

UNIVERSIDADE ESTADUAL PAULISTA – UNESP
FACULDADE DE ENGENHARIA DE ILHA SOLTEIRA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

Análise de Sensibilidade por Redes Neurais Para Estudos da Estabilidade Transitória de Sistemas Elétricos de Potência

Anna Diva Plasencia Lotufo

Tese de Doutorado submetida ao Programa de Pós-graduação em Engenharia Elétrica da Faculdade de Engenharia de Ilha Solteira – UNESP, como parte dos requisitos para a obtenção do título de *Doutor em Engenharia Elétrica*.

Ilha Solteira – SP, agosto de 2004.

Livros Grátis

<http://www.livrosgratis.com.br>

Milhares de livros grátis para download.

FICHA CATALOGRÁFICA

Elaborada pela Seção Técnica de Aquisição e Tratamento da Informação/Serviço Técnico de Biblioteca e Documentação da FEIS/UNESP

Lotufo, Anna Diva Plasencia

L884a Análise de sensibilidade por redes neurais para estudos da estabilidade transitória de sistemas elétricos de potência / Anna Diva Plasencia Lotufo. – Ilha Solteira : [s.n.], 2004

iii, 133 p. : il.

Tese (doutorado) – Universidade Estadual Paulista. Faculdade de Engenharia de Ilha Solteira, 2004

Orientador : Carlos Roberto Minussi

Bibliografia: 98-106

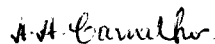
1. Análise de sensibilidade. 2. Estabilidade. 3. Sistemas elétricos de potência. 4. Redes neurais. 5. Lógica difusa.

ANÁLISE DE SENSIBILIDADE POR REDES NEURAIS PARA ESTUDOS DA ESTABILIDADE TRANSITÓRIA DE SISTEMAS ELÉTRICOS DE POTÊNCIA

ANNA DIVA PLASENCIA LOTUFO

**TESE SUBMETIDA À FACULDADE DE ENGENHARIA - CAMPUS DE ILHA
SOLTEIRA – UNESP – COMO PARTE DOS REQUISITOS NECESSÁRIOS PARA
A OBTENÇÃO DO TÍTULO DE DOUTOR EM ENGENHARIA ELÉTRICA**

COMISSÃO EXAMINADORA:



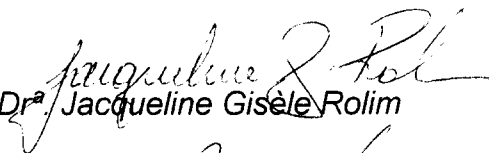
Prof. Dr. Aparecido Augusto de Carvalho
Coordenador do Programa de Pós-Graduação
em Engenharia Elétrica



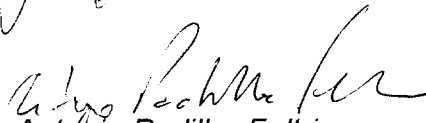
Prof. Dr. Carlos Roberto Minussi – orientador



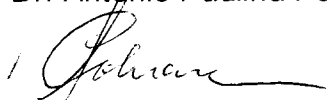
Prof. Dr. Walmir de Freitas Filho



Prof.^a Dr.^a Jacqueline Gisèle Rolim



Prof. Dr. Antonio Padilha Feltrin



Prof. Dr. Laurence Duarte Colvara

Ilha Solteira-SP, agosto de 2004.

Ao Pai do Céu.

Aos meus pais Dante e Diva.

AGRADECIMENTOS

Ao Minussi, orientador, colega e amigo, pela confiança depositada na realização desta tese, todo meu carinho.

Aos colegas do curso de Pós-Graduação em Engenharia Elétrica, em especial Mara, Carminha e Wagner pelas discussões e contribuições durante a realização deste trabalho.

Aos membros da banca de avaliação tanto desta tese (Walmir, Jacqueline, Laurence, Padilha, Hector, Arlan e Rubén), quanto do Exame Geral de Qualificação (Laurence, Padilha, Rubén, João Antônio e Mantovani), pelas valiosas críticas e sugestões que enriqueceram o conteúdo.

Ao professores das disciplinas cursadas pelos ensinamentos fornecidos com segurança e rigor.

A todos os amigos que sempre deram o incentivo necessário para que este trabalho pudesse se tornar realidade.

Aos meus pais, irmãos e demais membros da família que mesmo longe estiveram presente comigo.

Ao Departamento de Engenharia Elétrica.

RESUMO

Esta pesquisa tem por objetivo o desenvolvimento de uma metodologia, para análise de estabilidade transitória e para o controle preventivo de sistemas de energia elétrica, formulada por redes neurais *feedforward* multicamadas. A margem de segurança (método da energia) é empregada como critério de análise de estabilidade transitória, considerando-se defeitos tipo curto-circuito trifásico com saída de linha de transmissão. O funcionamento das redes neurais é constituído por duas fases principais: treinamento (ou aprendizado) e análise. A fase de treinamento requer uma grande quantidade de processamento para a sua realização, enquanto que a fase de análise é efetivada, praticamente, sem esforço computacional. Trata-se, por conseguinte, da principal justificativa para o uso de redes neurais para a resolução de problemas complexos que exigem soluções rápidas, sendo, portanto, adequadas para aplicações em tempo real. O treinamento da rede neural é realizado usando o algoritmo retropropagação (*backpropagation*) com controlador nebuloso e a adaptação da inclinação e deslocamento da função sigmóide (pós-sináptica). O controlador nebuloso é usado visando proporcionar uma convergência mais rápida e resultados mais precisos, se comparado ao algoritmo retropropagação tradicional. A adaptação da taxa de treinamento é efetuada usando a informação do erro global e a variação do erro global. A adaptação da inclinação e deslocamento da função sigmóide também é usada com o objetivo de melhorar a capacidade da obtenção de uma solução, ou seja, ampliar o espaço de busca. Após ter sido concluído o treinamento, a rede neural deverá estar apta a estimar a margem de segurança e a análise de sensibilidade. Com esta informação é possível desenvolver um método para a realização da correção da segurança (controle preventivo) baseado na realocação de geração e no corte de carga. A idealização do controle preventivo baseia-se no cálculo da sensibilidade, por redes neurais, usando-se a mesma estrutura empregada para a geração da análise de estabilidade

transitória fundamentadas na aplicação de estímulos de entrada (potência ativa, etc.) e de saída (margem de segurança associada). Portanto, ao ser concluído o treinamento da rede neural, estar-se-á concluindo, também, a matriz de sensibilidade, bastando tão somente armazenar os pesos da rede neural e realizar pequenas operações matriciais que representam cerca de 1% do tempo de processamento para a realização do treinamento. Para ilustrar a metodologia proposta são apresentados dois exemplos, um para um sistema teste de 3 máquinas e outro para um sistema real de 10 máquinas correspondente ao sistema sul-brasileiro. Deve-se ressaltar que esta metodologia de cálculo de sensibilidade poderá ser útil para a resolução de uma série de problemas em várias áreas do conhecimento. Este assunto deverá ser investigado em pesquisas futuras.

ABSTRACT

This work presents a procedure, for transient stability analysis and for preventive control of electric power systems, formulated by multilayer feedforward neural network. The security margin (energy method) is used as a criterion of the transient stability analysis considering faults like three-phase short-circuits with outage of transmission line. The performance of neural networks is constituted of two principal phases: training (or learning) and analysis. The training phase needs a great quantity of processing time for the realization, whereas the analysis phase is effectuated almost without computational effort. Therefore, this is the principal justification to use neural networks for solving complex problems that need fast solutions, and as a consequence being adequate for real time applications. The neural network training is realized using the backpropagation algorithm with fuzzy controller and the sigmoid (postsynaptic) function slope and translation adaptation. The fuzzy controller is used to provide a faster convergence and more precise results, if compared to the traditional Backpropagation algorithm. The adapting of the training rate is effectuated using the information of the global error, and global error variation. The adaptation of the slope and translation of the postsynaptic function is used for improving the capacity of obtaining a solution, i.e., to enlarge the space of search. After finishing the training, the neural network is capable to estimate the security margin, and the sensitivity analysis. With these information it is possible to develop a method for the realization of the security correction (preventive control) based on generation reallocation and load shedding. The preventive control idealization is based on the sensitivity calculus by neural networks, using the same structure employed for the generation of the transient stability analysis founded on the application of input stimulus (active power, etc) and output (associated security margin). Therefore, when the neural network is concluded, it is also concluded the sensitivity matrix, being enough to store the neural network weights and

effectuate little matrix operations that represent about 1% of the processing time for the training. To illustrate the proposed methodology it is presented an application considering a test system composed of 3 synchronous machines and another power system composed of 10 synchronous machines corresponding to the south Brazilian system. It is emphasized that this methodology can be useful for the solution of many problems in several areas of the knowledge. This matter will be investigated in future works.

SUMÁRIO

1. INTRODUÇÃO E MOTIVAÇÃO PARA A PESQUISA PROPOSTA	001
1.1. Introdução	001
1.2. Motivação Para Pesquisa Proposta	004
1.3. Contribuições	007
2. ESTADOS DE OPERAÇÃO DO SISTEMA	010
2.1. Introdução	010
2.2. Estados de Operação dos Sistemas de Energia Elétrica	010
2.3. Inserção da Pesquisa Proposta em Análise e Controle de Segurança	014
2.4. Conclusão	016
3. MODELO DO SISTEMA	018
3.1. Introdução	018
3.2. Modelo da Máquina Síncrona	020
3.3. Modelo Utilizado	023
3.4. Análise de Estabilidade Transitória	025
3.5. Conclusão	026
4. FORMULAÇÃO BÁSICA DO CONTROLE PREVENTIVO DINÂMICO	028
4.1. Introdução	028
4.2. Estado da Arte	028
4.3. Formulação do Problema por Redes Neurais	030
4.4. Conclusão	031

5. REDES NEURAIIS ARTIFICIAIS	032
5.1. Introdução	032
5.2. Estrutura da Rede Neural	033
5.3. Treinamento	034
5.4. Processo Adaptativo da Inclinação e da Translação da Função Sigmóide	041
5.5. Conclusão	046
6. ANÁLISE DE SENSIBILIDADE POR REDES NEURAIIS	048
6.1. Introdução	048
6.2. Cálculo da Sensibilidade por Redes Neurais	048
6.3. Exemplo Ilustrativo	053
6.4. Conclusão	058
7. DEFINIÇÃO DOS PADRÕES DE ENTRADA E DE SAÍDA DA REDE NEURAL	059
7.1. Introdução	059
7.2. Estímulos de Entrada	060
7.3. Estímulos de Saída	063
7.4. Conclusão	064
8. APLICAÇÃO	065
8.1. Introdução	065
8.2. Exemplos Ilustrativos Genéricos	066
8.3. Sistema Anderson & Fouad [2]	072
8.4. Sistema Sul-brasileiro (Rede Neural com Controlador Nebuloso)	080

8.5. Sistema Sul-Brasileiro (Rede Neural com Processo Adaptativo da Inclinação e da Translação da Função Sigmóide)	089
8.6. Conclusão	092
9. CONCLUSÃO E SUGESTÕES PARA TRABALHOS FUTUROS	093
9.1. Conclusão	093
9.2. Sugestões Para Trabalhos Futuros	095
10. REFERÊNCIAS BIBLIOGRÁFICAS	098
APÊNDICE A – Principais Conceitos em Redes Neurais Artificiais	107
APÊNDICE B – Principais Conceitos sobre Lógica Nebulosa	115
APÊNDICE C – Algoritmo Computacional Para Determinação da Margem de Segurança	119
APÊNDICE D – Dados dos Sistemas Exemplos	122
APÊNDICE E – Trabalhos Completos Publicados e Relacionados Com a Pesquisa de Doutorado	131

CAPÍTULO 1

INTRODUÇÃO E MOTIVAÇÃO PARA A PESQUISA PROPOSTA

1.1. INTRODUÇÃO

Análise de Estabilidade Transitória constitui-se num dos principais estudos realizados nos sistemas elétricos de potência, em consequência ao crescimento dos sistemas, tanto em porte como envolvendo longas distâncias. A análise de estabilidade transitória está inserida dentro de uma função maior que é a segurança de sistemas de potência, ou seja, é a capacidade de operar num estado de equilíbrio sob condições normais ou perturbadas. Desta forma, a segurança engloba vários aspectos que podem ser subdivididos em estáticos e dinâmicos. O estudo, ora em foco, está inserido na segurança dinâmica (Pavella *et al.* [63]). Dependendo de fatores como: intervalo de tempo, tamanho do distúrbio e a natureza física da instabilidade resultante, ainda é possível classificar em estabilidade de curto prazo ou de longo prazo; de pequenos distúrbios ou de grandes distúrbios. Mais especificamente, estes fenômenos classificam-se ainda em análise de tensão e de ângulos. A estabilidade de tensão refere-se à investigação sobre o comportamento do perfil de tensão nodal do sistema, em destaque, a observação e identificação de deficiência de suporte de tensão em decorrência do aumento da potência consumida (Wehenkel [78]). A estabilidade de ângulos é a que compõe a segurança dinâmica (Kundur [35], Pavella *et al.* [63]). Portanto, a estabilidade transitória é a capacidade de manter a operação síncrona de máquinas quando sujeitas a grandes distúrbios, que causam grandes excursões nos ângulos destas máquinas, como por exemplo: curto circuito, entrada ou saída de operação de equipamentos. Esta importância é ainda

mais evidenciada, considerando a prática desregulamentadora do setor elétrico em vários países (Pavella *et al.* [63]).

O modelo do sistema para análise de estabilidade é descrito por um conjunto de equações algébricas e diferenciais não-lineares. Para solucioná-las existem muitos métodos que foram evoluindo ao longo do tempo, desde os métodos de integração numérica, conhecidos como do domínio do tempo (Anderson & Fouad [2]), critério das áreas iguais Pavella *et al.* [63]), que usa o conceito de energia, sendo este um caso particular da teoria geral de Liapunov (Pai [59], Pavella *et al.* [63]), até chegar mais recentemente aos de aprendizagem automática, juntamente com a evolução dos computadores digitais.

O problema do despacho econômico clássico (Kirchmayer [34]) (estático), aplicado na operação de sistemas de energia elétrica, consiste num problema de minimização dos custos de operação (potência de saída) que atenda a demanda sujeito às restrições (limite de operação do gerador) (Kirchmayer [34]). Já o despacho de segurança visa a dar continuidade de fornecimento do serviço mesmo na possibilidade de falha de algum equipamento e considera várias restrições físicas (restrições de carregamento da linha podem ser temporariamente violadas) (Wehenkel [78]). O problema do despacho econômico clássico tem sido resolvido através de uma variedade de métodos, podendo-se citar: custos incrementais iguais (Kirchmayer [34]); método do gradiente, método de Newton, e mais recentemente as redes neurais, e outros algoritmos de inteligência artificial (Padhy [58]).

As funções custos, que são funções não-convexas e não-diferenciáveis, são geralmente aproximadas por funções quadráticas. A maioria dos métodos de solução adota esta aproximação em consequência da dificuldade em tratar com funções custos refletindo a não-linearidade das respostas dos geradores.

Os métodos de sucessivas linearizações são os mais usados, apesar de que o problema do despacho econômico seja não-linear, as linearizações impróprias podem induzir a mínimos locais.

Quando houver casos de instabilidade do sistema e / ou forem violados os limites de capacidade dos equipamentos, é necessário adotar providências que conduzam o sistema a um estado seguro, que é conhecido como controle de segurança. Os métodos para

controle preventivo dinâmico apareceram recentemente e as publicações disponíveis ainda são poucas (Bettiol [8], Fonseca & Minussi [22], Fouad & Jianzhong [23], Minussi & Freitas [50], Oliveira [57], Sobajic & Pao [67], Vittal *et al.* [76], Xue *et al.* [81]) entre outras, a maioria resolvendo o problema através de outras funções que não envolvem redes neurais.

Existem outros artigos que tratam do problema da análise de estabilidade, ou mesmo da segurança do sistema utilizando redes neurais (Fischer *et al.* [20], Lo & Peng [38]) (segurança estática), (Gu *et al.* [27], Niazi *et al.* [55], Takaue *et al.* [72], entre outros). Estes artigos analisados quando não tratam da segurança estática, consideram outras funções como o tempo crítico, tensão crítica, seleção de topologias críticas ou mesmo o agrupamento das contingências por faixas de severidade, mas todos com a preocupação de manter o sistema elétrico em funcionamento mesmo sob condições adversas, ou tomar medidas necessárias para evitar o colapso total.

Assim sendo, esta pesquisa visa desenvolver uma metodologia baseada nas redes neurais (Haykin [28], Kartalopoulos [31]) para analisar a estabilidade transitória, considerando defeitos tipo curto-circuito com saída de linhas de transmissão e principalmente para análises de sensibilidade (Frank [25]) de sistemas elétricos de potência que representam os instrumentos necessários para o controle preventivo. Dentro da mesma linha proposta nesta pesquisa, que consiste no controle de segurança através da análise de sensibilidade por redes neurais, pode-se citar a referência (Chauhan *et al.* [11]), porém com ênfase na segurança baseada na análise do colapso de tensão, enquanto esta pesquisa tem como ênfase a análise de sensibilidade da margem de segurança. Outros trabalhos que antecederam a este somente tratavam apenas da análise de estabilidade usando redes neurais (Marchiori [48], Minussi & Silveira [51], Silveira *et al.* [64], Park *et al.* [61], Pao & Sobajic [60]).

As redes neurais são recursos importantes para tratar o problema do controle preventivo considerando que, uma vez concluído o treinamento (atividade *off-line*), as análises podem ser concluídas quase que sem esforço computacional (basicamente os cálculos com a entrada e a saída da rede neural), e podem ser usados para aplicações em tempo real. É enfatizado (Lotufo *et al.* [43]–[45]) que o cálculo da sensibilidade é efetuado

sem esforço computacional e também que para obter o modelo de sensibilidade por procedimentos convencionais, envolve grande quantidade de cálculos matriciais complexos, consumindo muito tempo, principalmente para aplicações de sistemas de grande porte.

A rede neural usada é uma não-recorrente de múltiplas camadas com treinamento através do algoritmo retropropagação (RP) (*backpropagation*) (Werbos [79]). A taxa de treinamento do RP é ajustada por um controlador nebuloso (Arabshahi *et al.* [3], Lopes [39]) (baseado nos conceitos da lógica nebulosa) (Terano *et al.* [74]) monitorando o erro global (e a variação do erro global) durante o treinamento e, também, pelo ajuste dos parâmetros inclinação (subida) e translação da função sigmóide conforme referências (Stamatis *et al.* [69], Lopes [39]). É um mecanismo que visa melhorar a precisão dos resultados, como observado em (Lopes [40], Lopes *et al.* [41]–[42]). As variáveis usadas no treinamento são variáveis causais de um problema de análise de estabilidade transitória (potências nodais ativa e reativa) que são os estímulos de entrada da rede neural e as margens de segurança que são os estímulos de saída da rede neural gerados usando o método PEBS (*Potential Energy Boundary Surface* (Athay *et al.* [4]), Superfície Limite de Energia Potencial, no português), versão para uso em microcomputador. A margem de segurança, representada em função da energia total, pode ser interpretada como sendo uma medida da “distância” em relação à condição de instabilidade do sistema. O modelo de sensibilidade é referido à relação da margem de segurança e a potência elétrica nodal. Assim, pode ser estimada a realocação de geração e o corte de carga necessários para obter o estado seguro do sistema, isto é, o nível considerado adequado para estabilidade transitória.

1.2. MOTIVAÇÃO PARA A PESQUISA PROPOSTA

A pesquisa proposta tem por objetivo, então, o desenvolvimento de ferramenta para a determinação de um modelo de sensibilidade (entre a margem de segurança e a

mudança do perfil de geração / carga do sistema), via redes neurais, para uso no controle preventivo dinâmico, ou seja, levando-se em conta a estabilidade transitória de sistemas elétricos de potência. Trata-se, por conseguinte, de um mecanismo que visa auxiliar na prevenção, ou pelo menos, minimizar os efeitos de *blackout*.

A ocorrência de *blackouts* é um tanto rara, ou seja, possui uma probabilidade pequena, contudo quando ocorre pode levar a sérios riscos colocando em perigo os equipamentos e pessoas pela abrangência do caos em consequência, principalmente, aos sistemas serem que quase totalmente interligados, e o cotidiano das cidades serem extremamente dependentes da energia elétrica. Apesar da probabilidade de ocorrência ser pequena, tem ocorrido com uma certa frequência principalmente nos últimos anos (vide os ocorridos nos Estados Unidos e Canadá, Itália, e mesmo Brasil) (Novosel *et al.* [56]), cujos estudos estão se intensificando para se descobrir as principais causas e também proporem soluções para evitar ou mesmo minimizar os efeitos catastróficos de tal ocorrência.

Neste sentido, a segurança e a confiabilidade dos sistemas se fazem necessárias de uma forma bastante eficaz para evitar prejuízos materiais entre outros (Mountford & Austria [54], Taylor [73]). Para atender populações cada vez maiores, os sistemas de energia elétrica cresceram em tamanho e distâncias, pois os grandes centros consumidores estão longe dos centros produtores independente do tipo de combustível usado para geração. Às vezes também o investimento em linhas e geração não tem acompanhado o crescimento da população, sobrecarregando linhas e geradores, e isto pode levar a ocorrência de problemas associados a outros fatores, entre eles adversidades climáticas (Novosel *et al.* [56]).

Os grandes distúrbios estão quase sempre associados a contingências decorrentes principalmente de saída de linhas de transmissão e / ou de geradores, que originalmente podem provir de descargas atmosféricas, situações climáticas anormais, como um calor extremamente intenso, que altera os costumes (elevação da carga em consequência ao uso intenso de aparelhos de ar-condicionado num período curto e portanto às vezes não previsto no sistema previsor), falhas em equipamentos, e também a capacidade térmica das linhas de transmissão além da capacidade elétrica (Grudinín & Roytelman

[26]). A ocorrência simultânea de muitos destes fatores tem levado a ocorrência dos últimos *blackouts* (Novosel *et al.* [56]).

A interligação de sistemas elétricos caracteriza-se como um agente que melhora a confiabilidade, entre outras vantagens, mas com o crescimento dos sistemas, da população e dos costumes (uso intenso de energia elétrica), o problema causado por um defeito, que poderia ser local, também cresceu, pois expande-se rapidamente através das interligações atingindo às vezes todo o sistema, (Amin [1]).

Na impossibilidade do sistema responder a ocorrência de um defeito pode levar a desligamentos totais ou parciais e em consequência da interligação, o problema se expande rapidamente atingindo grande parcela da população. A introdução de funções de controle centralizadas para atuar de maneira eficaz ou que venham a amenizar as consequências da probabilidade de ocorrer uma emergência se faz necessária e urgente (Grudin & Roytelman [26]). Estas funções estão associadas à segurança e à estabilidade do sistema, e a tomada de decisões *on-line*, que exige também operadores com experiência e sistemas inteligentes visando auxiliar na tarefa de reconstruir o sistema em poucos minutos e evitar ou mesmo minimizar prejuízos, bem como outros inconvenientes (Amin [1]).

Outro fator que deve ser considerado também nos sistemas atuais é a desregulamentação destes, onde geração, transmissão e distribuição podem pertencer a diferentes empresas (Amin [1], Sweet [71]), mas ainda existem controvérsias em estudos recentes sobre ser este um dos fatores determinantes da ocorrência de *blackouts* conforme referências (Kezunovic *et al.* [33], Horovitz & Phadke [29]).

Muitas propostas de introduzir alguma função *on-line* para minimizar este problema têm sido feitas desde o trabalho de Fink & Carlsen [19], no qual já existia o alerta dos sistemas estarem funcionando no limite de suas capacidades, até mais recentes como os trabalhos de Horovitz & Phadke [29] que enfatiza a necessidade de melhoramento da proteção, e Novosel *et al.* [56] que propõem uma sequência de passos para prevenir e corrigir os efeitos decorrentes da ocorrência de um *blackout*.

A proposta desta pesquisa consiste em incorporar, na função controle preventivo, o controle preventivo dinâmico, ou seja, é uma atuação quase *on-line*, usando redes neurais artificiais, tomando as devidas providências, o redespacho de geração e / ou corte de carga. Desta forma, uma parcela menor da população será prejudicada, podendo a não desencadear grandes desligamentos ou ilhamentos de parte do sistema elétrico interligado.

1.3. CONTRIBUIÇÕES

Assim sendo, as principais contribuições deste trabalho podem ser destacadas da seguinte forma:

- 1) desenvolver uma metodologia, baseada em redes neurais, para analisar a estabilidade transitória, considerando defeitos tipo curto-circuito com saídas de linhas de transmissão e, principalmente, para análise de sensibilidade de sistemas elétricos de potência que representam instrumentos necessários para o controle preventivo;
- 2) a rede neural usada é uma não-recorrente de múltiplas camadas com treinamento através do algoritmo retropropagação (*backpropagation*). A taxa de treinamento do RP é ajustada por um controlador *nebuloso* (baseado na lógica nebulosa (Kartalopoulos [31], Terano *et al.* [74]) monitorando o erro global durante o treinamento, e uma segunda rede neural com o controle adaptativo da inclinação e translação da função sigmóide;
- 3) o cálculo da sensibilidade é efetuado sem esforço computacional, pois para obter o modelo de sensibilidade por procedimentos convencionais envolveria grande quantidade de cálculos matriciais complexos, consumindo muito tempo, principalmente para aplicações de sistemas de grande porte;
- 4) O desenvolvimento da metodologia neural para a estimação da sensibilidade visa, principalmente, realizar estudos em problemas de estabilidade transitória. Contudo, é

uma metodologia adequada para o estudo de uma série de problemas encontrados em várias áreas do conhecimento humano, em especial, aqueles em que os modelos são desconhecidos. Trata-se, portanto, de um tema que deverá ser objeto de investigações futuras.

Este texto está organizado em capítulos e apêndices, cujos conteúdos são assim descritos:

Capítulo 2. São apresentados os estados de operação dos sistemas de energia elétrica e como estes se inserem dentro da proposta deste trabalho.

Capítulo 3. Apresenta-se o modelo do sistema e a análise de estabilidade transitória.

Capítulo 4. É apresentado o controle preventivo dinâmico.

Capítulo 5. Apresentam-se os principais conceitos sobre a rede neural proposta, destacando o algoritmo de aprendizado retropropagação.

Capítulo 6. É apresentada a análise de sensibilidade, por redes neurais, proposta nesta pesquisa.

Capítulo 7. Apresenta-se a definição dos padrões de entrada e de saída da Rede Neural.

Capítulo 8. São apresentados os resultados para dois sistemas elétricos, um sistema teste de 3 máquinas e um sistema real de 10 máquinas, e primeiramente para duas funções não-lineares, cujos resultados são conhecidos.

Capítulo 9. São apresentadas as conclusões.

Capítulo 10. Encontram-se relacionadas as referências bibliográficas.

Apêndice A. Contém os principais conceitos sobre redes neurais artificiais.

Apêndice B. Contém os principais conceitos sobre lógica nebulosa.

Apêndice C. É apresentado o algoritmo computacional para o cálculo da margem de segurança.

Apêndice D. São apresentados os dados dos sistemas de energia elétrica sob estudo: (1) sistema de 9 barras, 9 linhas de transmissão e três geradores; (2) sistema sul-brasileiro composto por 45 barras, 73 linhas de transmissão e 10 máquinas síncronas.

Apêndice E. Contém os artigos completos publicados / aprovados para publicação que estão relacionados com a pesquisa de doutorado.

CAPÍTULO 2

ESTADOS DE OPERAÇÃO DO SISTEMA

2.1. INTRODUÇÃO

Neste capítulo apresentam-se os principais conceitos sobre os estados de operação e de análise de segurança de sistemas de energia elétrica. São abordados os principais estados operativos do sistema e transições de estado proporcionadas pela atuação de ações de controle. São abordados, também, os fenômenos associados à operação e aos estudos que devem ser realizados (análise de estabilidade transitória, estabilidade de tensão, etc.). Este capítulo está sendo apresentado com o propósito de situar a proposta da pesquisa de doutorado dentro do contexto do controle preventivo de sistemas de energia elétrica.

2.2. ESTADOS DE OPERAÇÃO DOS SISTEMAS DE ENERGIA ELÉTRICA

A análise de segurança é a responsável pela realização dos estudos destacados na Figura 1. Estes estudos abrangem a maioria dos problemas associados ao funcionamento dos sistemas de energia elétrica. Grande parte das metodologias destinadas à análise de segurança disponíveis na literatura especializada fazem suas inferências baseadas em índices que medem a severidade dos efeitos impostos ao sistema em consequência da ocorrência de defeitos. Visando estabelecer formas para interpretar tais efeitos, Dy Lyacco

[14] propôs a divisão do funcionamento de sistemas elétricos de potência descritos por cinco estados operativos principais:

- 1) normal;
- 2) de alerta;
- 3) de emergência;
- 4) *in extremis*;
- 5) restaurativo.

Todos estes estados são caracterizados pelo atendimento ou não das restrições de igualdades (E) (equações algébricas e diferenciais) e das restrições de desigualdades (I) que descrevem o funcionamento do sistema. As restrições de igualdades representam as leis físicas que regem a operação (por exemplo: balanço de potência), enquanto que as restrições de desigualdades estão associadas às violações operativas e de segurança. O balanço de potência corresponde em observar que a geração total deve suprir a carga total e as perdas elétricas associadas aos vários equipamentos da rede elétrica. As inequações (ou restrições de desigualdades) representam os limites físicos dos equipamentos elétricos, por exemplo, os limites de correntes, de potências elétricas que transitam nos sistemas de transmissão e de distribuição, das tensões nodais, entre outros (Kirchmayer [34]). Em resumo, estes estados são evidenciados através da observação do cumprimento ou não das equações e inequações que governam os sistemas elétricos. As transições de estados são estabelecidas em função da aplicação de ações corretivas que são o redespacho de geração, corte de carga, chaveamento de equipamentos elétricos, reajuste do perfil de tensão nodal, uso de mecanismos compensadores (FACTS, etc.) entre outros. Como ilustração, tomando-se o caso em que uma determinada linha esteja com seu limite violado (excesso de corrente e/ou diferença angular expressiva), pode-se resolver este problema, a princípio, através de um redespacho de geração. É evidente que este processo deve ser realizado com os devidos cuidados e com o uso de técnicas apropriadas (por exemplo, via otimização).

Na Figura 1 (Dy Liacco [14]) é, portanto, apresentado um esquema mostrando os vários estados operativos e suas transições (Dy Liacco [14], Pavella *et al.* [63]). Estes

estados são caracterizados pelas seguintes condições operativas, de acordo com as seguintes convenções (Dy Liacco [14]):

- E = atendimento das restrições de igualdades;
- I = atendimento das restrições de desigualdades;
- \bar{E} = não atendimento das restrições de igualdades;
- \bar{I} = não atendimento das restrições de desigualdades.

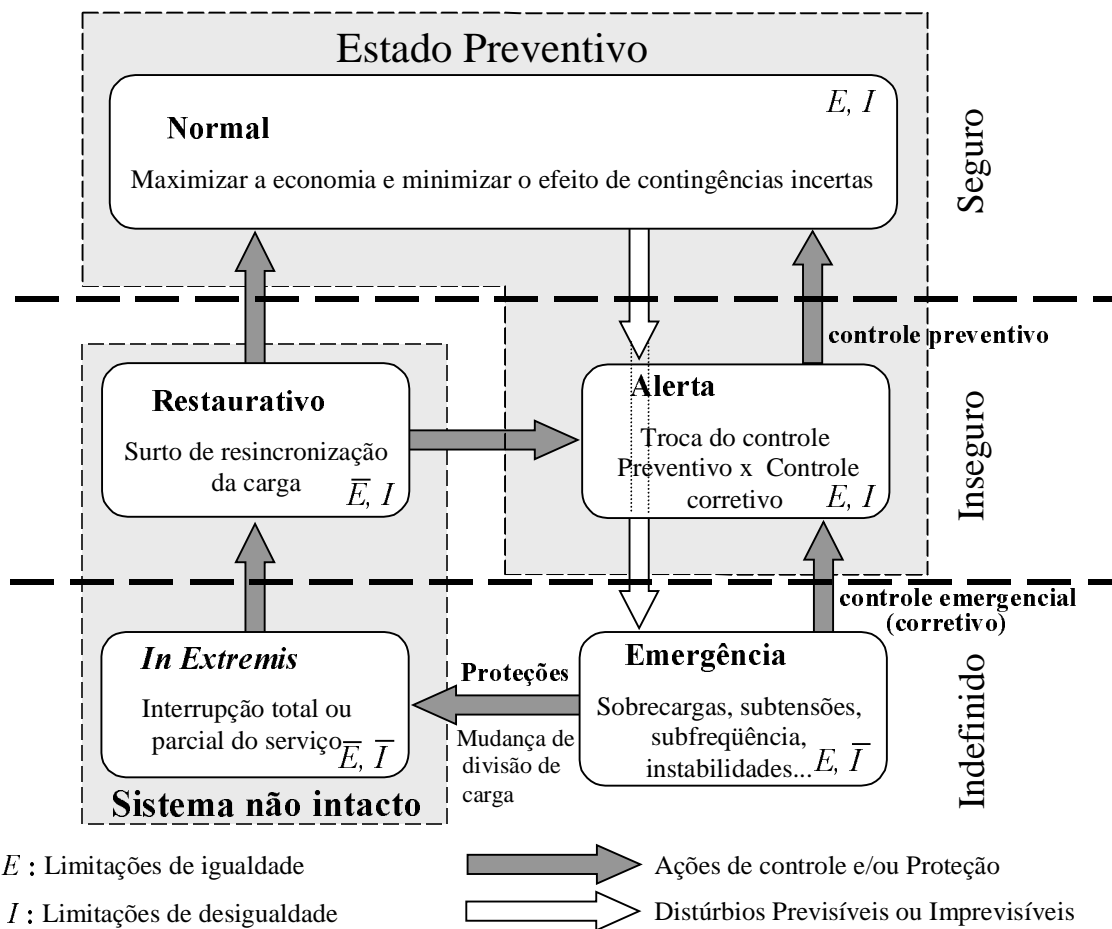


Figura 1. Estados de operação dos sistemas de energia elétrica e seus estados de transição.

Por conseguinte, os estados básicos são assim descritos:

- Estado Normal** : atende aos três conjuntos de restrições. Ocorrendo alguma das contingências selecionadas ainda não passa para o estado de emergência.
- Alerta** : as restrições de carga e operação são obedecidas e nem todas as de segurança (conjunto de contingências pré-selecionadas, as mais prováveis). O sistema ainda está intacto, mas ocorrendo alguma contingência selecionada pode levar para o estado de emergência. Ações preventivas podem ser tomadas para levar o sistema para o estado normal.
- Emergência** : são violadas as restrições de operação possivelmente por consequência de uma contingência, ocasionando o desligamento de um componente do sistema, mas mesmo assim o sistema ainda continua intacto. Este estado pode evoluir para o de alerta ou para o restaurativo onde partes do sistema são desligadas.
- Restaurativo** : após a eliminação de uma emergência quando há desligamento de componentes do sistema. As restrições de operação são então satisfeitas mas o sistema não está mais intacto. Quando se passa do estado de emergência para o restaurativo, pode haver, por exemplo, o alívio de carga.
- In Extremis*** : as restrições de igualdade e desigualdade não são satisfeitas, o sistema não está mais intacto, isto é, muitas partes do sistema foram perdidas. Ações de controle de emergência devem ser tomadas para salvar do colapso total (*blackouts*). Caso não for possível, passa para o estado restaurativo, onde a prioridade é reconectar o sistema.

2.3. INSERÇÃO DA PESQUISA PROPOSTA EM ANÁLISE E CONTROLE DE SEGURANÇA

A pesquisa proposta insere-se no contexto do controle preventivo. Mais especificamente no controle preventivo dinâmico, ou seja, são considerados os aspectos dinâmicos associados à estabilidade transitória do sistema. Considera-se, também, a estabilidade transitória de primeira oscilação, cuja modelagem é representada pelo modelo clássico (Anderson & Fouad [2]).

Tem-se como objetivo, a partir da análise de estabilidade transitória para os casos em que contingências podem conduzir à instabilidade ou provocar oscilações acentuadas nos ângulos das máquinas síncronas que potencialmente podem ocasionar instabilidade no sistema elétrico, desenvolver estratégias (ações) que possam promover a transição de estados críticos para o estado normal, em especial do estado de alerta para o estado normal.

Nesta pesquisa, o mecanismo para a realização da transição de estado é baseado no modelo de sensibilidade da margem de segurança do sistema em relação às ações de controle correspondentes à realocação de geração e, em casos extremos, ao corte de carga. Deste modo, pretende-se desenvolver o modelo de sensibilidade por redes neurais (assunto a ser abordado nos Capítulos 5 e 6). Evidentemente, conhecendo-se o modelo de sensibilidade pode-se, então, determinar os locais (barras) e os valores a serem modificados das potências nodais, por exemplo, empregando algum método de minimização disponível na literatura especializada (otimização linear ou não-linear, programação evolutiva (Padhy [58], Singh & David [66], Song & Irving [68]), redes neurais (Cichocki & Unbehauen [12]), inteligência coletiva (Kennedy & Eberhart [32]), etc.). Contudo, nesta pesquisa ater-se-á exclusivamente ao desenvolvimento do modelo de sensibilidade por redes neurais, deixando a aplicação otimizada para trabalhos futuros.

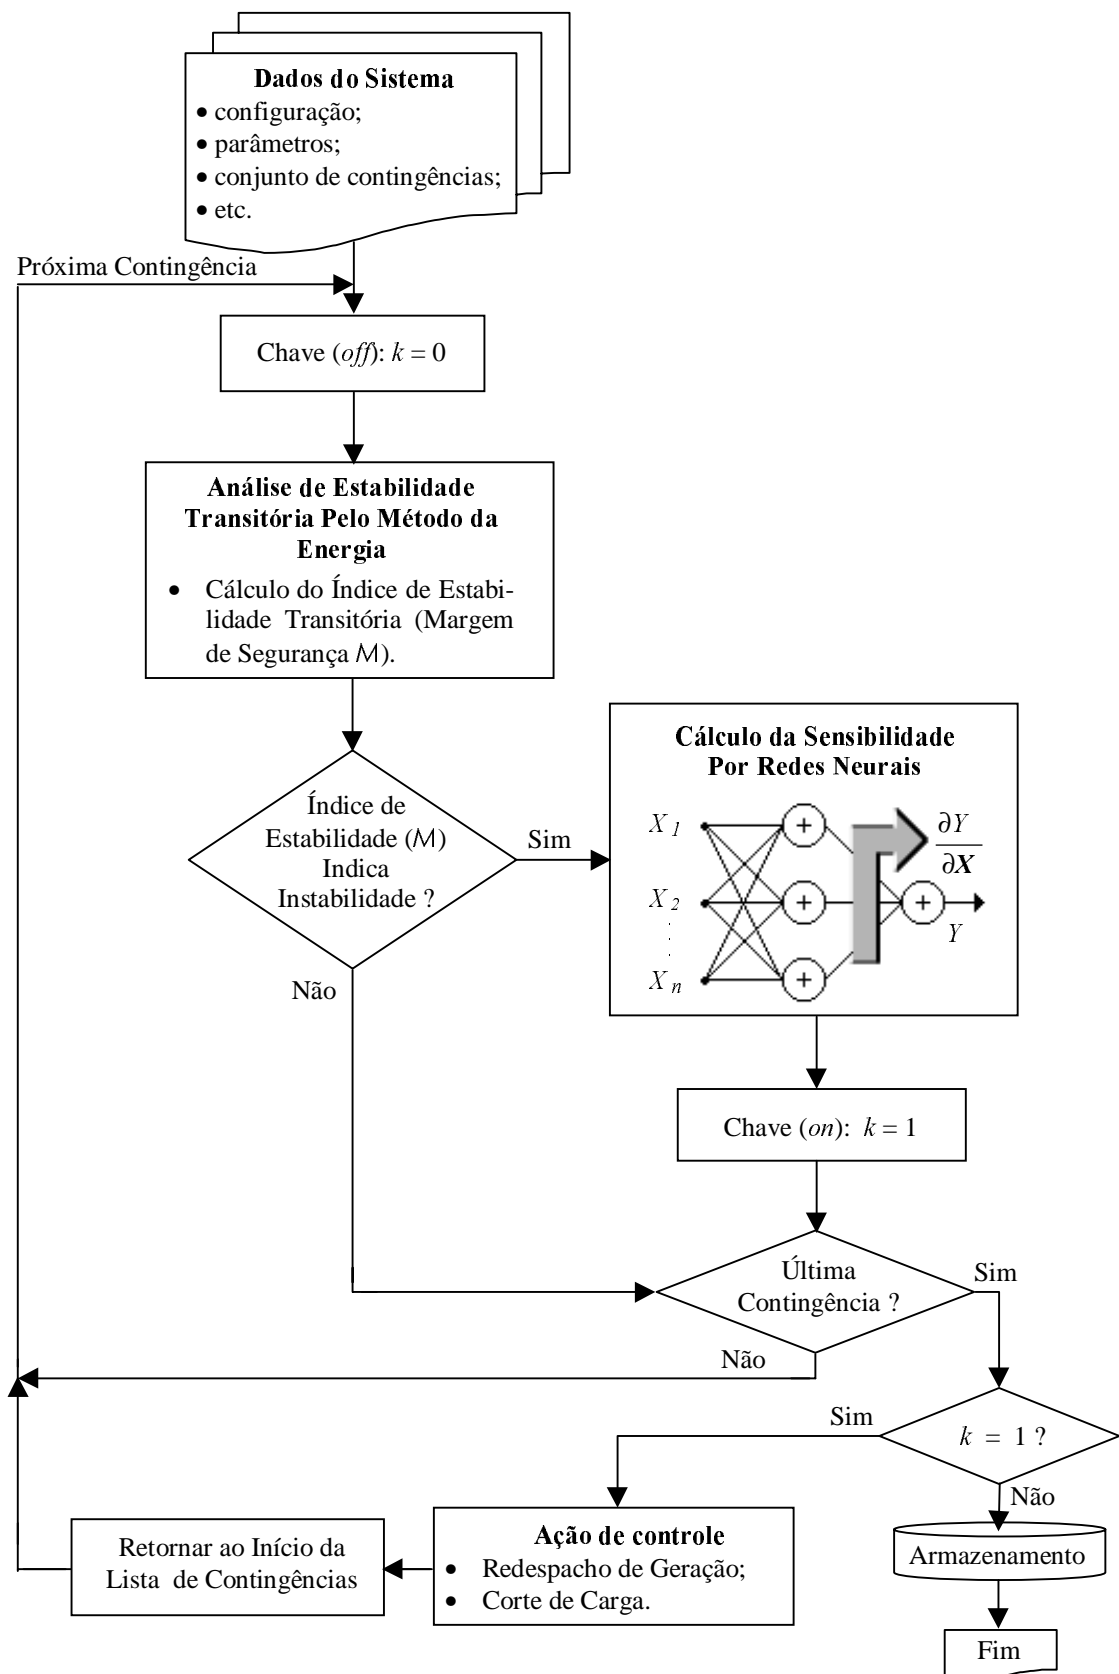


Figura 2. Diagrama esquemático do controle preventivo dinâmico.

Na Figura 2 é apresentado o esquema básico do trabalho proposto, basicamente restringindo-se ao desenvolvimento de um sistema neural para o cálculo de sensibilidade (análise de sensibilidade). A chave, identificada pelo parâmetro k , é usada para informar sobre o estado de sobrecarga (existência de índices de estabilidade inferiores a um valor limite) do sistema, de acordo com a seguinte convenção:

$$k = \begin{cases} 0, & \text{sistema sem sobrecarga;} \\ 1, & \text{sistema com sobrecarga.} \end{cases}$$

Assim, o algoritmo deixa de executar a correção de segurança quando a chave k estiver no estado aberto (*off*).

Este esquema mostra que toda vez que uma contingência indica sobrecarga do sistema, deve ser gerada uma restrição associada. O índice de estabilidade transitória será considerado, nesta pesquisa, representado pela margem de segurança M ([Pai [59]]), como abordada no Capítulo 3. Uma vez executada a análise de estabilidade e realizado o cálculo da sensibilidade (por redes neurais), deve-se calcular as alterações (realocação de geração) do estado de geração nominal, assim como, se necessário, o corte de carga. Estas alterações sobre o perfil de geração / carga são determinadas, quase sempre, por processo de otimização.

2.4. CONCLUSÃO

Foram apresentados neste capítulo os estados de operação dos sistemas de energia elétrica baseados na classificação proposta por Dy Liacco [14], e como o trabalho ora em curso se insere dentro destes estados, justificando a presente proposta através de um diagrama de blocos como mostrado na Figura 2. O modelo neural será desenvolvido nos Capítulos 5 e 6. Trata-se de uma concepção baseada numa rede neural *feedforward*

multicamadas com treinamento supervisionado (caracterizado por estímulos de entrada e de saída). O treinamento é realizado usando uma versão do algoritmo retropropagação (Werbos [79]) com controlador nebuloso (Lopes [39]) e adaptação de parâmetros da função não-linear (Stamatis *et al.* [69], Lopes [40]) para proporcionar maior capacidade de obtenção de soluções (maximização do espaço de busca) e como consequência reduzir a probabilidade de ocorrência de paralisia, se comparado à formulação convencional do retropropagação (Werbos [79]).

CAPÍTULO 3

MODELO DO SISTEMA E ANÁLISE DE ESTABILIDADE TRANSITÓRIA

3.1. INTRODUÇÃO

Apresenta-se, neste capítulo, o modelo que descreve a dinâmica do sistema de energia elétrica, considerando-se as grandes oscilações (grande aumento de carga, saída de equipamento elétrico de operação, curto-circuito, etc.). Trata-se do modelo da máquina síncrona e sua integração ao sistema. Este modelo é representado por equações algébricas e diferenciais não-lineares. A análise deste modelo permite inferir sobre a estabilidade do sistema. Os defeitos a serem considerados são curtos-circuitos trifásicos combinados com a saída das linhas sob defeito. Considera-se a análise de estabilidade de primeira oscilação, que é uma hipótese em que se pode empregar o chamado modelo clássico (Anderson & Fouad [2], Fouad & Vittal [24], Pai [57], Pavella *et al.* [63]). Posteriormente, é apresentado o critério de análise de estabilidade transitória, baseado no conceito de energia e margem de segurança.

A opção por esta abordagem mais simples de modelo deve-se ao fato de que, para extrair o conhecimento deste problema, via redes neurais, faz-se necessário impor uma rotina de dados que constitui a fase de treinamento da rede. Estes dados devem conter informações quantitativas e qualitativas de cada uma das contingências. Para efetivamente constituir uma boa capacidade de generalização (análise de situações não previstas nos casos simulados), faz-se necessária a utilização de um grande número de dados de entrada e de saída para a fase do treinamento da rede neural. Para atender estas características, somente podem ser proporcionados quando se utilizam os métodos diretos de análise, mais

especificamente, os métodos de energia (Athay *et al.* [4], Fouad & Vittal [24], Pai [59], Pavella *et al.* [63]).

Estes métodos, embora tenham apresentado grande evolução nos últimos anos (Colvara [13]), ainda há carência de resultados práticos para modelos mais elaborados (Stott [70]). Deve-se destacar que a simulação (resolução do sistema de equações algébricas e diferenciais não-lineares e exame das soluções obtidas) é considerada, pela literatura especializada, um *benchmark* de análise de transitórios eletromecânicos.

Nesta metodologia, pode-se simular qualquer modelo (qualquer que seja a sua sofisticação). Contudo, o grande obstáculo reside na obtenção somente da análise qualitativa, ou seja, a informação se o sistema é ou não estável para uma contingência em particular. Não é possível, a princípio, a menos que se empregue o método de tentativa e erro, saber quanto estável ou instável é o sistema. Além disto, os métodos de simulação consomem grande quantidade de tempo para a análise, isto porque empregam, entre outras rotinas, métodos de integração numérica, registros das curvas de oscilação, e envolvem a participação de um especialista para a conclusão da análise, tudo isto efetuando uma simulação por vez.

Em vista disto, neste trabalho, será abordado o problema da análise de estabilidade transitória através de redes neurais, levando-se em conta o modelo clássico. Os dados de entrada e de saída serão fornecidos por um programa computacional que foi implementado baseado na proposta apresentada na referência (Fonseca & Decker [21]), que é uma metodologia que emprega a resolução das equações diferenciais (método indireto) e o método da energia (método direto).

Este método é, portanto, híbrido e iterativo pois fornece o cálculo da margem de segurança (e o tempo crítico) do sistema para uma lista preestabelecida de contingências. Os resultados são bastantes precisos, cujos erros observados são apenas procedentes de arredondamentos e da tolerância adotada.

Quando se empregam o modelo clássico e um método de análise fundamentado na função energia do sistema, a representação dos ângulos das máquinas síncronas, referidas ao Centro de Ângulos (CA) (Pai [59]), constitui a melhor opção (Athay *et al.* [4]),

visto que as perdas elétricas, que são o grande obstáculo para a aplicação dos métodos da energia, podem ser mais facilmente incorporadas no modelo. Esta será, então, a alternativa a ser seguida nesta pesquisa.

3.2. MODELO DA MÁQUINA SÍNCRONA

As equações que descrevem o comportamento dos geradores são conhecidas como equações de oscilação. São equações diferenciais que consideram, por exemplo, as posições angulares das máquinas, a velocidade de resposta ao distúrbio, se este for equilibrado ou desequilibrado (Elgerd [16]).

Considere, portanto, um sistema composto de ns máquinas síncronas, sendo que PT_i é a potência mecânica do eixo da turbina e PG_i é a potência elétrica gerada. Se estas duas potências forem iguais, desprezadas perdas, o gerador estará funcionando com velocidade síncrona constante. Caso contrário, se existir uma diferença, esta diferença será usada para mudar a energia cinética ou a velocidade e dominar o conjugado de amortecimento nos enrolamentos de amortecimento.

A equação matemática de acordo com as referências Elgerd [16] , Kundur [35] e Venikov [75] é escrita como:

$$PT_i - PG_i = \frac{d}{dt}(Wcin_i) + Pd_i \quad (3.2.1)$$

sendo:

$$\begin{aligned} Wcin_i & \triangleq \text{energia cinética total do gerador mais turbina} \\ & = \left(\frac{f_i}{f^0}\right)^2 Wcin_i^0 \end{aligned} \quad (3.2.2)$$

$$f^0 = \text{frequência nominal do sistema;}$$

Pd_i = potência referente às perdas.

$Wcin_i^0$ = energia cinética da i -ésima máquina síncrona medida na frequência nominal.

A frequência f_i pode ser expressa, considerando-se as variações em torno da frequência nominal, da seguinte forma:

$$f_i = f^0 + \Delta f_i \quad (3.2.3)$$

Então:

$$\begin{aligned} Wcin_i &= \left(\frac{f^0 + \Delta f_i}{f^0} \right)^2 Wcin_i^0 \\ &= \left\{ 1 + 2 \frac{\Delta f_i}{f^0} + \left(\frac{\Delta f_i}{f^0} \right)^2 \right\} Wcin_i^0 \end{aligned} \quad (3.2.4)$$

Como as variações de frequência Δf_i são pequenas, pode-se usar a seguinte aproximação:

$$Wcin_i \cong \left\{ 1 + 2 \frac{\Delta f_i}{f^0} \right\} Wcin_i^0 \quad (3.2.5)$$

A derivada temporal da energia cinética total da i -ésima máquina síncrona pode ser expressa por (Elgerd [16]):

$$\frac{d}{dt}(Wcin_i) = \frac{2 Wcin_i^0}{f^0} \frac{d}{dt} \Delta f_i \quad (3.2.6)$$

Como (Elgerd [16]):

$$\Delta f_i = \frac{1}{2\pi} \Delta \delta_i \quad (3.2.7)$$

então:

$$\frac{d}{dt} \Delta f_i = \frac{d}{dt} \left\{ \frac{1}{2\pi} \Delta \delta_i \right\} \quad (3.2.8)$$

$$= \frac{1}{2\pi} \frac{d\delta_i}{dt} \quad (3.2.9)$$

sendo:

δ_i = posição angular do rotor em relação a uma referência que gira de modo síncrono.

Substituindo (3.2.9) em (3.2.6), obtém-se:

$$\frac{d}{dt} (Wcin_i) = \frac{Wcin_i^0}{\pi f^0} \frac{d^2 \delta_i}{dt^2} \quad (3.2.10)$$

Deve-se observar que, havendo desvios da velocidade do rotor em relação a velocidade síncrona, haverá a indução de correntes nos enrolamentos de amortecimento do rotor, as quais causam forças que tendem a impedir os movimentos. Este conjugado tende a crescer com a velocidade relativa $d\delta_i/dt$, de tal forma que:

$$Pd_i \approx D_i \frac{d\delta_i}{dt} \quad (3.2.11)$$

sendo:

D_i = um parâmetro positivo da máquina, denominado constante de amortecimento do rotor.

Considerando as equações (3.2.10) e (3.2.11), a equação (3.2.1) pode ser escrita da seguinte forma:

$$PT_i - PG_i = \frac{Wcin_i^0}{\pi f^0} \frac{d^2 \delta_i}{dt^2} + D_i \frac{d\delta_i}{dt} \quad (3.2.12)$$

Colocando a equação (3.2.12) em pu (por unidade), uma vez que é dada em MW, cuja base adotada é a potência nominal da i -ésima máquina síncrona, tem-se:

$$Pm_i - Pe_i = \frac{H_i}{\pi f^0} \frac{d^2 \delta_i}{dt^2} + D_i \frac{d\delta_i}{dt} \quad (3.2.13)$$

sendo:

$$\begin{aligned} H_i &\triangleq \text{constante de inércia definida por:} \\ &= \frac{Wcin_i^0}{Pr_i} \end{aligned} \quad (3.2.14)$$

$$\begin{aligned} Pm_i &\triangleq \text{potência mecânica de entrada (pu)} \\ &= \frac{PT_i}{Pr_i} \end{aligned} \quad (3.2.15)$$

$$\begin{aligned} Pe_i &\triangleq \text{potência elétrica de saída (pu)} \\ &= \frac{PG_i}{Pr_i} \end{aligned} \quad (3.2.16)$$

$$Pr_i = \text{potência nominal total da } i\text{-ésima máquina síncrona.}$$

Adaptando-se estas equações ao modelo clássico, e desconsiderando o amortecimento, tem-se as seguintes equações apresentadas na Seção 3.3 que descrevem o comportamento dinâmico das máquinas síncronas referidas ao CA (Centro de Ângulos).

3.3. MODELO UTILIZADO

O comportamento dinâmico da i -ésima máquina pode ser descrito pela seguinte equação diferencial (equação de oscilação da máquina síncrona) (Anderson & Fouad [2], Pai [59]):

$$M_i \frac{d^2 \theta_i}{dt^2} - g_i(\theta) = 0, \quad i \in N \quad (3.3.1)$$

sendo:

$$g_i(\theta) = Pm_i - Pe_i - M_i \frac{PCOA}{MT} \quad (3.3.2)$$

$$M_i = \frac{2 H_i}{\omega_s};$$

$\omega_s \triangleq$ velocidade síncrona (rad. elét/s)

$$= 2 \pi f^0;$$

$\theta_i \triangleq$ ângulo do rotor da i -ésima máquina síncrona referida ao CA (rad. elét.)

$$= \delta_i - \delta^g;$$

δ_i = ângulo do rotor da i -ésima máquina síncrona medida com relação a uma máquina que gira à velocidade síncrona (rad. elét.);

$$\delta^g = \sum_{j \in N} M_j \delta_j;$$

$PCOA \triangleq$ potência acelerante do CA

$$= \sum_{j \in N} (Pm_j - Pe_j);$$

$$MT = \sum_{j \in N} M_j;$$

$N \triangleq \{ 1, 2, \dots, ns \}$

= conjunto de índices das máquinas que compõem o sistema;

ns = número de máquinas síncronas.

A potência elétrica usada na equação (3.3.2), considerando-se as simplificações introduzidas no modelo clássico, pode ser calculada de várias formas. Uma delas e mais comum consiste em realizar o cálculo, a partir da matriz de admitância

reduzida às barras internas de geração, como proposto em (Anderson & Fouad [2], Pai [59]). Trata-se de um procedimento rápido do cálculo da potência elétrica, principalmente, quando esta se refere à condição de defeito (período de permanência do curto-circuito) e pós-defeito (eliminação do defeito com saída da linha de transmissão), empregando o método proposto na referência (Minussi & Freitas [50]).

3.4. ANÁLISE DE ESTABILIDADE TRANSITÓRIA

O diagnóstico da estabilidade transitória de sistemas de energia elétrica, considerando-se uma contingência de índice r , pode ser efetuado utilizando-se o critério da margem de segurança (Pai [59]):

$$M_r = \frac{(E_{critr} - E_{er})}{E_{critr}} \quad (3.4.1)$$

sendo:

E_{critr} = energia total crítica do sistema;

E_{er} = energia total do sistema avaliada no instante de eliminação do defeito (t_e).

A energia crítica (E_{crit}), assim como o tempo crítico (t_{crit}), poderão ser determinados através do método PEBS (*Potential Energy Boundary Surface* – Superfície Limite de Energia Potencial) (Athay *et al.* [4], Fonseca & Decker [21]), ou por outro procedimento que apresente um resultado similar, principalmente com relação a precisão.

Ressalta-se que quando são consideradas as condutâncias de transferência, a expressão (3.3.2) não se caracteriza como uma força potencial (Minussi & Freitas [50]), conseqüentemente, não é possível determinar uma função energia potencial do sistema – representada pela primeira integral do movimento (equação (3.3.1)) – que se

constitui como dependente do caminho de integração. Porém, neste trabalho, o termo energia total do sistema será utilizado sempre que houver referência à função tipo energia. Por conseguinte, a energia total, relativa ao sistema (3.3.1), é dada por (Athay *et al.* [4], Pai [59]):

$$E(\theta, \omega) = Ep(\theta) + Ec(\omega) \quad (3.4.2)$$

sendo:

$Ec(\omega) \triangleq$ energia cinética

$$= \frac{1}{2} \sum_{j \in N} M_j \omega_j^2 \quad (3.4.3)$$

$Ep(\theta) \triangleq$ energia potencial

$$= - \sum_{i \in N} \left[\int_{\theta_i^p}^{\theta_i} g_i(\theta) d\theta_i \right]. \quad (3.4.4)$$

Então, a estabilidade transitória para a r -ésima contingência pode ser avaliada, via margem de segurança, da seguinte forma (Pai [59]):

- se $M_r \geq 0$, o sistema é considerado **estável**, do ponto de vista da estabilidade transitória;
- se $M_r < 0$, o sistema é considerado **instável**, do ponto de vista da estabilidade transitória.

3.5. CONCLUSÃO

Foram apresentados, neste capítulo, o modelo geral da máquina síncrona (para fins da análise de estabilidade de primeira oscilação), bem como o modelo do sistema utilizado neste trabalho baseado no modelo clássico, com as justificativas para este uso.

Apresentaram-se, também, as equações utilizadas para a análise da estabilidade transitória em função da margem de segurança, que é o modelo utilizado nesta pesquisa. Este modelo será a base para o desenvolvimento do modelo neural para o cálculo da sensibilidade da margem de segurança com relação às variáveis de entrada (potência mecânica e potência das barras de carga). Este assunto será, então abordado nos capítulos subseqüentes.

CAPÍTULO 4

FORMULAÇÃO BÁSICA DO CONTROLE PREVENTIVO DINÂMICO

4.1. INTRODUÇÃO

O Controle Preventivo Dinâmico, também chamado de Controle ou Correção de Segurança, é uma atividade que visa eliminar, ou pelo menos atenuar os efeitos de perturbações, se houver violação de segurança. Estes efeitos estão associados a saídas de equipamentos, curto circuito, etc., que podem provocar a perda da estabilidade do sistema. A Correção de Segurança Estática tem sido investigada há algum tempo, o que não acontece com a correção de Segurança Dinâmica que ainda não dispõe de bibliografia farta. Neste capítulo, apresenta-se a formulação básica do controle preventivo dinâmico com vistas ao emprego de redes neurais como abordado nos capítulos subseqüentes.

4.2. ESTADO DA ARTE

O controle preventivo dinâmico, ou seja, considerando-se a análise de estabilidade transitória, tem sido abordado, na literatura especializada, basicamente usando duas metodologias:

- metodologias clássicas;
- inteligência artificial, em especial, as redes neurais artificiais.

Nas metodologias clássicas estão incluídas as técnicas de análise de sensibilidade a partir dos métodos da energia (Bettiol [8], Fonseca & Minussi [22], Fouad & Jianzhong [23], Fouad & Vittal [24], Minussi & Freitas [50], Oliveira [57], Pavella *et al.* [63], Singh & David [66], Takaue *et al.* [72], Vittal *et al.* [76], Xue *et al.* [81], entre outros).

Nas metodologias baseadas nas redes neurais, há dois enfoques: (1) emprego das redes neurais para avaliação da estabilidade transitória e controle preventivo realizado usando-se algum outro procedimento para efetivar, por exemplo, o redespacho de geração e / ou corte de carga (Djukanovic *et al.* [15], Liu *et al.* [37]), caracterizando-se como metodologias híbridas; (2) geração de modelo de sensibilidade (Lotufo *et al.* [43]–[45], Chauhan & Dave [11]). Contudo, a referência Chauhan & Dave [11] emprega um modelo de sensibilidade por redes neurais abordando o problema da estabilidade de tensão (Wehenkel [78]). Esta pesquisa de doutorado está inserida no contexto do item (2).

Assim sendo, nesta pesquisa será desenvolvida uma metodologia para o cálculo da sensibilidade de funções não-lineares desconhecidas por redes neurais. Como pode-se observar, há uma reduzidíssima oferta de referências disponíveis na literatura especializada com este enfoque. É uma proposta que visa desenvolver um mecanismo neural para o cálculo do modelo de sensibilidade, entre a margem de segurança do sistema, que é o critério de análise de estabilidade transitória empregado nesta pesquisa, e o vetor de potências ativa e reativa nodais, e testá-lo em aplicações práticas visando estabelecer a viabilidade desta metodologia. As potências nodais permitem a formulação de uma metodologia para a determinação de ações de controle usando-se o redespacho de geração, bem como, se necessário, o corte de carga (em casos extremos). Como parte da fase de testes, serão abordados, também, outros problemas acadêmicos de interesse de várias áreas do conhecimento humano.

Na próxima Seção (Seção 4.3) será apresentada a formulação básica do problema associado ao modelo de sensibilidade para a realização do controle preventivo dinâmico, cuja finalização de todo o processo será fundamentado nos Capítulos 5 (teoria sobre redes neurais) e 6 (proposição do modelo de sensibilidade por redes neurais) e 8 (aplicação).

4.3. FORMULAÇÃO DO PROBLEMA POR REDES NEURAIIS

Considerando-se uma lista composta por S contingências, a margem de segurança do sistema (equação (3.4.1)) deve satisfazer a seguinte relação (Minussi & Freitas [50]):

$$M \geq Mmin \quad (4.3.1)$$

sendo:

$Mmin$ = limite mínimo da margem de segurança do sistema ($Mmin \geq 0$).

As ações de controle devem promover modificações nas margens de segurança, tais que, as seguintes relações sejam satisfeitas (Minussi & Freitas [50]):

$$M_r^0 + \Delta M_r = Mmin, r = 1, 2, \dots, S \quad (4.3.2)$$

sendo:

M_r = margem de segurança referente a r -ésima contingência.

A mudança (ΔM_r) necessária à correção da margem de segurança pode ser estimada através da teoria de sensibilidade, de primeira ordem, por (Fonseca & Minussi [22], Lotufo *et al.* [43]–[45]):

$$\Delta M_r \cong \langle \partial M_r / \partial X, \Delta X \rangle \quad (4.3.3)$$

sendo:

$\partial M_r / \partial X$ = sensibilidade da margem de segurança com relação ao vetor X ;

ΔX = vetor correspondente à mudança nos componentes do vetor X .

$\langle \mathbf{u}, \mathbf{v} \rangle$ = produto interno dos vetores \mathbf{u} e \mathbf{v} n -dimensionais.

O vetor \mathbf{X} , neste trabalho, será representado pela potência ativa nodal, compreendendo a geração e as cargas do sistema. A obtenção do modelo de sensibilidade será tratada no Capítulo 6, através de redes neurais não-recorrentes.

4.4. CONCLUSÃO

Neste capítulo foi apresentada a formulação matemática genérica referente à proposta do controle preventivo dinâmico baseado na margem de segurança para utilização juntamente com as redes neurais na correção da segurança em função do índice considerado para atingir o nível de estabilidade. Ou seja, corresponde ao cálculo do vetor $\partial M_r / \partial \mathbf{X}$ (sensibilidade) por redes neurais (baseada em estímulo de entrada e saída). O uso da rede neural refere-se ao fato de que se está buscando obter a derivada parcial de uma função desconhecida, a qual corresponde, nesta pesquisa, a função margem de segurança que se conhece a sua expressão (3.4.1), porém, não se conhece a sua forma, pois ela é dependente de um grande conjunto de informações do sistema (estado, topologia, etc.). Certamente, é um problema complexo que, se resolvido por redes neurais, os objetivos desta pesquisa serão atingidos. A busca de uma alternativa para o cálculo para a diferenciação de funções desconhecidas será útil para o problema sob enfoque nesta pesquisa (controle preventivo), assim como para a resolução de uma série de problemas que são encontrados no mundo real, em especial aqueles em que não se conhecem os modelos do sistema que são, geralmente, encontrados nas áreas de biologia, medicina, agricultura, economia, sistemas previsionais, etc.

CAPÍTULO 5

REDES NEURAIS ARTIFICIAIS

5.1. INTRODUÇÃO

Neste Capítulo apresentam-se os principais conceitos básicos sobre redes neurais artificiais. O que se pretende é apresentar o desenvolvimento de uma arquitetura neural multicamadas com alimentação para frente (*feedforward*), que é uma das mais conhecidas estruturas neurais disponíveis na literatura especializada, cujo treinamento é realizado por uma versão (com inclusão de melhorias) do algoritmo retropropagação tradicional (formulação básica) (Werbos [79]). As melhorias incluídas são: (1) controlador nebuloso para a realização do ajuste da taxa de treinamento; (2) ajuste da inclinação e deslocamento da função sigmóide. O primeiro recurso destina-se a adaptação da taxa de treinamento com vistas a reduzir o tempo de treinamento (Jacobs [30]), ou seja, é um controlador que busca reduzir o erro de treinamento baseado nos conceitos da lógica nebulosa, enquanto o segundo recurso, trata do ajuste, de forma semelhante a adaptação de pesos do algoritmo retropropagação, da inclinação e do deslocamento da função sigmoidal, cujo objetivo é minimizar a possibilidade de ocorrência de paralisia e escape dos mínimos locais e conseqüentemente, convergir para um ponto mínimo global “com maior facilidade”. Estas providências tendem a tornar o treinamento mais rápido e mais confiável em comparação à formulação básica do método retropropagação. Esta versão do método retropropagação será abordada na seqüência com o propósito de gerar o vetor de sensibilidade da margem de segurança necessário para o desenvolvimento do controle preventivo dinâmico de sistemas de energia elétrica, como foi estabelecido no Capítulo 4.

5.2. ESTRUTURA DA REDE NEURAL

Os principais conceitos e definições sobre redes neurais são apresentados no Apêndice A.

A estrutura neural artificial a ser usada nesta pesquisa corresponde a uma rede *feedforward* (direta) multicamadas, conforme é ilustrada na Figura 3, com treinamento baseado no algoritmo retropropagação (Werbos [79]). Como já mencionado, nesta pesquisa será empregada uma formulação alternativa do método retropropagação com inclusão de um controlador nebuloso (Arabshahi *et al.* [3]), e um processo de adaptação (Stamatis *et al.* [69]) da inclinação e deslocamento da função sigmóide.




Figura 3. Estrutura de uma rede neural artificial.

Assim, a saída do i -ésimo elemento (neurônio) (Figura 4) é a combinação linear das entradas x_j dos elementos que são conectados ao elemento i através dos pesos w_{ij} (Widrow & Lehr [80]):

$$s_i = \sum_j w_{ij} x_j \quad (5.2.1)$$

Cada elemento s_i pode conter um peso *bias* w_0 , alimentado por uma entrada constante extra $x_0 = +1$.

A saída linear s_i é finalmente convertida em não-linearidade tipo relé (Widrow & Lehr [80]), sigmóide (Fine [18], Widrow & Lehr [80]), entre outras.




Figura 4. Modelo do neurônio artificial.

5.3. TREINAMENTO

Conforme proposto, o treinamento da rede neural escolhida será através do algoritmo retropropagação que consiste basicamente da apresentação de um padrão à entrada da rede causando uma resposta à saída, passando pela camada intermediária. Na camada de saída tem-se uma resposta real que será comparada com a resposta esperada e, portanto, sendo produzido um erro. Este erro é minimizado da saída para entrada recalculando os pesos dos neurônios através de um algoritmo de minimização, o gradiente descendente. O algoritmo converge quando este erro for menor ou igual a uma tolerância preestabelecida. De acordo com as principais referências (Fine [18], Haykin [28], Kartalopoulos [31], Widrow & Lehr [80], Wasserman [77]) são adotados como valores iniciais para os pesos, números aleatórios.

O treinamento, via retropropagação, é iniciado pela apresentação de um padrão X à rede, o qual produzirá uma saída Y . Em seguida calcula-se o erro de cada saída (diferença entre o valor desejado e a saída). O próximo passo consiste na determinação do erro propagado no sentido inverso, através da rede associada à derivada parcial do erro quadrático de cada elemento com relação aos pesos e, finalmente, ajustando os pesos de cada elemento. Um novo padrão é apresentado, assim, o processo é repetido, para todos os padrões, até que ocorra a total convergência ($|\text{erro}| \leq$ tolerância preestabelecida). Os pesos iniciais são normalmente adotados como números aleatórios. O algoritmo retropropagação consiste na adaptação de pesos com o propósito de minimizar o erro quadrático da rede. A soma do erro quadrático instantâneo de cada neurônio alocado na última camada (saída da rede) é dada por (Widrow & Lehr [80]):

$$\varepsilon^2 = \sum_{i=1}^{ns} \varepsilon_i^2 \quad (5.3.1)$$

sendo:

$$\varepsilon_i = d_i - y_i ;$$

d_i = saída desejada do i -ésimo elemento da última camada da rede;

y_i = saída do i -ésimo elemento da última camada da rede;

ns = número de neurônios da última camada da rede.

Considerando-se o neurônio de índice i da rede, e utilizando-se o método do gradiente descendente (Widrow & Lehr [80]), o ajuste de pesos pode ser formulado como (Fine [18], Widrow & Lehr [80]):

$$V_i(h+1) = V_i(h) + \theta_i(h) \quad (5.3.2)$$

sendo:

$$\theta_i(h) = -\gamma [V_i(h)];$$

γ = parâmetro de controle da estabilidade ou taxa de treinamento;

h = representa o índice de iteração;

$\nabla_i(h)$ = gradiente do erro quadrático com relação aos pesos do neurônio i avaliado em h ;

V_i = vetor contendo os pesos do neurônio i
= $[w_{0i} \ w_{1i} \ w_{2i} \ \dots \ w_{ni}]^T$.

Na equação (5.3.2) a direção adotada para minimizar a função objetivo do erro quadrático corresponde à direção contrária ao gradiente. O parâmetro γ determina o comprimento do vetor $[\theta_i(h)]$.

A função sigmóide é definida pelas equações a seguir, (Fine [18], Widrow & Lehr [80]), cujas representações gráficas estão contidas no Apêndice A:

$$y_i = \frac{1 - \exp(-\lambda s_i)}{1 + \exp(-\lambda s_i)} \quad (5.3.3)$$

ou

$$y_i = \frac{1}{1 + \exp(-\lambda s_i)} \quad (5.3.4)$$

sendo:

λ = constante que determina a inclinação da curva y_i

Ressalta-se que o espectro da função sigmóide y_i dada pela equação (5.3.3) ou (5.3.4) é $[-1, +1]$ ou $[0, +1]$, respectivamente.

O algoritmo retropropagação é abordado na literatura sob várias formas com o propósito de torná-lo mais rápido computacionalmente. Uma formulação bastante interessante é o algoritmo *retropropagação com momento* Widrow & Lehr [80]), o qual tem um efeito estabilizador (Haykin [28], Widrow & Lehr [80]).

$$V_{ij}(h+1) = V_{ij}(h) + \Delta V_{ij}(h) \quad (5.3.5)$$

em que:

$$\Delta V_{ij}(h) = 2 \gamma (1 - \eta) \delta_i(h) X_j + \eta \Delta V_{ij}(h - 1) \quad (5.3.6)$$

sendo:

V_{ij} = peso sináptico de interligação entre os neurônios i e j ;

η = constante de momento variando entre 0 e 1, $0 \leq \eta \leq 1$;

δ_j = derivada do erro quadrático (gradiente);

X = vetor de entrada;

$$\delta_j = \frac{\partial e_j^2}{\partial s_j} \quad (5.3.7)$$

sendo:

$$s_j(h) = V_j(h) X_j(h) \quad (5.3.8)$$

Os modos de treinamento podem ser de dois tipos, o chamado seqüencial e o por lote. O seqüencial é aquele em que o ajuste dos pesos é efetuado após cada padrão e o lote com todos os padrões ao mesmo tempo (Haykin [28]).

Então, efetuando-se o cálculo do gradiente como indicado na equação (5.3.2), considerando-se a função sigmóide definida pela equação (5.3.3) ou (5.3.4) e o termo momento, obtém-se o seguinte esquema de adaptação de pesos (Widrow & Lehr [80]):

$$V_{ij}(h+1) = V_{ij}(h) + \Delta V_{ij}(h) \quad (5.3.9)$$

sendo:

$$\Delta V_{ij}(h) = 2 \gamma (1 - \eta) \beta_j x_i + \eta \Delta V_{ij}(h - 1); \quad (5.3.10)$$

V_{ij} = peso correspondente à interligação entre o i -ésimo e j -ésimo neurônio;

γ = taxa de treinamento;

η = constante momento ($0 \leq \eta < 1$).

Se o elemento j encontrar-se na última camada, então:

$$\beta_j = \sigma_j \varepsilon_j \quad (5.3.11)$$

em que:

σ_j = derivada da função sigmóide dada pela equação (5.3.3) ou (5.3.4), respectivamente, com relação a s_j :

$$= 0,5 \lambda (1 - y_j^2) \quad (5.3.12)$$

$$= \lambda y_j (1 - y_j). \quad (5.3.13)$$

Se o elemento j encontrar-se nas demais camadas, tem-se:

$$\beta_j = \sigma_j \sum_{k \in R(j)} w_{jk} \beta_k \quad (5.3.14)$$

sendo:

$R(j)$ = conjunto dos índices dos elementos que se encontram na fileira seguinte à fileira do elemento j e que estão interligados ao elemento j .

O parâmetro γ serve como controle de estabilidade do processo iterativo.

Os pesos da rede são inicializados aleatoriamente considerando-se o intervalo $\{0,1\}$ (Widrow & Lehr [80]).

O treinamento via método retropropagação, pode ser efetuado, basicamente, de duas formas:

- *Procedimento 1.* Consiste em ajustar os pesos da rede (considerando-se todas as camadas), fazendo-se com que haja convergência para cada padrão, até que se complete o conjunto de padrões de entrada. O processo deverá ser repetido até a total convergência, *i.e.*, o erro quadrático

seja inferior a uma tolerância preestabelecida para os padrões considerados.

- *Procedimento 2.* Este procedimento é idêntico ao primeiro, porém, fazendo-se somente uma iteração (ajuste de pesos) por padrão.

O algoritmo retropropagação é considerado, na literatura especializada, um referencial em termos de precisão. Contudo, a sua convergência é bastante lenta. Deste modo, ajusta-se a taxa de treinamento γ durante o processo de convergência, visando a redução do tempo de execução do treinamento. O ajuste de γ é efetuado neste trabalho via procedimento baseado em um controlador nebuloso (Lopes [39]).

A idéia básica da metodologia (Lopes [39]) consiste na determinação do estado do sistema definido como sendo o erro global ε_g e a variação do erro global $\Delta\varepsilon_g$, cujo objetivo é a obtenção de uma estrutura de controle que consiga que o erro tenda para zero em um número reduzido de iterações, se comparado ao algoritmo retropropagação convencional. O controle, nesta pesquisa, é formulado usando os conceitos de lógica nebulosa, cujos principais conceitos encontram-se no Apêndice B. O erro global ε_g e sua variação $\Delta\varepsilon_g$ são os componentes do estado do sistema, e $\Delta\gamma$ é a ação de controle que deve ser exercida no sistema. Inicialmente, define-se o erro global (Lopes [39]), Lopes *et al.* [41]–[42]):

$$\varepsilon_g = \sum_{j=1}^{np} \sum_{i=1}^{ns} \varepsilon_i^2 \quad (5.3.15)$$

sendo:

ε_g = erro global da rede neural;

np = número de vetores padrões da rede.

O erro global corresponde ao cálculo de erros de todas as saídas (neurônios de saída), considerando-se todos os vetores padrões da rede. O treinamento deve ser executado utilizando o procedimento 2 (uma iteração por padrão). O erro global é calculado em cada iteração e ajustado o parâmetro γ , através de um acréscimo $\Delta\gamma$ determinado via lógica nebulosa. Este parâmetro será utilizado para ajustar o conjunto

de pesos da rede referente à iteração subsequente. O estado do sistema e a ação de controle são assim definidos (Lopes [39]), Lopes *et al.* [41]–[42]):

$$E^k = [\varepsilon g^k \quad \Delta \varepsilon g^k]^T \quad (5.3.16)$$

$$u^k = \Delta \gamma \quad (5.3.17)$$

sendo:

k = o índice que indica a iteração corrente.

O processo deverá, então, ser repetido até que o treinamento seja concluído. Trata-se de um procedimento bastante simples cujo sistema de controle requer um esforço adicional bastante reduzido, tendo em vista que o controlador possui duas variáveis de entrada e uma única de saída. O valor u é calculado pelo método da *denebulização* (Kartalopoulos [31], Terano *et al.* [74]).

A *denebulização* é um processo onde as funções de pertinência são amostradas para encontrar seu grau, e então este grau é usado na equação lógica para definir uma região de saída; a partir disto deduz-se a saída. Dos três métodos de *denebulização* existentes (Kartalopoulos [31]) escolheu-se o do centróide que encontra o centro de massa da variável de saída, isto é, da figura definida pelo conjunto de regras sobre o eixo da variável de controle.

Cada variável de estado deverá ser representada entre 3 e 7 conjuntos nebulosos. A variável de controle também deverá ser representada com o mesmo número de conjuntos nebulosos.

A variável εg deverá ser normalizada, considerando-se como fator de escala o primeiro erro global gerado pela rede, ou seja, de índice $k = 0$. Com esta representação, o intervalo de variação de εg deverá estar compreendido entre 0 e +1. Se a heurística de adaptação estiver devidamente sintonizada, a convergência do processo deverá ser exponencial decrescente. A variável $\Delta \varepsilon g$ deverá variar entre -1 e +1. Se o processo de convergência for exponencial decrescente os valores de $\Delta \varepsilon g$ deverão ser sempre negativos.

Neste caso, embora a escala de $\Delta\epsilon$ varie entre -1 e $+1$, deve-se empregar, no conjunto de regras, um ajuste fino entre -1 e 0 . No outro intervalo, o ajuste poderá ser mais relaxado. Visando estabelecer prioridade de atuação do regulador no intervalo inicial do treinamento, emprega-se uma função exponencial decrescente para corrigir os acréscimos $\Delta\gamma$ e evitar instabilidade no processo de convergência.

5.4. PROCESSO ADAPTATIVO DA INCLINAÇÃO E DA TRANSLAÇÃO DA FUNÇÃO SIGMÓIDE

Consiste na realização do ajuste, de forma sistemática, da inclinação (parâmetro λ) e de translação (parâmetro ρ) da função sigmóide como proposto na referência (Stamatis *et al.* [69], Lopes [40]). É um procedimento em que os parâmetros λ e ρ são adaptados de forma análoga ao que é realizado com relação aos pesos da rede neural, como abordado anteriormente. Neste caso, a regra de adaptação usada é a retropropagação. Assim, não é introduzida nenhuma complicação adicional, exigindo apenas um número maior de parâmetros a serem adaptados. O resultado obtido, contudo é bastante significativo, ou seja, o ajuste da inclinação da função sigmóide permite que se controle o espaço de busca de soluções o que efetivamente representa uma melhor perspectiva de se evitar a paralisia do processo de adaptação. A translação da função sigmóide, também, é uma eficiente alternativa que visa contribuir para que haja maior garantia que o processo adaptativo convirja para um ponto mínimo global. Deve-se ressaltar que o efeito de translação é mais eficiente em comparação ao controle da inclinação sigmoidal. Isto decorre pelo fato de que a tendência de melhoria da resposta, via o controle de inclinação, é fazer com que o parâmetro λ seja reduzido para um valor mínimo que é bastante limitado, ou seja, λ não deve ser menor, a princípio, de $0,4$ conforme indicação colhida nas várias experiências realizadas. No caso de translação, não há limite imposto. Deve-se ressaltar, ainda, que o algoritmo retropropagação realiza esta sintonia de forma automática.

Via de regra, tem-se observado que quase sempre se consegue realizar o treinamento (completada a convergência) usando os dispositivos ora abordados: controlador nebuloso para o ajuste da taxa de treinamento e a adaptação da inclinação e translação da função sigmóide. Porém, como esta metodologia é determinística não se pode garantir sempre que ocorra a convergência. O que efetivamente pode-se dizer, é que se trata de um procedimento que tem proporcionado bons resultados, destacando-se o caso da previsão de carga de sistemas de energia elétrica por redes neurais:

- (1) Na referência (Lopes *et al.* [41]) foi empregado o controlador nebuloso da taxa de treinamento, cujo resultado proporcionado foi uma redução de em torno de 25% no tempo de treinamento e a redução do erro da previsão (MAPE (*Mean Absolute Percentage Error*)) de 7 para menos de 3% em comparação ao algoritmo retropropagação convencional (Werbos [79]).
- (2) Na referência (Lopes *et al.* [42]) considerando-se o controlador nebuloso e a adaptação de λ e ρ , foram obtidos um erro da previsão de mesma magnitude como proporcionada na referência (Lopes *et al.* [41]) e uma redução do tempo de treinamento ainda maior, ou seja, o tempo de treinamento foi da ordem de 10 vezes menor, se comparado ao produzido pelo procedimento convencional.




Figura 5. Comportamento da função sigmóide em função do parâmetro λ (inclinação) e ρ (translação).




Figura 6. Comportamento da derivada da função sigmóide em relação aos pesos em função do parâmetro λ e ρ (translação).

As Figuras 5 e 6 mostram, respectivamente, os comportamentos da função sigmóide e da função σ (derivada da função sigmóide em relação aos pesos) em função do parâmetro λ : $\lambda_1 > \lambda_2 > \lambda_3 > 0$.

A forma geral das funções pós-sinápticas usadas para ajustar a rede neural é dada por (Stamatis *et al.* [69]):

$$y_i = f(\lambda, \rho, v, w) \quad (5.4.1)$$

Os parâmetros de inclinação e translação contém taxas de aprendizagem correspondentes denotadas por γ^λ e γ^ρ , respectivamente.




Figura 7. Arquitetura neural para ajustes dos parâmetros de inclinação e translação da função pós-sináptica.

A Figura 7 ilustra a arquitetura neural com ajustes dos parâmetros de inclinação e translação da função pós-sináptica, neste caso, a função sigmoideal (Stamatis *et al.* [69]).

O ajuste do parâmetro de inclinação da função sigmóide é dado por (Lopes [40], Lopes *et al.* [42]):

$$\lambda_i(r+1) = \lambda_i(r) + \theta_i^\lambda(r) \quad (5.4.2)$$

em que:

$$\begin{aligned} \theta_i^\lambda(r) &= -\gamma^\lambda [\nabla_i^\lambda(r)]; \\ \nabla_i^\lambda(r) &= \text{gradiente do erro quadrático relacionado a inclinação do neurônio } i; \\ \lambda_i &\triangleq \text{vetor contendo as inclinações do neurônio } i; \\ &= [\lambda_{0i} \ \lambda_{1i} \ \lambda_{2i} \ \dots \ \lambda_{ni}]^T. \end{aligned}$$

O gradiente ∇_i^λ é representado por (Lopes [40]):

$$\nabla_i^\lambda(r) = \frac{\partial \varepsilon_i^2}{\partial \lambda_i(r)} = 2\varepsilon_i \frac{\partial \varepsilon_i}{\partial \lambda_i} = -2\varepsilon_i \frac{\partial y_i}{\partial \lambda_i} = -2\varepsilon_i \sigma_i^\lambda$$

em que:

$\sigma_i^\lambda \triangleq$ derivada da função sigmóide relacionada a λ_i .

A regra geral que define a adaptação do parâmetro de inclinação da função sigmóide é dada da seguinte forma:

$$\lambda_i(r+1) = \lambda_i(r) + 2\gamma^\lambda \beta_i^\lambda$$

Regra que define o cálculo de β_i^λ :

$$\text{Última camada} \quad \beta_i^\lambda = \sigma_i^\lambda \varepsilon_i$$

$$\text{Demais camadas} \quad \beta_i^\lambda = \sigma_i^\lambda \sum_{j \in Q(i)} w_{ij} \beta_j^\lambda$$

Similar ao procedimento descrito acima, o ajuste do parâmetro translação da função sigmóide é indicado por:

$$\rho_i(r+1) = \rho_i(r) + \theta_i^\rho(r) \quad (5.4.3)$$

em que:

$$\begin{aligned} \theta_i^\rho(r) &= -\gamma^\rho [\nabla_i^\rho(r)]; \\ \nabla_i^\rho(r) &= \text{gradiente do erro quadrático referente ao deslocamento do neurônio } i; \\ \rho_i &\triangleq \text{vetor contendo os deslocamentos do neurônio } i; \\ &= [\rho_{0i} \ \rho_{1i} \ \rho_{2i} \ \dots \ \rho_{ni}]^T. \end{aligned}$$

E o gradiente ∇_i^ρ é calculado da seguinte maneira:

$$\nabla_i^\rho(r) = \frac{\partial \varepsilon_i^2}{\partial \rho_i(r)} = 2\varepsilon_i \frac{\partial \varepsilon_i}{\partial \rho_i} = -2\varepsilon_i \frac{\partial y_i}{\partial \rho_i} = -2\varepsilon_i \sigma_i^\rho$$

em que:

$\sigma_i^\rho \triangleq$ derivada da função sigmóide, relacionada a ρ_i .

A regra de adaptação do parâmetro translação da função sigmóide é mostrada pela equação (Lopes [42]):

$$\rho_i(r+1) = \rho_i(r) + 2\gamma^\rho \beta_i^\rho$$

Regra que define o cálculo de β_i^ρ

Última camada

$$\beta_i^\rho = \sigma_i^\rho \varepsilon_i$$

Demais camadas

$$\beta_i^\rho = \sigma_i^\rho \sum_{j \in Q(i)} w_{ij} \beta_j^\rho$$

A regra de adaptação dos parâmetros de inclinação e translação da rede é calculado de forma iterativa para todo o i -ésimo neurônio.

5.5 CONCLUSÃO

Neste capítulo apresentou-se uma pequena revisão sobre os principais conceitos de redes neurais utilizadas para o desenvolvimento da pesquisa, enfatizando a estrutura da rede neural e o treinamento, assim como as melhorias introduzidas durante o treinamento para melhorar o desempenho da rede principalmente em função do tempo de processamento para aplicações em tempo real. Trata-se de uma formulação alternativa do algoritmo retropropagação (Werbos [79]) com inclusão de um controlador nebuloso (Arabshahi *et al.* [3], Lopes [39]) para determinar, de forma “ótima”, a taxa de treinamento. Foi incluída, também, a adaptação de parâmetros da função sigmoideal (inclinação e deslocamento) (Stamatis *et al.* [69], Lopes [40]) com vistas a reduzir a possibilidade de paralisia que, às vezes, ocorre no treinamento via retropropagação convencional (Werbos [79]). A paralisia é um processo em que se observa a não atualização de pesos em consequência de realimentações (β_j) nulas ou muito pequenas. Efetuando-se o controle sobre tais parâmetros, pode-se proporcionar ao algoritmo retropropagação uma certa “imunidade” à perda da função sensorial. Assim sendo, o controlador nebuloso e a adaptação dos parâmetros da função sigmoideal conferem ao algoritmo retropropagação uma maior rapidez do treinamento e uma maior precisão conforme foi observado em várias aplicações (Lopes [39], Lopes *et al.* [41]–[42], Lotufo *et al.* [43]–[45]). Esta é a alternativa para o desenvolvimento de uma rede neural derivativa que será abordada no Capítulo (6). Contudo, há possibilidade do desenvolvimento de dispositivos para a análise da estabilidade transitória (Ferreira [17], Marchiori *et al.* [49]) e para o controle preventivo baseados em estruturas neurais mais eficientes, principalmente do ponto de vista da rapidez do treinamento, por exemplo, as redes neurais da família ART (*Adaptive Resonance Theory*) (Carpenter & Grossberg [9], Carpenter *et al.* [10]). Esta alternativa tem se mostrado eficiente para o caso de análise, porém, não se mostra tão evidente para aplicações como rotina de diferenciação (que é o

caso do controle preventivo), isto porque as redes neurais ART são caracterizadas como um mecanismo para classificação de padrões. É algo como um procedimento para manipulação de informações discretas. No caso do controle preventivo, o que se precisa efetivamente é a derivada de uma função desconhecida (a princípio) que é uma grandeza vetorial contínua. Daí decorre o fato de se optar pela rede neural *feedforward* com treinamento retropropagação (ou uma outra forma alternativa semelhante). Contudo, em pesquisas futuras dever-se-ão desenvolver estruturas que combinam o derivador analógico (rede neural retropropagação) com a manipulação de classes (por exemplo, as redes da linhagem ART).

CAPÍTULO 6

ANÁLISE DE SENSIBILIDADE POR REDES NEURAIIS

6.1. INTRODUÇÃO

Neste capítulo será desenvolvido o cálculo do vetor de sensibilidade da margem de segurança $\partial M_r / \partial X$ por redes neurais *feedforward* com treinamento realizado tomando-se como base o algoritmo retropropagação (Werbos [79]). Trata-se do algoritmo retropropagação com melhorias que foram introduzidas com vistas a tornar o treinamento mais eficiente (menor tempo de convergência) e com maior garantia de obtenção das soluções, se comparado ao treinamento realizado usando a formulação básica (Werbos [79]), ou seja, a incorporação de um controlador nebuloso para realizar o ajuste da taxa de treinamento (Arabshahi *et al.* [3]) e a adaptação da inclinação e deslocamento da função sigmóide (Stamatis *et al.* [69]). Visando ilustrar a metodologia proposta, apresenta-se um exemplo numérico simples de quatro entradas (já incluída a entrada *bias*) e uma única saída.

6.2. CÁLCULO DA SENSIBILIDADE POR REDES NEURAIIS

A proposta apresentada é de se calcular a sensibilidade $\partial M_r / \partial X$ através de redes neurais. Nas referências (Fonseca & Minussi [22], Minussi & Freitas Filho [50]), esta

sensibilidade era calculada a partir da expansão em série de Taylor da margem de segurança, considerando expressões que envolvem os ângulos das máquinas.

A margem de segurança e a análise de sensibilidade, fornecem subsídios para melhorar a segurança do sistema através da menor margem de segurança e usar o redespacho de geração / corte de carga para o controle da segurança dinâmica.

Portanto, de acordo com a nova proposta, o algoritmo retropropagação, definido no Capítulo 5 é iniciado apresentando um padrão $X \in \mathcal{R}^n$ a rede que dará uma saída $Y \in \mathcal{R}^m$. Seguindo, é calculado um erro em cada saída (a diferença entre o valor desejado e a saída). O próximo passo é determinar o erro retropropagado pela rede associado à derivada parcial do erro quadrático de cada elemento relacionado aos pesos, e finalmente ajustar os pesos de cada elemento. Então, um novo padrão é apresentado, e o processo deve ser repetido até que ocorra a convergência ($|\text{erro}| \leq \text{um valor prefixado}$ (muito pequeno)). Uma vez concluída esta etapa, o mecanismo de treinamento deixará de atuar, inclusive o controlador nebuloso, ficando apenas a estrutura da rede neural. Deste modo, a rede, a princípio, estará dotada com capacidade de generalização, ou seja, aplicando-se um vetor padrão de entrada qualquer, propagando-se o sinal no sentido direto (entrada para saída), resultará na saída uma estimativa da análise (diagnóstico) estabelecendo, deste modo, o mapeamento $X \rightarrow Y = f(X)$, $X \in \mathcal{R}^n$ e $Y \in \mathcal{R}^m$.

Usando-se esta idéia, pode-se estimar as derivadas das variáveis de saída (análise de sensibilidade) com relação aos componentes do vetor de entrada, usando-se a estrutura da rede neural treinada como descrita a seguir. A análise de sensibilidade, via redes neurais, servirá, neste trabalho, para a obtenção de $\partial M_r / \partial X$ problema definido pela equação (4.3.3):

$$\Delta M_r \cong \langle \partial M_r / \partial X, \Delta X \rangle \quad (6.2.1)$$

Tendo em vista que para a solução do problema do controle preventivo será adotada o redespacho de geração e o corte de carga (conforme formulação descrita no Capítulo 4), o vetor X corresponderá ao vetor de potências ativas (P) nodais.

Assim sendo, considere \mathbf{X}^k e \mathbf{Y}^k como sendo o k -ésimo par de vetores de entrada e de saída da rede neural. Considere, também, a rede neural não-recorrente (*feedforward*) mostrada na Figura 8. Trata-se da representação de uma rede composta por três camadas, onde são explicitadas as variáveis nos principais pontos da rede e as matrizes de peso. As camadas de entrada, e de saída possuem número de neurônios iguais a n (dimensão do vetor de entrada \mathbf{X}^k) e m (dimensão do vetor de saída \mathbf{Y}^k), respectivamente.




Figura 8. Rede Neural não-recorrente.

O que se pretende é obter a derivada parcial de y_p^k (p -ésimo componente do vetor \mathbf{Y}^k) com relação a x_j^k (j -ésimo componente do vetor de entrada \mathbf{X}^k). Para obtermos estas derivadas parciais, necessitam-se obter as derivadas parciais intermediárias (nas saídas dos neurônios da camada escondida) da rede neural. Assim, o cálculo das derivadas parciais de z_i^k (i -ésimo componente do vetor de saída \mathbf{z}^k), com relação a x_j^k , pode ser obtido da seguinte forma (Lotufo *et al.* [43]–[45]):

$$\frac{\partial z_i^k}{\partial x_j^k} = 0,5 \lambda w_{ji} (1 - \{z_i^k\}^2) \quad (\text{para função sigmóide (5.3.3)}) \quad (6.2.2)$$

ou:

$$\partial z_i^k / \partial x_j^k = \lambda w_{ji} z_i^k (1 - z_i^k) \quad (\text{para função sigmóide (5.3.4)}) \quad (6.2.3)$$

sendo:

x_j^k = j -ésimo componente do vetor de entrada \mathbf{X}^k ;

$$\mathbf{X}^k = [x_1^k \ x_2^k \ \dots \ x_n^k]^T; \quad (6.2.4)$$

k = índice referente ao k -ésimo vetor padrão.

A p -ésima saída intermediária (entrada da função sigmóide) da camada de saída da rede neural pode ser expressa por (Lotufo *et al.* [43]–[45]):

$$t_p^k = \{\mathbf{z}^k\}^T \mathbf{v}_p, \quad p = 1, 2, \dots, m \quad (6.2.5)$$

em que:

$$\mathbf{z}^k = [z_1^k \ z_2^k \ \dots \ z_n^k]^T \quad (6.2.6)$$

$$\mathbf{v}_p = [v_{1p} \ v_{2p} \ \dots \ v_{np}]^T. \quad (6.2.7)$$

Assim:

$$\partial y_p^k / \partial x_j^k = \{\partial y_p^k(\lambda, t_p^k) / \partial t_p^k\} \partial t_p^k / \partial x_j^k. \quad (6.2.8)$$

como:

$$\partial t_p^k / \partial x_j^k = \{\mathbf{v}_p^k\}^T \partial \mathbf{z}^k / \partial x_j^k \quad (6.2.9)$$

$$\partial \mathbf{z}^k / \partial x_j^k = [\partial z_1^k / \partial x_j^k \ \partial z_2^k / \partial x_j^k \ \dots \ \partial z_n^k / \partial x_j^k]^T, \quad (6.2.10)$$

então, substituindo equação (5.3.3), ou (5.3.4) na equação (6.2.8), obtém-se (Lotufo *et al.* [43]–[45]):

$$\partial y_p^k / \partial x_j^k = \lambda^2 / 4 (1 - \{y_p^k\}^2) \{v_p\}^T b_j^k \text{ (para função sigmóide (5.3.3))} \quad (6.2.11)$$

ou

$$\partial y_p^k / \partial x_j^k = \lambda^2 / 2 y_p^k (1 - y_p^k) \{v_p\}^T b_j^k \text{ (para função sigmóide (5.3.4))} \quad (6.2.12)$$

sendo:

$$b_j^k = [(1 - \{z_1^k\}^2) w_{j1} \quad (1 - \{z_2^k\}^2) w_{j2} \dots (1 - \{z_n^k\}^2) w_{jn}]^T \text{ (para função sigmóide (5.3.3))} \quad (6.2.13)$$

$$b_j^k = [z_1^k (1 - z_1^k) w_{j1} \quad z_{2k} (1 - z_1^k) w_{j2} \dots z_n^k (1 - z_n^k) w_{jn}]^T \text{ (para função sigmóide (5.3.4))} \quad (6.2.14)$$

Na Figura 9 apresenta-se o esquema neural para a obtenção da sensibilidade (análise de sensibilidade). As setas com linhas simples e duplas indicam dados escalares e vetoriais (ou matriciais), respectivamente. Nota-se que a sensibilidade depende das matrizes de pesos W e V , da saída y , do parâmetro λ e do vetor de saídas intermediárias z . Esta rotina é executada convencionalmente, ou seja, após a conclusão do treinamento, através de produtos matriciais simples, representando uma parcela muito pequena do tempo de processamento, se comparada à execução da etapa de treinamento.

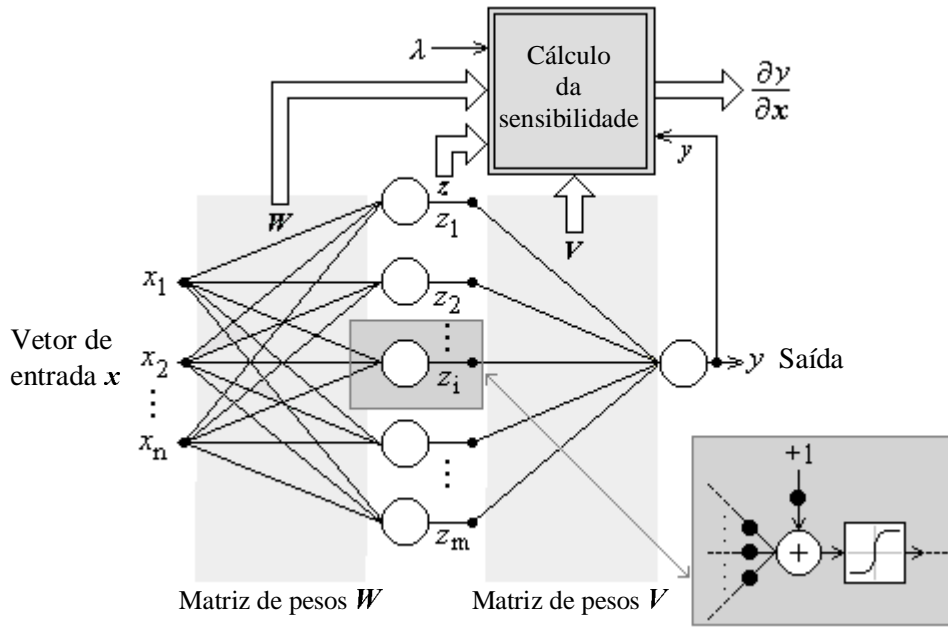


Figura 9. Rede neural para o cálculo da sensibilidade $\partial f(\mathbf{x})/\partial \mathbf{x}$.

6.3. EXEMPLO ILUSTRATIVO

Visando ilustrar análise de sensibilidade, via redes neurais, considera-se um exemplo em que se deseja realizar o mapeamento $y = f(\mathbf{x})$, $\mathbf{x} \in \mathcal{R}^4$ e $y \in \mathcal{R}$. Considera-se o seguinte vetor de entrada:

$$\mathbf{x}^0 = [1 \quad 1 \quad 1 \quad x_0 = 1]^T, \mathbf{x} \in \mathcal{R}^4. \quad (6.3.1)$$

Para realizar este exemplo, adota-se uma rede neural com 3 e 1 neurônios nas camadas de entrada e de saída, respectivamente, conforme é mostrado na Figura 10. Os pesos dos neurônios 1, 2 e 3 estão indicados nas cores vermelha, azul e verde,

respectivamente. Os pesos *bias* estão indicados na cor preta. Adota-se a função sigmóide definida pela equação (5.3.3): $y_i = \{1 - \exp(-\lambda s_i)\} / \{1 + \exp(-\lambda s_i)\}$ com $\lambda = 1$.




Figura 10. Rede neural para a realização $y = f(x)$, $x \in \mathcal{H}^4$ e $y \in \mathcal{H}$.

Supondo-se que, usando-se algum método de treinamento, foram obtidos os seguintes pesos:

$$W = \begin{bmatrix} 0,5 & 1 & 0,3 \\ 0,3 & 1,1 & 0,3 \\ 0,25 & 0,6 & 0,8 \\ 0,44 & 0,3 & 0,1 \end{bmatrix} \quad (6.3.2)$$

$$V = \begin{bmatrix} 0,3 \\ 0,2 \\ 0,5 \\ 1 \end{bmatrix} \quad (6.3.3)$$

Ressalta-se que as últimas linhas de W e V correspondem aos pesos *bias*.

Supondo-se que se deseja determinar o valor da saída (y) considerando-se uma variação no componente x_2 do valor 1 para 3 ou seja, $\Delta x_2 = 2$. Assim sendo:

$$y = y^0 + \Delta y \quad (6.3.4)$$

Para fins de simplicidade da interpretação são desconsiderados os pesos *bias*. Adotando-se o cálculo da sensibilidade por redes neurais, o acréscimo Δy pode ser determinado da seguinte forma:

$$\Delta y = \left\{ \frac{\partial y}{\partial \mathbf{x}} \right|_{\mathbf{x} = \mathbf{x}^0} \}^T \Delta \mathbf{x} \quad (6.3.5)$$

Neste exemplo, o acréscimo do vetor de entrada da rede neural corresponde a:

$$\Delta \mathbf{x} = [0 \ 2 \ 0 \ 0]^T \quad (6.3.6)$$

e o acréscimo da saída pode ser determinado por:

$$\Delta y = \frac{\partial y}{\partial x_2} \Big|_{\mathbf{x} = \mathbf{x}^0} \Delta x_2 \ (\Delta x_2 = 2) \quad (6.3.7)$$

Portanto, o que se deve determinar (via rede neural) é a sensibilidade de y em relação ao componente x_2 , ou seja:

$$\frac{\partial y}{\partial x_2} \Big|_{\mathbf{x} = \mathbf{x}^0} = ? \quad (6.3.8)$$

Neste caso, a rede neural, para fins de realizar esta sensibilidade está destacada na Figura 11.




Figura 11. Destaque da rede neural para o cálculo $\partial f(\mathbf{x})/\partial x_2$.

Assim, têm-se os seguintes pesos:

$$\begin{aligned} w_{21} &= 0,3 \\ w_{22} &= 1,1 \\ w_{23} &= 0,3 \\ v_{11} &= 0,3 \\ v_{21} &= 0,2 \\ v_{31} &= 0,5. \end{aligned}$$

A derivada parcial da saída em relação a x_2 pode ser calculada usando-se as equações (6.2.2) a (6.2.12):

$$\frac{\partial y}{\partial x_2} = \frac{\lambda}{2} (1 - y^2) V^T \frac{\partial \mathbf{z}}{\partial x_2} \quad (6.3.9)$$

sendo:

$$\mathbf{z} = [z_1 \ z_2 \ z_3]^T \quad (6.3.10)$$

$$\frac{\partial \mathbf{z}}{\partial x_2} = \frac{\lambda}{2} [(1 - z_1^2) w_{21} \ (1 - z_2^2) w_{22} \ (1 - z_3^2) w_{23}]^T \quad (6.3.11)$$

Usando-se os dados anteriormente estabelecidos, chegam-se aos seguintes resultados:

$$\mathbf{x}^0 = [x_1 \ x_2 \ x_3 \ x_0]^T = [1 \ 1 \ 1 \ 1]^T$$

$$y^0 = 0,3011$$

$$\Delta x_2 = 2$$

$$\left. \frac{\partial y}{\partial x_2} \right|_{\mathbf{x}=\mathbf{x}^0} = 0,0492$$

$$\Delta y = \left. \frac{\partial y}{\partial x_2} \right|_{\mathbf{x}=\mathbf{x}^0} \Delta x_2$$

$$= 0,0983$$

$$y = y^0 + \Delta y$$

$$= 0,3011 + 0,0983$$

$$= 0,3994.$$

Deve-se destacar que o valor real de y (calculada na saída da rede neural) vale:

$$y = 0,3719$$

ou seja, um erro absoluto:

$$|y_{\text{real}} - y_{\text{previsto via análise de sensibilidade pela rede neural}}| = 0,0276.$$

Outros exemplos estão relacionados na Tabela 1. Neste experimento, cada vetor \mathbf{x} recebe um incremento em um e dois componentes, apenas com o objetivo de verificação da precisão. Contudo, acréscimos múltiplos podem ser também contemplados.

Tabela1. Valores corretos e previstos (via análise de sensibilidade pela rede neural) da saída $y = f(x)$.

Vetor de Entrada Inicial (x^0)			Saída Inicial (y^0)	Vetor de Entrada (x)			Vetor de Sensibilidade $\partial y / \partial x$ Obtido pela Rede Neural			Saída (y)	
										Via análise de sensibilidade pela Rede neural	Valor Correto
1	2	3		1	2	3	1	2	3		
2	2	-1	0,2282	3	2	-1	0,0623	0,0535	0,1056	0,2905	0,2834
2	2	-1	0,2282	2	3	-1	0,0623	0,0535	0,1056	0,2817	0,2766
2	2	-1	0,2282	2	2	0	0,0623	0,0535	0,1056	0,3338	0,3193
3	-2	1	0,2575	4	-2	1	0,0814	0,0742	0,1005	0,3389	0,3240
3	-2	1	0,2575	3	-1	1	0,0814	0,0742	0,1005	0,3317	0,3175
3	-2	1	0,2575	3	-2	2	0,0814	0,0742	0,1005	0,3580	0,3379
-1	3	1	0,2801	0	3	1	0,0622	0,0506	0,0795	0,3423	0,3334
-1	3	1	0,2801	-1	4	1	0,0622	0,0506	0,0795	0,3307	0,3235
-1	3	1	0,2801	-1	3	2	0,0622	0,0506	0,0795	0,3596	0,3431
5	5	5	0,4605	2	5	5	0,007	0,0046	0,006	0,4584	0,4558
5	5	5	0,4605	5	2	5	0,007	0,0046	0,006	0,4591	0,4582
5	5	5	0,4605	5	5	2	0,007	0,0046	0,006	0,4587	0,4556
2	2	-1	0,2282	3	3	-1	0,0623	0,0535	0,1056	0,3440	0,3217
2	2	-1	0,2282	2	3	0	0,0623	0,0535	0,1056	0,3873	0,3529
2	2	-1	0,2282	3	2	-1	0,0623	0,0535	0,1056	0,3961	0,3583

6.4 CONCLUSÃO

Neste Capítulo foi apresentada a proposta principal da pesquisa de doutorado que se constitui na análise de sensibilidade por redes neurais, contendo o desenvolvimento das equações para aplicação no controle preventivo de sistemas de energia elétrica, e também de outros exemplos conforme mostrados nos capítulos subseqüentes.

CAPÍTULO 7

DEFINIÇÃO DOS PADRÕES DE ENTRADA E DE SAÍDA DA REDE NEURAL

7.1. INTRODUÇÃO

Neste Capítulo serão estabelecidos os critérios para a definição dos padrões de entrada e de saída (pares de treinamento) com vistas à realização do treinamento via retropropagação da rede neural *feedforward* multicamadas. Trata-se de um modelo do sistema referente ao mapeamento entre as variáveis de entrada e de saída. As entradas (estímulos de entrada) são as potências ativa e reativa nodais que são geradas de forma aleatória ou pseudo-aleatória (Silveira [65]), dentro de um espectro de variação preestabelecido em torno do caso base. Nesta pesquisa usa-se uma forma ligeiramente diferente àquela proposta em Silveira [65] em que as cargas reativas são estabelecidas mantendo-se o fator de potência nodal, ou seja, a proporcionalidade entre potência ativa e reativa dos barramentos. Esta alternativa tem proporcionado uma melhor qualidade do treinamento. As saídas (estímulos de saída) correspondem às margens de segurança (critério de análise de estabilidade transitória), as quais são geradas tomando-se como base um método de energia disponível na literatura (Fonseca & Decker [21]). Deste modo, estes estímulos são os elementos necessários à execução da fase de treinamento da rede neural. Deve-se notar que nesta fase a rede neural executará o mapeamento não-linear desconhecido entre entradas e saídas gerando, como consequência, uma saída de interesse referente ao gradiente da função desconhecida (modelo de sensibilidade) que é o principal objetivo desta pesquisa.

7.2. ESTÍMULOS DE ENTRADA

A estrutura neural proposta visa a análise de estabilidade transitória de sistemas de energia elétrica, que corresponde à determinação da margem de segurança, considerando-se defeitos de curto-circuito trifásico com saída de linha de transmissão. Os vetores padrões de entrada da rede neural são definidos como (Silveira [65]):

$$X = [P^T \ Q^T]^T \quad (7.2.1)$$

sendo:

X = vetor padrão de entrada da rede neural;

P = $[P_1 \ P_2 \ \dots \ P_n]^T$;

Q = $[Q_1 \ Q_2 \ \dots \ Q_n]^T$;

P_i = potência ativa da i -ésima barra do sistema;

Q_i = potência reativa da i -ésima barra do sistema;

n = número de barras do sistema.

Para a realização do treinamento – extração do conhecimento baseado em estímulos de entrada / saída – deve-se proceder a apresentação de um conjunto de dados, no caso, $X = [P^T \ Q^T]^T$ (entrada) e Y (saída), constituindo um conjunto de pares de treinamento. Trata-se de geração dos vetores P e Q , para a geração e para a carga do sistema por um procedimento de distribuição aleatória da geração (despacho aleatório para atender a demanda) e, também, de distribuição aleatória da carga (demanda aleatória), como mostrado a seguir (Silveira [65]).

Considere que um sistema com uma determinada topologia contendo NB barras, sendo que são NG barras de geração e as demais são barras de carga ($NL = NB - NG$). Considere, ainda, que se deseja realizar o despacho de geração para atender uma demanda variável tomando-se como referência o caso base: PG^0 , QG^0 , PL^0 e QL^0 ,

sendo:

PG^0 = vetor de potência ativa dos geradores do caso base;

QG^0 = vetor de potência reativa dos geradores do caso base;

PL^0 = vetor de potência ativa das cargas do caso base;

QL^0 = vetor de potência reativa das cargas do caso base.

Para se gerar um grande espectro de variação da demanda, o critério a ser usado refere-se a distribuição aleatória da demanda e, conseqüentemente, da geração para atender a demanda, tomando-se variações percentuais da carga e da geração em torno do caso base (considerado como sendo o perfil de geração / carga de 100%). Por exemplo, arbitrando-se um percentual de 10%, pode-se realizar vários perfis de geração e de carga realizando despachos de geração e definição da carga do sistema distribuindo-se a geração e a carga de forma aleatória nas barras do sistema, respeitando-se o percentual arbitrado.

As potências ativas das barras de geração podem ser definidas por (Silveira [65]):

$$PG_i = PG_i^0 + \Delta PG_i \quad (7.2.2)$$

sendo:

PG_i = potência ativa no i -ésimo gerador fixada aleatoriamente (ou pseudo-aleatoriamente);

$$\Delta PG_i = PG_{\text{total}}^0 \times PER \times AG_i / KG \quad (7.2.3)$$

$$PG_{total}^0 = \sum_{i \in \Omega(G)} PG_i^0 \quad (7.2.4)$$

$\Omega(G)$ = conjunto de barras de geração;

PER = percentual de variação da demanda (valores positivos e negativos: por exemplo, $PER = \pm 10\%$ correspondem a 90 e 110% do caso base, respectivamente);

AG_i = número aleatório de uma sequência de NG números gerados a partir de uma semente dada. Variando-se a semente, ter-se-á uma sequência diferente de valores, cujo espectro de variação está compreendido entre 0 e 1: $AG_i \in [0,1]$;

$$KG = 100 AG_{total} \quad (7.2.5)$$

$$AG_{total} = \sum_{i \in \Omega(G)} AG_i. \quad (7.2.6)$$

As potências reativas das máquinas síncronas são determinadas na rotina referente ao cálculo do fluxo de potência (barras PV).

Com relação às cargas ativas, os perfis de variação (curva variável de demanda) podem ser, então, obtidos por (Silveira [65]):

$$PL_i = PL_i^0 + \Delta PL_i \quad (7.2.7)$$

sendo:

PL_i = potência ativa na i -ésima carga fixada aleatoriamente;

$$\Delta PL_i = PL_{total}^0 \times PER \times AL_i / KL \quad (7.2.8)$$

$$PL_{total}^0 = \sum_{i \in \Omega(L)} PL_i^0 \quad (7.2.9)$$

AL_i = número aleatório de uma sequência de NL números gerados a partir de uma semente dada, $AL_i \in [0,1]$.

$$KL = 100 AL_{total} \quad (7.2.10)$$

$$AL_{total} = \sum_{i \in \Omega(L)} AL_i. \quad (7.2.11)$$

$\Omega(L)$ = conjunto de barras de cargas.

As cargas reativas são fixadas considerando-se uma distribuição que preserva o fator de potência referente ao caso base. Este procedimento tenta estabelecer uma distribuição com um nível de inter-relação entre a potência ativa mais plausível, se comparado ao usado em Silveira [65]. Contudo, pode-se buscar, também, outras formas de distribuição das cargas ativas que, em outras oportunidades, poder-se-ão investigar tal procedimento.

7.3. ESTÍMULOS DE SAÍDA

Os estímulos de saída compreendem, nesta pesquisa, os valores da margem de segurança (M) calculados conforme descrito no Capítulo 3 e Apêndice C, correspondendo ao emprego da metodologia PEBS (Athay *et al.* [3]) e versão PEBS iterativa (Fonseca & Decker [21]). Ou seja, os padrões de treinamento correspondem aos parâmetros:

$$X_j = [P_j^T \ Q_j^T]^T \text{ (entradas)} \quad (7.3.1)$$

$$Y_j = [M_j] \text{ (saídas)} \quad (7.3.2)$$

$$j = 1, 2, np.$$

sendo:

np = número de pares de padrões para a fase de treinamento.

Este modelo de estímulos podem ser melhor visualizados na Figura 12 (Ferreira [17]). São observadas duas fases: (1) Treinamento (linha na cor vermelha) e (2) Análise (ou testes) (linha tracejada).




Figura 12. Esquema de estímulos da Rede neural.

sendo:

$f(.)$ = função não-linear desconhecida que representa o mapeamento entre as entradas (X) e as saídas (Y).

7.4. CONCLUSÃO

Neste Capítulo foi definido o conjunto de padrões de entrada e de saída da rede neural. Trata-se de entradas compostas por potências ativa e reativa nodais fixadas de forma aleatória ou pseudo-aleatória. As saídas associadas correspondem aos resultados da análise de estabilidade transitórias representados pelas margens de segurança.

CAPÍTULO 8

APLICAÇÃO

8.1. INTRODUÇÃO

Apresentam-se, neste Capítulo, alguns exemplos de aplicação da metodologia proposta (controle preventivo dinâmico por redes neurais): (1) sistema Anderson & Fouad [2] composto por 3 máquinas síncronas, 9 linhas de transmissão / transformadores e 9 barras; (2) sistema sul-brasileiro formado por 10 máquinas síncronas, 73 linhas de transmissão e 45 barras, (Minussi [53]). São também apresentados neste capítulo exemplos de aplicação da metodologia proposta para outras funções, que não as do controle preventivo, como forma de validar e, também, mostrar as potencialidades da proposta numa etapa anterior. Estes exemplos incluem uma função seno, e uma outra função não-linear de uma variável conforme descrito no item a seguir.

Para a obtenção dos resultados aqui apresentados foi utilizado um microcomputador Pentium IV (1,7 GHz / 256 MB de memória RAM). O tempo de processamento refere-se somente à execução do algoritmo retropropagação, excluindo-se as operações de leitura / saída de dados, uma vez que o tempo despendido para o cálculo da sensibilidade é desprezível quando comparado com o tempo de treinamento.

8.2. EXEMPLOS ILUSTRATIVOS GENÉRICOS

A análise de sensibilidade (Frank [25]) constitui-se numa ferramenta de grande importância para a resolução de uma série de problemas encontrados em várias áreas do conhecimento humano: engenharia (Parrinello [62]), matemática (May-Duy & Tran-Cong [47]), física, economia (Barucci & Landi [6]), medicina, biologia (Audoly *et al.* [5]), etc., em especial, quando se enfoca a não-linearidade. Neste sentido, pode-se inferir sobre o comportamento do sistema frente à variação paramétrica sem que se necessite resolver um problema que envolve grande complexidade, por exemplo, sistemas de equações diferenciais e algébricas não-lineares. As conclusões comportamentais são extraídas a partir do cálculo da derivada parcial da função sob análise.

A análise de sensibilidade proposta através de redes neurais pode ser aplicada a qualquer situação real em que se deseje obter a sensibilidade do modelo sob estudo, como por exemplo em sistemas biológicos (Audoly *et al.* [5]), sistemas econômicos (Barucci & Landi [6]), entre outros, principalmente aqueles de difícil modelagem (Parrinello [62]).

Para testar a metodologia proposta, análise de sensibilidade por redes neurais, inicialmente aplicou-se para funções conhecidas, como por exemplo a função seno:

$$y = Y_{max} \text{ sen } x \quad (8.2.1)$$

sendo:

Y_{max} = amplitude da função senoidal.

Visando realizar esta função (e respectiva derivada) por redes neurais, deve-se normalizá-la para adequar ao espectro de variação da função sigmóide. Por exemplo, usando um valor de normalização igual a $Y_{normal} = Y_{max} / 0,8$, obtém-se:

$$y = 0,8 \text{ sen } x \quad (8.2.2)$$

sendo:

Y_{normal} = valor de normalização da função senoidal.

O valor real desta função pode ser determinado, posteriormente, multiplicando-se o resultado, obtido da realização pela rede neural, por Y_{normal} .

Nas Figuras 13 e 14 são mostradas as formas de onda da função senoidal (8.2.2) e sua derivada fornecida pela rede neural. Observa-se que a rede neural realizou a derivada desta função corretamente.




Figura 13. Função seno.




Figura 14. Derivada da Função seno.

A figura 15 apresenta este mesmo experimento empregando-se a versão do algoritmo retropropagação com controlador nebuloso. O que se observa é uma melhor aproximação, além de ser mais rápido, se comparado ao algoritmo retropropagação convencional (Werbos [79]).




Figura 15. Derivada da função senóide via retropropagação com controlador *fuzzy* (Arabshahi *et al.* [3], Lopes [39]).

Este exemplo foi realizado considerando-se os seguintes dados referentes à arquitetura e aos parâmetros da rede neural:

	RP Convencional	RP Fuzzy
• Número de vetores padrão	: 73	73
• Número de camadas	: 3	3
• Número neurônios por camada	: (1, 10, 1)	(1, 10, 1)
• Tipo de sigmóide	: $\frac{1 - \exp(-\lambda s_i)}{1 + \exp(-\lambda s_i)}$	$\frac{1 - \exp(-\lambda s_i)}{1 + \exp(-\lambda s_i)}$
• Taxa de treinamento (γ^0)	: 0,25	0,25
• Inclinação da função sigmóide (λ^0)	: 0,5	0,5
• Termo de momento	: 0,5	0,5

• Inclusão do controlador nebuloso	:	Não	Sim
• Decaimento exponencial	:	Não	0,5
• Inclusão do mecanismo para a adaptação de λ e ρ :		Não	Não
• Taxa de treinamento da inclinação da função sigmóide	:	Não	Não
• Taxa de treinamento da translação da função sigmóide	:	Não	Não
• Tempo de treinamento	:	1066 s	335,95 s
• Tempo de execução da análise e geração do modelo de sensibilidade	:	0,0077 s	0,0031 s

Na seqüência busca-se realizar uma função não-linear não trivial de uma única variável:

$$\begin{aligned}
 y = & 0,02 (12 + 3x - 3,5x^2 + 7,2 x^3) (1 + \cos 4\pi x) (2,4 \pi \cos 3\pi x) + \\
 & 0,02 (12 + 3x - 3,5x^2 + 7,2 x^3) (-4\pi \sin 4\pi x) (1 + 0,8 \sin 3\pi x) + \\
 & 0,02 (3 - 7x + 21,6 x^2) (1 + \cos 4\pi x) (1 + 0,8 \sin 3\pi x)
 \end{aligned} \quad (8.2.3)$$

A equação (8.2.3) corresponde a derivada, em relação à variável independente x , da função z (Mai-Duy & Tran-Cong [47]):

$$z = 0,02 (12 + 3 x - 3,5x^2 + 7,2 x^3) (1 + \cos 4\pi x) (1 + 0,8 \sin 3\pi x), 0 \leq x \leq 1 \quad (8.2.4)$$

que é um exemplo usado como *benchmark* na literatura para teste de desempenho. O uso da função derivada (8.2.3) se deve ao fato de torná-la mais complexa e, deste modo, servir como um melhor teste. As formas das funções (8.2.3) e (8.2.4) são mostradas nas Figura 16 e 17, respectivamente.




Figura 16. Função não-linear de acordo com a equação (8.2.3).




Figura 17. Função não-linear de acordo com a equação (8.2.4).

Nota-se, novamente, que a rede neural realizou a operação derivada parcial com uma boa aproximação, conforme pode ser observado na Figura 18.




Figura 18. Derivada da função não-linear da equação (8.2.3).

Este exemplo (equação (8.3.3)) caracteriza-se como uma ilustração importante, pois evidencia a capacidade da rede neural de realizar a derivada de funções complexas, principalmente quando as funções são desconhecidas. Deve-se destacar que a função (8.2.3) é uma forma explícita. Contudo, poderia ser apenas expressa por medidas obtidas de um processo qualquer (sistema a ser identificado). O que se pretende é determinar o modelo de sensibilidade de sistemas com modelos desconhecidos. Este caso corresponde a uma série de problemas encontrados no mundo real (engenharias, biologia, economia, etc.). É para este tipo de problema que esta pesquisa está sendo desenvolvida.

Este exemplo foi realizado considerando-se os seguintes dados referentes à arquitetura e aos parâmetros da rede neural:

RP Convencional	
• Número de vetores padrão	: 99
• Número de camadas	: 3
• Número neurônios por camada	: (1, 12, 1)
• Tipo de sigmóide	: $\frac{1 - \exp(-\lambda s_i)}{1 + \exp(-\lambda s_i)}$

• Taxa de treinamento (γ^0)	:	0,1
• Inclinação da função sigmóide (λ^0)	:	0,06
• Termo de momento	:	0,5
• Inclusão do controlador nebuloso	:	Não
• Decaimento exponencial	:	Não
• Inclusão do mecanismo para a adaptação de λ e ρ	:	Não
• Taxa de treinamento da inclinação da função sigmóide	:	Não
• Taxa de treinamento da translação da função sigmóide	:	Não
• Tempo de treinamento	:	4021,97 s
• Tempo de execução da análise e geração do modelo de sensibilidade	:	1,002 s

8.3. SISTEMA ANDERSON & FOUAD [2]

Apresentam-se, a seguir, os resultados obtidos, via metodologia proposta, considerando-se um sistema composto por 3 máquinas síncronas (Anderson & Fouad [2]) como mostrado na Figura 19, cujos dados encontram-se no Apêndice D.

Trata-se de um sistema de pequeno porte, contudo será usado para demonstrar a validade de metodologia proposta e o encorajamento para aplicações, considerando-se sistemas de energia elétrica reais de grande porte.

Neste estudo consideram-se defeitos de curto-circuito com tempo de eliminação igual a 6 ciclos (0,10s) com saída de linha de transmissão. Os valores em pu referem-se a uma base de 100 MVA.

Doravante, curto-circuito em barramento deve ser entendido como sendo um curto-circuito em linha de transmissão que, para fins de análise, é transferido para a barra mais próxima, como habitualmente é realizado na literatura técnico-científica.




Figura 19. Sistema de energia elétrica composto por 3 máquinas síncronas.

O treinamento da rede neural foi realizado considerando-se um conjunto de 90 perfis de geração e de carga e respectivas margens de segurança, constituindo 41 vetores padrões e respectivos valores de saída. A contingência corresponde a um curto-circuito trifásico na barra 7 com saída da linha de transmissão entre as barras 5 e 7. Esta contingência foi escolhida em consequência de ser a mais crítica entre os possíveis defeitos. As saídas (margens de segurança) foram geradas via método PEBS (Athay *et al.* [4]) versão proposta por Fonseca & Decker [21]. Cada perfil corresponde a um redespacho de geração em relação ao caso base (dados contidos no Apêndice D) realizado de forma pseudo-aleatória para atender a demanda, também, fixada de modo aleatório em cada barra. O universo de variação da carga encontra-se compreendido entre 80 e 120% ($\pm 20\%$) em relação à carga nominal total do sistema.

Na Tabela 2 mostra-se a análise comparativa entre os resultados obtidos, via método PEBS e por redes neurais (procedimento proposto). São considerados 10 perfis de geração e de carga distintos dos perfis utilizados no treinamento, fixados, igualmente, de forma pseudo-aleatória. Pode-se observar que os resultados produzidos pelas duas metodologias são bastante próximos. Este experimento corresponde a uma hipotética curva de geração para atender a uma curva de carga diária. Os valores de potência ativa e reativa (valor entre parênteses) estão relacionados somente nas barras com carga ou geração, ou seja, as barras 1, 2, 3, 5, 6 e 8. Nas demais barras não há carga e nem geração. Não constam

os valores de potência ativa e reativa na barra 1 (referência do sistema) e a potência reativa nas barras 2 e 3 (barras de geração), que são determinados via o cálculo do fluxo de potência.

Tabela 2. Análise comparativa dos resultados.

Perfil	Potência Elétrica Ativa (Reativa) em pu						Margem de Segurança (M)	
	Barramento							
	1	2	3	5	6	8	PEBS	Redes Neurais
1	Referência	1,670 (−)	0,888 (−)	1,264 (0,505)	0,956 (0,320)	1,008 (0,353)	0,055	0,064
2		1,745 (−)	0,968 (−)	1,337 (0,532)	0,965 (0,324)	1,083 (0,380)	−0,121	−0,133
3		1,856 (−)	1,012 (−)	1,410 (0,558)	0,978 (0,329)	1,155 (0,406)	−0,371	−0,379
4		1,787 (−)	1,149 (−)	1,342 (0,533)	1,252 (0,428)	1,012 (0,354)	−0,481	−0,467
5		1,755 (−)	1,228 (−)	1,308 (0,521)	1,225 (0,418)	1,1213 (0,394)	−0,384	−0,389
6		2,062 (−)	0,966 (−)	1,424 (0,563)	0,987 (0,331)	1,289 (0,455)	−0,664	−0,621
7		1,594 (−)	0,807 (−)	1,219 (0,488)	0,873 (0,290)	0,979 (0,342)	0,250	0,264
8		1,529 (−)	0,714 (−)	1,159 (0,467)	0,797 (0,262)	0,957 (0,334)	0,401	0,412
9		1,497 (−)	0,593 (−)	1,076 (0,437)	0,722 (0,235)	0,957 (0,334)	0,507	0,494
10		1,117 (−)	0,812 (−)	1,127 (0,455)	0,700 (0,227)	0,771 (0,266)	0,742	0,746

Ressalta-se que, a rede neural, além de realizar a análise da estabilidade (estimativa da margem de segurança), fornece o modelo da análise de sensibilidade ($\partial M_r / \partial X$) referente a da contingência analisada. Este vetor de sensibilidade $\partial M_r / \partial X$ serve, então, para definir um redespacho necessário para corrigir a margem de segurança para níveis preestabelecidos, ou seja, para níveis considerados seguros, do ponto de vista da

estabilidade transitória.

Na Tabela 3 apresentam-se as estimativas dos vetores de sensibilidade da margem de segurança em relação ao vetor de potência ativa $\partial M_r / \partial \mathbf{P}$ correspondente aos perfis de geração / carga relacionados na Tabela 2. Deste modo, supondo-se que se deseja corrigir a margem de segurança associada ao perfil mais crítico (sexto perfil da Tabela 2 que está destacado no estilo negrito) com margem de segurança $M^0_6 = -0,621$ (estimada pela rede neural) para uma margem de segurança $M_6 \triangleq (M^0_6 + \Delta M_6) \geq Mmin$. Adotando-se $Mmin = 0,3$ (Minussi & Freitas [50]), conclui-se que o redespacho de geração deverá proporcionar um deslocamento da margem de segurança $\Delta M_6 \geq 0,921$.

Tabela 3. Modelo de sensibilidade gerado pela rede neural.

Referente a Potência	Modelo de Sensibilidade $\partial M / \partial X$					
	Barramento					
	1	2	3	5	6	8
Ativa	1,422	-1,115	-0,324	-0,645	-0,466	0,166

Na Figura 20 estão registradas as curvas de oscilação das máquinas síncronas 2 e 3, tomando-se como referência a máquina síncrona 1. Adota-se o passo de integração (h) igual a 0,001s. A contingência correspondente a um curto-circuito trifásico na barra 7 com saída da linha de transmissão entre as barras 5 e 7 e sexto perfil de potência da Tabela 2. Na Figura 21 encontram-se registradas as curvas das energias cinética ($Ec(\omega)$), potencial ($Ep(\theta)$) e total ($E(\theta, \omega)$) definidas pelas equações (3.4.3), (3.4.4) e (3.4.2), respectivamente. A energia total é crescente até o tempo de eliminação de defeito, passando, a partir deste instante, a comportar-se com um valor constante. Nota-se que as máquinas síncronas apresentam um comportamento instável. A simulação foi interrompida após 0,5 s, tendo em vista que as curvas de oscilação das máquinas síncronas atingiram valores expressivos, que indicam claramente a instabilidade. Deve-se observar que a não-uniformidade de valores de $Ep(\theta)$ (e como consequência de $E(\theta, \omega)$) correspondentes aos valores do tempo próximos de zero, decorre do fato de que esta variável é obtida por meio de integração numérica (a energia potencial é representada por uma integral dependente do caminho de integração

(equação (3.4.4))) que, *a priori*, não se conhece o seu valor inicial. Nestas simulações, o valor de $(Ep(\theta))$ foi adotado, inicialmente, como sendo igual a zero.




Figura 20. Curvas de oscilação das máquinas síncronas (máquina síncrona 1 é adotada como referência) para a contingência correspondente a um curto-circuito trifásico na barra 7 com saída da linha de transmissão entre as barras 5 e 7 e sexto perfil de potência (sem redespacho de geração e sem corte de carga). Caso instável.

Este objetivo, corrigir a margem de segurança por análise de sensibilidade, pode ser conseguido, por exemplo, por meio de uma redução na potência gerada da máquina 2 e um aumento da potência da máquina síncrona 1 (referência). Tomando-se os coeficientes de sensibilidade correspondentes (Tabela 6): $\partial M_6 / \partial P_{m1} = 1,422$ e $\partial M_6 / \partial P_{m2} = -1,115$, assim, o valor a ser redespachado deverá ser igual a 0,363 pu.

Efetuando-se esta alteração, com relação ao sexto vetor de potência que está relacionado na Tabela 2, produzirá uma margem de segurança M_6 no valor de 0,28, conforme mostrado na Tabela 4, que é uma boa aproximação do objetivo a ser alcançado ($M \geq M_{min}$).




Figura 21. Curvas das energias cinética, potencial e total do sistema para a contingência correspondente a um curto-circuito trifásico na barra 7 com saída da linha de transmissão entre as barras 5 e 7 e sexto perfil de potência (sem redespacho de geração e sem corte de carga). Caso instável.

Tabela 4. Análise comparativa dos resultados.

Potência Elétrica Ativa em pu						Margem de Segurança	
Barramento							
1	2	3	5	6	8	PEBS	Redes Neurais
–	1,6998	0,966	1,424	0,987	1,289	0,280	0,305

Na Figura 22 estão registradas as curvas de oscilação das máquinas 2 e 3 tomando-se como referência à máquina síncrona 1, após ter sido realizado o redespacho de geração. Não foi realizado o corte de carga. Nota-se, neste caso, que as máquinas síncronas apresentam um comportamento estável. Por conseguinte, esta estratégia estabilizou o sistema. Na Figura 23 constam as curvas das energias cinética, potencial e total.




Figura 22. Curvas de oscilação das máquinas síncronas (máquina síncrona 1 adotada como referência) para a contingência correspondente a um curto-circuito trifásico na barra 7 com saída da linha de transmissão entre as barras 5 e 7 e sexto perfil de potência (com redespacho de geração e sem corte de carga). Caso estável.




Figura 23. Curvas das energias cinética, potencial e total do sistema para a contingência correspondente a um curto-circuito trifásico na barra 7 com saída da linha de transmissão entre as barras 5 e 7 e sexto perfil de potência (com redespacho de geração e sem corte de carga). Caso estável.

Este exemplo foi realizado considerando-se os seguintes dados referentes à arquitetura e aos parâmetros da rede neural:

	RP Convencional
• Número de vetores padrão	: 41
• Número de camadas	: 3
• Número neurônios por camada	: (18, 35, 1)
• Tipo de sigmóide	: $\frac{1 - \exp(-\lambda s_i)}{1 + \exp(-\lambda s_i)}$
• Taxa de treinamento (γ^0)	: 0,1
• Inclinação da função sigmóide (λ^0)	: 0,65
• Termo de momento	: 0,9
• Inclusão do controlador nebuloso	: Não
• Decaimento exponencial	: Não
• Inclusão do mecanismo para a adaptação de λ e ρ	: Não
• Taxa de treinamento da inclinação da função sigmóide	: Não
• Taxa de treinamento da translação da função sigmóide	: Não
• Tempo de treinamento	: 3,36 s
• Tempo de execução da análise e geração do modelo de sensibilidade	: 0,004 s

Esta aplicação, considerando-se um sistema pequeno (sistema acadêmico), foi proposta com vistas proporcionar uma melhor compreensão sobre a metodologia aqui desenvolvida. No próximo exemplo (sistema de maior porte: sistema de 10 máquinas síncronas, 73 linha de transmissão e 45 barras), pretende-se melhor explorar o modelo de sensibilidade.

8.4. SISTEMA SUL-BRASILEIRO (REDE NEURAL COM CONTROLADOR NEBULOSO)

Um segundo exemplo foi efetuado, considerando-se um sistema composto de 10 máquinas síncronas, 73 linhas de transmissão e 45 barras, baseado na configuração do Sistema Sul Brasileiro, (Minussi [53]), cujo diagrama unifilar está mostrado na Figura 24, e os demais dados encontram-se no Apêndice D.

São considerados defeitos tipo curto-circuito trifásico (com saída de operação de linha de transmissão) com tempo de eliminação do defeito igual a 0,15s (9 ciclos considerando uma operação a 60 Hz), seguida de uma saída de linha de transmissão.

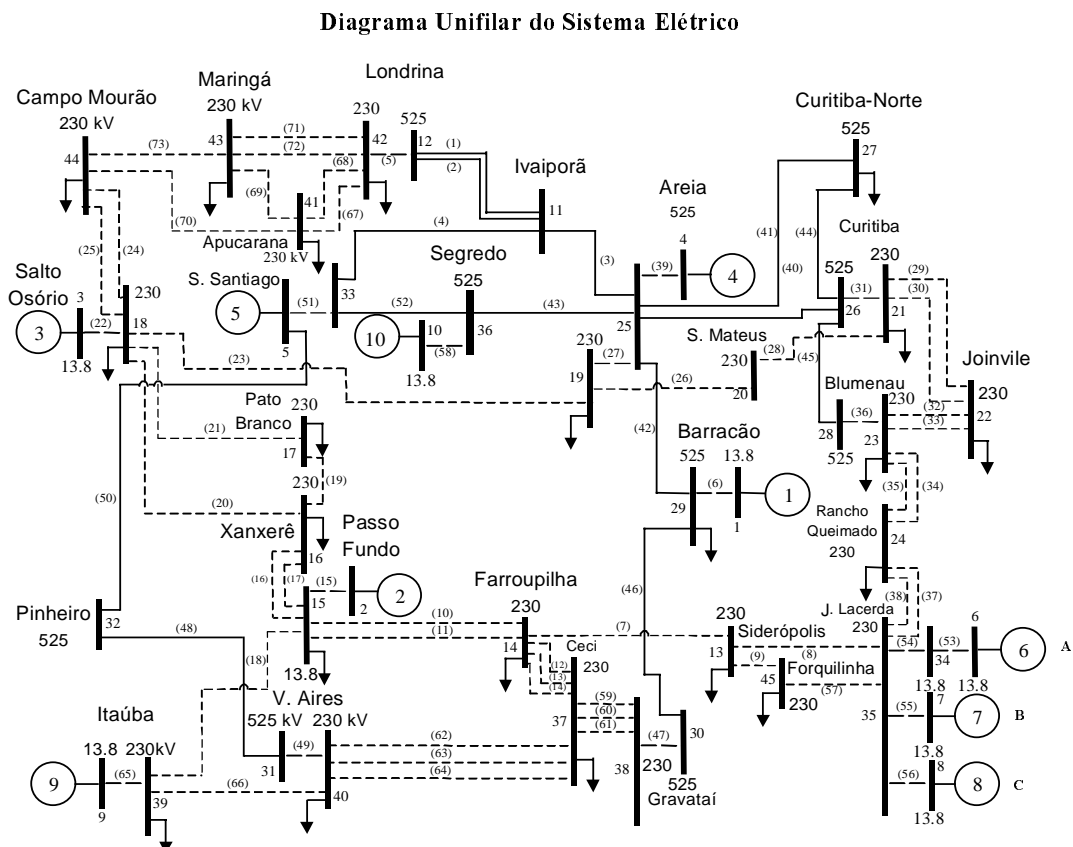


Figura 24. Diagrama unifilar do sistema sul-brasileiro.

A Tabela 5 mostra, como forma de ilustração, um perfil de geração do caso base, ou seja, para 100% da geração para um conjunto de contingências escolhidas também aleatoriamente. São mostradas a margem de segurança e a contingência com a respectiva linha retirada. Estes dados foram gerados utilizando um passo de integração de 0,001s.

Tabela 5. Margem de Segurança calculada para o caso base.

Número da Contingência	Dados do Defeito		Margem de Segurança (M)
	Barra sob Curto-circuito	Linha de Transmissão Removida	
1	17	16 – 17	0,8470
2	15	15 – 16	0,8250
3	36	25 – 36	0,9161
4	29	25 – 29	0,8056
5	15	14 – 15	0,8416
6	33	11 – 33	0,8630
7	29	29 – 30	0,8481
8	16	16 – 17	0,8447
9	16	16 – 18	0,8300
10	25	25 – 27	0,9440
11	30	29 – 30	0,9800
12	39	39 – 40	0,2089
13	13	13– 45	0,9320
14	25	25 - 29	0,9503
15	25	25 – 26	0,9444

Caracteriza-se como um perfil de geração típico e sua correspondente condição de segurança (representada pela margem de segurança). É identificada apenas uma contingência crítica (contingência 12, se considerarmos $M < M_{min}$, para $M_{min} = 0,3$) e para as demais contingências, o sistema é considerado estável. A margem de segurança mínima (M_{min}) é usada como limite inferior visando garantir uma certa margem de segurança aceitável ao sistema de energia elétrica (Minussi & Freitas [50]). Assim sendo, tomando-se o caso base como referência, o conjunto de dados de entrada (potências ativa e reativa nodais) e de saída (margens de segurança) para a fase de treinamento será determinado, considerando-se a variação da carga (supostamente representando a curva diária) e respectivo atendimento por parte da geração. Esta rotina, novamente, será realizada fazendo-se distribuições (de geração e de carga) de forma pseudo-aleatória (ou seja, a partir de sementes preestabelecidas), como proposta no Capítulo 7.

Visando, portanto, realizar a análise da estabilidade transitória e, se necessário, realizar, também, o controle preventivo por redes neurais para “qualquer” perfil de geração e de carga, proceder-se-á, a seguir, o treinamento da rede neural através do algoritmo retropropagação.

Assim, o treinamento da rede neural foi efetuado considerando um conjunto de 50 perfis de geração e carga e respectiva margem de segurança. Cada perfil corresponde a um redespacho de geração em relação ao caso base de uma maneira pseudo-aleatória, para atender a demanda, também fixada de maneira aleatória em cada barra. O universo de variação da carga está entre 95 e 112,5 %, em relação à carga nominal do sistema. Portanto, cada perfil é gerado considerando-se uma variação percentual em torno do estado nominal (caso base) e uma respectiva semente do processo de geração de sequência pseudo-aleatória. Assim, para um mesmo percentual, diferentes sementes geram diferentes despachos de geração de diferentes perfis de carga. Este procedimento gera um conjunto adequado de padrões para a fase de treinamento.

Este exemplo foi realizado considerando-se os seguintes dados referentes à arquitetura e aos parâmetros da rede neural:

	RP Convencional	RP Fuzzy
• Número de vetores padrão	: 50	50
• Número de camadas	: 3	3
• Número neurônios por camada	: (43,55,1)	(43,55,1)
• Tipo de sigmóide	: $\frac{1 - \exp(-\lambda s_i)}{1 + \exp(-\lambda s_i)}$	$\frac{1 - \exp(-\lambda s_i)}{1 + \exp(-\lambda s_i)}$
• Taxa de treinamento (γ^0)	: 0,07	0,07
• Inclinação da função sigmóide (λ^0)	: 0,3	0,3
• Termo de momento	: Não	Não
• Inclusão do controlador nebuloso	: Não	Sim
• Decaimento exponencial	: Não	0,75
• Inclusão do mecanismo para a adaptação de λ e ρ	: Não	Não
• Taxa de treinamento da inclinação da função sigmóide	: Não	Não
• Taxa de treinamento da translação da função sigmóide	: Não	Não
• Tempo de treinamento	: 7379,70 s	6898,63 s
• Tempo de execução da análise e geração do modelo de sensibilidade	: 0,015 s	0,015 s

Tomando-se, agora, um perfil de geração e de carga qualquer. Este perfil é gerado pseudo-aleatoriamente, considerando-se um acréscimo de 12,5% da geração e da carga total nominal e fixada uma semente igual a 2520, obtém-se os resultados relacionados na Tabela 6. Ressalta-se que o perfil de geração de carga escolhido poderia ter sido o caso base, cujos resultados foram mostrados na Tabela 5. Porém, o perfil escolhido neste exemplo corresponde a um possível estado operativo do sistema em um determinado instante diário que representa, salvo melhor julgamento, um caso mais interessante do ponto de vista ilustrativo.

Observa-se na Tabela 6 que há uma contingência instável ($M < 0$). Supondo-se que se deseja realizar a estabilização do sistema para a contingência número 12 que é a mais crítica, cujo comportamento angular das máquinas síncronas é mostrado na Figura 25. Observa-se que a máquina síncrona 9 é instável e demais máquinas são estáveis. Mostra-

se, na Figura 26, o comportamento das energias cinética, potencial e total associadas.

Tabela 6. Estudo de estabilidade transitória considerando-se um perfil de geração e de carga correspondente a uma distribuição pseudo-aleatória de 12,5% em relação ao caso base e semente igual a 2520.

Número da Contingência	Dados do Defeito		Margem de Segurança (M)
	Barra sob Curto-circuito	Linha de Transmissão Removida	
1	17	16 – 17	0,8222
2	15	15 – 16	0,7262
3	36	25 – 36	0,9016
4	29	25 – 29	0,7824
5	15	14 – 15	0,7494
6	33	11 – 33	0,8829
7	29	29 – 30	0,8704
8	16	16 – 17	0,8311
9	16	16 – 18	0,8123
10	25	25 – 27	0,9449
11	30	29 – 30	0,9750
12	39	39 – 40	-0,8188
13	13	13– 45	0,4829
14	25	25 - 29	0,9421
15	25	25 – 26	0,9486




Figura 25. Curvas de oscilação das máquinas síncronas (máquina síncrona 10 é adotada como referência) correspondente à contingência número 12 (sem redespacho de geração e sem corte de carga). Caso instável.




Figura 26. Curvas das energias cinética, potencial e total do sistema correspondente à contingência número 12 (sem redespacho de geração e sem corte de carga). Caso instável.

Na Tabela 7 encontram-se relacionadas os dados necessários para a realização da correção de segurança do sistema em consequência da contingência número 12. Neste exemplo, serão empregados a realocação de geração e corte de carga. Estão destacados os coeficientes (gerados pela rede neural) correspondentes as maiores sensibilidades referentes à geração e à carga, respectivamente. Neste caso, para a estabilização do sistema será necessário um corte de carga na barra 40 e uma redução da geração na barra 9.

Tabela 7. Resultados analisados antes e depois da ação de controle (realocação de geração/ corte de carga).

Estado	Item	Valor
Inicial	Margem de segurança Inicial (M^0)	-0,8188
Alvo	Margem de segurança alvo ($Mmin$)	0,3
Deslocamento da Margem de Segurança	Variação da margem de segurança necessária ($M^0 - Mmin$)	1,1188
Identificação das Barras mais Sensíveis	Barra de geração mais sensível	9
	Barra de carga mais sensível	40
Análise de Sensibilidade	Coeficiente de Sensibilidade da barra 9 ($\partial M_r / \partial P_9$)	-1,1435
	Coeficiente de Sensibilidade da barra 40 ($\partial M_r / \partial P_{40}$)	0,255
Ação de Controle	Realocação de Geração na barra 9	-0,8
	Corte de carga na barra 40	0,8
Final	Margem de segurança final (M^f)	0,330

Suponha que se deseje corrigir a margem de segurança de $M^0 = -0,8188$ para $M \geq Mmin = 0,3$. Então a ação de controle (redespacho de geração / corte de carga) fornece um deslocamento da margem de segurança de $\Delta M \geq 1,1435$. Este objetivo, por análise de sensibilidade, é obtido, por exemplo, por uma redução da geração na máquina número 9, e uma redução de carga associada a barra 40. Esta redução correspondente a 0,8 pu, produz uma margem de segurança final de 0,330, que é uma boa aproximação do objetivo a ser atingido ($M \geq Mmin$). Na Tabela 8 são mostrados os resultados da análise de estabilidade transitória, após realizados o redespacho de geração e o corte de carga.

Tabela 8. Estudo de estabilidade transitória considerando-se um perfil de geração e de carga correspondente a uma distribuição pseudo-aleatória de 12,5% em relação ao caso base, semente igual a 2520, redução da geração ativa na barra 9 e corte de carga ativa na barra 40 no valor de 0,8 pu.

Número da Contingência	Dados do Defeito		Margem de Segurança (M)
	Barra sob Curto-circuito	Linha de Transmissão Removida	
1	17	16 – 17	0,8063
2	15	15 – 16	0,7169
3	36	25 – 36	0,8895
4	29	25 – 29	0,7679
5	15	14 – 15	0,7406
6	33	11 – 33	0,8304
7	29	29 – 30	0,8718
8	16	16 – 17	0,8148
9	16	16 – 18	0,7934
10	25	25 – 27	0,9413
11	30	29 – 30	0,9800
12	39	39 – 40	0,3301
13	13	13– 45	0,4719
14	25	25 - 29	0,9342
15	25	25 – 26	0,9470

Na Figura 27 são mostradas as evoluções das máquinas síncronas, após a realização do redespacho de geração e do corte de carga. Neste caso, pode-se observar que todas as máquinas síncronas encontram-se estabilizadas. Na Figura 28 são mostradas as curvas das energias cinética, potencial e total associadas.




Figura 27. Curvas de oscilação das máquinas síncronas (máquina síncrona 10 é adotada como referência) correspondente à contingência número 12 (com redespacho de geração e com corte de carga). Caso estável.




Figura 28. Curvas das energias cinética, potencial e total do sistema correspondente à contingência número 12 (com redespacho de geração e com corte de carga). Caso estável.

Deve-se ressaltar que a margem de segurança mínima (M_{min}) igual a 0,3 foi adotada, nesta pesquisa, com o propósito de não exigir em demasia a mudança do estado do sistema, que é determinado, em geral, por despacho econômico, devendo, portanto, ser preservado sempre que possível (Minussi & Freitas [50]). Contudo, do ponto de vista de segurança, corresponde a um perfil ligeiramente estável ou marginalmente estável, conforme pode-se observar no comportamento das curvas de oscilação (Figura 27). O mesmo se observa com relação ao sistema Anderson & Fouad (Figura 22). Deve-se ressaltar, ainda, que este valor foi adotado apenas como um exemplo. Um outro valor mais rigoroso pode ser perfeitamente usado, a critério dos usuários.

8.5. SISTEMA SUL-BRASILEIRO (REDE NEURAL COM PROCESSO ADAPTATIVO DA INCLINAÇÃO E TRANSLAÇÃO DA FUNÇÃO SIGMÓIDE)

Um terceiro exemplo de controle preventivo foi realizado também para o sistema sul brasileiro de 45 barras, conforme descrito anteriormente, mas agora utilizando a rede neural com processo adaptativo para o ajuste da inclinação e translação da função sigmóide, seguindo as referências Stamatis *et al.* [69], Lopes [40], conforme descrito no Capítulo 5 (Seção 5.4).

São consideradas as mesmas condições do exemplo mostrado na Seção 8.4, ou seja, o mesmo conjunto de treinamento. A solução obtida, salvos pequenos erros, é a mesma do caso anterior. Contudo, a adaptação da inclinação e da translação sigmoidal, como mencionado anteriormente, é empregada como forma de “garantir” a obtenção de uma solução. Este efeito se explica, tendo em vista que, ao se variar a inclinação, está-se modificando o formato da derivada da função sigmóide (σ), em relação à atividade s (saída intermediária), *i.e.*, aumentado-se a base desta função, por consequência, disponibiliza-se um maior espaço de busca das soluções, e, ao se deslocar o centro (movimento de translação) da sigmóide, busca-se uma posição “ótima” desta função para melhor representar a saída. A função σ é uma grandeza positiva que contém 2 valores nulos (vide

Figura 29): (1) quando a saída intermediária (s) da função sigmóide tende para $-\infty$ e (2) quando s tende para $+\infty$, ou seja, para s muito negativa, ou muito positiva, respectivamente. Deve-se observar que σ representa uma parcela que compõe a variação (Equação (5.3.6)) dos pesos da rede neural. A distância (base de σ) entre estes 2 pontos nulos de σ , representa o espaço de busca das soluções. Os pesos somente serão atualizados se s estiver contido entre os pontos (a) e (b) (correspondente a $\beta > 0$). Fora deste intervalo (correspondente a $\beta = 0$), ocorre a chamada paralisia do processo adaptativo. Assim, havendo um maior espaço de busca, maiores são as chances de haver solução para o treinamento, como consequência, busca-se reduzir a possibilidade de ocorrência de paralisia que, com certeza, é a maior responsável pelo insucesso do treinamento do algoritmo retropropagação.

Concluindo, a adaptação da inclinação e da translação sigmoidal visa, primordialmente, oferecer maior possibilidade de obtenção das soluções (conjunto de pesos ajustados). Via de regra, o número de iterações do algoritmo RP, com a inclusão deste mecanismo de adaptação, é menor se comparado ao número de iterações executadas pelo RP convencional. Como consequência, este mecanismo de adaptação reduz, também, o tempo de treinamento, conforme foi observado nas várias simulações realizadas.

Este exemplo foi realizado considerando-se os seguintes dados referentes à arquitetura e aos parâmetros da rede neural:

	RP convencional com adaptação da inclinação e translação sigmoidal	RP fuzzy com adaptação da inclinação e translação sigmoidal
	$\underbrace{\hspace{10em}}$	$\underbrace{\hspace{10em}}$
• Número de vetores padrão	: 50	50
• Número de camadas	: 3	3
• Número neurônios por camada	: (43,55,1)	(43,55,1)
• Tipo de sigmóide	: $\frac{1 - \exp(-\lambda s_i)}{1 + \exp(-\lambda s_i)}$	$\frac{1 - \exp(-\lambda s_i)}{1 + \exp(-\lambda s_i)}$

• Taxa de treinamento (γ^0)	: 0,07	0,07
• Inclinação da função sigmóide (λ^0)	: 0,3	0,3
• Termo de momento	: Não	Não
• Inclusão do controlador nebuloso	: Não	Sim
• Decaimento exponencial	: Não	0,65
• Inclusão do mecanismo para a adaptação de λ e ρ :	Sim	Sim
• Taxa de treinamento da inclinação da função sigmóide	: 0,007	0,007
• Taxa de treinamento da translação da função sigmóide	: 0,1	0,1
• Tempo de treinamento	: 635,80 s	616,52 s
• Tempo de execução da análise e geração do modelo de sensibilidade	: 0,015 s	0,015 s




Figura 29. Mecanismo de adaptação de pesos, via algoritmo retropropagação.

Estes exemplos (sistema sul-brasileiro) foram processados com uma rede neural considerando-se um erro admissível (tolerância) correspondente a 10^{-2} . Contudo, se considerarmos uma tolerância menor, o tempo de treinamento crescerá bastante. Por

exemplo, com uma tolerância de 10^{-3} , o tempo de treinamento passará de 10 horas, e dependendo dos parâmetros escolhidos pode não convergir, principalmente para o treinamento utilizando o algoritmo retropropagação convencional, conforme observado nas simulações realizadas. Deve-se, porém, entender que a tolerância de 10^{-2} , para o caso em que a saída é a margem de segurança, os resultados são adequadamente precisos, para fins de análise e correção de segurança (erro inferior a 10%).

8.6. CONCLUSÃO

Neste capítulo foram apresentados os diversos exemplos aplicados para mostrar a potencialidade da proposta apresentada neste trabalho, primeiramente para funções não-lineares conhecidas, como uma função seno, e outra baseada na referência Mai-Duy & Tran-Cong [47], assim como para dois sistemas elétricos, um sistema exemplo baseado em Anderson & Fouad [2], e outro sistema elétrico real (sistema sul-brasileiro).

Ressalta-se, porém, que podem ser geradas, pela rede neural, restrições de estabilidade transitória (Equação (4.3.2)) para um conjunto de interesse de contingências, *e.g.*, para todas as contingências que apresentem margem de segurança inferior a um dado limiar predefinido. Estas restrições podem ser agregadas a outras restrições do sistema (balanço de potência, limite físicos dos equipamentos elétricos, etc.) e resolvido o problema do controle preventivo através, por exemplo, do uso de algum método de otimização. Este assunto é um dos itens sugeridos, no Capítulo 9, para trabalhos futuros.

CAPÍTULO 9

CONCLUSÕES E SUGESTÕES PARA TRABALHOS FUTUROS

9.1. CONCLUSÃO

Foi proposto nesta pesquisa um procedimento para a realização do controle preventivo dinâmico (considerando a estabilidade transitória) de sistemas elétricos de potência, baseado na análise de sensibilidade, cujo modelo foi gerado por uma rede neural multicamadas não-recorrente. A análise de estabilidade transitória é um dos principais estudos realizados em Sistemas de Energia Elétrica. Trata-se de um procedimento que visa avaliar os efeitos provocados por perturbações que causam grandes excursões nos ângulos das máquinas síncronas, *e.g.*, curto-circuito, saída e entrada de operação de equipamentos elétricos. Neste caso, o modelo do sistema é descrito por um conjunto de equações algébricas e diferenciais não-lineares. Nos casos instáveis e / ou havendo violação do limite de capacidade dos equipamentos, faz-se necessária a adoção de medidas que possibilitem conduzir o sistema ao estado seguro, sendo esta atividade definida como controle de segurança ou controle preventivo. Deste modo, esta pesquisa visou o desenvolvimento de uma metodologia baseada nas redes neurais (Fine [18], Kartalopoulos [31], Wasserman [77]) para a análise de estabilidade transitória – considerando-se defeitos de curto-circuito com saída de linha de transmissão – e, principalmente, para a análise de sensibilidade (Frank [25]) de sistemas elétricos de potência, as quais representam os instrumentos necessários para realizar o controle preventivo. As redes neurais são recursos importantes para a abordagem do problema do controle preventivo, tendo em vista que, uma vez realizado o treinamento (atividade realizada *off-line*), a análise pode ser concluída praticamente sem esforço computacional (compreendendo, basicamente, ao cálculo da

informação entre a entrada e saída da rede neural), podendo ser empregada para aplicações em tempo real. É importante destacar que o cálculo da sensibilidade é efetuado sem acréscimo do esforço computacional. Devendo-se destacar, ainda, que a obtenção do modelo de sensibilidade, por procedimentos convencionais, envolve um grande número de cálculos matriciais complexos que, geralmente, consomem grande quantidade de tempo de cálculo, principalmente, para aplicações em sistemas de grande porte.

O treinamento da rede neural foi efetuado usando o algoritmo retropropagação (Werbos [79]) com controlador nebuloso (Arabshahi *et al.* [3], Lopes [39]) e também com o ajuste da inclinação e translação da função sigmóide (Stamatis *et al.* [69], Lopes [40], Lopes *et al.* [42]). O controlador nebuloso, e o ajuste dos parâmetros fornecem uma convergência mais rápida e resultados mais precisos (Lopes [40], Lopes *et al.* [42]) quando comparados com o algoritmo retropropagação tradicional (Werbos [79], Widrow & Lehr [80]), ajustando a taxa de treinamento, usando a informação do erro global e variação do erro global. Uma vez finalizado o treinamento, a rede está apta a estimar a margem de segurança e a análise de sensibilidade. Com estas informações é possível desenvolver um procedimento para efetuar a correção de segurança (controle preventivo) para níveis considerados adequados para o sistema. O procedimento proposto é um resultado preliminar, o qual é um ponto de partida para procedimentos mais elaborados de controle preventivo (análise de estabilidade considerando um conjunto de contingências, geração ótima, pré-despacho, etc.).

Inicialmente, foram realizadas duas aplicações, que correspondem ao cálculo da sensibilidade de funções de uma única variável, como forma de testar e ilustrar a metodologia proposta. Posteriormente, foram realizadas duas outras aplicações: (1) Sistema Anderson & Fouad [2]; (2) Sistema Sul-brasileiro (Minussi [53]), uma somente com o controlador nebuloso e outra contendo o ajuste dos parâmetros inclinação e translação da função sigmóide. Destas aplicações, pode-se concluir que a metodologia proposta é promissora para os exemplos simulados, destacando-se o tempo de simulação praticamente *on-line* para utilização em centros de controle de operação de sistemas elétricos. A metodologia proposta, portanto, apresentou um desempenho que pode ser considerado satisfatório. Porém, foram observados alguns problemas nas aplicações, assim destacados: (1) treinamento é demorado, principalmente quando se emprega sistemas de grande porte e

grandes conjuntos de padrões de treinamento; (2) há necessidade de uso de um conjunto de dados volumoso, para a fase de treinamento, para se obter os resultados desejados; (3) dificuldade de inclusão de novos padrões (realização do treinamento continuado).

Assim sendo, deve-se ressaltar que esta rede neural pode ser aplicada para a resolução do modelo de sensibilidade em tempo real. Contudo, o treinamento é realizado de modo *off-line*. Ainda que foram implementadas melhorias (inclusão do controlador nebuloso e a adaptação da inclinação e deslocamento da função pós-sináptica) no algoritmo retropropagação tradicional (Werbos [79]), o treinamento é bastante longo, especialmente quando se trabalha com sistemas de grande porte. Deve-se destacar, também, que o principal resultado destas melhorias refere-se à adaptação da função pós-sináptica, isto porque é um recurso que visa, principalmente, “garantir” a obtenção de uma solução ou, pelo menos, que haja uma maior liberdade de ação para o mecanismo de adaptação de pesos (impedindo a ocorrência de paralisia (Wasserman [77])), através do alargamento do espaço de busca.

Em vista disto, as sugestões que serão apresentadas na subseção subsequente visam tornar esta técnica mais competitiva.

9.2. SUGESTÕES PARA TRABALHOS FUTUROS

Os resultados desta pesquisa podem ser considerados satisfatórios (do ponto de vista da precisão e rapidez na obtenção das soluções), conforme argumentado anteriormente. Porém, sugerem-se algumas melhorias e procedimentos que podem ser implementados com o propósito de tornar esta metodologia mais eficiente:

- 1) desenvolvimento de novas ou testes de outras redes neurais que apresentem melhor eficiência, principalmente com relação ao tempo de execução do treinamento, tornando o sistema neural mais rápido. Neste contexto, por exemplo, sugere-se a abordagem com

a rede neural de base radial (Haykin [28], Kung [36], Wasserman [77]), à qual pode-se perfeitamente implementar, com os devidos cuidados, os resultados desenvolvidos nesta pesquisa;

- 2) desenvolver estratégias de implementação do treinamento continuado. Este é um assunto que vem sendo, cada vez mais, objeto de investigação, visto que a maioria das redes neurais tem apresentado dificuldades no tratamento desta questão. A solução mais elementar é retreinar a rede neural quando devem ser considerados novos padrões, ou seja, inicia-se novamente o processo de treinamento. Esta abordagem torna-se pouco eficiente para aplicações práticas. Novas propostas baseadas, por exemplo, a teoria da ressonância adaptativa (ART) (Carpenter & Grossberg, S. [9], Carpenter *et al.* [10]) em que o treinamento continuado pode ser perfeitamente realizado. Contudo, há uma certa dificuldade de calcular a sensibilidade (que é um modelo contínuo), em consequência das redes neurais ART trabalharem com informações na forma discreta e não na forma contínua. Assim, o desafio está lançado.
- 3) nesta pesquisa foram usados os dados gerados por simulação (potências nodais e margens de segurança associadas). Porém, seria bastante importante considerar, também, os dados disponíveis nos centros de controle, ou seja, juntar todas estas informações com vistas a tornar o sistema mais eficiente, inclusive, possivelmente, contemplar modelos mais elaborados, *e.g.*, o modelo completo de Park (Stott [70]).
- 4) Aplicar a metodologia proposta em problema relacionado à previsão de carga por redes neurais (Lopes *et al.* [41]). Neste caso, é realizar a análise de sensibilidade como forma de estabelecer as correlações entre causa e efeito na previsão, ou seja, estabelecer quais são as variáveis mais importantes, assim como aquelas que podem ser desconsideradas com vistas a reduzir o volume de informação a ser manipulado pela rede neural na fase de treinamento. Como consequência direta ter-se-á uma redução do tempo de treinamento e, principalmente, melhorar a qualidade das soluções, pois usam-se somente as variáveis mais importantes e evitando-se os possíveis ruídos produzidos por variáveis irrelevantes.
- 5) desenvolver metodologias híbridas envolvendo, por exemplo, a geração do modelo de sensibilidade por redes neurais (como realizado nesta pesquisa) e novas técnicas de

otimização (redes neurais (Cichocki & Unbehauen [12]), inteligência coletiva (Kennedy, & Eberhart [32]), otimização evolutiva (Song & Irving [68]), etc.), visando obter soluções ótimas (ou subótimas) para o redespacho de geração e para o corte de carga;

- 6) aplicação da metodologia aqui proposta para resoluções de outros problemas importantes no ambiente de sistemas elétricos de potência, por exemplo, a determinação de estratégias de intercâmbio de energia (Lotufo [46]) que vêm ganhando maior importância na atualidade, tendo em vista a prática de política de desregulamentação do setor elétrico;
- 7) aplicação deste sistema neural para a resolução de outros problemas que são evidenciados em outras áreas do conhecimento humano (medicina, agricultura, biologia, etc.), em especial, nos casos onde não estão disponibilizados ou são desconhecidos os modelos pertinentes.

CAPÍTULO 10

REFERÊNCIAS BIBLIOGRÁFICAS

- [1] Amin, M. “Toward Self-Healing Energy Infrastructure Systems”, *IEEE Computer Applications in Power*, pp.20-28, Vol. 14, N.1, January 2001.
- [2] Anderson, P.M. and Fouad, A.A. “Power System Control and Stability”, *IEEE Series on Power Engineering*, U.S.A., Second Edition, 2003.
- [3] Arabshahi, P.; Choi, J. J.; Marks II, R. J. and Caudell, T.P. “Fuzzy Parameter Adaptation in Optimization”, *IEEE Computational Science & Engineering*, pp. 57-65, Spring 1996.
- [4] Athay, T.; Sherkat, V. R.; Podmore, R.; Virmani, S. and Pench, C. “Transient Energy Stability Analysis”, *System Engineering for Power: Emergency Operating State Control – Section IV*, U.S. Department of Energy Publication, N. CONF-790904-P1, 1979.
- [5] Audoly, S. A.; Bellu, G.; D’Agìò, L.; Saccomani, M. P. and Cobelli, C. “Global Identifiability of Nonlinear Models of Biological Systems”, *IEEE Transactions on Biomedical Engineering*, Vol. 48, N. 1, pp. 55 – 65, January 2001.
- [6] Barucci, E. and Landi, L. “Computational Methods in Finance: Option Pricing”, *IEEE Computation Science & Engineering*, pp. 66- 80, Spring 1996.
- [7] Bender, E. A. “Mathematical Methods in Artificial Intelligency”, Los Alamitos, CA, U.S.A., *IEEE Computer Society Press*, 1996.

- [8] Bettiol, A. L. “Maximum Power Transfer in Transient Stability Constrained Power Systems”, *PhD Thesis*, University of Liège, Liège, Belgium, 1999.
- [9] Carpenter, G. A. and Grossberg, S. “Pattern Recognition by Self-organizing Neural Networks”, Cambridge, Massachusetts, U.S.A., *The MIT Press*, 1991.
- [10] Carpenter, G. A.; Grossberg, S.; Markuzon, N.; Reynolds, J. H. and Rosen, D. B. “Fuzzy ARTMAP: A Neural Network Architecture for Incremental Supervised Learning of Analog Multidimensional Maps”, *IEEE Transactions on Neural Networks*, pp. 698-713, Vol. 3, N.5, September 1992.
- [11] Chauhan, S. and Dave, M. P. “Sensitive Based Voltage Instability Alleviation Using ANN”, *Electrical Power and Energy Systems*, pp. 651-657, No. 25, November-2003.
- [12] Cichocki, A. and Unbehauen, R. “Neural Networks for Optimization and Signal Processing”, New York, NY, U.S.A., *John Wiley & Sons*, 1993.
- [13] Colvara, L. D., “Método automático de análise de estabilidade de sistemas de energia elétrica considerando modelos detalhados: um desenvolvimento”, *Tese de Livre Docência*, Universidade Estadual Paulista, UNESP, Ilha Solteira, SP, 1996.
- [14] Dy Liacco, T. E. “Real Time Computer Control of Power Systems”, *Proceedings of IEEE*, pp. 884-891, Vol. 62, N.7, July 1974.
- [15] Djukanovic, M.; Sobajic, D.J. and Pao, Y-H. “Neural Net Based Determination of Generator-Shedding Requirements”, *IEE Proceedings – C*, Vol. 136, No. 5, pp. 427 – 436, 1992.
- [16] Elgerd, O.I. “Electric Energy Systems Theory: An Introduction”, New York, NY, *MacGraw Hill Book Company*, 1971.
- [17] Ferreira, W. P. “Análise Dinâmica de Contingências de Sistemas de Energia Elétrica por Redes Neurais Baseadas na Teoria da Ressonância Adaptativa”, *Tese de Doutorado*, Programa de Pós-graduação em Engenharia Elétrica, UNESP de Ilha Solteira, Novembro-2003.

- [18] Fine, T. L. “Feedforward Neural Network Methodology”, U.S.A., *Springer-Verlag*, 1999.
- [19] Fink, L. H. and Carlsen, K. “Operating Under Stress and Strain”, *IEEE Spectrum*, pp. 48-53, March 1978.
- [20] Fischer, D.; Szabados, B and Poehlman, S. “Automatic Contingency Grouping Using Partial Least Squares and Feed Forward Neural Network Technologies Applied to the Static Security Assessment Problem”, *2003 Large Engineering Conference on Power Engineering*, pp. 84-89, May 2003.
- [21] Fonseca, L. G. and Decker, I. C. “Iterative Algorithm for Critical Energy Determination in Transient Stability of Power System”, Rio de Janeiro, RJ, *IFAC - Symposium Planning and Operation in Electric Energy System*, pp. 483–489, 1985.
- [22] Fonseca, L. G. S. e Minussi, C. R. “Redespacho de Geração Para Controle de Segurança Dinâmica em Sistemas de Energia Elétrica Através da Análise de Sensibilidade”, Belém, PA, *8^o Congresso Brasileiro de Automática*, pp.735–740, 1990.
- [23] Fouad, A. A. and Jianzhong, T. “Stability Constrained Optimal Rescheduling of Generation”, *IEEE Transactions on Power Systems*, pp. 105–112, Vol. 8, N.1, 1993.
- [24] Fouad, A. A. and Vittal, V. “Power System Transient Stability Analysis Using the Transient Energy Function Method”, Englewood Cliffs, New Jersey, *Prentice Hall*, 1992.
- [25] Frank, P. K. “Introduction to System Sensitivity Theory”, New York, NY, U.S.A., *Academic Press*, 1978.
- [26] Grudinin, N. and Roytelman, I. “Heading off Emergencies in Large Electric Grids”, *IEEE Spectrum*, pp.42-47, Vol. 34, N.4, April 1997.
- [27] Gu, X. P.; Tso, S. K. and Zhang, Q. “Combination of Rough Set Theory and Artificial Neural Networks for Transient Stability”, *Proceedings PowerCon 2000*,

- International Conference on Power System Technology*, Vol. 1, pp. 19 – 24, December 2000.
- [28] Haykin, S. “Neural Networks- A Comprehensive Foundation”, Upper Saddle River, NJ, U.S.A., *Prentice Hall, Inc.*, 1999.
 - [29] Horovitz, S. H. and Phadke, A. G. “Boosting Immunity to Blackouts”, *IEEE Power & Energy*, pp. 47-53, Vol. 1, N. 5, 2003.
 - [30] Jacobs, R. A. “Increased Rates of Convergence Through Learning Rate Adaptation”, *Neural Networks*, pp. 295 – 307, Vol. 1, 1988.
 - [31] Kartalopoulos, S. V. “Understanding Neural Networks and Fuzzy Logic”, New York, NY, U.S.A., *IEEE Press*, 1996.
 - [32] Kennedy, J. and Eberhart, R. C. “Swarm Intelligence”, *The Morgan Kaufmann Publishers*, New York, U.S.A., 2001.
 - [33] Kezunovic, M.; Abur, A.; Edris, A. and Sobajic, D. “Data Integration / Exchange”, *IEEE Power & Energy*, pp. 14-19, Vol. 2, N. 2, 2004.
 - [34] Kirchmayer, L. K. “Economic Operation of Power Systems”, New York, NY, U.S.A., *John Wiley & Sons*, 1958.
 - [35] Kundur, P. “Power System Stability and Control”, Palo Alto, CA, U.S.A., EPRI Editors, *Mc Graw Hill*, 1994.
 - [36] Kung, S. Y. “Digital Neural Networks”, Englewood Cliffs, New Jersey, U.S.A., *Prentice-Hall*, 1993.
 - [37] Liu, Y.; Lin, F. and Chu, X. “Transient Stability Control Decision By Compound Neural Network”, *Proceedings of the 2002 International Joint Conference on Neural Networks*, Honolulu, HI – U.S.A., pp. 328-332, May-2002.
 - [38] Lo, K. L. and Peng, L. J. “Design of Artificial Neural Networks for On-line Static Security Assessment Problems”, *Proceedings of the 4-th International Conference on*

- Advances in Power System Control, Operation and Management*, APSCOM-97, Hong Kong, pp. 288-293, 1997.
- [39] Lopes, M. L. M. “Desenvolvimento de um Sistema Previsor de Cargas Elétricas via Redes Neurais”, *Dissertação de Mestrado*, Programa de Pós-graduação em Engenharia Elétrica, UNESP de Ilha Solteira, Dezembro-2000.
- [40] Lopes, M. L. M. “Desenvolvimento de uma Rede Neural Para Previsão de Cargas em Sistemas de Distribuição de Energia Elétrica”, *Projeto de Tese de Doutorado*, FAPESP / Proc. No. 00/15120-1, 2000 a 2004.
- [41] Lopes, M. L. M.; Minussi, C. R.; Lotufo, A. D. P. “Electric Load Forecasting Formulation by a Fast Neural Network”, *Engineering Intelligent Systems*, pp.51-57, Vol. 11, N. 1, March 2003.
- [42] Lopes, M. L. M.; Lotufo A. D. P. and Minussi, C. R. “A Fast Electric Load Forecasting Using Adaptive Neural Networks”, Bologna, Itália, *IEEE Bologna Power-Tech 2003*, June 2003, 7 p.
- [43] Lotufo, A.D.P.; Lopes, M.L.M.; and Minussi, C. R. “Dynamic Preventive Control of Electric Power Systems by Neural Networks”, Salvador, BA, *V INDUSCON-Conferência de Aplicações Industriais*, paper code 144, July 2002.
- [44] Lotufo, A.D.P.; Lopes, M. L. M; and Minussi, C. R. “A Neural Network for Transient Stability Analysis and Preventive Control of Electric Energy Systems”, São Paulo, SP, *Proceedings of VI Brazilian Conference on Neural Networks*, pp. 91-96, June 2003.
- [45] Lotufo, A.D.P.; Lopes, M. L. M; e Minussi, C. R. “Análise de Sensibilidade por Redes Neurais Para Aplicação em Estabilidade Transitória de Sistemas Elétricos de Potência”, *3º Congresso Temático de Dinâmica e Controle – DINCON’2004*, Ilha Solteira, SP, pp. 1347 – 1355, Maio-Junho-2004.
- [46] Lotufo, A. D. P. “Determinação de Estratégias de Intercâmbio em Sistemas de Energia Elétrica Interligados com Restrição de Estabilidade Transitória”, *Relatório de*

Atividades Trienal referente ao Regime de Dedicação Integral à Docência e Pesquisa, UNESP de Ilha Solteira, Abril-1994.

- [47] Mai-Duy, N. and Tran-Cong, T. “Approximation of Function and its Derivative Using Radial Basis Function Networks”, *Applied Mathematical Modelling*, No. 27, pp. 197-220, 2003.
- [48] Marchiori, S. C. “Estabilidade Transitória de Sistemas de Energia Elétrica: Uma Metodologia de Análise via Rede Neural ARTMAP Nebulosa”, *Dissertação de Mestrado*, Programa de Pós-graduação em Engenharia Elétrica, UNESP de Ilha Solteira, Agosto-2001.
- [49] Marchiori, S., Minussi, C. R. e Lotufo, A. D. P. “Rede Neural ARTMAP Nebulosa Para Análise de Estabilidade Transitória de Sistemas de Energia Elétrica”, *Learning and Nonlinear Models*, pp. 61-78, Vol. 1, N.1, 2002.
- [50] Minussi, C. R. and Freitas, W. “Sensitivity Analysis for Transient Stability”, *IEEE Proceedings on Generation, Transmission And Distribution*, pp. 669-674, Vol. 145, N.6, 1998.
- [51] Minussi, C. R. and Silveira, M. C. G. “Transient Stability Analysis of Electric Power Systems by Neural Networks”, Rio de Janeiro, RJ, 38rd *Midwest Symposium on Circuits And Systems*, pp. 1305-1308, 1995.
- [52] Minussi, C. R. “Curso Sobre Redes Neurais Artificiais”, *Programa de Pós-graduação em Engenharia Elétrica*, UNESP de Ilha Solteira, 1995.
- [53] Minussi, C. R. “Controle de Segurança Dinâmica em Sistemas de Energia Elétrica”, *Tese de Doutorado*, Programa de Pós Graduação em Engenharia Elétrica UFSC, Florianópolis, SC, Novembro 1990.
- [54] Mountford, J. and Austria, R. R. “Keeping the Lights on!”, *IEEE Spectrum*, pp. 34-39, Vol. 36, N. 6, June 1999.

- [55] Niazi, K.R.; Arora, C. M. and Surana, S. L. "Power System Security Evaluation Using ANN: Feature Selection Using Divergence", *Electric Power System Research*, pp.161-167, N.69, 2004.
- [56] Novosel, D.; Begovic, M. M. and Madani, V. "Shedding Light on Blackouts", *IEEE Power & Energy*, pp. 32-43, Vol. 2, N. 1, 2004.
- [57] Oliveira, E. N. "Utilização de Índices de Estabilidade Transitória para Redespacho de Geração", *Tese de Doutorado*, Programa de Pós-graduação em Engenharia Elétrica, UNESP de Ilha Solteira, Abril-2004.
- [58] Padhy, N. P. "Unit Commitment Using Hybrid Models: A Comparative Study for Dynamic Programming, Expert Systems, Fuzzy System and Genetic Algorithms", *Electrical Power and Energy Systems*, pp. 827-836, N. 23, 2000.
- [59] Pai, M. A. "Power System Stability", *North Holland Control Series*, Amsterdam, The Netherlands, *North Holland Publishing Company*, 1981.
- [60] Pao, Y. H. and Sobajic, D.J. "Combined Use of Unsupervised and Supervised Learning for Dynamic Security Assessment", *IEEE PICA-91*, pp. 278-284, 1991.
- [61] Park, Y. M.; Kin, G. W.; Cho, H. S. and Lee, K. Y.N. "A New Algorithm for Kohonen Layer Learning with Application to Power System Stability Analysis", *IEEE Transactions on Systems, Man, And Cybernetics*, pp. 1030-1033, Vol. 27, N. 6, December 1997.
- [62] Parrinello, M. "Simulating Complex Systems Without Adjustable Parameters", *IEEE Computing in Science & Engineering*, pp. 22 – 27, November/December 2000.
- [63] Pavella, M.; Ernst, D. and Ruiz-Vega, D. "Transient Stability of Power Systems A Unified Approach to Assessment and Control", Boston, U.S.A., *Kluwer Academic Publisher*, 2000.

- [64] Silveira, M. C. G.; Lotufo, A. D. P. and Minussi, C. R. “Transient Stability Analysis of Electrical Power Systems Using a Neural Network Based on Fuzzy ARTMAP”, Bologna, Itália, *IEEE Bologna Power-Tech 2003*, June 2003, 8p.
- [65] Silveira, M. C. G. “Análise de Estabilidade Transitória por Redes Neurais ARTMAP Nebulosas Modulares”, *Tese de Doutorado*, Programa de Pós-graduação em Engenharia Elétrica, UNESP de Ilha Solteira, Outubro-2003.
- [66] Singh, S. N. and David, A. K. “Optimal Dispatch in Dynamic Security Constrained Open Power Market”, *Electrical Power and Energy Systems*, N. 24, pp. 363 – 369, 2002.
- [67] Sobajic, D. J. and Pao, Y.H. “Artificial Neural-Net Based Dynamic Security Assessment for Electric Power Systems”, *IEEE Transactions on Power Systems*, pp. 220-227, Vol. 4, N.1, February 1989.
- [68] Song, Y-H. And Irving, M. R. “Optimization Techniques for Electrical Power Systems. Part 2: Heuristics Optimization Methods”, *Power Engineering Journal*, pp. 151 – 160, June 2001.
- [69] Stamatis, N.; Parthimos, D. and Griffith, T. M. “Forecasting Chaotic Cardiovascular Time Series with an Adaptive Slope Multilayer Perceptron Neural Network”, *IEEE Transactions on Biomedical Engineering*, pp. 1441-1453, Vol. 46, N.12, 1999.
- [70] Stott, B. “Power System Dynamic Response Calculations”, *Proceedings of the IEEE*, v.67, n.2, pp. 219 – 241, 1979.
- [71] Sweet, W. “Restructuring the Thin-Stretched Grid”, *IEEE Spectrum*, pp. 43-49, Vol. 37, N.6, June 2000.
- [72] Takaue, J.; Takahashi, K.; Ohtaka, T. and Iwamoto, S. “Transient Stability Preventive Control Using Critical Clearing Time Sensitivity”, *IEEE/PES Transmission and Distribution Conference and Exhibition 2002: Asia Pacific*, Vol. 3, pp. 1518-1523, October 2002.

- [73] Taylor, C.W. “Improving Grid Behavior”, *IEEE Spectrum*, pp. 40-45, Vol. 36, N.6, June 1999.
- [74] Terano, T.; Asai, K. and Sugeno, M. “Fuzzy Systems Theory and Its Applications”, U.S.A., *Academic Press*, 1991.
- [75] Venikov, V. A.; Anisimova, N. D.; Ezhkov, V. V.; Zhukov, L. A.; Likten, J.V.; Fiedorov, D. A. y Tsovianov, A. N. “Calculos de Estabilidad de Sistemas Electricos Automatizados”, Moscou, Russia, *Editora Mir*, 1970.
- [76] Vittal, V.; Zhou, E. Z., Hwang, C. and Fouad, A. A. “Derivation on Stability Limits Using Analytical Sensitivity of The Transient Energy Margin”, *IEEE Transactions on Power Systems*, pp. 1363–1372, Vol. 4, N.2, 1989.
- [77] Wasserman, P. D. “Neural Computing - Theory and Practice”, New York, U.S.A., *Van Nostrand Reinhold*, 1989.
- [78] Wehenkel, L. “Machine-Learning Approaches to Power-System Security Assessment”, *IEEE Expert Intelligent Systems & Their Applications*, pp. 60-72, September / October, 1997.
- [79] Werbos, P. J. “Beyond Regression: New Tools For Prediction And Analysis in The Behavioral Sciences”, *Master Thesis*, Harvard University, Cambridge, MA, U.S.A., 1974.
- [80] Widrow, B. and Lehr, M. A. “30 Years of Adaptive Neural Networks: Perceptron, Madaline, and Backpropagation”, *Proceedings of the IEEE*, pp. 1415-1442, Vol. 78, N.9, 1990.
- [81] Xue, Y.; Van Cutsem, Th. and Ribbens-Pavella, M. “Real-Time Analytic Sensitivity Method for Fast Transient Stability Assessment of Large Power Systems”, *IEE Proceedings*, pp. 107–116, Vol. 135, Pt. C. N.2, 1988.

APÊNDICE A

PRINCIPAIS CONCEITOS EM REDES NEURAIS ARTIFICIAIS

Genericamente, define-se uma rede neural como uma rede de comunicação adaptativa que liga uma função custo a uma saída desejada (Fine [18], Kartalopoulos [31], Kung [36], Wasserman [77]). Matematicamente, uma rede neural representa um sistema dinâmico que pode ser modelado como um conjunto de equações diferenciais e/ou algébricas, não-lineares acopladas (Kartalopoulos [31]).

As redes neurais são compostas de neurônios interligados formando camadas, distinguindo-se em camadas de entrada, intermediárias e de saída. No entanto, estas redes precisam aprender a tarefa para poder atuar. Isto está associado aos pesos de ligação entre os neurônios. Os valores finais dos pesos constituem o programa da rede neural artificial (Kartalopoulos [31], Kung [36], Widrow & Lehr [80], Wasserman [77]). A Figura 30 ilustra uma rede neural genérica, conforme descrito anteriormente, contendo uma camada de entrada, camadas intermediárias e uma de saída (Minussi [52]).




Figura 30. Rede neural artificial.

Existem diversos modelos de redes neurais, desde sua concepção inicial, a partir do primeiro neurônio artificial de McCulloch-Pitt (Kartalopoulos [31]), que envolvia a modelagem de um único neurônio, em que foi detectada a necessidade de uma realimentação, sendo contemplada com o *Perceptron* multicamadas. Na seqüência cronológica pode-se citar os modelos ADALINE (*ADaptive Linear NEuron*) (Widrow & Lehr [80]) e MADALINE (*Multi ADALINE*) (Widrow & Lehr [80]). O *Perceptron* multicamadas, é uma espécie de pré-requisito para o algoritmo *retropropagação* (Werbos [79]). O *Perceptron* faz parte de uma segunda geração de modelos, uma vez que a primeira geração de modelos desenvolvidos, não continham realimentação.

O modelo de McCulloch-Pitts desenvolvido em 1943, o qual descreve um neurônio, está representado na Figura 31, cuja atividade s é a soma de n entradas ponderadas por seus respectivos pesos. Esta atividade alimenta uma função não-linear $f(.)$ que produz um sinal que será enviado aos demais neurônios. As não-linearidades mais empregadas são: relé, lógica *threshold* e sigmóide. O neurônio de McCulloch-Pitts pode conter também um peso *bias* w_0 alimentado por uma constante $x_0 = +1$ que desempenha o controle do nível de saída do neurônio.

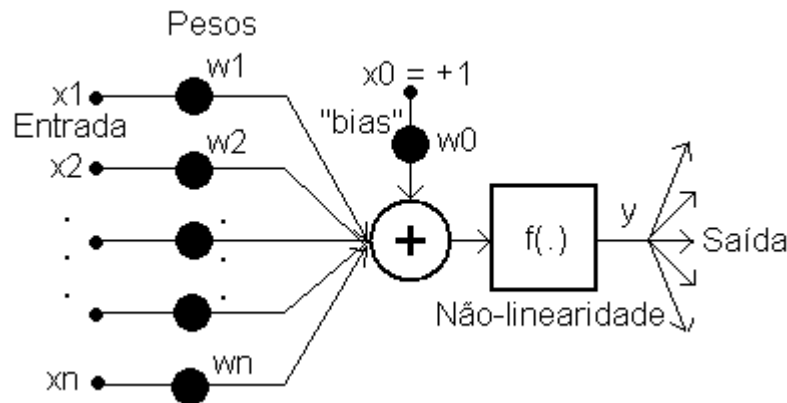


Figura 31. Modelo do neurônio de McCulloch-Pitts.

As Figuras 32 a 35 mostram as funções não-lineares mais utilizadas conforme descrito anteriormente.




Figura 32. Função relé.

$$f(s) = \begin{cases} +1, & \text{se } s \geq 0 \\ -1, & \text{se } s \leq 0 \end{cases}$$




Figura 33. Função lógica *threshold*.




Figura 34. Função sigmóide (1).

$$f(s) = \frac{1 - \exp(-\lambda s_i)}{1 + \exp(-\lambda s_i)}$$

sendo:

λ = inclinação da curva.




Figura 35. Função sigmóide (2).

$$f(s) = \frac{1}{1 + \exp(-\lambda s_i)}$$

O modelo de neurônio ADALINE é mostrado na Figura 36. A função de saída é uma combinação linear das entradas. Na implementação discreta, estes elementos recebem, no instante k , um vetor padrão de entrada:

$$\mathbf{X}k = [x_0 = +1 \ x_{1k} \ x_{2k} \ \dots \ x_{nk}]^T \quad (\text{A.1.1})$$

e uma resposta desejada d_k . Os componentes do vetor padrão de entrada são ponderados por um conjunto de coeficientes, ou seja, pelo vetor de pesos:

$$\mathbf{W} = [w_0 \ w_1 \ w_2 \ \dots \ w_n]^T \quad (\text{A.1.2})$$

A soma das entradas ponderadas é, então, avaliada (calculada), produzindo uma combinação linear correspondente ao produto interno:

$$s_k = \langle \mathbf{X}_k, \mathbf{W} \rangle \quad (\text{A.1.3})$$

Os componentes de \mathbf{X}_k podem ser valores reais ou binários. Porém, os pesos são valores essencialmente reais.

Durante o processo de treinamento, os padrões de entrada e de respostas desejadas correspondentes são apresentados à rede neural. Um algoritmo de adaptação ajusta, automaticamente, os pesos de tal forma que as saídas fiquem próximas dos valores desejados.

A rede neural ADALINE consiste no mecanismo de adaptação linear em série com relé (função não-linear), que é empregada para produzir uma saída binária ± 1 :

$$Y_k = \text{sgn}(s_k) \quad (\text{A.1.4})$$

sendo:

$\text{sgn}(\cdot)$ = função sinal.

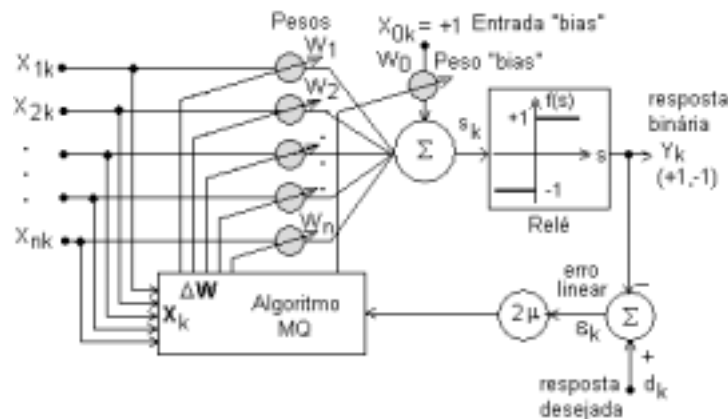


Figura 36. Rede neural ADALINE.

A rede neural MADALINE (*Multi-ADALINE*) é constituída por vários elementos ADALINE. Contudo, o processo de treinamento é bem mais complexo, se comparado ao ADALINE. A rede neural apresentada na Figura 36, associada a algum mecanismo de adaptação de pesos (treinamento), é uma rede ADALINE.

As redes neurais classificam-se basicamente em dois tipos, redes recorrentes e redes não recorrentes (Kartalopoulos [31]).

As redes recorrentes são aquelas que contém laços de realimentação, ou seja, contém conexões das saídas de uma determinada camada para a entrada da mesma ou de camadas anteriores. As entradas de um neurônio são as saídas dos demais neurônios da camada anterior. As redes que possuem esta estrutura desenvolvem uma memória a longo prazo nos neurônios internos. As redes não recorrentes caracterizam-se estruturalmente por estarem dispostas em camadas. Nestas redes cada camada de neurônios recebe sinais somente das camadas anteriores, ou seja, elas não possuem laços de realimentação.

Redes não-recorrentes ou *feedforward* não possuem memória, sendo que, sua saída é exclusivamente determinada em função da entrada e dos valores dos pesos. A rede neural mostrada na Figura 36 é uma não-recorrente.

A propriedade mais importante das redes neurais é a habilidade de aprender e com isso melhorar seu desempenho. Isso é feito através de um processo iterativo de ajustes aplicados a seus pesos que correspondem ao treinamento.

Portanto, para isto podem existir dois tipos de aprendizagem, o supervisionado e o não-supervisionado, (Widrow & Lehr [80]).

Num aprendizado supervisionado, compara-se saída desejada (conhecida, *a priori*, quando aplicado, na entrada um estímulo padrão) com saída objetivo. As duas saídas são, então, comparadas produzindo um erro, o qual é processado até que um erro mínimo seja alcançado. Neste processo de minimização, são feitos ajustes nos pesos de ligação dos neurônios. Já o não supervisionado, consiste num mecanismo de adaptação de pesos considerando somente o conjunto de padrões de entrada, isto é a rede se auto-organiza (Kartalopoulos [31], Widrow & Lehr [80]). A Figura 37 (Minussi [52]) ilustra o aprendizado supervisionado, enquanto o não-supervisionado é mostrado na Figura 38 (Minussi [52]).




Figura 37. Treinamento supervisionado.




Figura 38. Treinamento não-supervisionado.

Um dos algoritmos de treinamento mais comuns é o retropropagação (*backpropagation*) (Werbos [79]). Define-se o retropropagação como uma aplicação da regra da cadeia do cálculo diferencial (Bender [7]) em redes *feedforward* (não recorrentes, isto é sem laços de realimentação). O objetivo é minimizar um erro em torno de um conjunto de padrões de treinamento, utilizando-se o método do gradiente descendente. Chama-se retropropagação porque a informação é transmitida no sentido contrário ao da propagação, iniciando da saída e movendo-se para a entrada. O algoritmo retropropagação ajusta os pesos na direção oposta ao erro do gradiente instantâneo (Bender [7], Haykin [28], Kartalopoulos [31], Widrow & Lehr [80]). Portanto, dentre os princípios fundamentais das redes neurais pode-se citar:

- a) os casos particulares de redes de acordo com o número de neurônios, ou ainda, se estes são neurônios de entrada ou de saída, ou a quantidade de neurônios por camada;
- b) as funções mais utilizadas (o propósito da função não-linear aplicada é assegurar que a resposta do neurônio seja limitada, ou seja, que a resposta real seja controlável). As duas funções mais utilizadas são o degrau unitário ou relé e a função sigmóide;
- c) a taxa de aprendizagem: geralmente é um número pequeno e positivo que influencia a velocidade e a precisão do processo de aprendizado;

- d) o modo de processamento ou treinamento, se sequencial ou *por lote*, sendo o primeiro o mais utilizado;
- e) o critério de parada: ou seja, quando a convergência foi atingida, pode ser através da norma Euclidiana do vetor gradiente, quando esta atingir um valor suficientemente pequeno e preestabelecido, ou quando a taxa de variação do erro médio quadrático for suficientemente pequena.

APÊNCICE B

LÓGICA NEBULOSA

Lógica nebulosa é uma forma matemática para representação de definições vagas. Conjuntos nebulosos são generalizações da teoria de conjunto convencional. Contém objetos que contemplam imprecisão no referido conjunto. O grau de pertinência é definido por um valor da função de pertinência a qual possui valores compreendidos entre 0 e +1. Deste modo, a seguir são apresentados os principais conceitos sobre lógica nebulosa que são utilizados nesta pesquisa.

Definição 1. Considere uma coleção de objetos Z . Então, um conjunto nebuloso A em Z é definido como sendo o conjunto de pares ordenados:

$$A = \{(z, \mu_A(z)) | z \in Z\} \quad (\text{B.1})$$

sendo:

$\mu_A(z)$ = valor da função de pertinência do conjunto nebuloso A correspondente ao elemento z .




Figura 39. Conjuntos Nebulosos.

Operações semelhantes a *AND*, *OR* e *NOT* são alguns dos mais importantes operadores de conjuntos nebulosos. Supondo-se que A e B são dois conjuntos nebulosos com funções de pertinências designadas por $\mu_A(z)$ e $\mu_B(z)$, respectivamente, então, tem-se (Kartalopoulos [31], Terano *et al.* [74]):

- a) *Operador AND ou interseção de dois conjuntos.* A função de pertinência da interseção destes dois conjuntos nebulosos ($C = A \cap B$) é definida por:

$$\mu_C(z) = \min \{ \mu_A(z), \mu_B(z) \}, \quad z \in Z \quad (\text{B.2})$$




Figura 40. Operador AND.

- b) *Operador OR ou união entre dois conjuntos.* A função de pertinência da união destes conjuntos nebulosos ($D = A \cup B$) é definida por:

$$\mu_D(z) = \max \{ \mu_A(z), \mu_B(z) \}, \quad z \in Z \quad (\text{B.3})$$




Figura 41. Operador OR.

- c) *Operador NOT ou o complemento de um conjunto nebuloso.* A função de pertinência do complemento de A , A' é definida por:

$$\mu_{A'}(z) = 1 - \mu_A(z), \quad z \in Z. \quad (\text{B.4})$$




Figura 42. Operador NOT.

- d) *Relação Nebulosa.* A função nebulosa R de A em B pode ser considerada como um grafo nebuloso e é caracterizada pela função de pertinência $\mu_R(z,y)$, a qual satisfaz a seguinte regra de composição:

$$\mu_B(z) = \max_{z \in Z} \{ \min [\mu_R(z,y), \mu_A(z)] \} \quad (\text{B.5})$$

A Figura 43 mostra as características da função de pertinência, na qual a altura ou magnitude é normalizada em 1. O grau de pertinência é determinado pela projeção vertical do parâmetro de entrada do eixo horizontal no limite mais alto da função de pertinência, possuindo valores compreendidos entre 0 e 1, (Lopes [39]).




Figura 43. Funções de Pertinência.

O controle nebuloso é um mecanismo constituído, basicamente, de três partes: *nebulização* que converte variáveis reais em variáveis lingüísticas; *inferência* que consiste na manipulação de base de regras utilizando declarações *if-then* e, ainda, operações nebulosas, como definidas anteriormente (equações (B.1)–(B.5)) e *denebulização* que converte o resultado obtido (variáveis lingüísticas) em variáveis reais.

As funções de pertinência nebulosas podem ter diferentes formas, tais como triangular, trapezoidal e gaussiana, de acordo com a preferência / experiência do projetista.

O método mais comum de desnebulização é o método de centro de área (centróide) (Kartalopoulos [31]; Terano *et al.* [74]) que encontra o centro da gravidade da solução dos conjuntos nebulosos. Para um conjunto nebuloso discreto tem-se (Kartalopoulos [31]; Terano *et al.* [74]):

$$u = \frac{\sum_{i=1}^n \mu_i \delta_i}{\sum_{i=1}^n \mu_i} \quad (\text{B.6})$$

sendo:

δ_i = valor do conjunto que possui um valor de pertinência μ_i ;

n = número de regras nebulosas.

O valor u calculado pela equação (B.6) corresponde a projeção do centro de inércia da figura definida pelo conjunto de regras sobre o eixo da variável de controle.

Cada variável de estado geralmente é representada entre 3 e 7 conjuntos nebulosos.

APÊNDICE C

ALGORITMO COMPUTACIONAL PARA DETERMINAÇÃO DA MARGEM DE SEGURANÇA

A análise de estabilidade transitória de sistemas de energia elétrica será efetuada combinando-se o Método Direto de Lyapunov e a resolução das equações diferenciais (metodologia híbrida), considerando-se defeitos tipo curto-circuito com saída de operação de linha de transmissão. Esta combinação é empregada como forma de se obter maior precisão, se comparada ao Método Direto de Lyapunov. A função de Lyapunov adotada será do tipo energia. Neste caso, a análise da estabilidade é efetuada comparando-se a energia adquirida durante o transitório com uma energia crítica. A energia crítica corresponde à máxima energia que o sistema pode acumular de tal modo que sua estabilidade seja preservada. A energia crítica e, conseqüentemente, o tempo crítico serão determinados baseados no conceito PEBS (*Potencial Energy Boundary Surface* (Athay *et al.* [4]) iterativo (Fonseca & Decker [21]), cujo algoritmo empregado corresponde ao apresentado na referência Silveira [65]. Este algoritmo tem sido adotado, tendo em vista a precisão comparável à simulação, com custo computacional consideravelmente inferior (Fonseca & Decker [21]).

A estabilidade transitória para a r -ésima contingência pode ser avaliada, via margem de segurança, da seguinte forma (Pai [59]):

- se $M_r \geq 0$, o sistema é considerado *estável*, do ponto de vista da estabilidade transitória;
- se $M_r < 0$, o sistema é considerado *instável*, do ponto de vista da estabilidade transitória.

A derivada direcional da energia potencial pode ser expressa de modo similar ao apresentado nas referências (Athay *et al.* [4], Fonseca & Decker [21], Pai [59]), por:

$$D(\theta) = - \frac{\langle \mathbf{g}(\theta), (\theta - \theta^P) \rangle}{\|\theta - \theta^P\|_e} \quad (\text{B.1})$$

sendo:

$$\mathbf{g}(\theta) = [g_1(\theta) \ g_2(\theta) \ \dots \ g_{ns}(\theta)]^T \quad (\text{B.2})$$

$$g_i(\theta) = Pm_i - Pe_i - M_i \frac{PCOA}{MT} \quad (\text{B.3})$$

$\langle ., . \rangle =$ produto interno de dois vetores ns -dimensionais;

$\|\cdot\|_e =$ norma euclidiana.

A derivada direcional $D(\theta)$ possui a propriedade de se manter sempre positiva para trajetórias (soluções das equações diferenciais) estáveis (Athay *et al.* [4], Fonseca & Decker [21], Pai [59]). Os pontos $\theta \in \mathcal{R}^n$ correspondentes aos zeros da derivada direcional, que primeiro são lançados quando se percorre uma direção radial, a partir da origem, determinam uma superfície definida como sendo Superfície Limite de Energia Potencial ou PEBS (Athay *et al.* [4]). Por conseguinte, o procedimento de determinação da energia e tempo crítico apresentado na referência Fonseca & Decker [21] consiste na busca de um ponto na trajetória sob falta, por processo iterativo, tal que a evolução pós-falta, que começa neste ponto, encontre a máxima aproximação da PEBS. Considerando-se, então, os resultados apresentados anteriormente, pode-se descrever o algoritmo através dos seguintes passos (Silveira [65]):

Passo 1. Ler os dados.

Passo 2. Determinar o fluxo de potência do sistema pré-falta, através do método desacoplado rápido.

Passo 3. Iniciar o contador de contingências:

$r = 1.$

Passo 4. Contador de contingências:

$$r = r + 1.$$

Passo 5. Calcular as matrizes reduzidas às barras internas de geração para as configurações de falta e pós-falta.

Passo 6. Calcular o ponto de equilíbrio pós-defeito. Emprega-se, neste caso, o método de Newton, considerando a topologia da rede reduzida às barras internas de geração.

Passo 7. O ponto de equilíbrio pós-defeito é estável? Se verdadeiro, ir ao passo 8. Do contrário, emitir mensagem que a contingência não possui ponto de equilíbrio e, conseqüentemente, o sistema é considerado instável para a contingência analisada e retornar ao passo 4.

Passo 8. Determinar o tempo crítico e a energia crítica:

- (a) o cálculo das trajetórias sob falta e pós-falta é determinado através do método Runge-Kutta de segunda ordem (integração numérica das equações diferenciais (3.3.1));
- (b) energia e tempo crítico determinados utilizando-se o algoritmo proposto na referência (Fonseca & Decker [21]). A função de Lyapunov tipo energia é avaliada de acordo com as expressões (3.4.2)–(3.4.4).

Passo 9. Última contingência ? Se verdadeiro, ir ao passo 10. Do contrário, retornar ao passo 4.

Passo 10. Emitir relatório em forma de tabelas contendo os principais dados e resultados (tempo crítico, energia crítica, energia correspondente ao instante de eliminação de defeito, margem de segurança, etc.).

Passo 11. Finalizar o processo de cálculo.

APÊNDICE D

Neste Apêndice são relacionados os diagramas unifilares e dados dos sistemas estudados nesta pesquisa. Trata-se dos sistemas de 3 máquinas (sistema Anderson & Fouad [2]) e de 10 máquinas síncronas, 45 barras e 73 linhas de transmissão, respectivamente.

D.1. DADOS DO SISTEMA EXEMPLO ANDERSON & FOUAD [2]

Tabela 9. Dados das máquinas síncronas.

Máquina Síncrona	Potência Mecânica (pu)	Reatâncias		H (s)
		x_d (pu)	x'_d (pu)	
1	Referência	0,1460	0,0608	9,552
2	1,63	0,8958	0,1198	3,333
3	0,85	1,3125	0,1813	2,352

Tabela 10. Dados das cargas.

Potência Elétrica	Barra de Carga		
	5	6	8
Ativa	1,25	0,90	1,00
Reativa	0,50	0,30	0,35

Tabela 11. Dados do sistema de transmissão.

Elemento do Sistema de Transmissão					
No.	Nó Inicial	Nó Final	Resistência R (pu)	Reatância X (pu)	Susceptância $Shunt$ (pu)
1	1	4	0,0000	0,0570	0
2	4	5	0,0100	0,0850	0,0880
3	4	6	0,0170	0,0920	0,0790
4	5	7	0,0320	0,1610	0,1530
5	6	9	0,0390	0,1700	0,1790
6	2	7	0,0000	0,6250	0
7	7	8	0,0080	0,0720	0,7450




Figura 39. Sistema de energia elétrica composto por 3 máquinas síncronas.

D.2. DADOS DO SISTEMA SUL BRASILEIRO

Tabela 12. Dados das máquinas síncronas.

Máquina Síncrona	Reatâncias		H (s)
	x_d (pu)	x'_d (pu)	
1	0,0367	0,0367	30,44
2	0,1037	0,1037	10,56
3	0,0284	0,0284	38,34
4	0,0241	0,0241	62,25
5	0,0243	0,0243	55,24
6	0,1352	0,1352	4,37
7	0,1534	0,1534	6,8
8	0,0800	0,0800	12,5
9	0,0432	0,0432	20,24
10	0,0216	0,0216	62,46

Tabela 13. Dados do sistema de transmissão.

Elemento do Sistema de Transmissão				
No.	Nó Inicial	Nó Final	Impedância série (pu) ($Z = R + j X$)	Susceptância <i>Shunt</i> (pu)
1	11	12	0,0007 + j 0,0145	0
2	11	12	0,0007 + j 0,0145	0
3	11	25	0,0018 + j 0,0227	0
4	11	33	0,0014 + j 0,0204	0
5	12	42	0,0 + j 0,0063	0

Tabela 13. Dados do sistema de transmissão. (Continuação).

Elemento do Sistema de Transmissão				
No.	Nó Inicial	Nó Final	Impedância série (pu) ($Z = R + jX$)	Susceptância <i>Shunt</i> (pu)
6	1	29	0,0 + j 0,0136	0
7	13	14	0,0386 + j 0,1985	0
8	13	35	0,0096 + j 0,0491	0
9	13	45	0,0033 + j 0,0167	0
10	14	15	0,0463 + j 0,2378	0
11	14	15	0,0463 + j 0,2378	0
12	14	37	0,0177 + j 0,091	0
13	14	37	0,0177 + j 0,091	0
14	14	37	0,0177 + j 0,091	0
15	2	15	0,0 + j 0,046	0
16	15	16	0,0163 + j 0,0835	0
17	15	16	0,0163 + j 0,0835	0
18	15	39	0,025 + j 0,1548	0
19	16	17	0,0163 + j 0,0835	0
20	16	18	0,0316 + j 0,1621	0
21	17	18	0,0153 + j 0,0861	0
22	3	18	0,0 + j 0,0114	0
23	18	19	0,0306 + j 0,1523	0
24	18	44	0,0344 + j 0,176	0
25	18	44	0,0344 + j 0,176	0
26	19	20	0,0245 + j 0,1256	0
27	19	25	0,0 + j 0,030	0
28	20	21	0,0088 + j 0,0415	0
29	21	22	0,0182 + j 0,0935	0
30	21	22	0,0182 + j 0,0935	0
31	21	26	0,0 + j 0,0062	0
32	22	23	0,0154 + j 0,0776	0

Tabela 13. Dados do sistema de transmissão. (Continuação).

Elemento do Sistema de Transmissão				
No.	Nó Inicial	Nó Final	Impedância série (pu) ($Z = R + jX$)	Susceptância <i>Shunt</i> (pu)
33	22	23	0,0154 + j 0,0776	0
34	23	24	0,0216 + j 0,1105	0
35	23	24	0,0216 + j 0,1105	0
36	23	28	0,0 + j 0,0062	0
37	24	35	0,018 + j 0,092	0
38	24	35	0,018 + j 0,092	0
39	4	25	0,0 + j 0,0067	0
40	25	26	0,0019 + j 0,028	0
41	25	27	0,0019 + j 0,0274	0
42	25	29	0,0014 + j 0,0195	0
43	25	36	0,0005 + j 0,007	0
44	26	27	0,0005 + j 0,0069	0
45	26	28	0,0012 + j 0,0175	0
46	29	30	0,0021 + j 0,0309	0
47	30	38	0,0 + j 0,0062	0
48	31	32	0,0022 + j 0,030	0
49	31	40	0,0 + j 0,0062	0
50	32	33	0,0014 + j 0,0195	0
51	5	33	0,0 + j 0,0114	0
52	33	36	0,0005 + j 0,007	0
53	6	34	0,0 + j 0,0871	0
54	34	35	0,0 + j 0,059	0
55	7	35	0,0 + j 0,0701	0
56	8	35	0,0 + j 0,045	0
57	35	45	0,0129 + j 0,0657	0
58	10	36	0,0 + j 0,0068	0
59	37	38	0,0022 + j 0,0111	0

Tabela 13. Dados do sistema de transmissão. (Continuação).

Elemento do Sistema de Transmissão				
No.	Nó Inicial	Nó Final	Impedância série (pu) ($Z = R + jX$)	Susceptância <i>Shunt</i> (pu)
60	37	38	0,0022 + j 0,0111	0
61	37	38	0,0022 + j 0,0111	0
62	37	40	0,0207 + j 0,0933	0
63	37	40	0,0207 + j 0,0933	0
64	37	40	0,0207 + j 0,0933	0
65	9	39	0,0 + j 0,0236	0
66	39	40	0,0202 + j 0,1129	0
67	41	42	0,0125 + j 0,064	0
68	41	42	0,0125 + j 0,064	0
69	41	43	0,011 + j 0,1184	0
70	41	44	0,0229 + j 0,1174	0
71	42	43	0,0229 + j 0,1174	0
72	42	43	0,0229 + j 0,1174	0
73	43	44	0,0181 + j 0,0929	0

Tabela 14. Dados das barras.

Barra	Tipo (*)	Potência ativa (pu)	Potência reativa (pu)
1	2	6,5000	
2	2	2,1500	
3	2	10,5000	
4	2	11,1000	
5	2	13,2500	
6	2	0,9000	
7	2	1,2000	

Tabela 14. Dados das barras. (Continuação).

Barra	Tipo (*)	Potência ativa (pu)	Potência reativa (pu)
8	2	2,4100	
9	2	4,9000	
10	3	referência	
11	1	0	-2,1300
12	1	0	0
13	1	1,7700	0,6800
14	1	1,9100	0,4200
15	1	1,7100	0,1850
16	1	1,2600	0,4700
17	1	0,4600	0,1470
18	1	2,8100	0,5650
19	1	2,7900	0,6070
20	1	1,3000	-0,7060
21	1	4,2700	-1,2500
22	1	3,1000	0,4100
23	1	4,2400	-0,0940
24	1	1,1700	0,5310
25	1	0	0
26	1	0	-1,4470
27	1	3,6800	-0,7560
28	1	0	0
29	1	1,7400	-1,1380
30	1	0	-1,5960
31	1	0	-1,6030
32	1	0	-1,6150
33	1	0	0
34	1	1,2600	0,3980
35	1	0	0
36	1	0	0
37	1	8,1300	1,1000

Tabela 14. Dados das barras. (Continuação).

Barra	Tipo (*)	Potência ativa (pu)	Potência reativa (pu)
38	1	6,1200	-4,5500
39	1	4,0400	1,3500
40	1	3,9300	-1,1100
41	1	2,6200	0,1320
42	1	2,2900	0,8300
43	1	1,8400	-0,3980
44	1	1,3900	-0,4630
45	1	0,9010	-0,4470

(*) Barra tipo: 1 \rightarrow barra de carga (PQ)
2 \rightarrow barra de geração (PV)
3 \rightarrow barra de referência (P θ).

Diagrama Unifilar do Sistema Elétrico

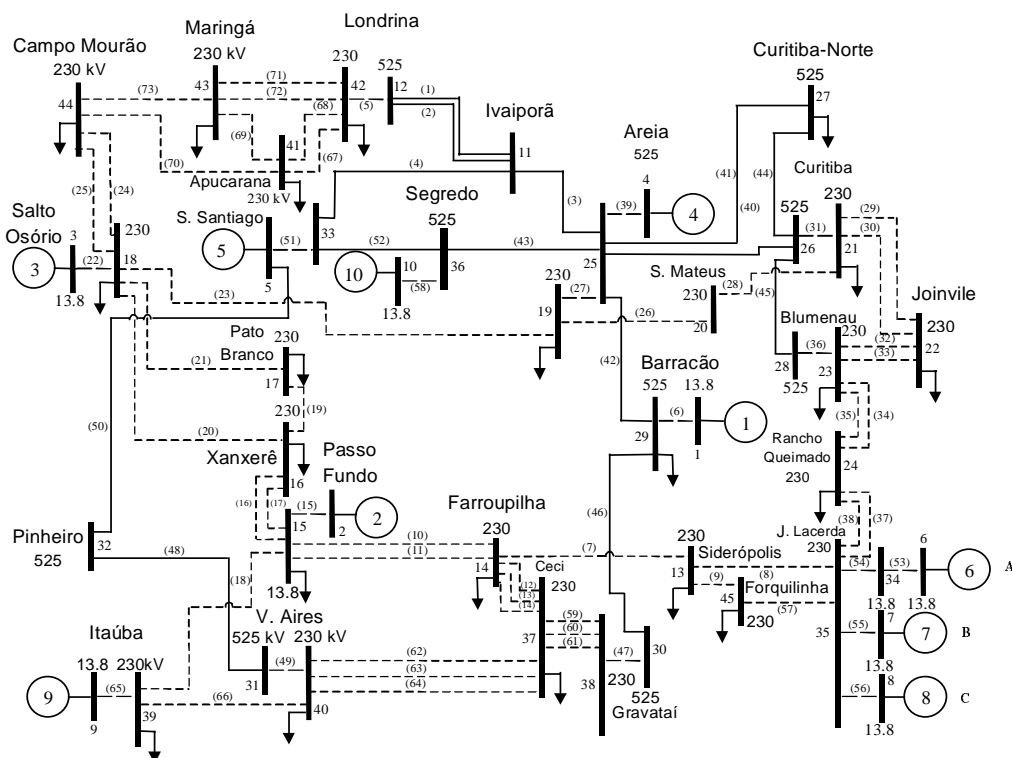


Figura 40. Sistema Sul brasileiro.

Tabela 15. Principais contingências usadas nas simulações.

Contingência	Barra sob Curto-circuito	Linha de Transmissão Removida
1	17	16 – 17
2	15	15 – 16
3	36	25 – 36
4	29	25 – 29
5	15	14 – 15
6	33	11 – 33
7	29	29 – 30
8	16	16 – 17
9	16	16 – 18
10	25	25 – 27
11	30	29 – 30
12	39	39 – 40
13	13	13– 45
14	25	25 - 29
15	25	25 – 26

APÊNDICE E

ARTIGOS COMPLETOS PUBLICADOS

De acordo com as exigências do Regulamento do PPGEE (Programa de Pós-graduação em Engenharia Elétrica) da Faculdade de Engenharia de Ilha Solteira – UNESP o aluno do Doutorado deverá ter publicado ou ter sido aceito para publicação, no mínimo, dois artigos completos, relacionados com a pesquisa da tese, em periódicos, congressos ou eventos similares que possuem corpo técnico de revisores de competência reconhecida pela comunidade científica. Assim sendo, neste Apêndice são apresentados os artigos completos que foram publicados e relacionados com a pesquisa de doutorado:

1. **Lotufo**, A.D.P.; Lopes, M.L.M; and Minussi, C.R. “Dynamic Preventive Control of Electric Power Systems by Neural Networks”. Salvador, Ba, *V INDUSCON-Conferência de Aplicações Industriais*, paper code 144, July 2002.
2. **Lotufo**, A.D.P.; Lopes, M.L.M; and Minussi, C.R. “A Neural Network for Transient Stability Analysis and Preventive Control of Electric Energy Systems”. São Paulo, SP, *Proceedings of VI Brazilian Conference on Neural Networks*, pp. 91-96, June 2003.
3. **Lotufo**, A.D.P.; Lopes, M .L. M; e Minussi, C.R. “Análise de Sensibilidade por Redes Neurais Para Aplicação em Estabilidade Transitória de Sistemas Elétricos de Potência”. Ilha Solteira, SP, 3º Congresso Temático de Dinâmica e Controle da SBMAC, DINCON 2004, junho 2004, pp.1347-1354.

Foram publicados (ou aceitos para publicação), também , em parceria com os demais integrantes da equipe de trabalho (Orientador / Orientandos), outros artigos completos sobre análise de estabilidade transitória e previsão de carga por redes neurais. Estes artigos também estão inseridos no contexto da pesquisa de doutorado, ou seja, análise de controle preventivo dinâmico.

4. Minussi, C.R., Ramos, L.M. Marchiori, S.C. Lopes, M.L.M. and **Lotufo, A.D.P.** “Neural Networks to Transient Stability Analysis of Electrical Power Systems”, Proceedings of the V Brazilian Conference on Neural Networks - *V Congresso Brasileiro de Redes Neurais*, pp. 31-36, 2001 - PUC, Rio de Janeiro – RJ.
5. Marchiori, S.C., Minussi, C.R. e **Lotufo, A.D.P.** “Rede Neural ARTMAP Nebulosa Para Análise de Estabilidade Transitória de Sistemas de Energia Elétrica”. *Learning and Nonlinear Models*, pp. 61-78, Vol. 1, N.1, 2002.
6. Lopes, M.L.M.; Minussi, C.R.; **Lotufo, A.D.P.** “Electric Load Forecasting Formulation by a Fast Neural Network”, *Engineering Intelligent Systems*, pp.51-57, Vol. 11, N. 1, March 2003.
7. Silveira, M.C.G.; **Lotufo, A.D.P.** and Minussi, C.R. “Transient Stability Analysis of Electrical Power Systems Using a Neural Network Based on Fuzzy ARTMAP”, Bologna, Itália, *IEEE Bologna Power-Tech 2003*, June 2003, 7 p. Paper No. 43.
8. Lopes, M.L.M.; **Lotufo A.D.P.** and Minussi, C.R. “A Fast Electric Load Forecasting Using Adaptive Neural Networks”, Bologna, Itália, *IEEE Bologna Power-Tech 2003*, 2003. 6 p. Paper No. 48.
9. Ferreira, W.P., Silveira, M.C.G. **Lotufo A.D.P.**, e Minussi, C.R. “Análise de Estabilidade Transitória de Sistemas de Energia Elétrica Por Rede Neural Baseada na Teoria Da Ressonância Adaptativa”, *CLAGTEE, 5th Latin American Congress on Electricity Generation and Transmission*, Águas de São Pedro, SP, novembro 2003.
10. Lopes, M.L.M.; **Lotufo A.D.P.** e Minussi, C.R. “Previsão de Curto-Prazo de Cargas Elétricas Por Redes Neurais”, *CBA 2004*, outubro-2004, Gramado-RS, 6 p. Artigo aceito para apresentação e publicação.
11. Ferreira, W.P. Silveira, M.C.G. e **Lotufo, A.D.P.** e Minussi, C.R. “Análise de Estabilidade Transitória de Sistemas de Energia Elétrica Via Rede Neural ART-ARTMAP Nebulosa”, *VIII Simpósio Brasileiro de Redes Neurais*, São Luiz – MA, 6 p. Artigo aceito para apresentação e publicação.

12. Lopes, M.L.M.; Minussi, C.R. and **Lotufo, A.D.P.** “Electric Load Forecasting Using a Fuzzy ART&ARTMAP Neural Network”, *Applied Soft Computing Journal*. 6 p. Artigo aceito para publicação.

Livros Grátis

(<http://www.livrosgratis.com.br>)

Milhares de Livros para Download:

[Baixar livros de Administração](#)

[Baixar livros de Agronomia](#)

[Baixar livros de Arquitetura](#)

[Baixar livros de Artes](#)

[Baixar livros de Astronomia](#)

[Baixar livros de Biologia Geral](#)

[Baixar livros de Ciência da Computação](#)

[Baixar livros de Ciência da Informação](#)

[Baixar livros de Ciência Política](#)

[Baixar livros de Ciências da Saúde](#)

[Baixar livros de Comunicação](#)

[Baixar livros do Conselho Nacional de Educação - CNE](#)

[Baixar livros de Defesa civil](#)

[Baixar livros de Direito](#)

[Baixar livros de Direitos humanos](#)

[Baixar livros de Economia](#)

[Baixar livros de Economia Doméstica](#)

[Baixar livros de Educação](#)

[Baixar livros de Educação - Trânsito](#)

[Baixar livros de Educação Física](#)

[Baixar livros de Engenharia Aeroespacial](#)

[Baixar livros de Farmácia](#)

[Baixar livros de Filosofia](#)

[Baixar livros de Física](#)

[Baixar livros de Geociências](#)

[Baixar livros de Geografia](#)

[Baixar livros de História](#)

[Baixar livros de Línguas](#)

[Baixar livros de Literatura](#)
[Baixar livros de Literatura de Cordel](#)
[Baixar livros de Literatura Infantil](#)
[Baixar livros de Matemática](#)
[Baixar livros de Medicina](#)
[Baixar livros de Medicina Veterinária](#)
[Baixar livros de Meio Ambiente](#)
[Baixar livros de Meteorologia](#)
[Baixar Monografias e TCC](#)
[Baixar livros Multidisciplinar](#)
[Baixar livros de Música](#)
[Baixar livros de Psicologia](#)
[Baixar livros de Química](#)
[Baixar livros de Saúde Coletiva](#)
[Baixar livros de Serviço Social](#)
[Baixar livros de Sociologia](#)
[Baixar livros de Teologia](#)
[Baixar livros de Trabalho](#)
[Baixar livros de Turismo](#)