sum_i \bar{w}_i f_i = \frac{\sum_i w_i f_i}{\sum_i w_i}$$

Todos os nós e todas as camadas explicitadas acima constituem uma rede neural que é funcionalmente equivalente a um sistema fuzzy. Por poder-se interpretar o sistema fuzzy como uma rede neural, lançam-se mão então dos algoritmos de treinamento das redes neurais para se ajustar os parâmetros de um sistema fuzzy.

2.5 – CONCLUSÕES

As razões que levam ao estudo e à aplicação das técnicas de IA podem ser resumidas em: (1) os sistemas inteligentes tem capacidade intrínseca de aprender de dados de entrada e generalizar; (2) estas técnicas não requerem o modelo matemático exato do sistema; (3) oferecem uma maneira simples, porém robusta, de implementar soluções que cubram um grande intervalo de valores dos parâmetros do sistema e que levem em consideração grandes distúrbios; e (4) a simplicidade do conceito torna-o de fácil implementação.

Considerando as razões acima e que grande parte dos problemas de sistemas de potência possuem características que podem ser abordadas pelas técnicas aqui estudadas, conclui-se esse capítulo com a certeza de que as técnicas de IA tem um grande potencial de aplicação para a solução do problema de avaliação da estabilidade de tensão.

Capítulo 3

Estabilidade de Tensão: Conceitos e Critérios

3.1 - INTRODUÇÃO

A instabilidade de tensão está fortemente associada à deficiência no suporte de reativo do sistema. Essa deficiência se manifesta, por exemplo, em uma situação na qual os principais troncos de transmissão encontram-se operando próximos aos seus limites de máxima transferência e as reservas de geração de potência reativa nos centros de carga estão praticamente esgotadas.

Para grandes perturbações no sistema provocadas, por exemplo, por curto-circuitos, desligamentos de linhas de transmissão, etc., a instabilidade de tensão pode se manifestar imediatamente (poucos segundos) após a perturbação, de forma similar ao problema de instabilidade angular (**instabilidade de tensão transitória**), ou decorrido algum tempo (vários minutos) após a perturbação, através da degradação lenta do perfil de **tensões** (**instabilidade de tensão de longo prazo**).

A instabilidade de tensão transitória é influenciada fortemente por componentes da carga com dinâmica rápida (motores de indução, por exemplo) e dispositivos rápidos de controle de tensão. No caso da instabilidade de tensão de longo prazo, os principais responsáveis pelo fenômeno são os transformadores com comutação automática de tap sob carga (LTC), os limitadores de sobreexcitação dos geradores (OXL), cargas termostáticas, chaveamento de bancos de capacitores e indutores, controle secundário de tensão, variação temporal da carga, etc.

Os métodos de avaliação da estabilidade de tensão podem ser divididos em duas categorias: estáticos e dinâmicos. Os métodos estáticos baseiam-se na análise de sistemas de equações algébricas obtidas a partir do modelo de fluxo de potência em sua versão convencional ou modificada. Os métodos dinâmicos, em geral, baseiam-se em soluções no tempo de sistemas de equações diferenciais e algébricas representando o desempenho dinâmico dos componentes do sistema. Embora o fenômeno da instabilidade de tensão seja essencialmente dinâmico, os métodos estáticos são importantes pela sua eficiência computacional e pelas informações que produzem com relação a sensibilidades e margens de estabilidade. Os métodos de simulação, por sua vez, reproduzem de forma mais precisa o comportamento do sistema e são a única forma de se determinar a cronologia dos eventos que, eventualmente, conduzem a uma situação de instabilidade.

Os métodos dinâmicos são indispensáveis no estudo da instabilidade de tensão transitória pois somente com esse tipo de método é possível representar, de forma precisa, o comportamento dos componentes do sistema com resposta rápida. A instabilidade de tensão de longo prazo pode também ser estudada por métodos dinâmicos, devido à necessidade da representação da cronologia dos eventos, porém não exige, necessariamente, uma representação precisa dos efeitos transitórios mais rápidos. Métodos baseados em modelos simplificados da dinâmica do sistema, levando em consideração apenas os aspectos relevantes à avaliação da estabilidade de tensão, têm sido utilizados com sucesso nesse tipo de estudo (Van Cutsem, *et. al.*, 1995).

Os fatos expostos anteriormente levaram os engenheiros de planejamento e de operação a questionarem-se constantemente em alguns pontos, tais como: *quão distante está operando o sistema do ponto de instabilidade ?; ou, haveria um índice capaz de quantificar esta “distância” ?; quais poderiam ser as causas de uma eventual instabilidade de tensão para este sistema ?; e quais seriam as ações de controle que evitariam o fenômeno da instabilidade ?*

No sentido de procurar responder as principais preocupações dos engenheiros de sistemas de potência, e de apresentá-las de forma organizada e concisa é que se estrutura este capítulo da seguinte forma:

Na seção 3.2 é traçado um resumo sobre as principais causas e os principais efeitos nos sistemas de potência quando da ocorrência do fenômeno da instabilidade de tensão, com algumas considerações sobre as duas principais abordagens utilizadas nos estudos.

Na seção 3.3 é apresentado o equacionamento do Método da Continuação e as principais diretrizes sobre a utilização deste método no estudo da estabilidade de tensão.

Apresenta-se em 3.4 um estudo operativo elaborado para o ONS (Operador Nacional do Sistema Elétrico) considerando a perda de um barramento no Sistema Nordeste em que foram utilizados os critérios de avaliação de Estabilidade de Tensão relacionados nas seções 3.2 e 3.3.

A seção 3.5 efetua uma conclusão dos levantamentos feitos neste capítulo.

3.2 – O ESTUDO DA ESTABILIDADE DE TENSÃO

Nos últimos anos aconteceram vários incidentes envolvendo problemas relacionados ao controle de tensão. Alguns deles evoluíram para o colapso de tensão, como por exemplo, o colapso no sistema Francês em 1978 e 1987, o colapso no sistema da Suécia em 1983, os colapsos no sistema da Flórida (EUA) em 1985, e no sistema do Japão em 1987 (Taylor,1994).

Convencionou-se denominar este problema de estabilidade de tensão, que envolve três aspectos básicos: o distúrbio ao qual a rede de energia elétrica é submetida; as características da carga; e os controles disponíveis para a manutenção de um nível aceitável para a magnitude de tensão (Taylor,1994). Estes aspectos, que interagem

fortemente entre si, afetam a habilidade da rede em transferir potência reativa do centro gerador ao centro consumidor.

Nesta seção são apresentadas as definições básicas para o entendimento do fenômeno da instabilidade de tensão, assim como os critérios atualmente utilizados no sistema elétrico brasileiro para definir a segurança do ponto de operação em relação à estabilidade de tensão.

3.2.1 – CONCEITOS E DEFINIÇÕES BÁSICAS

Com o aumento do interesse e da quantidade de pesquisas na área de estabilidade de tensão, passou a ter grande importância a sua classificação dentro do contexto da “estabilidade de sistemas de potência”.

Os termos estabilidade de tensão e estabilidade angular (ou estabilidade do rotor) possuem uma forte ligação entre si, o que causa certa dificuldade em separar as formas de evolução destes fenômenos. Muitas vezes a estabilidade de tensão está relacionada com problemas de natureza angular. Entretanto, na maioria das vezes, existe uma certa predominância de uma forma em relação a outra, o que permite que a análise seja feita focando-se aspectos específicos para cada caso.

O problema da instabilidade de tensão, idealmente deveria ser tratado utilizando-se técnicas analíticas e computacionais que levassem em consideração a natureza dinâmica da rede elétrica. A palavra “*estabilidade*” implica um sistema dinâmico. Entretanto em algumas circunstâncias, a instabilidade de tensão se processa de forma dinâmica lenta, o que possibilita a aplicação de uma série de algoritmos numéricos estáticos na análise de uma variedade de problemas relativos à operação dessas redes.

O fenômeno da *instabilidade de tensão* apresenta como característica própria a progressiva depreciação da tensão (processo iniciado por um carregamento desordenado,

ou contingência) atingindo em certos casos uma condição de equilíbrio cujos valores de magnitude são inaceitáveis, o que caracteriza o **colapso de tensão**.

O problema do colapso de tensão não deve ser confundido com os problemas normais de queda de tensão que acontecem durante a operação diária do sistema. Apesar do sistema poder apresentar instabilidade de tensão sem se caracterizar o colapso, desejável seria que o sistema não fosse sujeito nem mesmo a esta instabilidade, e que o estado pós-distúrbio equilibrado do sistema apresentasse um perfil de tensões com valores dentro de limites aceitáveis. Ou seja, neste caso o sistema permaneceria estável depois que se seguisse uma contingência significativa ou um aumento exagerado de carga. O sistema poderia ser assim denominado **seguro em relação à tensão**.

A instabilidade de tensão envolve os seguintes aspectos básicos:

- As características da carga, sob o ponto de vista da rede nos níveis mais altos de tensão;
- Os recursos disponíveis para o controle de tensão na rede, os quais influem na habilidade da rede em transmitir potência, particularmente potência reativa, do ponto de produção ao ponto de consumo;
- distúrbio ao qual a rede pode ser eventualmente submetida.

Os distúrbios afetam a configuração dos fluxos de reativo da rede e principalmente a resposta da carga em relação à variações na tensão, atingindo equipamentos importantes para a manutenção do equilíbrio de potência reativa. Um distúrbio de particular interesse ao estudo da estabilidade de tensão é o do súbito carregamento do sistema. Por outro lado, durante todo o processo de decaimento da tensão, as cargas apresentam sensibilidades diversas em relação à variação da magnitude da tensão. Cada tipo de carga tem sua resposta específica para o distúrbio considerado. Os equipamentos responsáveis pelo controle do balanço de potência reativa do sistema (geração de reativo, tapes dos

transformadores, bancos de capacitores, cortes de carga por subtensão, etc.), são de fundamental importância para a determinação da segurança do sistema.

As duas questões básicas que se colocam no estudo da instabilidade de tensão consistem em determinar se o sistema é seguro em relação à tensão e determinar quais ajustes que devem ser realizados para que o mesmo encontre um ponto de operação satisfatório.

3.2.2 – CRITÉRIOS DE DESEMPENHO

A literatura tem apresentado uma extensa lista de publicações que analisam o problema de estabilidade de tensão, tanto estática quanto dinamicamente (Ajarapu and Lee, 1998). Embora o problema de estabilidade de tensão possua característica dinâmica, existem várias abordagens que analisam o problema como estático, fazendo uso da suposição de que o processo de instabilidade de tensão acontece lenta e progressivamente, proporcionando desta forma, condições para que a avaliação do problema envolva somente a resolução do conjunto de equações do fluxo de potência. Este tipo de análise é computacionalmente mais eficiente que a análise dinâmica. A abordagem estática apresenta limitações quanto à indicação da ocorrência da instabilidade, embora seja um bom indicativo da tendência de instabilidade do sistema.

Desde que o problema de instabilidade de tensão está fortemente relacionado a uma condição de operação estressada, necessário se faz estudar o comportamento do sistema em pontos de alto carregamento, tal que seja possível determinar uma “margem” de segurança para propósitos de análise da estabilidade de tensão.

Através de sucessivas soluções de fluxo de carga, é possível obter uma curva P-V que mostra o comportamento da tensão das barras do sistema para cada nível de carregamento utilizado, conforme pode ser observado na Figura 3.1.




Figura 3.1 – Curva P-V

O “extremo” da curva é denominado ponto crítico, ou ponto de bifurcação estática. Este ponto pode ser interpretado da seguinte maneira: para uma condição de carga, em adição a solução normal do fluxo de carga, que é tipicamente o ponto de operação atual, muitas outras soluções podem ser encontradas. A solução mais próxima ao ponto de equilíbrio estável (operação atual) é o ponto de equilíbrio instável. Estes pontos de equilíbrio se aproximam um do outro enquanto o sistema for sendo carregado, até o ponto onde somente uma única solução existe.

Neste ponto de bifurcação, um autovalor real do Jacobiano do fluxo de carga se torna zero, isto é, a matriz $[J]$ se torna singular. Logo, para pontos de operação próximos ao ponto crítico, esta se torna numericamente mal - condicionada.

Pode-se observar na Figura 3.1 que existem sempre dois níveis de tensões para transmitir-se o mesmo valor de potência. Embora teoricamente seja possível o sistema operar na parte inferior da curva, isto não é levado a efeito na prática, pois para se produzir a potência necessária com uma tensão com valor reduzido seriam necessários altos valores de corrente, o que não é uma situação aconselhável e nem segura para a operação de um sistema de potência.

O limite de carregamento estático da rede (ponto crítico da curva P-V) não é necessariamente o limite de instabilidade de tensão. A instabilidade e o colapso de tensão

podem vir bem antes do ponto crítico, que representa um limite da rede baseado num específico padrão de carregamento-geração (Taylor, 1994).

O colapso de tensão ocorre para pontos na parte superior da curva P-V, para situações de extremo carregamento, causado por distúrbio que provoca um desbalanço entre a produção e o consumo de potência reativa. Nesta situação crítica, o sistema está muito sensível a variações de carga. Variações estas que obedecem características próprias e de difícil determinação relativas a dinâmica da carga.

Uma margem de potência reativa efetiva é uma indicação da segurança de tensão ou robustez do sistema em relação à estabilidade de tensão de longo-termo envolvendo grandes distúrbios (Sodré, Almeida e Salgado, 1997), (WSCC, 1998). Para facilitar ainda mais a análise de segurança é desejável que os operadores do sistema disponham de atualizações em tempo real da curva de capacidade dos geradores.

Além dos estudos baseados em simulação, para determinação da reserva rápida de potência reativa, pode-se recorrer a outros critérios que devem ser atendidos para que o sistema possa ser dito seguro em relação à instabilidade de tensão. O Índice Margem, baseado na análise da curva P-V, é uma das mais importantes indicações da segurança de tensão do sistema em relação à instabilidade de tensão de longo-termo envolvendo grandes distúrbios. Este índice quantificado numa suposta margem do ponto de operação ao ponto de máxima transferência de potência, está baseado numa análise matemática do conjunto de equações algébricas não-lineares do fluxo de carga.

A Figura 3.2 ilustrando a obtenção deste índice, mostra duas curvas P-V's para duas situações diferentes: uma situação de operação corrente e um ponto de operação pós-distúrbio. A margem de carregamento MC_{oa} (operação atual) é maior que a margem de carregamento do ponto de operação pós-distúrbio, MC_{pd} . A curva P-V devida ao ponto de operação pós-distúrbio também apresenta uma relação de variação da tensão (ΔV) em relação à potência (ΔP), maior que a curva P-V devida à operação atual.

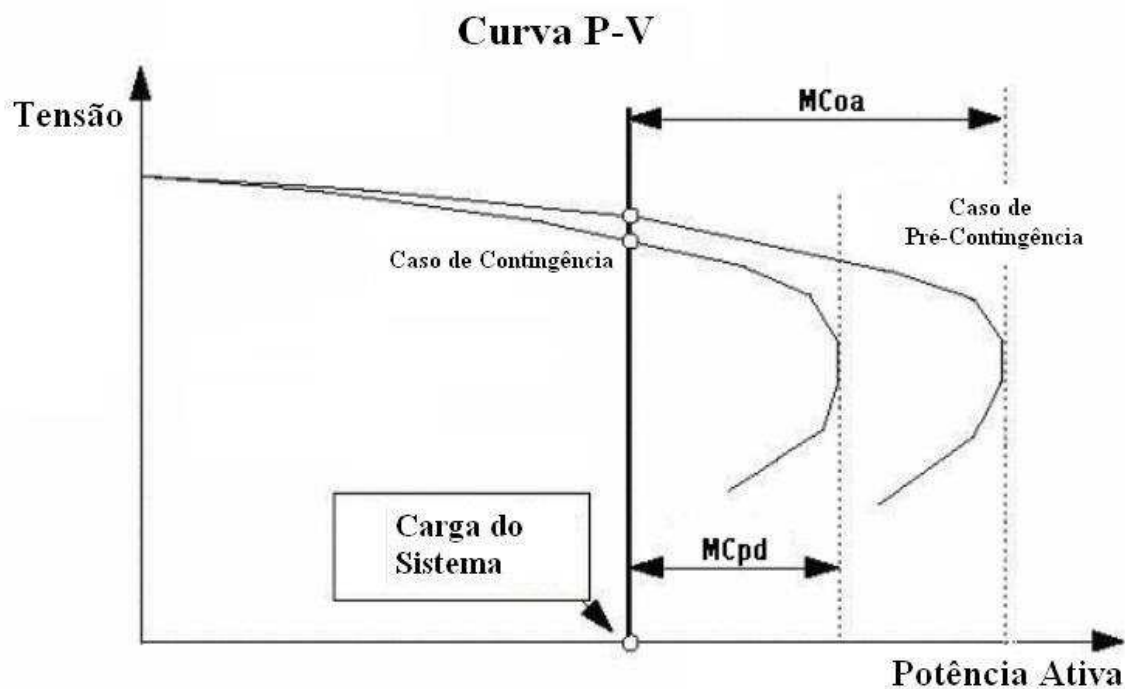


Figura 3.2 – Curva P-V

Quanto menor for a distância do ponto de operação ao ponto crítico, maior a possibilidade do sistema apresentar problemas se for submetido a um distúrbio. Posto que, quanto mais próximo do ponto extremo da curva o ponto de operação estiver, mais as tensões apresentarão o comportamento de grande declínio em função de pequenas variações de carga. Estas variações de carga são devidas à grande parcela de potência reativa que se apresenta no pico de demanda do sistema.

3.2.3 – DIRETRIZES E CRITÉRIOS PARA ESTUDOS

Nesta seção são apresentadas as diretrizes utilizadas pelo ONS para os estudos de estabilidade de tensão. Vale ressaltar que este tipo de estudo está inserido no rol dos estudos especiais, ou seja, faz parte do conjunto dos estudos que são efetuados quando da comprovação de sua necessidade por algum dos agentes do sistema (ONS, 2002). Outra valiosa informação apresentada são os critérios que devem ser utilizados para a avaliação da condição de operação do sistema em seguro ou inseguro.

No âmbito dos estudos para ampliações e reforços da rede básica a abordagem para investigações da estabilidade de tensão tem a finalidade principal de avaliar qualitativamente as diversas opções de obras vislumbradas, apontando possíveis complementos de obras ou equipamentos, e podendo alterar a ordem das prioridades das opções. Além disso, a proposição adequada de ampliações e reforços da Rede Básica sob o ponto de vista de estabilidade de tensão permitirá a desativação dos esquemas especiais de corte de carga em regime permanente e da maioria dos esquemas de corte em emergência hoje existentes em todo o Brasil. No âmbito de estudos operacionais, a análise de estabilidade de tensão em regime permanente tem por finalidade a verificação de necessidade de definição de condições especiais de operação ou de implantação de esquemas especiais de corte de carga, inserção de capacitores, etc.

Nas análises sob o ponto de vista de ampliação e reforços, uma abordagem prática é a utilização dos métodos ditos estáticos, que possibilitam grande varredura de situações que o sistema pode ficar submetido, buscando-se envoltórias das situações em que o sistema pode ser considerado estável. O levantamento de curvas P-V's se mostrou a metodologia mais adequada para a determinação das margens de estabilidade.

Deve ser observado que numa análise em regime permanente através do Fluxo Continuado existem algumas considerações que influenciam a margem que foi computada:

1. – Modelagem das cargas ativa e reativa
2. – Fator de potência mantido constante
3. – Aumento da carga do sistema completo ou aumento apenas de uma região específica do sistema.
4. – Representação dos LTC's
5. – Redespacho dos geradores para incremento de carga

A seguir são feitas algumas considerações com o objetivo de esclarecer as questões acima e também são explicitadas as margens de carregamento que são utilizadas como critérios no Sistema Brasileiro.

Se o modelo real das cargas não é conhecido, pode-se utilizar testes em campo para uma modelagem mais adequada, ou mesmo recorrer aos programas de modelagem. Atualmente ainda não se dispõe de modelos mais apurados, sendo recomendada a utilização do modelo de carga tipo potência constante para as componentes ativa e reativa;

Assim como o modelo da carga, o fator de potência também exerce importante papel na determinação das margens de potência do sistema. Em princípio os fatores de potência devem permanecer constantes no processo de incremento da carga.

A ação automática dos tapes, em algumas situações, pode ser benéfica com relação ao fenômeno de instabilidade de tensão. Mas, em geral, a atuação dos LTC's e dos reguladores de tensão de distribuição implica comportamento de carga equivalente a potência constante, tendendo a diminuir as margens. Observa-se que a representação de carga tipo potência constante já considera implicitamente a atuação de LTC e reguladores de tensão da distribuição.

No caso de não se representar os transformadores da distribuição, deve-se estipular um valor mínimo de tensão, abaixo do qual considera-se esgotado o LTC do transformador, passando-se a modelar a carga com um modelo ZIP.

Na impossibilidade de se representar “motores de indução” no estudo, mas tendo-se noção do percentual deste tipo de carga ativa ao longo dos barramentos, deve-se estipular dois valores de tensão, a saber:

(a) Valor abaixo do qual é necessário alterar o fator de potência a cada aumento da carga;

(b) valor abaixo do qual considera-se o motor “estolado” e, conseqüentemente, fora de operação.

As contingências críticas, sob o ponto de vista de estabilidade de tensão do sistema, podem ser diferentes daquelas críticas para estabilidade angular. Pode-se utilizar uma ferramenta que seja capaz de avaliar o índice de severidade das contingências do sistema, para que se possa elaborar a seleção daquelas mais relevantes para a análise de estabilidade de tensão.

As margens mínimas propostas como critério estão baseadas na taxa média de crescimento anual da carga nos últimos 10 anos, nos erros médios históricos de previsão de carga (diferença entre o valor previsto e verificado), no âmbito do planejamento, e no atraso de obras de um ano (já que, normalmente, a data de entrada em operação das obras é referente ao mês anterior ao de máxima demanda anual e um atraso normal de meses desta obra significa a não entrada no período crítico). Outro aspecto levantado é o próprio valor de demanda considerado nos estudos. A demanda considerada nos estudos de planejamento é baseada no valor máximo da demanda média horária (demanda integralizada em 1 hora) prevista para o respectivo ano. No entanto, em algumas regiões do Brasil, a diferença entre os valores de demanda instantânea e integralizada pode alcançar índices de até 12%. Nestas regiões em que esta diferença é significativa, este aspecto deve ser considerado no estabelecimento de margens.

O critério para condição normal de operação foi estabelecido considerando que a margem deveria incorporar o atraso de obra de um ano, o erro inerente à própria previsão de carga de um ano para outro e a diferença entre os valores de demanda instantânea e integralizada do valor da carga da área analisada. Portanto, em condição normal, a margem variará de região para região, dependendo do valor de índice de ponta dentro da ponta (ONS, 2002).

Desta forma, a margem para condição normal proposta é:

$$\text{Margem} \geq (6 + \text{DI} / \text{D}) \%$$

Onde:

6% = Taxa média de crescimento de carga + Erro médio de previsão de carga

DI = Demanda máxima instantânea

D = Demanda máxima integralizada de uma hora

O critério para condição de contingência simples foi estabelecido considerando que a margem deveria incorporar o atraso de obra de um ano e o erro inerente à própria previsão de carga de um ano para outro. Desta forma, a margem para condição de contingência simples proposta é :

$$\text{Margem} \geq 6\%$$

Considerando os critérios para os Estudos no Sistema Brasileiro, o Submódulo 23 não aborda a margem para contingências múltiplas.

No Seção 3.4 será apresentado como a margem de carregamento do sistema é considerada para os estudos operacionais.

3.3 – MÉTODO DA CONTINUAÇÃO

Considerando que a Curva P-V (margem de carregamento) é o indicador mais utilizado atualmente para análise da segurança do ponto de operação do sistema, é apresentado neste capítulo o método de automatização das soluções de fluxo de carga que implementam o traçado da Curva P-V.

Os métodos convencionais de solução do problema de fluxo de potência, tais como os métodos de Newton-Raphson e Desacoplado Rápido, em sua formulação básica, apresentam dificuldades de convergência quando o sistema de transmissão aproxima-se de um ponto de máxima transferência de potência (ponto crítico). Em muitas situações, por exemplo na análise de estabilidade de tensão, pode se tornar necessário a obtenção de

soluções do fluxo de potência muito próximas ao ponto crítico ou mesmo além do ponto crítico, ou seja, na parte inferior da curva P-V.

Existem vários métodos para resolver o problema descrito acima. Entre os mais conhecidos encontra-se o chamado Método da Continuação (Continuation Power Flow) descrito em (Ajarapu and Christy, 1992), (Cañizares and Alvarado, 1993), (Sodré, Almeida e Salgado, 1997). Este método é capaz de produzir uma seqüência de soluções do problema de fluxo de potência para um dado cenário de variação de carga. O método utiliza um esquema de previsão-correção para encontrar uma trajetória de soluções do sistema de equações definindo o problema de fluxo de potência, reformulado para incluir um parâmetro representando a variação da carga. A idéia básica do método é ilustrado na Figura 3.3.

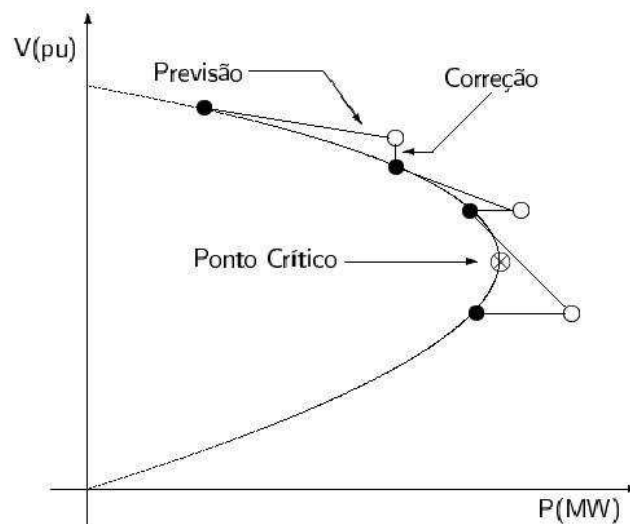


Figura 3.3 - Ilustração do esquema de previsão-correção do Método da Continuação

3.3.1 - REFORMULAÇÃO DAS EQUAÇÕES DO FLUXO DE POTÊNCIA

A variação da carga ativa e reativa nas barras do sistema é representada pela variação de um único parâmetro λ da forma seguinte:

$$P_{lk} = P_{lk}^0 + \lambda[\gamma_k S \cos \psi_k]$$

$$Q_{lk} = Q_{lk}^0 + \lambda[\gamma_k S \sen \psi_k]$$

onde

P_{lk}^0, Q_{lk}^0 : carga ativa e reativa inicial na barra k ;

γ_k : fator de variação da carga na barra k ;

ψ_k : fator de variação do fator de potência na barra k ;

S : valor arbitrário de potência aparente (MVA_r) usado como referência para o escalamento do parâmetro λ .

Uma versão simplificada das expressões acima, supondo um crescimento uniforme da carga com fator de potência constante, é dada por

$$P_{lk} = P_{lk}^0 (1 + \lambda)$$

$$Q_{lk} = Q_{lk}^0 (1 + \lambda)$$

Para acompanhar o crescimento da carga, a geração de potência ativa deve ser também ajustada de acordo com a expressão

$$P_{gk} = P_{gk}^0 (1 + \lambda \beta_k)$$

onde

P_{gk}^0 , : geração ativa inicial na barra k ;

β_k : fator de variação da geração na barra k ;

O Subsistema I de equações do fluxo de potência passa, então, a ser escrito na forma seguinte

$$P_{gk}^0 (1 + \lambda \beta_k) - P_{lk}^0 + \lambda [\gamma_k S \cos \psi_k] - g_{pk}(\bar{\theta}, \bar{v}) = 0, \quad k \in \{PV, PQ\}$$

$$Q_{gk}^0 - Q_{lk}^0 + \lambda [\gamma_k S \sin \psi_k] - g_{qk}(\bar{\theta}, \bar{v}) = 0, \quad k \in \{PV, PQ\}$$

onde

$$g_{pk}(\bar{\theta}, \bar{v}) = V_k \sum_{m \in \Omega_k} V_m (G_{km} \cos \theta_{km} + B_{km} \sin \theta_{km})$$

$$g_{qk}(\bar{\theta}, \bar{v}) = V_k \sum_{m \in \Omega_k} V_m (G_{km} \sin \theta_{km} - B_{km} \cos \theta_{km})$$

As equações acima podem ser colocadas na forma compacta

$$\bar{f}(\bar{x}) = \bar{0} \quad (3.1)$$

onde $\bar{x} = [\bar{\theta}^T \quad \bar{v}^T \quad \lambda]^T$ e $0 \leq \lambda \leq \lambda_{crit}$. No caso de $\lambda = 0$, essas equações se reduzem às equações usuais do fluxo de potência.

3.3.2 - ETAPA DE PREVISÃO

A partir da solução do caso base, uma previsão da próxima solução pode ser obtida caminhando-se um certo passo na direção da tangente à curva. O vetor tangente é obtido tomando-se a diferencial total de ambos os lados de (3.1).

$$d\bar{f}(\bar{x}) = \frac{\partial \bar{f}(\bar{x})}{\partial(\theta)} d\theta + \frac{\partial \bar{f}(\bar{x})}{\partial(v)} dv + \frac{\partial \bar{f}(\bar{x})}{\partial(\lambda)} d\lambda = 0 \quad (3.2)$$

ou

$$[F_\theta \quad F_v \quad F_\lambda] \begin{bmatrix} d\theta \\ dv \\ d\lambda \end{bmatrix} = 0 \quad (3.3)$$

onde

$$F_{\theta} = \frac{\partial f(x)}{\partial(\theta)}; \quad F_v = \frac{\partial f(x)}{\partial(v)}; \quad F_{\lambda} = \frac{\partial f(x)}{\partial(\lambda)}$$

Note que a partição $[F_{\theta} \quad F_v]$ em (3.3) é o Jacobiano do método de Newton-Raphson.

O sistema de equações (3.3) tem uma incógnita a mais que o número de equações. Para resolver esse sistema, é necessário que uma das incógnitas tenha seu valor especificado (por exemplo, no valor ± 1). Esta variável recebe o nome de Parâmetro da Continuação. Neste caso, tem-se

$$\begin{bmatrix} F_{\theta} & F_v & F_{\lambda} \\ \bar{e}_k & & \end{bmatrix} \begin{bmatrix} d\theta \\ dV \\ d\lambda \end{bmatrix} = \begin{bmatrix} \bar{0} \\ \pm 1 \end{bmatrix} \quad (3.4)$$

onde

$$\bar{e}_k = \begin{bmatrix} 0 & \dots & 0 & 1 & 0 & \dots & 0 \end{bmatrix}$$

O parâmetro de continuação deve ser escolhido de maneira tal que tenha a maior taxa de variação próximo à solução em questão. Duas situações devem ser observadas:

Próximo ao caso base (carga normal): variações relativamente grandes na carga (λ) produzem pequenas variações nas componentes de $\bar{\theta}$ e \bar{v} . Neste caso, λ deve ser escolhido como parâmetro da continuação.

Próximo ao ponto crítico (carga pesada): pequenas variações na carga (λ) produzem grandes variações em algumas componentes de $\bar{\theta}$ e \bar{v} . Neste caso, a componente de $\bar{\theta}$ e \bar{v} com maior taxa de variação deve ser escolhida como parâmetro de continuação.

Uma vez calculado o vetor tangente, a previsão da solução é calculada por

$$\begin{bmatrix} \theta^{p+1} \\ V^{p+1} \\ \lambda^{p+1} \end{bmatrix} = \begin{bmatrix} \theta^p \\ V^p \\ \lambda^p \end{bmatrix} + \sigma \begin{bmatrix} d\theta \\ dV \\ d\lambda \end{bmatrix} \quad (3.5)$$

onde σ define o passo a ser dado na direção do vetor tangente e p é o contador de passos do processo da continuação. A escolha de σ afeta bastante o desempenho do método. Se σ for pequeno, o número de passos necessários para se alcançar a solução desejada é muito grande e, conseqüentemente, o tempo de computação muito elevado. Se σ for demasiadamente grande, a etapa de correção pode não convergir.

3.3.3 - ETAPA DE CORREÇÃO

Nesta etapa do processo, o sistema de equações definido em (3.1) é aumentado de uma equação que define o valor da variável escolhida como parâmetro da continuação na etapa de previsão. O valor atribuído a esta variável é igual ao valor previsto para esta variável de acordo com (3.5). O novo conjunto de equações tem o seguinte aspecto

$$\begin{bmatrix} f(\theta, v, \lambda) \\ x_k - \eta \end{bmatrix} = [0] \quad (3.6)$$

onde k é o índice da variável escolhida como parâmetro da continuação e η é o valor calculado para esta variável na etapa de previsão.

O sistema de equações definido em (3.6) pode ser resolvido pelo método de Newton-Raphson com uma implementação muito semelhante ao caso do fluxo de potência convencional.

Exemplo 3.1 Seja o sistema simples mostrado na Figura 3.4 onde a barra 1 é uma barra infinita (módulo e ângulo de fase da tensão constantes).




Figura 3.4 - Sistema para exemplo do Método de Continuação

(a) Variação da carga:

$$P_{lk} = P_{lk}^0 (1 + \lambda)$$

$$Q_{lk} = Q_{lk}^0 (1 + \lambda)$$

(b) Equações do fluxo de potência incluindo o parâmetro λ

$$f_p(\theta, v, \lambda) = -P_l^0 (1 + \lambda) - VB_{21} \sin \theta = 0$$

$$f_q(\theta, v, \lambda) = -Q_l^0 (1 + \lambda) - V^2 B_{22} + VB_{21} \cos \theta = 0$$

ou

$$\vec{f}(\vec{x}) = \vec{0}$$

onde $\vec{x} = [\theta \quad v \quad \lambda]^T$.

(c) Vetor tangente

De (3.3), obtem-se para este caso particular

$$\begin{bmatrix} \frac{\partial f_p}{\partial \theta} & \frac{\partial f_p}{\partial v} & \frac{\partial f_p}{\partial \lambda} \\ \frac{\partial f_q}{\partial \theta} & \frac{\partial f_q}{\partial v} & \frac{\partial f_q}{\partial \lambda} \\ \frac{\partial f_r}{\partial \theta} & \frac{\partial f_r}{\partial v} & \frac{\partial f_r}{\partial \lambda} \end{bmatrix}_{\theta^p, v^p, \lambda^p} \begin{bmatrix} d\theta^p \\ dV^p \\ d\lambda^p \end{bmatrix} = \mathbf{0}$$

O sistema de equações acima tem 2 equações e 3 incógnitas. Uma terceira equação pode ser acrescentada ao sistema fazendo-se $d\lambda = \pm 1$. O sinal na expressão anterior depende do fato de λ estar crescendo (+) ou decrescendo (-). Assim, tem-se:

$$\begin{bmatrix} \frac{\partial f_p}{\partial \theta} & \frac{\partial f_p}{\partial v} & \frac{\partial f_p}{\partial \lambda} \\ \frac{\partial f_q}{\partial \theta} & \frac{\partial f_q}{\partial v} & \frac{\partial f_q}{\partial \lambda} \\ \frac{\partial f_r}{\partial \theta} & \frac{\partial f_r}{\partial v} & \frac{\partial f_r}{\partial \lambda} \\ \mathbf{0} & \mathbf{0} & \mathbf{1} \end{bmatrix}_{\theta^p, v^p, \lambda^p} \begin{bmatrix} d\theta^p \\ dV^p \\ d\lambda^p \end{bmatrix} = \begin{bmatrix} \mathbf{0} \\ \mathbf{0} \\ \pm 1 \end{bmatrix}$$

Quando estiver-se próximo ao ponto crítico, deve-se escolher outro parâmetro de continuação. Por exemplo, $v = \pm 1$. Neste caso, ter-se-ia:

$$\begin{bmatrix} \frac{\partial f_p}{\partial \theta} & \frac{\partial f_p}{\partial v} & \frac{\partial f_p}{\partial \lambda} \\ \frac{\partial f_q}{\partial \theta} & \frac{\partial f_q}{\partial v} & \frac{\partial f_q}{\partial \lambda} \\ \frac{\partial f_r}{\partial \theta} & \frac{\partial f_r}{\partial v} & \frac{\partial f_r}{\partial \lambda} \\ \mathbf{0} & \mathbf{1} & \mathbf{0} \end{bmatrix}_{\theta^p, v^p, \lambda^p} \begin{bmatrix} d\theta^p \\ dV^p \\ d\lambda^p \end{bmatrix} = \begin{bmatrix} \mathbf{0} \\ \mathbf{0} \\ \pm 1 \end{bmatrix}$$

Ambos os casos acima podem ser escritos, de forma compacta, como

$$\begin{bmatrix} J'(\bar{x}^p) \\ \bar{e}_k \end{bmatrix} [d\bar{x}^p] = [\pm \bar{e}_k^T]$$

onde

$$\bar{e}_k = [0 \ 0 \ 1] \quad \text{ou} \quad \bar{e}_k = [0 \ 1 \ 0]$$

e

$$J'(\bar{x}^p) = [J(\bar{x}^p) \quad J_\lambda(\lambda^p)]$$

onde

$$J(x^p) = \begin{bmatrix} \frac{\partial f_p}{\partial \theta} & \frac{\partial f_p}{\partial v} \\ \frac{\partial f_q}{\partial \theta} & \frac{\partial f_q}{\partial v} \\ \frac{\partial \theta}{\partial \theta} & \frac{\partial v}{\partial v} \end{bmatrix}_{\theta^p, v^p} ; \quad J_\lambda(\lambda^p) = \begin{bmatrix} \frac{\partial f_p}{\partial \lambda} \\ \frac{\partial f_q}{\partial \lambda} \\ \frac{\partial \lambda}{\partial \lambda} \end{bmatrix}_{\lambda^p}$$

Neste exemplo, as matrizes $J(\bar{x}^p)$ e $J_\lambda(\lambda^p)$ são dadas por

$$J(x^p) = \begin{bmatrix} -V^p B_{21} \cos \theta^p & -B_{21} \sin \theta^p \\ -V^p B_{21} \sin \theta^p & -2V^p B_{22} + B_{21} \cos \theta^p \end{bmatrix} ; \quad J_\lambda(\lambda^p) = \begin{bmatrix} -P_{L0} \\ -Q_{L0} \end{bmatrix}$$

(d) Etapa de Previsão

A previsão da solução no passo $p + 1$ é dada por

$$\begin{bmatrix} \theta^{p+1} \\ V^{p+1} \\ \lambda^{p+1} \end{bmatrix} = \begin{bmatrix} \theta^p \\ V^p \\ \lambda^p \end{bmatrix} + \sigma \begin{bmatrix} d\theta \\ dV \\ d\lambda \end{bmatrix}$$

onde σ é o escalar que determina o passo a ser dado na direção escolhida.

(e) Etapa de Correção

A etapa de correção consiste em resolver, pelo método de Newton-Raphson, o sistema de equações (3.6). Em cada iteração do processo de solução, o sistema linear a ser resolvido é

$$\begin{bmatrix} & J'(x) & \\ \mathbf{0} & \mathbf{0} & \mathbf{1} \end{bmatrix} \begin{bmatrix} \bar{\theta} \\ \bar{v} \\ \bar{\lambda} \end{bmatrix} = \begin{bmatrix} f_p(\theta, v, \lambda) \\ f_q(\theta, v, \lambda) \\ -(\bar{\lambda} - \lambda) \end{bmatrix}$$

no caso em que o parâmetro de continuação escolhido é λ , ou

$$\begin{bmatrix} & J'(x) & \\ \mathbf{0} & \mathbf{1} & \mathbf{0} \end{bmatrix} \begin{bmatrix} \bar{\theta} \\ \bar{v} \\ \bar{\lambda} \end{bmatrix} = \begin{bmatrix} f_p(\theta, v, \lambda) \\ f_q(\theta, v, \lambda) \\ -(\bar{V} - V) \end{bmatrix}$$

no caso em que o parâmetro de continuação escolhido é V .

3.4 – RESULTADOS

O objetivo desta seção é mostrar como são efetuados os estudos e analisadas as condições de operação em relação à estabilidade de tensão para um caso específico. Como exemplo deste tipo de análise apresentamos um estudo operacional realizado para analisar e definir as configurações e os procedimentos operativos necessários para a indisponibilidade do barramento principal de 230 kV da SE Bom Nome (BNO) na área Norte da CHESF, para o ano de 2001, (ANDESA, 2001).

A operação da área Norte nesta configuração apresenta restrições consideráveis, principalmente em relação ao suprimento das SE's de Fortaleza e Milagres, sendo necessário consideráveis restrições de carga nos períodos de carga pesada e média. Desta forma, faz-se necessário adotar intercâmbio do Norte para o Nordeste superior a 300 MW. É necessário também disponibilizar o máximo de unidades geradoras de B.Esperança nesta configuração, de modo a minimizar a sobrecarga no ATR de B.Esperança.

Vale ressaltar que durante a operação de suprimento à área Norte exclusivamente pelos circuitos de 500 kV, o sistema apresenta uma grande sensibilidade às variações de carga, especialmente, nas SE's da área de Fortaleza. Desta forma, os CE's de Fortaleza e Milagres deverão ser operados de maneira a evitar seu excursionamento aos pontos extremos de fornecimento ou absorção de potência reativa.

3.4.1 – CONFIGURAÇÃO

- a) Para a configuração da área Norte da CHESF, de acordo com as premissas definidas pelo ONS, tomou-se como indisponível os trechos de circuitos FEX 230 kV entre Paulo Afonso e Milagres 230 kV, para serem convertidos para 500 kV.
- b) Durante o período de indisponibilidade da barra de 230 kV da SE Bom Nome, foi considerada a seguinte configuração:
 - *1 circuito 230 kV Paulo Afonso – Bom Nome (04F2 ou 04F3) energizado, utilizando a barra auxiliar, alimentando o ATR 230 / 69 kV – 33 MVA e suas cargas derivadas.*
 - *Dois circuitos Paulo Afonso – Bom Nome 230 kV e os três circuitos Bom Nome – Milagres 230 kV, desenergizados.*
 - *O eixo 230 kV Mossoró – Açú aberto.*
- c) O diagrama unifilar simplificado abaixo (Figura 3.5), mostra a configuração dos circuitos da rede de transmissão da área Norte, nesta configuração de indisponibilidade do barramento principal de 230 kV da SE Bom Nome.

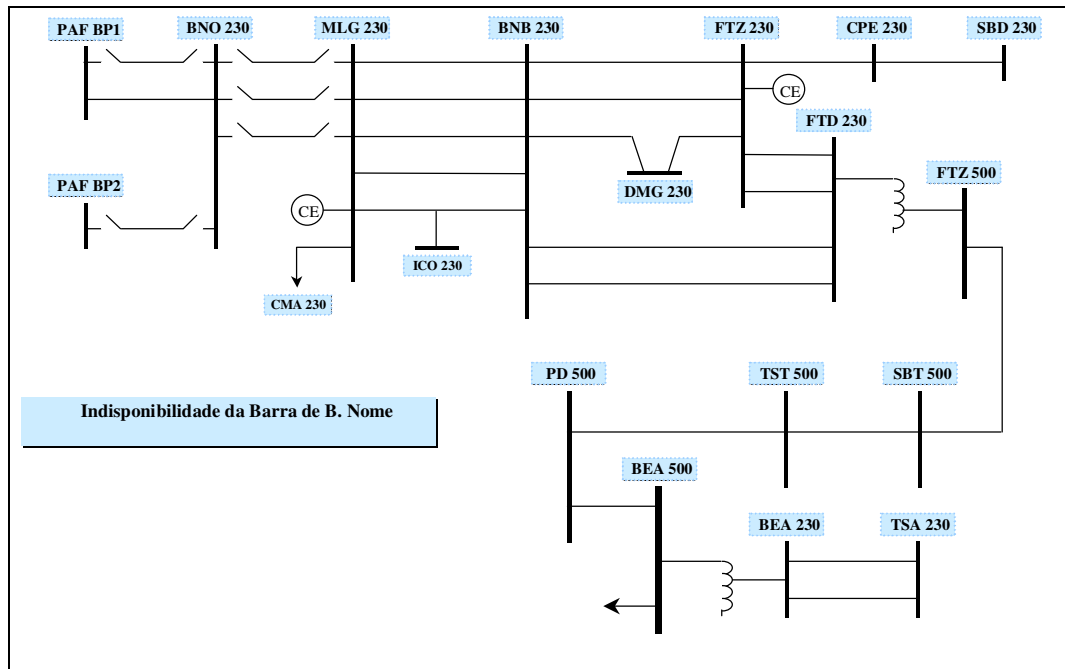


Figura 3.5 – Configuração Básica

3.4.2 - CRITÉRIO PARA DEFINIÇÃO DO LIMITE DE TRANSMISSÃO

Os valores definidos como limite de transmissão correspondem a uma carga 5% inferior aos valores calculados para o limite de transmissão estático da área Norte da CHESF.

Ressalta-se entretanto, que nessa configuração, o sistema ficará submetido a dois pontos de estrangulamento de transmissão, quais sejam:

1. - Elevado carregamento nos circuitos do eixo de 500 kV Sobradinho – S. J. Piauí – B. Esperança, principalmente para valores de intercâmbio $N \rightarrow NE$ inferior a 300 MW.
2. - Carregamento nos CE's de Fortaleza e Milagres, aliada a uma elevada sensibilidade da potência reativa gerada pelos mesmos, para uma variação da carga.

DURANTE A INDISPONIBILIDADE

- a) Durante o período da indisponibilidade do barramento principal de 230 kV da SE Bom Nome, o suprimento as cargas da área Norte da CHESF será feita através da malha de 500 kV P. Dutra – Fortaleza e do eixo 230 kV Teresina – Fortaleza, via SE Cauípe.
- b) Nesta configuração, haverá uma tendência do CE de Milagres se manter absorvendo reativo e, apesar do sistema ficar operando próximo ao seu limite estático de transmissão, o CE de Fortaleza não apresentará carregamento muito elevado. Essa situação é bastante preocupante, haja vista que a sensibilidade operativa dos despachadores, adquiridas e vivenciadas no seu dia a dia, será significativamente diferente em relação ao sistema operando nesta configuração.
- c) Os valores máximos de carga que poderão ser supridos, serão função do intercâmbio Norte para o Nordeste. A Tabela 3.1 a seguir mostra os valores limites de suprimento da área Norte da CHESF.

Tabela 3.1 – Limites de suprimento de carga na área Norte da CHESF, durante a liberação da barra principal de 230 kV da SE Bom Nome

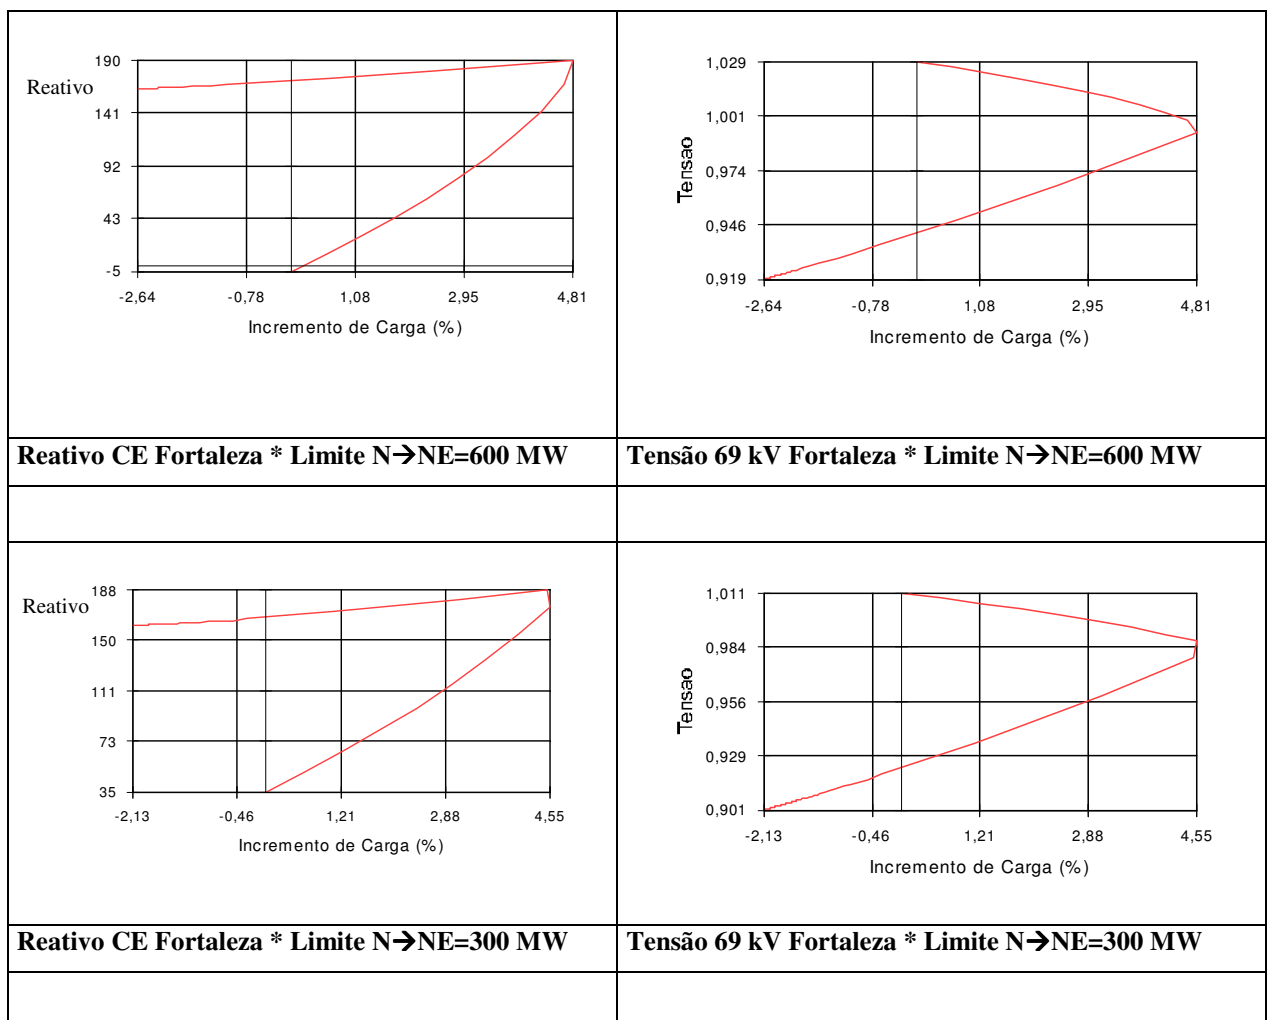
Intercâmbio Norte → Nordeste	Carga Suprida (MW)	Fluxo nos ATR (MW)	
		FTZ	BEA
0	535	2 x 435	313
300	665	2 x 500	330
> 600	700	2 x 520	335

d) Destacamos que o limite de suprimento das cargas, na condição de intercâmbio nulo, foi definido em função dos níveis de tensão estabelecidos no eixo B. Esperança – S. J. Piauí.

Nesta situação, o carregamento do circuito Sobradinho – S.J. Piauí – B. Esperança é bastante elevado, podendo atingir valores superiores a 1300 MW. Diante disso recomenda-se que seja evitada a liberação da barra de 230 kV da SE Bom Nome com Intercâmbio N→NE inferior a 300 MW.

e) A Figura 3.6 mostra as curvas de estabilidade estática de algumas grandezas elétricas, em cada situação limite definida.

Este caso estudado foi bastante interessante porque demonstrou de forma contundente como é utilizado o limite máximo de carregamento na operação do sistema. No caso analisado, como citado anteriormente, foi utilizado o limite de carregamento de 5%. Vale ressaltar que houve casos em que a tensão e os carregamentos dos equipamentos estavam dentro dos limites toleráveis e que a Curva P-V apresentava valores de máximo carregamento do sistema menores que 5%. Nesta situação foi necessário um maior corte de carga para que a margem de carregamento estivesse maior que 5%.



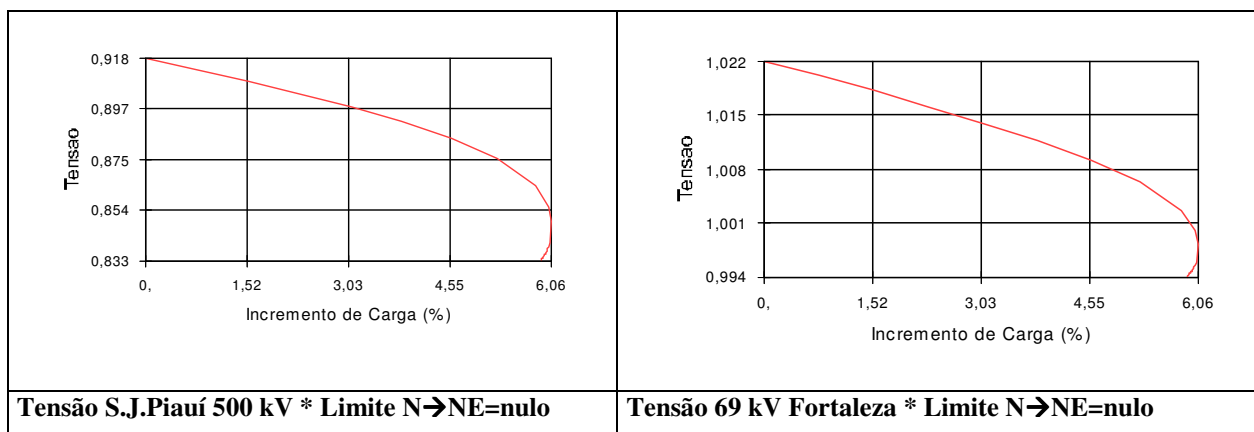


Figura 3.6 - Curvas de Estabilidade Estática

3.5 – CONCLUSÕES

Neste capítulo foi demonstrada a extensa utilização do critério de carregamento baseado na computação da Curva P-V como o indicador do estado de operação do sistema em seguro ou inseguro pelas empresas do setor elétrico ao redor do mundo. Foi mostrado de forma explícita sua utilização pelo ONS no Módulo 23 e pelos estudos do planejamento da operação, conforme resultados apresentados na seção 3.4. Vale lembrar também que o Western Electric Coordinating Council utiliza de forma bastante contundente o critério da Curva P-V (conforme será visto no Capítulo 4.).

Vale ressaltar que a análise da segurança on-line em relação à estabilidade de tensão está sendo implantada nas empresas, e que um dos critérios utilizados é a margem de carregamento da Curva P-V. Os pontos de operação dividem-se em seguro e inseguros (como duas classes para reconhecimento de padrões), em função disso é naturalmente viável a utilização da técnica das redes neurais artificiais para a solução deste problema, principalmente em tempo real.

Capítulo 4

Resultados

4.1 - INTRODUÇÃO

Neste capítulo serão apresentados os resultados do reconhecimento de padrão para a análise de segurança em relação à estabilidade de tensão obtidos. Além destes é apresentado de forma resumida os principais requisitos funcionais necessários para a elaboração de um módulo de avaliação de estabilidade de tensão on-line (*AET on-line*). Através destes requisitos e dos resultados obtidos, fica demonstrada a viabilidade da aplicação das técnicas de inteligência artificial para a solução do problema de estabilidade de tensão nos centros de controle das empresas do setor de energia elétrica.

4.2 - ANÁLISE DA SEGURANÇA

Um subsistema de análise da segurança, que é parte integrante de um SGE (Sistema de Gerenciamento de Energia), tem como objetivo monitorar a operação corrente e a segurança do sistema elétrico, fornecendo ao operador uma estimativa confiável do estado do sistema, informando quando da ocorrência de condições operativas não desejáveis e produzindo estratégias de controle que permitam alterar o ponto de operação para uma condição operativa normal. Além disso, deve possibilitar aos engenheiros da operação a

realização de estudos relativos a condições de pós-operação e análise detalhada da condição operativa corrente e futura, através da simulação de manobras na rede elétrica. Além de permitir às equipes de programação e supervisão o estabelecimento e a revisão do programa de operação do sistema elétrico.

O objetivo desta seção é descrever um conjunto de diretrizes para avaliação da estabilidade de tensão, e também os requisitos funcionais, para um módulo de avaliação de estabilidade de tensão on-line (*AET on-line*).

4.2.1 - AVALIAÇÃO DA ESTABILIDADE DE TENSÃO ON-LINE

Esta seção descreve algumas diretrizes técnicas para a avaliação da ET (Estabilidade de Tensão), que pode ser aplicada tanto para estudos on-line como para estudos off-line.

A metodologia mais utilizada atualmente pelas empresas do setor elétrico ao redor do mundo para análise da segurança do sistema em relação à estabilidade de tensão, visa determinar se o ponto de operação é estável ou quão distante ele está da instabilidade (*seguro ou alerta*), em função do índice margem obtido através do Método da Continuação (ONS, 2002), (WSCC, 1998).

Anteriormente as empresas só se asseguravam de manter as tensões dentro de alguns limites, mas não garantiam um estado operativo seguro em relação à estabilidade de tensão. Atualmente, Virginia Power, Florida Power, BC Hydro, e as empresas da Suécia usam reservas de potência reativa e magnitudes de tensão como indicadores para o corte automático de carga e para a implementação de medidas corretivas para evitar o colapso de tensão.

O uso das reservas de potência reativa como indicador para a análise da segurança está baseado na característica principal do fenômeno da instabilidade de tensão: o

desbalanço entre o consumo e a geração de potência reativa. Este indicador está fortemente baseado na experiência dos operadores e em estudos de simulação.

De forma geral pode-se dizer que um ponto de operação é geralmente considerado seguro em relação à tensão para condições de operação, se:

1. – a margem de ET de todas as contingências selecionadas satisfazem o critério de margem;
2. – as tensões consideradas antes da contingência e avaliadas após a contingência satisfazem o critério da taxa de variação em relação à carga;
3. – a reserva de potência reativa antes e após a contingência de fontes específicas satisfazem o critério de reserva de MVAr.

A seguir apresentam-se os critérios utilizados na WECC (Western Electricity Coordinating Council) para a análise da estabilidade de tensão (WSCC, 1998).

Após os grandes distúrbios ocorridos no sistema elétrico da WECC em 2 e 3 de julho de 1996 e 10 de agosto do mesmo ano, um grupo de estudo foi formado para executar avaliações das ocorrências. Estes estudos resultaram em dois relatórios, onde ambos identificaram questões que requeriam maiores investigações. Para atacar estas questões foi formado um grupo de trabalho para estudar os dois principais problemas levantados nos relatórios anteriores: as *margens de potência reativa* e os *critérios para estabilidade de tensão* para todos os membros do WECC. Ambas as questões procuram minimizar impactos adversos causados por saídas em cascata e ajudar na rápida recomposição do sistema.

Vale ressaltar que as margens e os critérios adotados por todas as companhias membros do WECC cobrem o período após as oscilações transitórias terem amortecido e antes que o operador possa tomar alguma ação manual, e antes também que o intercâmbio

de área programado possa ser ajustado. Estando este período além do tempo transitório, as mudanças dos taps dos transformadores teriam tempo para se ajustar. O colapso de tensão transitório devido à instabilidade angular não é considerado no relatório da WECC. É assumido que as simulações de estabilidade transitória para as contingências consideradas mostrariam que o sistema seria estável e atenderia aos critérios da WECC.

A WECC determina que ambas as metodologias P-V e V-Q devem ser utilizadas para avaliação de margem. Sistemas membros da WECC podem usar qualquer tipo de método para avaliação da estabilidade de tensão, podem também usar um outro método qualquer para escolha de contingência, etc.; entretanto, as margens de estabilidade de tensão devem ser demonstradas por ambas as análises P-V e V-Q. Cada análise separadamente é necessária para confirmar os resultados uma da outra (isto é, a análise P-V é necessária para confirmar os resultados da análise V-Q e vice versa).

Em adição às análises P-V e V-Q outras valiosas ferramentas podem ser utilizadas para ajudar na compreensão do fenômeno do colapso, tais como, simulações dinâmicas completas, simulações quase-dinâmicas rápidas, análise modal e Fluxo de Potência Ótimo com restrição de segurança. Os membros do WECC podem usar outros métodos além das análises P-V e V-Q com propósitos exploratórios para adquirir maior compreensão sobre o problema; entretanto, a quantidade de margem deve ser demonstrada, obrigatoriamente, por ambas as análises V-Q e P-V, como descrito no relatório.

Os critérios da estabilidade de tensão da WECC são especificados em termos das margens de potência ativa e reativa. Todos os sistemas membros devem prover obrigatoriamente as margens especificadas na Tabela 4.1.

Os critérios da Tabela 4.1. se aplicam igualmente para o sistema com todos os elementos em serviço, como também para a situação em que um elemento é removido e o sistema é reajustado. Os elementos do sistema incluem qualquer equipamento, tais como, geradores, linhas de transmissão, transformadores, fonte de potência reativa, etc. Para o propósito da análise da estabilidade de tensão deve-se considerar a saída do elemento que

dá a maior redução de margem do caso base (o sistema deve ser reajustado após esta saída).

Os ajustes do sistema após o elemento ser removido do caso base (para a análise dos Níveis de Desempenho de A a D) incluem todos os ajustes que podem ser feitos dentro de 60 minutos para trazer o sistema para uma condição de operação de regime aceitável. Estes ajustes incluem, redespacho de geração, entrada de nova geração, ajustes de taps, ajustes de intercâmbio, etc.).

Padrões de geração, níveis e características de carga, capacidade de potência reativa dos geradores, tap's de transformadores, e fluxos de potência entre áreas e sistemas vizinhos são alguns dos parâmetros chave para os estudos de estabilidade de tensão. Os estudos devem ser conduzidos para verificar se o sistema é dinamicamente estável. Isto é importante para demonstrar que não existe instabilidade angular causando o colapso de tensão.

Tabela 4.1 - Critérios WSCC.

NÍVEL DE DESEMPENHO	DISTÚRBIO	Margem MW (Método P-V)	Margem MVAr (Método V-Q)
A	Iniciado por: Falta ou Não Falta Distúrbio DC Qualquer elemento, tal como: Um Gerador Um Circuito Um Transformador Uma Fonte e Potência Reativa Um Monopolo DC	$\geq 5\%$	Margem do Pior Caso
B	Seção de Barra	$\geq 2,5\%$	50% da Margem requerida no Nível A
C	Qualquer Combinação de Dois Elementos, tais como: Uma Linha e um Gerador Uma Linha e uma Fonte de Potência Reativa Dois Geradores Dois Circuitos Dois Transformadores Duas Fontes de Potência Reativa Bipolo DC	$\geq 2,5\%$	50% da Margem requerida no Nível A
D	Qualquer Combinação de Três ou mais Elementos, tais como Três ou mais circuitos em paralelo Uma Subestação completa Uma Planta completa incluindo chaveamento	≥ 0	≥ 0

É largamente conhecido que o perfil de tensão sozinho é um indicador pobre para a segurança da estabilidade de tensão. Os níveis de tensões podem estar normais, mas com os geradores, os compensadores síncronos e os SVC's próximos dos limites de corrente, resultando em um provável colapso de tensão caso ocorra algum distúrbio. Portanto, é prudente especificar uma margem de potência reativa ou um critério de margem de MW.

A literatura indica que uma margem de 5% de carga (com fator de potência constante) ou um aumento de 5% no fluxo entre áreas é uma margem razoável. O Reino Unido e o Japão estão usando um aumento de carga de 5% como o critério para a estabilidade de tensão, este critério foi baseado em experiência e análises. O critério de 5% de aumento de carga poderia também cobrir condições onde reforços adicionais ao sistema estão com sua entrada em operação atrasada devido a restrições de construção.

Atualmente as curvas P-V e V-Q, ou outros métodos, não estão sendo utilizados na operação em tempo real. Na falta de qualquer programa on-line a única maneira existente, atualmente, para os operadores avaliarem a margem é através da medição da reserva de potência reativa a partir de várias fontes. As reservas de potência reativa de geradores, compensadores síncronos, SVC's e STATCOM's são indicadores sensíveis para a estabilidade de tensão. Se a reserva de potência reativa disponível de um determinado gerador é diminuída, tal que o limite da corrente de campo é alcançado, a corrente de campo dos geradores próximos podem também alcançar seus limites resultando num colapso de tensão.

Como proposto neste trabalho irá ser demonstrada a viabilidade das técnicas de reconhecimento de padrão da inteligência artificial para aplicação na operação em tempo real em relação à análise da segurança da estabilidade de tensão.

A quantidade de margem de potência reativa requerida como determinada pelos estudos de planejamento devem ser mantidas na operação em tempo real. Esta margem deve estar disponível a partir de uma combinação de fontes de potência reativa on-line e off-line. As fontes de potência dinâmicas on-line incluem geradores, compensadores síncronos, SVC's, etc. As fontes off-line incluem capacitores chaveados automaticamente

ou outras fontes de potência reativa. A cada fonte deve ser dado um fator de peso específico. Os pesos devem ser determinados por estudos off-line, onde a contribuição de cada gerador para o suprimento da potência reativa requerida pode ser usada para a determinação dos pesos.

A BPA, em colaboração com o EPRI, está testando um software para monitorar as reservas de potência reativa e avaliar a segurança de tensão, em seu centro de controle. Como em todos os projetos de pesquisa, o operador deve estar cauteloso no uso de tais ferramentas, até que experiência suficiente seja obtida (IEEE/PES, 2002).

4.2.2 - REQUISITOS FUNCIONAIS DO MÓDULO *ON-LINE*

O módulo de *AET on-line* (Avaliação da Estabilidade de Tensão on-line) deve operar em conjunto com o ambiente do SGE (Sistema de Gerenciamento de Energia) monitorando o estado do sistema de potência periodicamente, sob demanda, ou sob ocorrência de mudanças significativas no estado do sistema, para garantir a segurança contra ocorrência de contingências. Devendo estar disponível também no modo de estudo. As contingências selecionadas devem ser classificadas em dois grupos: *seguro* e *inseguro* (IEEE/PES, 2002).

A Figura 4.1 mostra os principais componentes (módulos) de uma *AET on-line*. O Monitor de Mudança dispara a execução orientada a eventos da função AET baseada nos dados analógicos e no status do sistema recebido do SCADA. Alternativamente, o Controle da Seqüência de Tempo-Real do SGE pode ser aumentado para incluir a ativação da execução da *AET on-line* através de um mecanismo de mensagem SGE/*AET on-line*. A Seleção de Contingências é configurada separadamente para permitir a exclusão ou a inclusão de um filtro de Contingências. A Análise das Contingências para avaliação da estabilidade de tensão pode ser configurada para usar ou a análise estática (regime permanente) ou a simulação dinâmica, dependendo das características das contingências de interesse para a empresa. O Monitor de Segurança de Tensão determina os limites operacionais seguros ou as regiões de operação para assegurar as margens de estabilidade

de tensão adequadas. O Módulo de Melhoria da Segurança fornece uma assistência aos operadores na determinação das ações corretivas e/ou preventivas contra a ameaça da instabilidade de tensão.

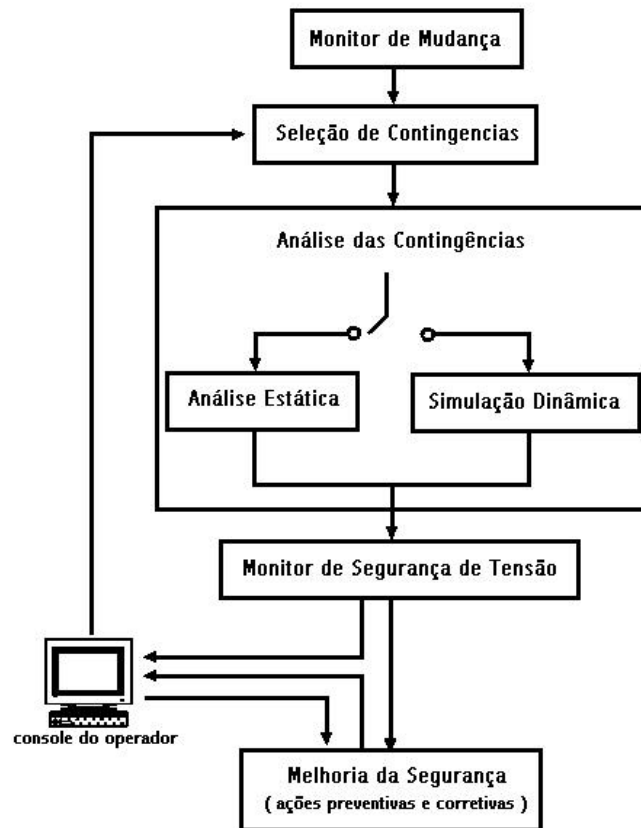


Figura 4.1 – Módulo *AET on-line*

É esperado que a *AET on-line* rode normalmente como parte da seqüência dos processos do tempo real, começando através da solução do Estimador de Estados. Ela pode ser ajustada para executar seguindo cada solução do Estimador de Estados ou um múltiplo desta. Portanto, em sua execução normal os resultados da *AET on-line* estão baseados em disparos do sistema obtidos para intervalos de tempo definidos (de 5 a 30 minutos dependendo da implementação específica, sendo uma análise a cada 20 minutos um valor de referência razoável).

Os requisitos de desempenho da plataforma da *AET on-line* declarados abaixo estão baseados na suposição de cenários de tamanho e desempenho razoáveis.

Os parâmetros de execução são os seguintes:

1. periodicidade da execução: 20 minutos.
2. análise de contingências: 300 contingências com diferentes graus de complexidade, incluindo não mais do que 30 contingências severas (um bom processo de seleção de contingências não poderá selecionar mais do que 30 contingências para processamento completo).
3. execução da AET: incluirá seleção de contingências, classificação, graduação e determinação de limites, como também, o cálculo de ações corretivas e preventivas.

Os limites da operação determinados pela *AET on-line* devem apresentar um erro de menos de 2% dos limites que seriam obtidos a partir da análise da mesma condição de operação realizando estudos off-line através da utilização de modelos detalhados.

Ao final desta seção tem-se um pequeno resumo das seguintes funções básicas da *AET on-line*:

- Seleção de Contingências
- Avaliação da Segurança de Tensão
- Ações de Controle Preventivo e Corretivo

Seleção de Contingências

É impraticável e desnecessário analisar em detalhe todas as possíveis contingências. Geralmente somente um número determinado e limitado de contingências ameaça a estabilidade de tensão. Estas contingências podem ser diferentes daquelas consideradas para a estabilidade angular, sobrecarga ou tensão fora dos limites. É requerido então para esta função do Módulo *AET on-line* a capacidade de definir uma lista das mais importantes contingências podendo aumentar e filtrar as contingências e selecionar aquelas mais prováveis de causarem problemas, de forma que estas sejam analisadas em detalhe.

Avaliação da Segurança de Tensão

Os operadores necessitam saber se o sistema e as condições de operação atendem os critérios de estabilidade de tensão. O critério pode especificar quão distante o sistema deveria estar da fronteira da instabilidade da tensão em termos de aumento de carga, aumento de transferência, ou outras formas de “stress”, quando sujeito a qualquer uma das contingências selecionadas. Pode haver outros critérios que devem ser atendidos também, tais como, reserva de reativo em diferentes partes do sistema e limites de declínio de tensão pós-contingência.

Estes cálculos envolvem análise detalhada de todas as contingências selecionadas em vários estados de operação do sistema. Técnicas de análise estática (baseadas em fluxo de carga) podem executar estes cálculos na maioria dos casos, mas métodos de análise dinâmica (simulação no domínio do tempo) podem ser ocasionalmente requeridos.

Vale salientar que esta função básica do módulo *AET on-line* que pode ser satisfatoriamente substituída por um sistema de reconhecimento de padrões utilizando IA.

Ações de Controle Preventivo e Corretivo

Se o sistema não tiver margem de estabilidade de tensão suficiente para uma ou mais das contingências selecionadas, devem ser determinadas ações para mover o estado do sistema de maneira tal a criar margem suficiente. Estas ações de controle preventivo devem ser tomadas antes que alguma contingência aconteça. A *AET on-line* deve prover diferentes alternativas de ações de controle, tais como, chaveamento de capacitor/reator, redespacho de geração, etc., e determinar o impacto de cada ação de controle sobre a segurança de tensão do sistema.

Caso ocorram contingências múltiplas, ações especiais de controle corretivo devem ser necessárias para impedir a instabilidade de tensão. Estas ações de controle corretivo geralmente intimidam os clientes (interrupção do serviço ou degradação da qualidade da energia) e portanto são reservadas para uso em resposta a distúrbios muito severos do

sistema. Um exemplo de uma ação de controle deste tipo é a coordenação do corte de carga. A *AET on-line* deve ser capaz de determinar o melhor cenário (local e quantidade mínima de corte de carga requerida) para os esquemas de ações corretivas envolvendo corte automático de carga.

A *AET on-line* deve validar a efetividade das ações de controle. Para o controle corretivo podem ser requeridas simulações dos eventos e das seqüências de controle no domínio do tempo. Para um desempenho aceitável numa aplicação on-line, as técnicas de simulações especiais no domínio do tempo necessitam ser computacionalmente mais rápidas do que os métodos convencionais e ainda capturar a dinâmica e as constantes de tempo importantes para a estabilidade de tensão.

4.3 – RESULTADOS SISTEMA SUL-SUDESTE

Nesta seção são apresentados os resultados obtidos com algumas técnicas de IA utilizadas na análise do Sistema Sul-Sudeste: MLP, kNN, RBF-DDA, Combinador Neural e o Sistema Neuro-Fuzzy ANFIS. Inicialmente será descrito como foram gerados os vetores padrões, relacionados ao sistema de potência equivalente do Sul-Sudeste, para o treinamento e o teste dos Sistemas IA (subseção 4.3.1).

Existem várias formas de se analisar o comportamento dos sistemas para estudos de índices e margens relativos à instabilidade de tensão. A abordagem utilizada levou em consideração o aumento total e uniforme das cargas em todas as barras do sistema mantendo-se constante o fator de potência (Soares e Caldas, 1997). O modelo utilizado neste estudo para a representação da carga é o modelo de potência constante.

O objetivo dos sistemas inteligentes, neste caso particular, é classificar o ponto de operação do sistema entre uma de duas condições: seguro ou alerta. As condições do sistema são determinadas em função do Índice Margem obtido através do Método da Continuação. Para uma condição segura foi estabelecido que o máximo carregamento do

Sistema Sul-Sudeste, a partir do ponto de operação do sistema, fosse maior que 3%. No caso de uma condição alerta o máximo carregamento estaria abaixo de 3%.

No caso de uma condição de operação do sistema ser classificada como alerta não necessariamente significa que o sistema estaria irremediavelmente fadado à instabilidade de tensão, mas sim que este teria uma forte propensão a tal. Esta indicação serviria como alerta aos operadores, que estariam então aptos a tomarem algumas das medidas importantes contra a instabilidade de longo termo, resumidas em (Taylor, 1996).

4.3.1 - PONTOS DE OPERAÇÃO E CONTINGÊNCIAS

O Sistema Sul-Sudeste (Figura 4.2) é a representação do sistema Sul do Brasil, no ano de 1996, alimentado por Itaipú e pelo sistema do Sudeste do país. Consiste de 77 barras, 144 linhas de transmissão, 14 geradores, 7 transformadores com LTC, operando nos níveis de tensão de 750, 525, 230, 138, e 69 kV.

A área crítica indicada pelo vetor tangente de predição são as barras: S. Maria - 138, S. Vicente - 138 e Alegrete - 69. Esta é a área que irá sofrer as piores conseqüências da Instabilidade de Tensão. Os geradores relevantes para o sistema Sul-Sudeste são: Itaipú, Salto Santiago, Passo Fundo, Salto Osório, Jorge Lacerda, Charqueado e GBM Rocha.

Os elos de transmissão avaliados como os mais importantes, são aqueles que ligam o sistema sul ao sudeste, particularmente o transformador Ivaiporã-525. Dentro do sistema sul algumas das linhas são importantes, tal como, as LT's que estão conectadas à barra de Gravataí-525 (Sodré, Almeida e Salgado, 1997).

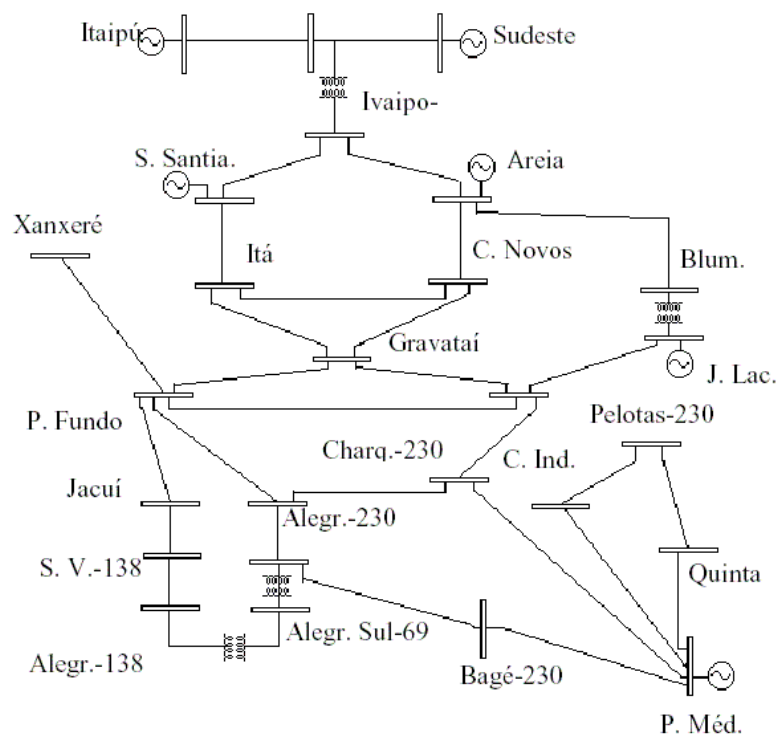


Figura 4.2 - Sistema Sul-Sudeste

Os elementos dos vetores \vec{x} - padrões de entrada das redes neurais -, são definidos com os valores das grandezas elétricas presentes na operação do sistema, quais sejam, as tensões e os ângulos das barras; e as injeções de potência ativa e reativa (todos os valores em pu).

Tais padrões para o Sistema Sul-Sudeste foram determinados através de uma aproximação da curva de carga diária do sistema. Estes são avaliados no intervalo de tempo da curva onde o sistema se encontra mais carregado (horário de pico), posto que os incidentes de instabilidade de tensão relatados na literatura acontecem prioritariamente neste momento (Taylor, 1994). Foram simulados dois dias de operação para extração dos vetores \vec{x} que fazem parte dos conjuntos de treinamento e teste. A diferença entre as duas curvas de carga diárias foi a mudança dos fatores de potência em algumas barras do sistema.

Algumas das barras escolhidas para a mudança do fator de potência pertencem à área crítica do sistema. É considerada também uma análise de contingências, onde foram

escolhidas algumas contingências entre os elementos do sistema mais importantes na manutenção da estabilidade de tensão. Algumas outras contingências foram escolhidas dentro da área crítica indicada pelo vetor tangente de predição. E algumas outras foram escolhidas para que o conjunto dos elementos para teste e treinamento fosse representativo. Não está sendo levado em consideração nesta análise de contingências o atendimento a algumas das restrições operacionais: magnitude de tensão e fluxo nos equipamentos de transmissão.

Algumas das contingências que devem ser ressaltadas são: a saída dos geradores da Usina Termelétrica de Jorge Lacerda, citada como contingência característica dos incidentes de instabilidade de tensão na região Sul (Soares e Caldas, 1997); saída das unidades geradoras de S. Osório, Passo Fundo e Jacuí; saída da linha de transmissão que liga a barra S.Vicente - 138 a barra Alegrete1 - 138; saída da linha de transmissão que liga a barra C. Ind. - 230 a barra Pelotas - 230.

Cada contingência considerada tem o seu Índice Margem específico, o que a faz pertencer à classe segura ou à classe dos padrões alerta. Como pode ser visto na Figura 4.3, onde são apresentadas três curvas P-V's da barra S. Vicente - 138, relativas a um ponto de operação do sistema com duas condições de contingência (curvas 2 e 3). A curva 3 apresenta um Índice Margem menor que 3%, o que faz com que esta condição de operação do sistema pertença a classe alerta. As contingências consideradas para a curva 3 foram a saída conjunta das unidades geradoras de Jacuí e Itaúba.




Figura 4.3 - Curvas P-V

É importante ressaltar a forma como foi feita a normalização dos dados e a melhora dos resultados obtidos com esta normalização. Todos os elementos dos conjuntos de treinamento e teste (vetores padrões) são normalizados pelo mesmo valor, ou seja, pega-se a maior tensão e todos os valores de tensão, de todos os outros vetores, são divididos por este valor. Faz-se a mesma coisa para o ângulo e para as injeções de potência ativa e reativa.

Na geração dos elementos para o estudo dos classificadores foi levado em consideração também, além da normalização, que cada ponto de operação (ponto da curva de carga diária) tivesse uma contingência que pertencesse à classe segura e outra contingência que levasse o sistema à uma condição de operação alerta.

Outra importante consideração na formação dos padrões de treinamento e teste é o tamanho dos vetores. Em alguns resultados deste trabalho foram considerados vetores de dimensão 20, ou seja, para o sistema de potência em estudo foram consideradas apenas 5 barras críticas, a partir das quais os valores de potência ativa e reativa, ângulo e tensão formam os elementos dos vetores padrões (Sodré e Mota, 2000). Em trabalhos anteriores foram consideradas todas as 77 barras do sistema (Neto, Sodré e Carvalho Jr., 1998).

Todas as considerações acima garantiram, conforme verificado, a menor margem de erro nos testes com os classificadores considerados.

Os dados usados no treinamento e no teste (apenas dois dias), contabilizam 70 condições de operação. Estas estão divididas entre os pontos de operação da curva de carga diária e suas condições obtidas através de contingências.

4.3.2. - RESULTADOS DO COMBINADOR

O uso do Combinador SMPM proposto (subseção 2.2.5) leva a se trabalhar com dois classificadores que demonstraram serem muito mais rápidos no que diz respeito à etapa de treinamento, do que a MLP atuando sozinha.

A primeira etapa dos resultados foi a utilização somente de uma MLP para a solução do problema. O que rendeu os seguintes resultados: a arquitetura final da MLP tem apenas uma camada escondida (hidden layer) com 6 neurônios e um único neurônio na camada de saída (output layer). Esta rede apresentou uma taxa de acerto de 95%. Apesar do grande desempenho final, assim como todos as MLP's, a deste trabalho não foi diferente em levar um considerável tempo de treinamento de quase duas horas.

O tamanho da MLP revelou-se muito pequeno em virtude principalmente do processo de formação utilizado nos elementos dos conjuntos de treinamento e teste. Foi visto que a geração dos elementos executada como citado anteriormente conduz à uma quase independência em relação às arquiteturas das MLP's testadas, como também pode ser visto em (El-Keib and Ma, 1995).

A segunda etapa consistiu no treinamento de uma RBF-DDA, que rendeu uma taxa de acerto de 47 %. Muito inferior à MLP, mas com um tempo de treinamento 10 vezes menor, o que enseja a utilização de tal rede num combinador.

A terceira etapa foi a construção de um kNN para a solução do mesmo problema enfrentado pela duas redes anteriores. Uma grata surpresa revelou-se no desempenho apresentado pelo kNN: uma taxa de acerto de 71% para o caso de considerarmos os 2 vizinhos mais próximos.

Tabela 4.2 - Primeiro Conjunto de Resultados

Métodos	Taxa de Acerto
MLP	95%
KNN	71%
RBF-DDA	47%
SMPM	73%

Apesar da RBF-DDA e do kNN apresentarem um desempenho inferior ao da MLP, as características individuais das duas redes são bastantes satisfatórias a uma aplicação num combinador.

O combinador proposto tem na condição IF um gerador de números aleatórios denominado RAND, que gera números inteiros de 1 a 10 numa distribuição uniforme. A condição IF será satisfeita para um acerto de 10% do RAND, ou seja, escolhido um número entre 1 e 10, por exemplo 2, toda vez que o RAND gerar o número 2 a condição IF será verdadeira e a combinação será feita, caso contrário a saída do combinador será a saída do kNN. Esta estratégia de combinação leva em consideração peculiaridades do problema de instabilidade de tensão e do Sistema Sul-Sudeste estudado. Para ajudar na compreensão da matemática do combinador aqui proposto repete-se abaixo a mesma figura utilizada na subseção 2.2.5.




Figura 4.4 – Combinador SMPM

Como foi dito anteriormente não há nada que justifique uma aplicação geral do Combinador SMPM. Por causa de sua característica estatística o SMPM rendeu em média uma taxa de acerto de 73% (Sodré, Neto e Carvalho Jr., 1999).

4.3.3. - RESULTADOS DO SISTEMA NEURO-FUZZY

São apresentados neste ítem o resultados obtidos na classificação do sistema neuro-fuzzy para avaliação da segurança do sistema Sul-Sudeste em relação à instabilidade de tensão. Assim como os resultados individuais dos dois classificadores considerados e a comparação entre estes (Sodré e Mota, 2000).

A primeira etapa foi a utilização somente de uma MLP para a solução do problema. Esta rede apresentou uma taxa de acerto de 86%.

A segunda etapa foi a construção de um kNN para a solução do mesmo problema enfrentado pela MLP anterior, tendo esta apresentando uma taxa de acerto de 75% (para o caso de considerarmos os 3 vizinhos mais próximos).

Na etapa final treinou-se o sistema neuro-fuzzy ANFIS, que teve um desempenho equiparável ao da MLP, ou seja, a taxa de acerto ficou em 86% também. Mas o ANFIS demonstrou ser mais rápido no que diz respeito à etapa de treinamento, do que a MLP atuando sozinha: 1000 vezes mais rápido.

Apesar do kNN apresentar um desempenho inferior ao da rede neural MLP, o tempo despendido na etapa de avaliação foi equiparável ao tempo gasto no treinamento do ANFIS. O que qualifica o sistema neuro-fuzzy testado como superior aos dois classificadores com os quais foi comparado. Os resultados finais relevantes estão resumidos na Tabela 4.3.

Tabela 4.3 - Segundo Conjunto de Resultados

Métodos	Taxa de Acerto	Tempo de Treinamento (seg.)
ANFIS	86%	10
MLP	86%	10800
KNN	76%	10

4.4 – RESULTADOS SISTEMA NORTE-NORDESTE

O Sistema Norte-Nordeste (Figura 4.5) utilizado neste trabalho representa os subsistemas brasileiros do Norte e do Nordeste conjuntamente, inclusive com as interligações entre os subsistemas Norte, Nordeste e Sudeste no ano de 2010. Consiste de 482 barras operando nos níveis de tensão de 500, 230, 138, 69 e 13.8 kV, 14 usinas hidrelétricas, 7 térmicas e 10 parques eólicos.

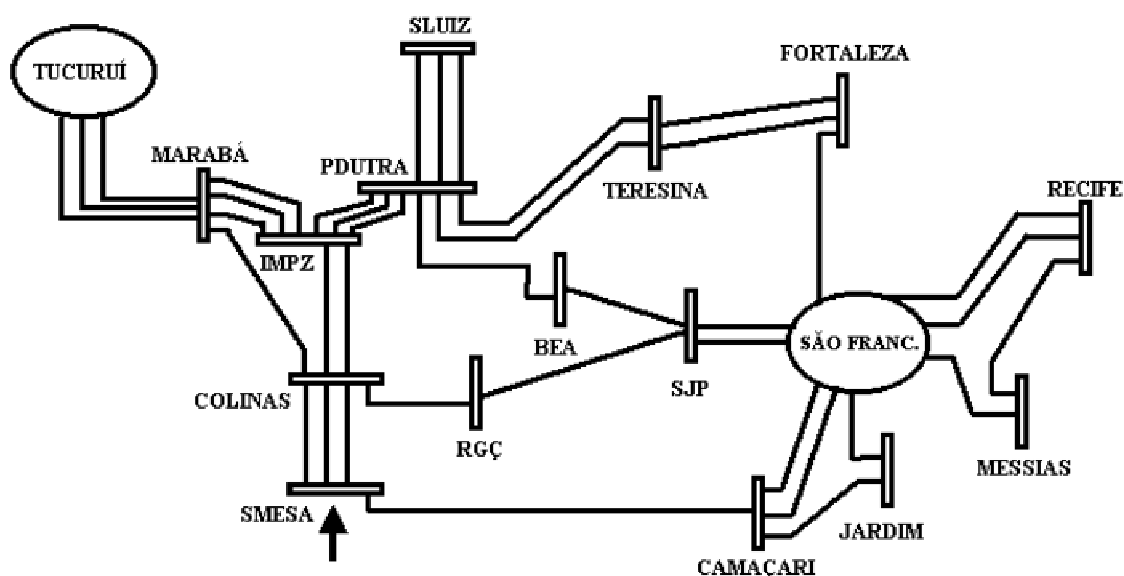


Figura 4.5 - Sistema Norte-Nordeste ano 2010 – Principais Troncos de 500 kV.

A principal característica do Sistema Norte-Nordeste é uma grande dependência em relação à geração hidrelétrica de apenas 2 (duas) bacias hidrográficas, a do rio Tocantins com os 8325 mil MW instalados de Tucuruí (as 2 etapas) e o Rio São Francisco com 9840

mil MW instalados. Isso faz com que cada vez mais o Sistema Norte-Nordeste seja dependente da energia enviada pelo Sudeste/Centro-Oeste.

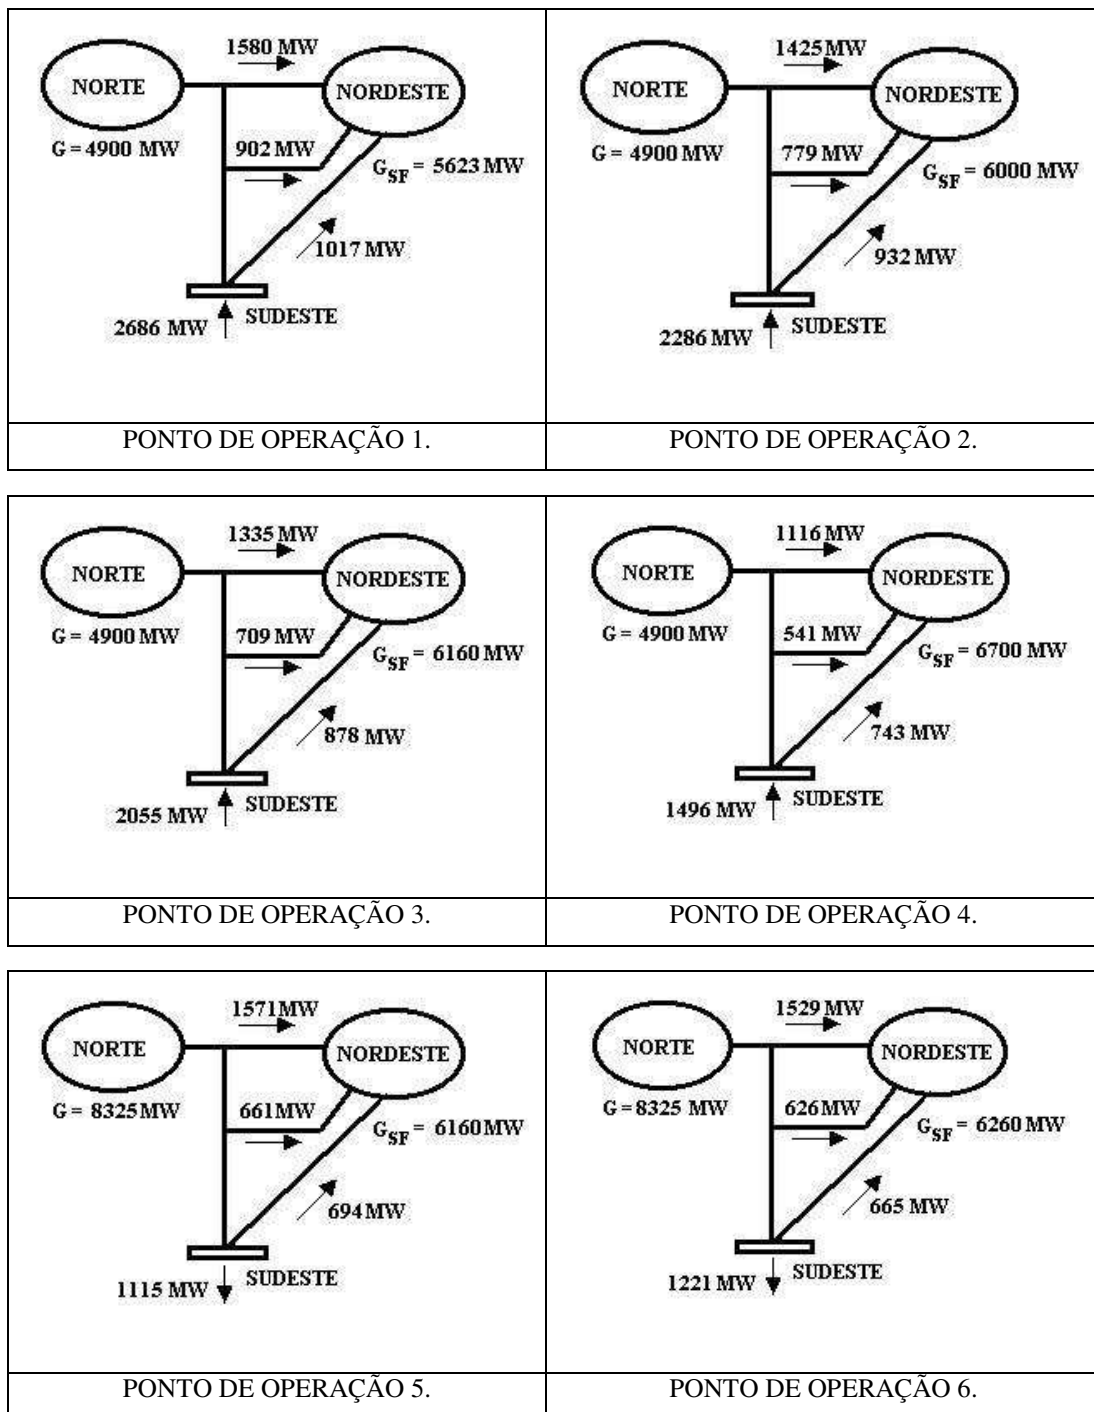
Uma das características mais interessantes da Bacia do Rio Tocantins é a forte sazonalidade de sua vazão, onde nos meses úmidos do ano (de janeiro a junho) essa vazão chega a atingir até 24000 m³/s e no período seco a vazão pode atingir o mínimo de 2000 m³/s. Sendo os meses secos do ano exatamente o período em que a demanda encontra-se em seus valores mais elevados, pode-se considerar que para o atendimento à carga máxima do Norte-Nordeste as interligações desempenham um papel preponderante, mesmo com a presença das térmicas instaladas, posto que o problema do gás natural ainda encontra-se sem solução.

Para o ano de 2010 contam-se com as seguintes quatro interligações entre os subsistemas (Figura 4.5): as 2 (duas) linhas de transmissão de 500 kV entre a SE Presidente Dutra e a SE Teresina mais a linha de 500 kV entre as SE's Presidente Dutra e Boa Esperança (BEA), perfazendo a chamada Ligação Norte-Nordeste; a nova interligação com entrada em operação prevista para o ano de 2007 constando das linhas Colinas-Ribeiro Gonçalves-São João do Piauí 500 kV e a duplicação da LT São João do Piauí-Sobradinho 500 kV, chamada interligação Colinas-Sobradinho; a interligação Sudeste-Nordeste com a linha de transmissão de 500 kV entre as SE's de Serra da Mesa e Correntina; e a interligação Norte-Sul com a entrada em operação do terceiro trecho em 2008. Como limites de importação de energia pelo subsistema Nordeste para o ano de 2010 pode-se considerar o limite de 3500 MW, conforme PAR 2006-2008 (2005).

4.4.1 - PONTOS DE OPERAÇÃO E CONTINGÊNCIAS

Levando-se em consideração as peculiaridades para a operação do Sistema Norte-Nordeste, conforme explicitadas acima, fez-se uma análise de máximo carregamento para gerar os pontos de operação inseguros e seguros, para o caso de carga pesada no ano de 2010. Esses pontos de operação irão formar a Base de Dados para o treinamento e o teste dos sistemas classificadores em estudo.

Como as interligações estão determinando de forma muito contundente a condição de operação do Sistema Norte-Nordeste, foram considerados vários valores de intercâmbios para a geração da Base de Dados. Segue na Figura 4.6 os pontos de operação que foram gerados para que a partir deles seja criada a Base de Dados.



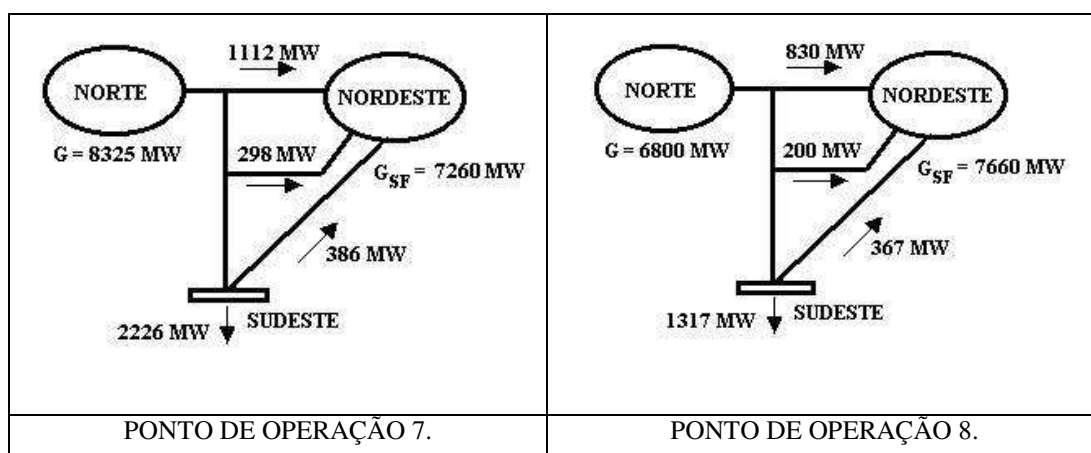


Figura 4.6 – Pontos de operação para o Sistema Norte-Nordeste.

Cada um desses 8 pontos de operação estão caracterizados de forma única pelas diferentes condições de importação de energia pelo Nordeste e pelas diferentes gerações de potência do Complexo Hidroelétrico do São Francisco e pela geração da hidroelétrica de Tucuruí.

Por exemplo, para o PONTO DE OPERAÇÃO 1., a geração de Tucuruí está em 4900 MW e a geração do São Francisco, contabilizando todas as hidroelétricas da cascata, está em 5263 MW. As cargas máximas para o ano de 2010 no Norte e no Nordeste são de aproximadamente 4800 MW e 10600 MW, respectivamente, isto faz com que se necessite de um recebimento de energia do Sudeste de aproximadamente 2700 MW, levando-se em conta as gerações das usinas termoeletricas e de outras bacias hidrográficas do Nordeste.

Na classificação dos pontos de operação da Figura 4.6 optou-se pela classificação desses em seguro ou inseguro, considerando já uma lista de contingências. Ou seja, dado um ponto de operação para o qual se deseja determinar a sua condição, deve-se pegar todas as contingências de uma dada lista e determinar se para todas aquelas contingências o máximo carregamento do sistema atende os requisitos específicos.

Caso exista apenas uma contingência da lista em que o máximo carregamento fique abaixo do limite especificado, então o ponto de operação é classificado como inseguro.

Para o ponto de operação ser classificado como seguro é necessário que todas as contingências da lista escolhida atendam o requisito de máximo carregamento.

A idéia é que não seja necessário executar o fluxo de carga de uma contingência para depois entrar com esse resultado num sistema classificador qualquer. O que se pretende é criar um Banco de Dados que já leve em conta a lista de contingências.

A maneira como foi feita anteriormente para a Análise do Sistema Sul-Sudeste era tal que se necessitava executar o fluxo para a contingência e depois dar como dado de entrada (vetor padrão) para o sistema classificador os valores de tensão, ângulo, etc. do sistema de potência considerando a contingência.

Para a Análise do Sistema Norte-Nordeste está sendo considerada uma forma diferente ao que foi feito para o Sistema Sul-Sudeste. Para exemplificar melhor as duas metodologias adotadas segue uma explicação sucinta.

Na análise do Sistema Sul-Sudeste foi considerado que para um dado ponto de operação ser classificado em seguro ou inseguro, era necessário executar toda a lista de contingências obtendo-se a solução do fluxo de carga para cada contingência. Cada fluxo de carga de cada contingência seria um dado de entrada para o sistema classificador, ou seja, para um dado ponto de operação existem N padrões que devem ser fornecidos para o sistema classificador. Caso um só dos N padrões seja classificado como inseguro o ponto de operação é dito INSEGURO. A Figura 4.7 exemplifica o Sistema de Avaliação de Estabilidade utilizado para o Sul-Sudeste.

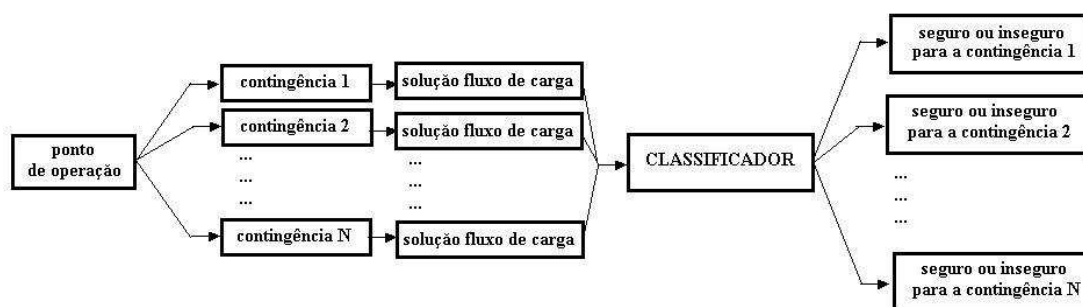


Figura 4.7 – Avaliação de Estabilidade para o Sistema Sul-Sudeste.

Para a Avaliação do Sistema Norte-Nordeste foi utilizada a seguinte estratégia: dado um ponto de operação para ser classificado, é suficiente que apenas esse ponto de operação seja apresentado ao sistema classificador. Isso porque anteriormente, durante a etapa da construção da Base de Dados, usada para treinar e testar o sistema classificador, esse ponto de operação já foi determinado como sendo inseguro ou seguro, pois todas as contingências já foram analisadas de forma *off-line*. A Figura 4.8 exemplifica o Sistema de Avaliação de Estabilidade utilizado para o Norte-Nordeste.




Figura 4.8 – Avaliação de Estabilidade para o Sistema Norte-Nordeste.

Tendo sido visto até o momento como foram analisadas as condições de operação críticas para o Sistema Norte-Nordeste e como será a estratégia para a avaliação da estabilidade de tensão em relação às contingências, deve-se, antes de ser mostrada a lista de contingências com a respectiva classificação dos pontos de operação, explicar uma outra estratégia adotada para o caso de análise de sistemas de potência de grande porte.

Conforme o Prof. Paulo Mendes (Mendes, 1999), optou-se por separar o sistema em áreas. Essa forma de analisar a estabilidade de tensão por área, ou seja, o máximo carregamento da Curva P-V para um dado conjunto de barras, facilita a construção

posterior dos sistemas classificadores, principalmente se o sistema de potência contém muitas centenas de barras.

Essa facilidade é devida ao menor tamanho do vetor padrão e devida também à que alguns sistemas de potência possuem em sua topologia conjuntos de barras que são afetadas de forma conjunta pela mesma condição de operação, o que caracteriza que possa ser feita uma análise de operação da área olhando-se unicamente as grandezas elétricas dessas barras.

Neste trabalho pretende-se desenhar uma metodologia que seja de aplicação geral. A proposta é dividir o sistema em áreas e dessas áreas escolher só algumas barras para a construção do vetor padrão. Então um sistema de Análise de Segurança para Avaliação da Estabilidade de Tensão *on-line* segue como na Figura 4.9. Se apenas uma área é considerada insegura todo o sistema passa a ser inseguro. Essa divisão em áreas tem uma vantagem de apontar para o operador qual área vai requerer uma ação preventiva. A desvantagem é que é necessário treinar um sistema classificador para cada área.

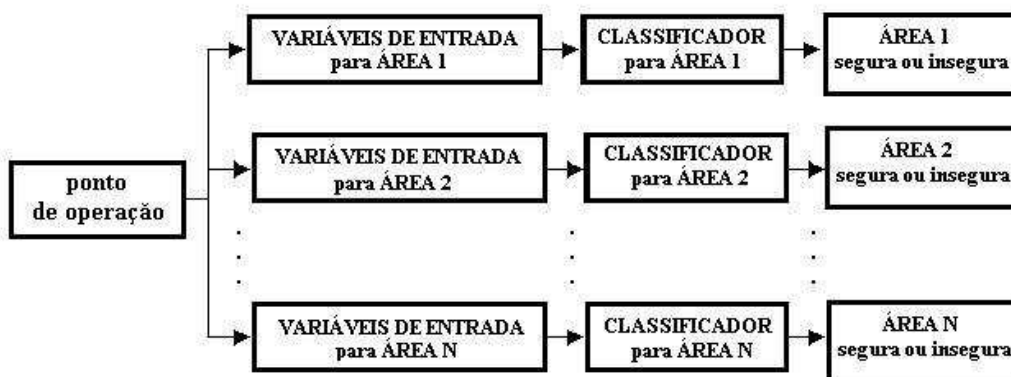


Figura 4.9 – Sistema de Avaliação de Estabilidade por Áreas.

Em relação à lista de contingências, que deve ser considerada para determinar-se se aquela área é segura ou não, cada área deve ter sua lista exclusiva. Nessa lista devem constar também contingências que não sejam de elementos que pertençam à área, mas que afetam o máximo carregamento da área, como por exemplo, as interligações entre os subsistemas.

Considerando-se que o trabalho realizado para uma área do Sistema Norte-Nordeste seria o mesmo trabalho realizado para todas as outras áreas, com relação à metodologia de escolha do número de barras para formação do vetor padrão e a escolha da melhor estrutura do sistema classificador, então foi feita a opção de se trabalhar apenas com a Área Leste do Subsistema Nordeste.

A Área Leste é composta de 84 barras que são alimentadas principalmente pelo 500kV da SE Recife-2, notadamente as áreas de Natal, Campina Grande, João Pessoa, Recife e Maceió.

As contingências consideradas para a área leste podem ser vistas na Tabela 4.4

Tabela 4.4 – Lista de Contingências para a Área Leste do Subsistema Nordeste.

Da BARRA	Para BARRA	Circuito
Serra da Mesa 500 kV	Correntina 500 kV	1
Colinas 500 kV	Ribeiro Gonçalves 500 kV	1
P. Dutra 500 kV	Teresina II 500 kV	2
P. Dutra 500 kV	Boa Esperança 500 kV	1
Xingó 500 kV	Messias 500 kV	1
Angelim II 500 kV	Recife II 500 kV	2
Recife II 500 kV	Messias 500 kV	1
Banabuiú 230 kV	Mossoró 230 kV	2
Síncrono de Recife II (uma unidade)		

Considerando a Área Leste e a sua respectiva lista de contingências, os pontos que foram gerados (Figura 4.6) são classificados pelo máximo carregamento da Curva P-V do seguinte modo: para a contingência que resulta num máximo carregamento menor que 5%, foi considerado que o ponto de operação é inseguro. Se todas as contingências da lista têm máximo carregamento acima de 5% então o ponto de operação é classificado como seguro.

Segue a Tabela 4.5 onde estão listados os pontos de operação para a formação da Base de Dados e suas respectivas classificações.

Tabela 4.5 – Classificação dos Pontos de Operação.

PONTOS DE OPERAÇÃO	CLASSE
1	INSEGURA
2	INSEGURA
3	INSEGURA
4	SEGURA
5	INSEGURA
6	INSEGURA
7	SEGURA
8	SEGURA

A Base de Dados será construída a partir dos 8 pontos de operação, já classificados em seguro e inseguro conforme Tabela 4.5. Optou-se nesse trabalho por gerar uma Base de Dados de forma que os seus vetores padrão fossem aleatoriamente com variações randômicas de 5%, 20%, 60% e 90%.

Para gerar uma dessas Bases de Dados parte-se de um ponto de operação da Figura 4.6 e monta-se o vetor padrão. A partir desse vetor padrão criam-se 200 vetores padrão de forma aleatória. Considerando-se os pontos de operação da Figura 4.6 são criados 1600 vetores padrão, ou seja, o tamanho da Base de Dados de onde irá se extrair o resultado dos sistemas classificadores é de 1600 vetores, desses foram escolhidos 1120 vetores para treinamento e 480 para teste.

A criação aleatória segue a seguinte lógica: para cada elemento do vetor padrão é gerado um número aleatório *rand* cujo valor esteja, por exemplo, entre $-0.9 < rand < +0.9$. Então o elemento do novo vetor padrão será $ele = ele * (1 + rand)$.

Mostra-se na Figura 4.10 as variáveis *rand* para a criação de um vetor padrão aleatório de 164 elementos. Esse vetor padrão foi construído a partir de 41 barras da Área Leste, cada barra determina 4 elementos do vetor padrão (tensão, ângulo, injeção de potência ativa e injeção de potência reativa). Vê-se que as variações estão entre -0.9 e +0.9, ou seja, está sendo criado um vetor randômico com 90% de variação.




Figura 4.10 – Variações para as 164 variáveis de um vetor padrão.

Considerando que se pode gerar vetores padrão para a Área Leste que não sejam com todas as 82 barras da área, foi feita uma análise de quais barras são as críticas para que fosse construído um vetor padrão de menor tamanho, conforme resultados do sistema Sul-Sudeste. A Tabela 4.6 mostra algumas das barras mais sensíveis da Área Leste.

Tabela 4.6 – Barras críticas da Área Leste.

Nº da BARRA	NOME
648	MUSSURE 069
745	STA RITA 069
658	PENEDO 069
649	PIRAPAMA 069
643	BONGI 069
660	PAU FERRO 069
650	MIRUEIRA 069
659	MACEIO 069

A partir da relação das barras críticas da Área Leste foi feita uma análise para se determinar quantas barras deveriam ser utilizadas para a formação do vetor padrão para treinamento do sistema classificador, o que gerou os seguintes resultados:

Tabela 4.7 – Análise de número de barras para formação do vetor padrão.

5 BARRAS	5%	20%	60%	90%
ANFIS	99.4 %	99.2 %	90.6 %	82.92 %
RPROP	100 %	99.2 %	90 %	83.96 %

17 BARRAS	5%	20%	60%	90%
ANFIS	99.4 %	99.2 %	95.6 %	89.20 %
RPROP	100 %	100 %	96.7 %	93.50 %

41 BARRAS	5%	20%	60%	90%
ANFIS	100 %	99.58 %	94.2 %	82.08 %
RPROP	100 %	100 %	98.1 %	93.75 %

Foram gerados três conjuntos de resultados, um conjunto para cada tamanho de vetor padrão que se queria analisar. Primeiramente foi feita uma análise para uma Base de Dados que foi construída com vetores padrão de tamanho 20. Foram escolhidas as 5 barras mais críticas da Área Leste para gerar o vetor padrão. O segundo conjunto de resultados foi para um vetor padrão de tamanho 68 (17 barras) e o terceiro conjunto de resultados com vetor padrão de 164 elementos (41 barras).

Então para cada um dos 8 pontos de operação da Figura 4.6 foram gerados de forma aleatória 200 vetores padrão, o que rende uma Base de Dados de 1600 vetores, conforme explicado anteriormente. Para cada conjunto de resultados foram gerados ainda Bases de Dados aleatórias de variações de 5%, 20%, 60% e 90%. Para cada conjunto e para cada Base de Dados foram feitos testes usando os sistemas classificadores ANFIS e RPROP.

Vê-se na Tabela 4.7 que ao se trabalhar com 17 barras, que corresponde a 20% das barras da Área Leste, obtêm-se um bom resultado. Para a Base de Dados aleatória de variação de 5% e 20% os resultados apresentados são tecnicamente iguais, o que faz crer que é indiferente trabalhar-se com 5, 17 ou 41 barras para a formação do vetor padrão. Mas ao se analisar os resultados para as Bases de Dados aleatórias de variação de 60% e 90%, são encontrados resultados superiores para os vetores padrão de 17 e 41 barras.

Em relação à questão prática de se trabalhar com um vetor padrão de 68 elementos (17 barras) ou 164 elementos (41 barras) é mais vantajoso que se trabalhe com o menor vetor possível, pois a eficiência do sistema classificador será maior. Apesar disso os

resultados apresentados na próxima seção são para os vetores padrão construídos com 17 barras e 41 barras.

4.4.2. - RESULTADOS DO SISTEMA HÍBRIDO

Os primeiros resultados a serem observados, em função das análises já efetuadas para o sistema Sul-Sudeste, são os resultados relativos aos três tipos de classificadores cujo desempenho deseja-se comparar, que são, o MLP com treinamento backpropagation; o RPROP; e o ANFIS.

Em relação à rede neural com treinamento backpropagation, aqui denominada MLP, analisamos dois resultados, conforme Tabela 4.8. Esses resultados apresentaram um tempo de treinamento extremamente longo, comparados com o tempo de treinamento apresentados pela rede neural com treinamento “resilient propagation” (RPROP) e o tempo de treinamento apresentado pelo sistema neuro-fuzzy ANFIS.

Em relação à taxa de acerto, para a Base de Dados aleatória com variação de 5% e 1600 vetores padrão, o RPROP apresentou o melhor resultado.

Vale ressaltar também a grande quantidade de classificações falso seguro pela MLP, que são as classificações mais preocupantes num Sistema de Avaliação de Segurança *on-line*. Uma classificação falso seguro é quando o sistema após ser apresentado à um dado de entrada classifica-o como seguro, sendo na verdade aquele ponto de operação um ponto inseguro. As classificações falso inseguro são o inverso das classificações falso seguro e podem ser consideradas como contribuindo para a segurança do sistema, desde que não degradem o desempenho da operação.

Tabela 4.8 – Resultados considerando MLP convencional.

17 BARRAS / 5 %	Tempo de treinamento	Taxa de acerto	falso seguro	falso inseguro
MLP	6.67 min.	75.6 %	58	59
MLP	2.83 h.	96.2 %	13	5
ANFIS	3.02 seg.	99.4 %	3	0
RPROP	4.6 seg.	100 %		

Conforme os resultados demonstraram, o tempo de treinamento da MLP é muito extenso, desempenho já apresentado para o Sistema Sul-Sudeste, optando-se então por não mais utilizar esse tipo de treinamento nos testes futuros a serem analisados.

Conforme os próximos resultados foram se delineando, observou-se que o RPROP tinha um desempenho bastante equivalente ao sistema ANFIS. Esta equivalência conduziu o trabalho à uma proposta de um sistema classificador que contivesse o melhor das duas abordagens, a abordagem neural e a abordagem fuzzy.

Aproveitando-se das vantagens particulares de ambas as abordagens neural e fuzzy, pretende-se ganhar o poder de “compressão” de uma grande massa de dados através da rede neural e com a abordagem fuzzy pretende-se obter uma estrutura onde possam ser incorporados o conhecimento linguístico dos operadores.

Em relação ao sistema fuzzy, outro “ganho” advindo da sua utilização seria a facilidade da apropriação de um novo conhecimento, pois o sistema fuzzy não apresenta o problema da plasticidade. Ou seja, qualquer nova regra colocada num sistema fuzzy será avaliada em paralelo em relação a todas as regras já existente. O dilema da plasticidade praticamente não existe. E como neste trabalho está sendo utilizado o sistema neuro-fuzzy ANFIS, em que o ajuste dos parâmetros (variáveis) do sistema fuzzy é feito de forma automática ainda há uma vantagem adicional em relação aos sistemas fuzzy tradicionais.

O sistema classificador proposto foi realizado numa estrutura série. Foram compostos dois classificadores híbridos, o híbrido RPROP (Figura 4.12) e o híbrido kNN

(Figura 4.13), que tiveram seus desempenhos comparados com as técnicas analisadas até o momento.

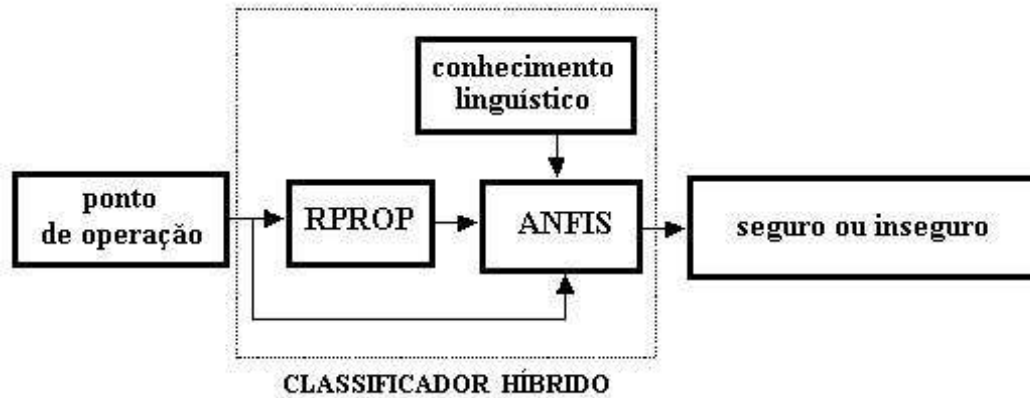


Figura 4.11 – Sistema Classificador Híbrido RPROP.

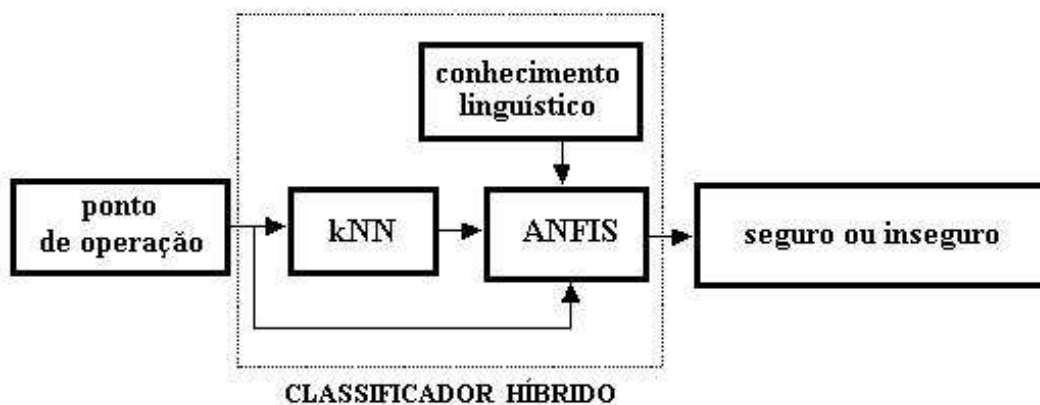


Figura 4.12 – Sistema Classificador Híbrido kNN.

O funcionamento dessa estrutura de sistema classificador dá-se da seguinte forma: o ponto de operação é primeiramente avaliado pelo primeiro classificador da estrutura série, qual seja o RPROP ou o kNN, em seguida o resultado (que é um número real entre $-\infty$ e $+\infty$ ou um vetor) é avaliado pelo sistema neuro-fuzzy ANFIS. Então a saída do sistema híbrido é seguro ou inseguro.

Cabe ressaltar que essa estrutura pode também aproveitar qualquer “conhecimento” que os operadores possam querer incorporar ao sistema, como por exemplo: *If (intercâmbio é alto) then (segurança é mínima)*. E essas regras, conforme explicadas acima, podem ser

colocadas de forma aleatória no sistema ANFIS, sendo todas as regras fuzzy interpretadas de forma paralela. O único cuidado que deve ser exercido quando da incorporação do conhecimento linguístico no ANFIS é avaliar de forma crítica o desempenho do sistema resultante.

O primeiro conjunto de resultados (Tabela 4.9) são para a Base de Dados formada com o vetor padrão de 17 barras. Para esse vetor padrão de 68 elementos foram geradas 4 Bases de Dados aleatórias distintas, uma Base de Dados com variação de 5%, outra com variação de 20% e as duas restantes com variações de 60% e 90%.

Tabela 4.9 – Resultados com vetor padrão de 17 barras e Bases de Dados de 5%, 20%, 60% e 90%.

17 BARRAS / 5 %	Tempo de treinamento	Taxa de acerto	falso seguro	falso inseguro
ANFIS	3.02 seg.	99.4 %	3	0
RPROP	4.6 seg.	100 %		
HÍBRIDO RPROP	≅ 4.6 seg.	100 %		
17 BARRAS / 20 %	Tempo de treinamento	Taxa de acerto	falso seguro	falso inseguro
ANFIS	10.1 min.	99.2 %	0	4
RPROP	18.46 seg.	100 %		
HÍBRIDO RPROP	≅ 18.46 seg.	100 %		
17 BARRAS / 60 %	Tempo de treinamento	Taxa de acerto	falso seguro	falso inseguro
ANFIS	2.7 min.	95.6 %	4	17
RPROP	2.3 min.	96.7 %	2	14
HÍBRIDO RPROP	≅ 2.3 min.	98.8 %	0	6
17 BARRAS / 90 %	Tempo de treinamento	Taxa de acerto	falso seguro	falso inseguro
ANFIS	59.2 seg.	89.2 %	31	21
RPROP	1.53 min.	93.5 %	18	13
HÍBRIDO RPROP	RPROP + 2.31 seg.	95.4 %	3	19
kNN com 3 vizinhos		74.8 %	61	60
kNN com 9 vizinhos		68.5 %	65	86
kNN com 27 vizinhos		72.5 %	28	104
HÍBRIDO kNN (com 3 vizinhos)		76.2 %	16	98

Para esse primeiro conjunto de resultados, considerando as variações aleatórias de 5% e 20%, foram comparados apenas os três sistemas seguintes: ANFIS; RPROP; e o sistema classificador Híbrido RPROP. Tendo a rede neural com treinamento RPROP resultado numa taxa de acerto de 100%, conseqüentemente o Híbrido RPROP também apresenta como resultado uma taxa de acerto de 100%.

Cabe ressaltar que o sistema ANFIS operando sozinho e não na estrutura híbrida, resulta num sistema fuzzy de 2 regras e 410 parâmetros a serem otimizados para um vetor de entrada de 68 elementos. Essa estrutura é determinada de forma automática pelo algoritmo auto-construtivo denominado *subtractive clustering* (Chiu, 1994). Esse algoritmo é bastante rápido e de apenas um único passo (não sendo iterativo), pegando um conjunto de dados de pares entrada-saída e gerando um sistema fuzzy que modela a relação entrada-saída estimando o número de clusters e os centros dos clusters para o conjunto de dados.

Para o sistema ANFIS operando na estrutura do Híbrido RPROP têm-se um sistema fuzzy de 2 (duas) regras e 8 (oito) parâmetros a serem otimizados para um vetor de entrada de 1 (um) elemento. Isso faz com que o trabalho da lógica fuzzy e a incorporação do conhecimento lingüístico dos operadores seja facilitada.

Em todos os casos testados a rede neural RPROP utilizada é formada por 5 (cinco) neurônios na camada escondida e 1 (um neurônio) na camada de saída, o que resulta em 350 parâmetros a serem otimizados.

Considerando o resultado para a Base de Dados aleatória com 90% de variação para os dois sistemas híbridos em estudo, o Híbrido RPROP e o Híbrido kNN, apresenta-se um resultado muito superior do Híbrido RPROP pois o seu tempo de treinamento é de aproximadamente 1.57 minutos, contabilizando os 1.53 minutos de treinamento da rede neural RPROP e mais os 2.31 segundos da treinamento do neuro-fuzzy ANFIS. Considerando também a quantidade de classificações falso seguro o Híbrido RPROP mostrou-se muito superior. Para esses resultados também foram testados o tradicional método de classificação kNN não tendo sido demonstrados resultados satisfatórios.

O segundo conjunto de resultados (Tabela 4.10) são para as Bases de Dados formadas com o vetor padrão de 41 barras. Para esse vetor padrão de 164 elementos foram geradas também as 4 (quatro) Bases de Dados aleatórias com variação de 5%, 20%, 60% e 90%.

Tabela 4.10 – Resultados com vetor padrão de 41 barras e Bases de Dados de 5%, 20%, 60% e 90%.

41 BARRAS / 5 %	Tempo de treinamento	Taxa de acerto	Falso seguro	falso inseguro
ANFIS	19.06 seg.	100 %		
RPROP	5.05 seg.	100 %		
41 BARRAS / 20 %	Tempo de treinamento	Taxa de acerto	falso seguro	falso inseguro
ANFIS	55 min.	99.6 %	1	1
RPROP	4.61 seg.	100 %		
41 BARRAS / 60 %	Tempo de treinamento	Taxa de acerto	falso seguro	falso inseguro
ANFIS	31 min.	94.17 %	21	7
RPROP	23,73 seg.	98.12 %	5	4
HÍBRIDO RPROP		98.54 %	3	4
41 BARRAS / 90 %	Tempo de treinamento	Taxa de acerto	falso seguro	falso inseguro
ANFIS	4.74 min.	82.08 %	64	22
RPROP	49.32 seg.	93.75 %	5	25
HÍBRIDO RPROP	RPROP + 0.11 seg.	93.96 %	4	25

Para esses resultados com 41 barras o Híbrido RPROP apresenta um desempenho também mais vantajoso do que os outros sistemas classificadores. O tempo de treinamento é praticamente igual a 49 segundos, para a Base de Dados de variação de 90%, com a vantagem de se ter uma quantidade menor de classificações falso seguro, notadamente para a Base de Dados de variação de 60%.

4.5 - CONCLUSÕES

Todos os sistemas classificadores considerados neste trabalho conduziram ao desenvolvimento de um arranjo vantajoso das duas principais técnicas de reconhecimento de padrão utilizadas, as redes neurais e os sistemas fuzzy. Em relação à sua aplicação para análise de segurança de sistemas de potência, pode-se dizer que o sistema classificador Híbrido RPROP mostrou-se ser o melhor arranjo entre todos. Pois conta, o Híbrido RPROP com a vantagem de incorporar a capacidade de tratamento de uma grande massa de dados da rede neural e a capacidade de tratamento do conhecimento de alto nível da lógica fuzzy.

É importante ressaltar o processo de construção dos dados do sistema de potência como peça chave no desempenho apresentado. Tratamento este que levou em consideração a normalização dos vetores padrão e a facilidade de formação dos vetores de entrada da rede, desde que os seus elementos são apenas as grandezas elétricas do sistema.

Deve-se ressaltar também que nesse trabalho foi delineada uma metodologia para dividir o sistema de potência em áreas e trabalhar-se com um número reduzido de barras para a geração do vetor padrão.

Capítulo 5

Conclusões e Trabalhos Futuros

A presente Tese após realizar a demonstração das principais técnicas de inteligência artificial faz um resumo dos conceitos básicos do problema de estabilidade de tensão, ressaltando a adequação da ferramenta ao problema que se pretende solucionar.

Neste trabalho foram exploradas várias técnicas de reconhecimento de padrão contando-se com as redes neurais MLP, e RBF-DDA. Estas duas redes são paradigmas das estratégias de redes supervisionadas e construtivas, respectivamente. Estas foram comparadas com uma das mais tradicionais técnicas de reconhecimento de padrão o kNN. Ainda foi proposto, de forma preliminar, neste trabalho um combinador neural.

Posteriormente foram elucidados os mecanismos da lógica fuzzy, que suportam os modos de raciocínio que são aproximados ao invés de exatos. A lógica fuzzy constitui a base para o desenvolvimento de métodos e algoritmos de modelagem e controle de processos bastante eficientes, permitindo a redução da complexidade e a facilidade da implementação. Tornando-se a solução para problemas até então intratáveis por técnicas clássicas. O sistema baseado em lógica fuzzy utilizado foi o sistema ANFIS, tendo sido demonstrado ser de uso factível.

Foi demonstrada neste trabalho a extensa utilização do critério de carregamento baseado na computação da Curva P-V como o indicador do estado de operação do sistema em seguro ou inseguro, em relação à estabilidade de tensão, pelas empresas do setor

elétrico ao redor do mundo. Esta classificação viabiliza a aplicação de técnicas de reconhecimento de padrão.

Os resultados finais para o Sistema Norte-Nordeste desenharam uma metodologia geral de divisão do sistema de potência em áreas, para que possa ser implementada de forma prática a análise de segurança em redes elétricas de grande porte. Essa metodologia pode ser implementada em qualquer sistema de potência e sua portabilidade, apesar de não ser completa, é garantida pela rede neural RPROP, que praticamente não varia seus números de camadas e neurônios, e pela capacidade auto-constitutiva do sistema neuro-fuzzy ANFIS.

Tendo sido estudadas e analisadas várias técnicas de IA conclui-se que essas novas ferramentas da engenharia são companheiras indispensáveis na tarefa da análise da segurança on-line, conforme já explicitado na revisão bibliográfica. Acredita-se que a sua aplicação pode resultar numa simbiose fecunda com as outras técnicas já existentes, sendo a principal vantagem das técnicas de IA sua facilidade de aplicação e implementação, não requerendo sistemas computacionais de grande porte nem requerendo algoritmos matemáticos de elevada complexidade.

Como conclusão pode-se afirmar que a abordagem do problema da avaliação da segurança através do Sistema Híbrido RPROP apresenta uma ótima qualidade de solução, sendo superior às outras estruturas de classificadores analisadas, conseguindo aproveitar as vantagens das soluções das redes neurais artificiais e dos sistemas fuzzy.

TRABALHOS FUTUROS

Como caminhos a serem trilhados para a implementação de sistemas de análise de segurança utilizando-se das técnicas de inteligência artificial pretende-se indicar alguns trabalhos posteriores que devem ser mapeados para posterior implementação prática:

1. – Classificação dos pontos de operação do sistema de potência em gradações de segurança, tais como, *muito seguro*, *seguro*, *pouco seguro* ou *inseguro*. Essas gradações

tem como objetivo facilitar a atuação dos operadores do sistema em intervenções para correção de situações adversas.

2. – Implementar a incorporação do conhecimento linguístico no Classificador Híbrido RPROP.
3. – Incorporar a análise de transitório eletromecânico na definição dos pontos de operação seguros e inseguros.
4. – Desenvolver estratégias de controle preventivo e corretivo utilizando-se técnicas de inteligência artificial.
5. – Desenvolver um sistema computacional para Avaliação da Estabilidade de Tensão *on-line*.
6. – Analisar a integração das diversas técnicas para a Avaliação da Estabilidade de Tensão *on-line* juntamente com o sistema classificador Híbrido RPROP, notadamente as técnicas de avaliação rápida no tempo.

Referências

Ajjarapu, V., and Christy, C. (1992). “The continuation power flow: A tool for steady state voltage stability analysis”, *IEEE Transactions on Power Systems*, 7(1):416_423, February.

Ajjarapu, V., and Lee, B. (1998) “Bibliography on Voltage Stability”, *IEEE Transactions on Power Systems*, Vol. 13, N. 1, February.

Amjady, N., (2003). “Dynamic voltage security assessment by a neural network based method”, *Electric Power Systems Research* 66, 215-226.

ANDESA. (2001). Relatório Técnico N RT-01-06.01 – INDISPONIBILIDADE DO BARRAMENTO PRINCIPAL DE 230 kV DA SE BOM NOME, ANDESA.

Avila-Rosales, R.; Sadjadpour, A.; Gibescu, M.; Morison, K.; Hamadani, H. and Wang L., (2003). “ERCOT's implementation of on-line dynamic security assessment”, *Power Engineering Society General Meeting*, 2003, IEEE, Volume: 3, 13-17 July, Pages:1948 - 1951 Vol. 3.

Avramovic, B. and Fink, L. K. (1992). “Real-time reactive security monitoring,” *IEEE Trans. Power Syst.*, vol. 7, pp. 432–437, February.

Bansal, R. C. (2003). “Bibliography on the Fuzzy Set Theory Applications in Power Systems (1994-2001)”, *IEEE Transactions on Power Systems*, Vol. 18, NO. 4, NOVEMBER, pp. 1291-1299.

Bao, L.; Huang, Z. and Xu, W., (2003). “Online Voltage Stability Monitoring Using Var Reserves”, *IEEE Transactions on Power Systems*, Vol. 18, No. 4, November.

Beale, R. and Jackson, T. (1990). “Neural Computing: An Introduction”, Adam Hilger.

- 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*, June 23th-26th, 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):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.
- Chiu, S. (1994). "Fuzzy Model Identification Based on Cluster Estimation," *Journal of Intelligent & Fuzzy Systems*, Vol. 2, No. 3, Sept. 1994.
- Dinavahi, V.R. and Srivastava, S.C., (2001), "ANN based voltage stability margin prediction" *Power Engineering Society Summer Meeting, IEEE* , Volume: 2 , 15-19 July, Pages: 1275 - 1280 vol.2.
- Ejebe, G. C.; Irisarri, G. D.; Mokhtari, S.; Obadina, O.; Ristanovic, P. and Tong, J., (1996). "Methods for contingency screening and ranking for voltage stability analysis of power systems," *IEEE Transactions on Power Systems*, Vol. 11, No. 1, Feb.
- El-Keib, A. A. and Ma, X. (1995). "Application of Artificial Neural Networks in Voltage Stability Assesment", *IEEE Transactions on Power Systems*, Vol. 10, N. 4, pp. 1890-1896.
- El-Sharkawi, M. A. and Niebur, D. (1996). "Application of Artificial Neural Networks to Power systems", *IEEE Tutorial* (Editors).
- Franchi, L.; Gambelunghe, A.; Salvati, R. and Sforza, M., (2003). "Online Dynamic Security Assessment at the Italian Independent System Operator", *IEEE Bologna Power Tech Conference*, June 23th-26th, Bologna, Italy.

Gupta, M. M. and Sinha, N. K. (1996). "Intelligent Control Systems - Theory and Applications", IEEE Press Inc.

Hatziargyriou, *et al.* (2001), "Preliminary Results from the more advanced control advice project for secure operation of isolated power systems with increased renewable energy penetration and storage", 2001 IEEE Porto Power Tech Conference 10th-13th September, Porto, Portugal.

Haykin, S. (1994). "Neural networks: a comprehensive foundation", Macmillan College Publishing Company, New York.

Höhfeld, M. and Schürman, B. (1993). "The Roles of Neural Networks and Fuzzy Logic in Process Optimization", Siemens Review - R&D Special - Fall.

Huang, P.-H. (1994). "Analysis of Power System Dynamic Stability via Fuzzy Concepts", Fuzzy Logic Technology and Applications, R. J. Marks II - Editor, IEEE Press Inc.

IEEE/PES, Power System Stability Subcommittee, Special Publication. (2002). "Voltage Stability Assessment: Concepts, Practices and Tools", Final Document.

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., (2000). "Online dynamic security assessment: implementation problems and potential use of artificial intelligence", Power Engineering Society Summer Meeting, 2000. IEEE , Volume: 1 , 16-20 July, Pages:340 – 345.

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 , Volume: 4 , 16-20 July, Pages:2014 - 2018 vol. 4.

- 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.
- La Scala, M.; Trovato, M. and Torelli, F., (1996). “A Neural Network-Based Method for Voltage Security Monitoring”, *IEEE Transactions on Power Systems*, Vol. 11, No. 3, August.
- Lachs, W. R. and Sutanto, D. (1995). “Rotor heating as an indicator of system voltage instability,” *IEEE Trans. Power Syst.*, vol. 10, pp. 175–181, February.
- Lambert Torres, G., *et. al.* (1998), “Planejamento e Operação de Sistemas de Potência Sob Incertezas Via Técnicas Difusas”, *Proceedings of VI SEPOPE*, Salvador, Brazil.
- Lin, C.-T. and Lee, C. S. G. (1996). *Neural Fuzzy Systems - A Neuro-Fuzzy Synergism to Intelligent Systems*, Prentice Hall.
- Liu, C.-W.; Chang, C.-S.; and Su, M.-C.; (1998). “Neuro-Fuzzy Networks for Voltage Security Monitoring Based on Synchronized Phasor Measurements”, *IEEE Transactions on Power Systems*, Vol. 13, No. 2, May.
- Maiorano, A. and Trovato, M., (1998). “A neural network-based tool for preventive control of voltage stability in multi-area power systems”, *Neurocomputing* 23, 161-176.
- Marannino, P.; Berizzi, A.; Merlo, M.; Demartini, G.; (2002). “A rule-based fuzzy logic approach for the voltage collapse risk classification”, *Power Engineering Society Winter Meeting*, 2002. *IEEE*, Volume: 2, 27-31 Jan.
- 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 Potência”, julho, Tese de Doutorado, Coordenação dos Programas de Pós-Graduação em Engenharia – COPPE, UFRJ.

Mendes, P. P. de C.; Falcão, D. M.; da Silva, A. P. A., (2000a). “Real Time Steady State Voltage Stability Assessment with a Grid of Artificial Neural Networks.”, SEPOPE – Simpósio de Especialistas em Planejamento da Operação e Expansão Elétrica, Brasil.

Mendes, P. P. de C.; Falcão, D. M.; 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.

Momoh, J. A., Ma, X. W., and Tomsovic, K. (1995). “Overview and Literature Survey of Fuzzy Set Theory in Power Systems”. *IEEE Transactions on Power Systems*, Vol. 10, No. 3.

Natível, G.; Jacquemart, Y.; Sermanson, V. and Nérin, G., (2000). “Integrated Framework for Voltage Security Assessment”, *IEEE TRANSACTIONS ON POWER SYSTEMS*, VOL. 15, NO. 4, NOVEMBER.

Neto, J. F., Sodrê E., e Carvalho Jr., M. A. de, (1998). “Utilização de Redes Neurais para Determinação da Segurança de Sistemas de Potência em Relação à Instabilidade de Tensão de Longo Termo”, *Proceedings of VI SEPOPE*, Salvador, Brazil.

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 (Operador Nacional do Sistema Elétrico), (2002). Módulo 23 – Critérios para Estudos.

ONS (Operador Nacional do Sistema Elétrico), (2005). PLANO DE AMPLIAÇÕES E REFORÇOS NA REDE BÁSICA - PERÍODO 2006 A 2008 - SUMÁRIO EXECUTIVO.

Prada, R. B.; Palomino, E. G. C.; dos Santos, J. O. R.; Bianco, A. and Pilotto, L.A.S., (2002). “Voltage stability assessment for real-time operation”, *IEE Proc.-Gener. Transm. Distrib.*, Vol. 149, No. 2, March.

Prampero, Paulo Sérgio. (1998). “Combinação de Classificadores para Reconhecimento de Padrões”, Dissertação de Mestrado, Instituto de Ciências Matemáticas de São Carlos (ICMSC) da Universidade de São Paulo.

- 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*.
- Repo, S., and Jarventausta, P., (2003). "Implementation Issues of On-line Data-driven Voltage Stability Assessment", ISAP - Intelligent Systems Application to Power Systems, Lemnos, Greece 31st August- 3rd September.
- Schilling, M. T., *et al*, (1996). "Problemas e Estratégias Emergentes em Sistemas de Potência", *Proceedings of V SEPOPE*, Recife-PE.
- SNNS - Stuttgart Neural Network Simulator, (1995). User Manual –Version 4.1, Report N^o. 6/95, Institute for Parallel and Distributed High Performance System, University of Stuttgart, Germany.
- Soares, V. L. de C. e Caldas, G. P. (1997). "Estabilidade de Tensão - Estudo do Sistema Sul", *XIV SNPTEE*, Belém-PA.
- Sobajic, D. J. and Pao, Y.-H. (1989). "Artificial Neural-Net Based Dynamic Security Assessment for Electric Power Systems", *IEEE Trans. on Power Systems*, Vol. 4, No. 1, pp. 220-224.
- Sodré, E. e Mota, Wellington 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., Neto, J. F. e Carvalho Jr., M. A. de, (1999). "Um Combinador de Redes Neurais para Determinação do Colapso de Tensão", *VIII ERLAC - Encontro Regional Latino Americano da CIGRÉ*, Ciudad del Este, Paraguay.
- Sodré, E., Vasconcelos G.C., Cavalcanti, G.D., e Adeodato, P.J. (1998). "SAPRI: Um Sistema Integrado Baseado em Redes Neurais", *5th SBRN - Simpósio Brasileiro de Redes Neurais*, 9-11, December, Belo Horizonte, Brasil.
- Sodré, E., Almeida, K. C. e Salgado, R. (1997). "Avaliação Estática da Estabilidade de Tensão via Método da Continuação", *XIV SNPTEE*, Belém-PA.

de Souza, A. C. Z., de Souza, J. C. S. and da Silva, A. M. L., (2000) “On-Line Voltage Stability Monitoring”, IEEE Transactions on Power Systems, Vol. 15, No. 4, NOVEMBER.

Taylor, C. W. (1994). *Power System Voltage Stability*, McGraw-Hill, Inc.

Taylor, C. W. (1996). “Optimizing Voltage Stability: Finding Effective Voltage Instability Countermeasures”, *Proceedings of V SEPOPE*, Recife, Brazil.

Taylor, C. W. (1998). “Survey of Advanced Angle Stability Control: progress report on behalf of CIGRÉ TF 38.02.17”, *Proceedings of VI SEPOPE*, Salvador, Brazil.

Taylor, C. W. and Ramanathan, R. (1998). “BPA reactive power monitoring and control following the August 10, 1996 power failure,” in Proc. VI Symp. Specialists Elect. Oper. Expansion Planning, Salvador, Brazil, May 24–29.

Taylor, C.; Venkatasubramanian, M. V. and Chen, Y., (2000). “Wide-Area Stability and Voltage Control”, VII SEPOPE, 21 a 26 de maio, Curitiba (PR) – Brasil.

Taylor, C. and Wilson, R. E., (2004). “BPA’s Wide-Area Stability and Voltage Control System (WACS): overview and large-scale simulations”, IX SEPOPE, 23 a 27 de maio, Rio de Janeiro (RJ) – Brasil.

Tomsovic, K., and Chow, M. Y., (edited by), (2000). “Tutorial on Fuzzy Logic Applications in Power Systems”, IEEE/PES Winter Meeting, Singapore.

Tomsovic, K. (Project Leader); Bose, A.; Stuart, R.; Williams, B.; Willis, M.; Chen, L. and Vaziri, M., (2001). “Automated Operating Procedures for Transfer Limits”, PSERC – Power System Engineering Research Center, Publication 01-05, May.

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., Jacquemart, Y., Marquet, J.-N., and Pruvot, P. (1995). "A comprehensive analysis of mid-term voltage stability", IEEE Transactions on Power Systems, 10(3):1173_1182, August.
- Van Cutsem, T., Vournas, C., (1998). "Voltage Stability of Electric Power Systems", Kluwer Academic Publishers (Power Electronics and Power Systems Series).
- Van Cutsem, T. (2000). "Voltage Instability: Phenomena, Countermeasures, and Analysis Methods", Proceedings of the IEEE, Vol. 88, NO. 2, February.
- Van Cutsem, T., Capitanescu, F., Moors, C., Lefebvre, D., and Sermanson, V., (2000). "An advanced tool for preventive voltage security assessment", Proc. 7th SEPOPE, Curitiba (Brazil), May.
- Vasconcelos G.C., Adeodato, P.J., Carvalho Filho, E.C.B., Sodré, E.A., Cavalcante, G.D. (1999). "Neural network based automatic target processing and recognition". Seventh IEE Conference on Image Processing and its Applications (IPA99) 12 - 15 July 1999 - Manchester, UK
- Vournas, C. D.; Manos, G. A.; Kabouris, J.; Christoforidis, G.; Hasse, G. and Van Cutsem, T., (2003). "On-Line Voltage Security Assessment of the Hellenic Interconnected System", IEEE Bologna Powertech 2003 Conference, Bologna (Italy), June 23-26.
- WSCC (Western Systems Coordinating Council) Report, (1998). "Voltage Stability Criteria, Undervoltage Load Shedding Strategy, and Reactive Power Reserve Monitoring Methodology".
- Yabe, K.; Koda, J.; Yoshida, K.; Chiang, K. H.; Khedkar, P. S.; Leonard, D. J. and Miller, N., (1996). "Conceptual Designs of AI-based Systems for Local Prediction of Voltage Collapse", IEEE Transactions on Power Systems, Vol. 11, No. 1, February.
- Yen, J., Langari, R., and Zadeh, L. A. (1995). *Industrial Applications of Fuzzy Logic and Intelligent Systems*, IEEE Press Inc.
- Zhang, Y.; Wehenkel, L.; Rousseaux, P. and Pavella, M., (1997). "SIME: A hybrid approach to fast transient stability assessment and contingency selection", Electrical Power & Energy Systems, Vol. 19, No. 3, pp. 195-208.

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 , Volume: 2 , Pages:888 – 892, 27-31 Jan. 2002.