

unesp

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

DISSERTAÇÃO DE MESTRADO
EM
ENGENHARIA ELÉTRICA

1210000987



Te.987

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

"ANÁLISE DE ESTABILIDADE TRANSITÓRIA DE SISTEMAS DE
ENERGIA ELÉTRICA ATRAVÉS DE REDES NEURONAIS"

DISSERTAÇÃO SUBMETIDA À UNIVERSIDADE ESTADUAL PAULISTA - UNESP,
PARA OBTENÇÃO DO TÍTULO DE MESTRE EM ENGENHARIA ELÉTRICA (ME).

MARIA DO CARMO GOMES DA SILVEIRA

1210000987



17295
12.04.95-UNESP

UNESP- "CAMPUS" DE ILHA SOLTEIRA SERVIÇO DE BIBLIOTECA E DOCUMENTAÇÃO	
DATA DE CHEGADA	DATA DE TCMB 30.08.95
REGISTRO POR Oulza	TOMBO Te. 987
ACQUIÇÃO Locação R\$ 20,00 Autor	CLASSIFICAÇÃO

ILHA SOLTEIRA-SP, DEZEMBRO DE 1994


**ANÁLISE DE ESTABILIDADE TRANSITÓRIA DE SISTEMAS DE ENERGIA
ELÉTRICA ATRAVÉS DE REDES NEURONAIS**


MARIA DO CARMO GOMES DA SILVEIRA


DISSERTAÇÃO SUBMETIDA À FACULDADE DE ENGENHARIA DE ILHA
SOLTEIRA - UNESP COMO PARTE DOS REQUISITOS NECESSÁRIOS PARA
A OBTENÇÃO DO TÍTULO DE MESTRE EM ENGENHARIA ELÉTRICA (ME).


ANTONIO PADILHA FELTRIN, D.Sc. - COORDENADOR

BANCA EXAMINADORA


CARLOS ROBERTO MINUSSI, D.Sc. - ORIENTADOR


ANTONIO PADILHA FELTRIN, D.Sc.


GERALDO CAIXETA GUIMARÃES, PhD.

ILHA SOLTEIRA, DEZEMBRO-94

BCpIS
FEIS-UNESP

RESUMO

Este trabalho tem por objetivo investigar o emprego de Redes Neurais Artificiais no diagnóstico da estabilidade transitória de Sistemas de Energia Elétrica (determinação de tempos críticos para faltas tipo curto-circuito com saída de operação de linha de transmissão). Redes Neurais são concepções inspiradas no funcionamento do cérebro, exibem, por conseguinte, capacidade de aprender com a experiência baseada em estímulos entrada-saída (treinamento supervisionado) ou somente entrada (treinamento não-supervisionado). São capazes de estabelecer mapeamentos de sistemas altamente complexos, como é o caso do problema da estabilidade transitória, inferidos através de relações entre conjuntos de dados de entrada e saída. A rede neuronal utilizada é do tipo não-recorrente composta por neurônios de McCulloch-Pitts com não-linearidades sigmoidais. O treinamento da rede é efetuado através do algoritmo *Back-Propagation* com momento. A entrada é composta pelo vetor potência ativa nodal e dados sobre o defeito, representados de modo análogo ao código binário. A saída (tempo crítico) é determinada através de um programa computacional baseado em uma metodologia híbrida — simulação / método direto de Liapunov. Trata-se de uma rede de menor dimensão em comparação às principais proposições encontradas na literatura, necessitando, conseqüentemente, um menor custo computacional na execução do treinamento. O modelo dinâmico do sistema é representado pelo modelo clássico e o estado encontra-se referido ao centro de ângulos. Modelos mais elaborados, em princípio, podem ser analisados, fazendo-se as devidas adaptações. Apresenta-se uma aplicação considerando um sistema composto por 08 máquinas síncronas, 23 linhas de transmissão e 17 barras como forma de ilustração da metodologia proposta.



ABSTRACT

This work aims to investigate the use of artificial neural networks in the analysis of the transient stability of Electric Power Systems (determination of critical clearing time for short-circuit faults type with electric power transmission line outage). Neural networks are conceptions inspired in the brain functioning. They show, therefore, ability to learn with experience based either in input-output stimulus (supervised learning) or only in input stimulus (non-supervised learning). They are capable to map highly complex systems as is the case of transient stability problems, deduced from relations between sets of input and output data. The neural network used is of the feedforward type made up of neurons of McCulloch-Pitts with sigmoidal non-linearities. The network training is carried out by the Back-Propagation with moment algorithm. The input is compounded by the nodal active power vector and the fault data, represented in a similar way to the binary code. The output (critical clearing time) is determined through a computational program based in a hybrid methodology using simulation / Lyapunov Direct Method. That is a network of reduced dimension when compared to the main proposals found in the literature. For this reason it has a smaller computational cost to perform the training. The system dynamic model is represented by the classical model and the state is referred to the inertial center. More elaborated models, in principle, can be analyzed doing the necessary adaptations. To illustrate the proposed methodology, it is presented an application considering a system having by 08 synchronous machines, 23 transmission lines, and 17 busbars.



Aos meus pais, José e Maria.



Ao meu marido, Cícero José.
Aos meus filhos, Jaqueline e Vinícius.



AGRADECIMENTOS

Ao Prof. Dr. **Carlos Roberto Minussi**, pela dedicação do seu tempo em função do meu crescimento profissional, pelo apoio frente aos problemas encontrados e pela proveitosa orientação.

A UNESP - Campus de Ilha Solteira, pelas condições que me foram dadas para que esse trabalho se realizasse, professores e colegas do Curso de Pós-Graduação em Engenharia Elétrica, funcionários e a todos aqueles que deram contribuição para que este trabalho se concretizasse.

Aos meus pais, que são os primeiros a me incentivar nos estudos, pelo constante e tão necessário apoio.

Ao meu marido pelo apoio e incentivo na minha carreira profissional.

Aos meus filhos pelas horas em que estive ausente, em função da realização desse trabalho.



NOTAÇÃO E SIMBOLOGIA

Os superscritos (e) e (p) denotam os estados e configurações sob e pós-defeito, respectivamente.

Letras em negrito maiúsculas e minúsculas representam matrizes e vetores.

$\mathbf{R}$ = campo dos números reais

$\| \mathbf{a} \|_e$ = norma Euclidiana de $\mathbf{a} \in \mathbf{R}^q$

$\langle \mathbf{a}, \mathbf{b} \rangle$ = produto interno de $\mathbf{a}$ e $\mathbf{b} \in \mathbf{R}^q$

SEE = Sistema de Energia Elétrica

ng = número de máquinas que compõem o sistema

$P_i(\delta)$ = $P_{m_i} - P_{e_i}$

P_{m_i} = potência mecânica de entrada (pu)

P_{e_i} = potência elétrica entregue pela máquina síncrona (pu)

M_i = $2H_i/2\pi f_0$

H_i = constante de inércia (s)

f_0 = frequência nominal da rede (60Hz)

D_i = constante de amortecimento (pu)

δ_i = posição angular medida com relação a um eixo que gira à velocidade síncrona (rad.elét.)



- w_i = desvio de velocidade angular da máquina síncrona com relação à velocidade síncrona (rad. elét./s)
- N = $\{1, 2, \dots, n_g\}$ = conjunto de índices das máquinas que compõem o sistema
- t = tempo (s)
- $g_i(\theta)$ = $P_{m_i} - P_{e_i} - (M_i/MT) PCA$
- PCA = potência acelerante do centro de ângulos
 $= \sum_{j \in N} (P_{m_j} - P_{e_j})$
- MT = $\sum_{j \in N} M_j$
- θ_i = posição angular da i-ésima máquina síncrona referida ao centro de ângulos
 $= \delta_i - \delta_0$
- ω_i = velocidade angular da i-ésima máquina síncrona referida ao centro de ângulos
 $= w_i - w_0$
- δ_0 = $MT^{-1} \sum_{j \in N} M_j \delta_j$
- w_0 = $MT^{-1} \sum_{j \in N} M_j w_j$
- F_{ij} = $E_i E_j B_{ij}$
- H_{ij} = $E_i E_j G_{ij}$
- E_k = tensão interna da k-ésima máquina síncrona
- Y_{AD} = matriz de admitância nodal do sistema
- Y_{RED} = matriz de barra reduzida às barras internas de geração
- G_{ij} = condutância de transferência entre a i-ésima máquina e a j-ésima máquina síncrona



B_{ij}	= susceptância de transferência entre a i-ésima máquina e a j-ésima máquina síncrona
B-P	= algoritmo <i>Back-Propagation</i>
$\mathbf{X}$	= vetor padrão = $[x_1 \ x_2 \ x_3 \ \dots \ x_n]^T$
T	= transposto
$\mathbf{W}$	= vetor peso = $[w_1 \ w_2 \ \dots \ w_n]^T$
$\mathbf{U}$	= $[x_0 = +1 \ \mathbf{X}^T]^T$
$\mathbf{V}$	= $[w_0 \ \mathbf{W}^T]^T$
v_{ij}	= peso correspondente à interligação entre o i-ésimo e j-ésimo neurônio
w_0	= peso <i>bias</i>
$\mathbf{Y}$	= vetor contendo a saída da rede neuronal
ε_i	= erro do i-ésimo neurônio da camada de saída da rede = $d_i - y_i$
λ	= constante que determina a inclinação da função sigmóide
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
μ	= parâmetro de controle da estabilidade do processo iterativo
h	= índice de iteração

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

η = constante momento

σ_i = $\text{sgm}'(s_i)$
= derivada da função sigmóide com relação a s_i
= $\lambda y_i (1 - y_i)$

s = saída do neurônio

sigmóide = não-linearidade tipo tangente hiperbólica

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

$\mathbf{H}$ = $E[\mathbf{X}\mathbf{X}^T]$

E = valor esperado

$\mathbf{P}$ = $[P_1 \ P_2 \ \dots \ P_\rho]^T$

P_i = potência ativa da i -ésima barra do sistema

$\mathbf{Bin}$ = vetor contendo o número da contingência representado em código de modo idêntico ao código binário

ρ = número de barras do sistema

nb = número de *bits* correspondente ao número da contingência

$\epsilon_{\text{máx}}$ = erro máximo admissível

PEBS = Superfície Limite de Energia Potencial (*Potential Energy Boundary Surface*)

$E(\theta, \omega)$ = energia total do sistema
= $E_c(\omega) + E_p(\theta)$

$E_c(\omega)$ = energia cinética

$E_p(\theta)$ = energia potencial

E_{crit} = energia total crítica do sistema

E_e = energia total correspondente ao tempo de eliminação de defeito

M = margem de segurança do sistema

$D(\theta)$ = derivada direcional da energia potencial.

x

SUMÁRIO

1. INTRODUÇÃO	01
2. MODELO DO SISTEMA.....	04
2.1. INTRODUÇÃO	04
2.2. MODELO DO SISTEMA REFERIDO AO CENTRO DE ÂNGULOS	05
2.3. CONCLUSÃO	10
3. REDES NEURONAIS ARTIFICIAIS	11
3.1. INTRODUÇÃO	11
3.2. MODELO DE NEURÔNIO	11
3.2.1 MODELO BIOLÓGICO	12
3.2.2. MODELO NEURONAL ARTIFICIAL	13
3.3. ESTRUTURA DE REDES NEURONAIS.....	16
3.4. TREINAMENTO DE REDES NEURONAIS.....	17
3.5. TREINAMENTO ATRAVÉS DO ALGORITMO <i>BACK-PROPAGATION</i>	20
3.5.1. <i>BACK-PROPAGATION</i> COM MOMENTO.....	24
3.6. O ALGORITMO <i>BACK-PROPAGATION</i>	27
3.7. PROBLEMAS DO TREINAMENTO	27
3.7.1. PARALISIA DA REDE	27
3.7.2. MÍNIMOS LOCAIS	28
3.7.3. TAMANHO DO PASSO	28
3.8. CONCLUSÃO	29
4. REDE NEURONAL PROPOSTA.....	30
4.1. INTRODUÇÃO	30
4.2. DIMENSIONAMENTO DA REDE.....	30
4.2.1. NÚMEROS DE CAMADAS	31
4.2.2. NÚMEROS DE NEURÔNIOS POR CAMADA.....	31



4.3. FUNÇÃO SIGMÓIDE	32
4.4. ESTÍMULOS ENTRADA-SAÍDA.....	34
4.5. CONCLUSÃO	37
5. RESULTADOS	38
5.1. INTRODUÇÃO	38
5.2 RESULTADOS	38
5.3. CONCLUSÃO	47
6. CONCLUSÃO E SUGESTÕES PARA FUTUROS TRABALHOS	48
6.1. CONCLUSÃO	48
6.2. SUGESTÕES PARA FUTUROS TRABALHOS	49
7. REFERÊNCIAS BIBLIOGRÁFICAS	50
APÊNDICE A - DETERMINAÇÃO DE TEMPOS CRÍTICOS.....	57
1. IMPLEMENTAÇÃO COMPUTACIONAL	57



CAPÍTULO 1

INTRODUÇÃO

A análise de Estabilidade Transitória constitui-se num dos principais estudos realizados em SEE (Sistemas de Energia Elétrica). Esta análise pode ser efetuada, *e.g.*, por simulação (solução numérica das equações diferenciais não-lineares que descrevem a dinâmica do sistema). Um procedimento alternativo consiste na obtenção da análise sem resolver tais equações diferenciais, como é o caso do Método Direto de Liapunov ([34], [39]).

Tendo em vista o grande número de contingências a serem analisadas, a simulação, assim como o Método Direto de Liapunov, são procedimentos que ainda apresentam custos computacionais pouco compatíveis com as aplicações em tempo real. Neste trabalho, procurar-se-á, então, investigar o uso de Redes Neurais Artificiais no diagnóstico da Estabilidade Transitória de SEE, tendo como principal objetivo a redução do custo computacional.

Redes Neurais são concepções em *hardware* e / ou *software* baseadas no modelo de como o cérebro humano codifica e processa informações. As aplicações são geralmente destinadas às soluções de problemas difíceis de serem obtidas através de rotinas convencionais em computadores digitais, *e.g.*, visão artificial, memória endereçada por conteúdo, controle em tempo-real, otimização combinatória, etc. Em SEE destacam-se as seguintes aplicações: previsão de carga ([8], [16], [17], [36], [37]), análise de segurança estática ([2], [18], [31], [51]), análise de estabilidade transitória / determinação de tempos críticos ([7], [27], [28], [35], [45]), identificação de fontes harmônicas ([13], [33]), modelagem de cargas ([24]), análise e identificação de faltas ([19], [21]), reconfiguração de redes de distribuição ([20]), despacho econômico ([38]) e outros tipos de aplicações ([1], [43], [46]).



Para se obter os resultados desejados, ou seja, que a rede tenha condições de efetuar análises complexas, como o caso de problemas de Estabilidade Transitória em SEE, tais redes são configurações dotadas de várias unidades de neurônios dispostos em fileiras, formando um arranjo complexo de interligações ([3], [6], [9], [11], [12], [14], [15], [22], [23], [25], [42], [47]).

As interligações são formadas por pesos que devem ser ajustados em função de um conjunto de padrões que produzam saídas (soluções) desejadas. Esta atividade é definida Treinamento ou Aprendizado, sendo elaborado em *off-line*. Uma vez ajustada convenientemente, a rede deverá ser capaz de emitir, para padrões não constantes no conjunto de treinamento, um diagnóstico com precisão satisfatória.

Deste modo, para o caso de Estabilidade Transitória de SEE, este diagnóstico pode ser efetuado sem custo computacional. Isto, em princípio, pode ser visto como uma possibilidade de viabilização da análise em tempo real.

Um projeto de uma Rede Neuronal consiste em definir o tipo, o número de neurônios empregados e o número de fileiras. Consiste, ainda, em construir o conjunto de dados padrão, e em escolher ou propor técnicas para ajustes de pesos. A Rede Neuronal proposta neste trabalho será uma rede multi-fileiras com não-linearidades tipo sigmóide ([25], [47] - [50]).

O ajuste será efetuado através da técnica *Back-Propagation* (B-P) ([40], [41], [48], [49]). Esta técnica tem se mostrado eficiente e não apresenta restrições quanto ao tipo de rede e é considerada pela literatura como um *benchmark* em termos de precisão. Contudo, o tempo de processamento é relativamente alto. A formulação adotada neste trabalho, principalmente, considerando-se a função sigmóide com λ pequeno (λ é uma constante que determina a inclinação da função sigmóide), tem proporcionado um desempenho satisfatório também quanto ao custo computacional. A utilização de λ pequeno, permite uma escolha dos pesos da rede menos restritiva, que de certo modo, diminui a possibilidade de ocorrência de paralisia no algoritmo B-P. A Rede Neuronal será desenvolvida visando a determinação de tempos críticos de eliminação de defeito tipo curto-circuito. Os tempos críticos, para fins de treinamento da rede, serão determinados



através do uso de método híbrido - simulação / Método Direto de Liapunov ([10], [29]) em computadores IBM PC ou compatíveis.

O modelo dinâmico do sistema adotado neste trabalho será o modelo clássico ([4], [39]), com o objetivo exclusivo de reduzir o custo computacional na geração dos dados para o treinamento. Ressalta-se, entretanto, que poderão ser utilizados, em princípio, modelos mais elaborados, sem a necessidade de se promover modificações significativas na arquitetura proposta.

Este texto está assim organizado: No Capítulo 2 apresenta-se o modelo do sistema (modelo clássico) com variáveis de estado referidas ao centro de ângulos do sistema. No Capítulo 3 são apresentados os principais fundamentos teóricos sobre Redes Neurais. No Capítulo 4 apresenta-se o detalhamento da Rede Neuronal proposta para o diagnóstico da Estabilidade Transitória. No Capítulo 5 é apresentado um teste computacional considerando-se um sistema composto por 08 máquinas síncronas, 23 linhas de transmissão e 17 barras comparando-se os resultados obtidos através da Rede Neuronal proposta e através de simulação. Finalmente, no Capítulo 6 apresentam-se as conclusões e sugestões para trabalhos futuros.



CAPÍTULO 2

MODELO DO SISTEMA

2.1. INTRODUÇÃO

O objetivo deste trabalho é investigar a utilização de redes neuronais na determinação de tempos críticos em problemas de estabilidade transitória de SEE (Sistemas de Energia Elétrica).

Redes neuronais são concepções que exibem capacidade de aprenderem com a experiência baseada em estímulos tipo entrada - saída. Com isto é possível efetuar diagnósticos complexos. No caso da análise de estabilidade transitória estes estímulos podem ser definidos através de dados do sistema (entrada) e resposta (saída) determinada, por exemplo, via utilização do programa computacional TRANSDIR (um dos mais conhecidos no setor elétrico) ou um outro *software* disponível aos usuários para esta finalidade. Portanto, redes neuronais podem efetuar análises, em princípio, considerando-se qualquer modelo, bastando apenas compor adequadamente os referidos estímulos. Estes *software* constituem-se num procedimento de simulação da dinâmica do sistema para todo tipo de modelo desde o clássico até o mais elaborado, como o modelo completo de Park.

Neste trabalho serão desenvolvidas análises considerando o modelo dinâmico do sistema correspondente ao modelo clássico, como ponto de partida, tendo em vista, principalmente, a necessidade de se efetuar estudos e testes que possam orientar e / ou propor soluções alternativas para o diagnóstico e controle em tempo real de SEE.



Apresenta-se neste capítulo, o modelo clássico, considerando-se a rede elétrica reduzida às barras internas de geração e ângulos/velocidades referidos ao centro de inércia do sistema.

2.2. MODELO DO SISTEMA REFERIDO AO CENTRO DE ÂNGULOS

Considerando-se um Sistema de Energia Elétrica composto por n máquinas síncronas a equação diferencial que descreve o movimento da i -ésima máquina síncrona (modelo clássico), pode ser expressa por ([4], [5], [10], [34]):

$$M_i \ddot{\delta}_i - P_i(\delta) + D_i \dot{\delta}_i = 0, i \in N \quad (2.2.1)$$

sendo:

i = índice da máquina síncrona atribuído no modelo

$$P_i(\delta) = P_{m_i} - P_{e_i} \quad (2.2.2)$$

$$M_i = 2 H_i / 2\pi f_0$$

H_i = constante de inércia (s)

f_0 = frequência nominal da rede (60 Hz)

D_i = constante de amortecimento (pu)

δ_i = posição angular medida com relação a um eixo que gira à velocidade síncrona (rad. elét.)



w_i = desvio de velocidade angular da máquina síncrona com relação à velocidade síncrona (rad. elét./s)

P_{m_i} = potência mecânica de entrada (pu)

P_{e_i} = potência elétrica entregue pela máquina síncrona (pu)

N = $\{ 1, 2, \dots, n_g \}$ = conjunto de índices das máquinas que compõem o sistema.

A equação diferencial ordinária não-linear de segunda ordem (2.2.1) pode ser decomposta em duas equações diferenciais de primeira ordem, da seguinte forma ([5], [10], [34]):

$$\dot{\delta}_i = w_i \quad (2.2.3)$$

$$M_i \dot{w}_i = P_i(\delta) + D_i w_i, \quad i \in N \quad (2.2.4)$$

O ponto sobre variáveis representa o operador diferencial (d/dt),

sendo:

t = tempo (s).

Neste trabalho considerar-se-á o amortecimento do sistema uniforme ([34]), ou seja:

$$D_i / M_i = D_j / M_j = \text{Constante}, \quad \forall i, j \in N.$$

Tendo em vista a consideração das condutâncias de transferência (parte real da matriz de admitância reduzida às barras internas de geração), é conveniente adotar-se o CENTRO DE ÂNGULOS ([5], [34]) como referência do sistema. Neste caso, e considerando-se os amortecimentos uniformes, o modelo (2.2.3) - (2.2.4) pode ser expresso por ([5], [10], [30], [34]):

$$\dot{\theta}_i = \omega_i \quad (2.2.5)$$

$$M_i \dot{\omega}_i = g_i(\theta) - D_i \omega_i \quad (2.2.6)$$

sendo:

$$g_i(\theta) \triangleq P_{m_i} - P_{e_i} - (M_i / MT) PCA$$

$$PCA \triangleq \text{potência acelerante do centro de ângulos} \quad (2.2.7)$$

$$= \sum_{j \in N} (P_{m_j} - P_{e_j}) \quad (2.2.8)$$

$$MT \triangleq \sum_{j \in N} M_j$$

$$\begin{aligned} \theta_i &= \text{posição angular da } i\text{-ésima máquina síncrona referida ao centro de ângulos} \\ &= \delta_i - \delta_0 \end{aligned} \quad (2.2.9)$$

$$\begin{aligned} \omega_i &= \text{velocidade angular da } i\text{-ésima máquina síncrona referida ao centro de ângulos} \\ &= w_i - w_0 \end{aligned} \quad (2.2.10)$$

em que:

$$\delta_0 = \frac{1}{MT} \sum_{j \in N} M_j \delta_j \quad (2.2.11)$$



$$w_0 = \dot{\delta}_0. \quad (2.2.12)$$

As condutâncias de transferência representam as perdas do sistema no modelo reduzido às barras internas de geração.

A formulação do modelo referido ao centro de ângulos, equações (2.2.5) e (2.2.6), apresenta as seguintes propriedades ([30], [34]):

PROPRIEDADE 1. A potência acelerante do centro de ângulos, avaliada no ponto de equilíbrio estável, é nula ([34]).

PROPRIEDADE 2. O somatório do produto da posição angular θ pela inércia de cada máquina do sistema é igual a zero, *i.e.*,

$$\sum_{j \in N} M_j \theta_j = 0 \quad (2.2.13)$$

PROPRIEDADE 3 O somatório do produto da velocidade angular ω pela inércia de cada máquina do sistema é igual a zero:

$$\sum_{j \in N} M_j \omega_j = 0 \quad (2.2.14)$$



A propriedade 1 é estabelecida a partir da formulação do problema do fluxo de potência, que é determinado fazendo-se ($P_m - P_e = 0$) para todas as máquinas que compõem o sistema. Isto equivale a determinação de um ponto de operação (equilíbrio) do sistema. Deste modo, conclui-se que a PCA é nula quando avaliada em um ponto de operação estável do sistema. A PCA será diferente de zero sempre que houver deslocamento do estado do sistema em torno do ponto de equilíbrio, ou seja, durante as oscilações eletromecânicas.

Da propriedade 2 conclui-se que os ângulos θ_i 's são linearmente dependentes. O mesmo ocorre com as velocidades ω_i 's (Propriedade 3). Por conseguinte, o conhecimento de $(2n - 2)$ variáveis de estado do sistema permite o cálculo das duas variáveis restantes, utilizando-se as equações (2.2.13) e (2.2.14).

A potência elétrica (P_e), no modelo definido pelas equações (2.2.5) e (2.2.6), considerando-se o modelo da rede elétrica reduzida às barras internas de geração, pode ser expressa por ([4]):

$$P_{e_i} = \sum_{\substack{j=1 \\ j \neq i}}^{ng} (F_{ij} \sin \theta_{ij} + H_{ij} \cos \theta_{ij}) + E_i^2 G_{ii} \quad (2.2.15)$$

$$F_{ij} = E_i E_j B_{ij} \quad (2.2.16)$$

$$H_{ij} = E_i E_j G_{ij} \quad (2.2.17)$$

sendo:

E_k = tensão interna da k-ésima máquina síncrona.

Os parâmetros G_{ij} e B_{ij} são definidos como sendo condutância e susceptância de transferência, respectivamente. Estes parâmetros correspondem às partes real e imaginária, respectivamente, da matriz de admitância reduzida às barras internas de geração, definida por ([4]):



$$Y_{RED} = Y_{GG} - Y_{GL} Y_{LL}^{-1} Y_{LG} \quad (2.2.18)$$

sendo que: as matrizes Y_{GG} , Y_{GL} , Y_{LL} e Y_{LG} são sub-matrizes da matriz de admitância nodal do sistema, considerando-se as barras internas de geração e cargas transformadas em admitâncias constantes, definida por ([4]):

$$Y_{AD} = \begin{bmatrix} Y_{GG} & Y_{GL} \\ Y_{LG} & Y_{LL} \end{bmatrix} \quad (2.2.19)$$

sendo:

os subscritos G e L representam os índices relativos às barras de geração e cargas, respectivamente.

2.3. CONCLUSÃO

Foi apresentado neste Capítulo o modelo dinâmico do sistema para fins de estudo da estabilidade transitória. Este modelo corresponde ao modelo clássico com redução às barras internas de geração e o estado referido ao centro de inércia do sistema.



CAPÍTULO 3

REDES NEURONAIS ARTIFICIAIS

3.1. INTRODUÇÃO

Apresenta-se, neste Capítulo, os principais conceitos sobre Redes Neurais Artificiais, visando o diagnóstico da estabilidade transitória de Sistemas de Energia Elétrica, especificamente na determinação de tempos críticos de eliminação de defeitos tipo curto-circuito com saída de operação de linha de transmissão.

Serão apresentados a estrutura de uma rede neuronal *feedforward*, seus componentes e funcionamento. Serão abordados as formas de treinamento. Neste contexto, apresentar-se-á o desenvolvimento matemático do algoritmo *Back-Propagation* convencional e com momento.

3.2. MODELO DE NEURÔNIO

Apresenta-se, a seguir, o modelo de neurônio biológico mais conhecido na literatura. Ressalta-se que vários tipos de neurônios têm sido identificados, cada qual se distingue dos demais pela forma do corpo celular. Estas diferenças morfológicas exibem especializações funcionais importantes. A identificação das funções destes neurônios






FIGURA 1 . Modelo de um neurônio biológico.

3.2.2. MODELO NEURONAL ARTIFICIAL

Os modelos de neurônios artificiais foram concebidos baseados no funcionamento dos neurônios biológicos. Vários modelos foram propostos na literatura. Apresenta-se, a seguir, o modelo de McCulloch-Pitts ([26]) que é o mais empregado na área. O modelo deste neurônio é mostrado na Figura 2.

Este modelo consiste de uma atividade s que é a soma de n entradas (X) ponderadas por seus respectivos pesos (W). Esta atividade alimenta uma função não-linear $f(.)$ que produz um sinal que será conduzido aos demais neurônios. As não-




FIGURA 2. Modelo de neurônio de McCulloch-Pitts.

linearidades mais empregadas são funções tipo relé, lógica *threshold*, linear com saturação e sigmóide. As não-linearidades tipo relé e lógica *threshold* são apropriadas para trabalhos com dados binários, enquanto que a função sigmóide é recomendada para aplicações cujos dados de entrada são analógicos. O neurônio de McCulloch-Pitts pode conter, ainda, um peso *bias* w_0 alimentado por uma constante $x_0 = +1$ que atua como controle do nível de saída do neurônio.

A função do peso *bias* pode ser demonstrada como no modelo abaixo. Considera-se, como ilustração, o neurônio de McCulloch-Pitts com não-linearidade tipo relé.

Os vetores padrão de entrada e pesos podem ser expressos por:

$$U = [x_0 = 1 \quad X^T]^T \quad (3.2.2.1)$$

e

14

$$\mathbf{V} = [w_0 \ \mathbf{W}^T]^T \quad (3.2.2.2)$$

sendo:

$$\mathbf{X} = [x_1 \ x_2 \ x_3 \ \dots \ x_n]^T$$

$$\mathbf{W} = [w_1 \ w_2 \ w_3 \ \dots \ w_n]^T$$

$$w_0 = \text{peso } bias$$

$$(T) = \text{transposto.}$$

Os vetores $\mathbf{U}$ e $\mathbf{V}$ possuem dimensões $(n+1)$. A saída do neurônio pode ser, então, expressa por:

$$s = \mathbf{U}^T \mathbf{V} \text{ (hiperplano)} \quad (3.2.2.3)$$

Esta saída intermediária (s) passa por uma não-linearidade tipo relé. Assim, este neurônio separa, se possível, padrões em duas classes, ou seja, $+1$ e -1 . Estas classes são determinadas pelos valores positivos e negativos de (s), respectivamente. Portanto, $s = 0$ representa um hiperplano de comutação. Neste caso, os vetores $(n+1)$ - dimensionais $\mathbf{U}$ e $\mathbf{V}$ são ortogonais entre si. A saída (s) pode ser expressa como:

$$s = x_0 \ w_0 + \mathbf{W}^T \mathbf{X} \quad (3.2.2.4)$$

Assim, o valor de (s) na origem ($\mathbf{X} = \mathbf{0}$) vale:

$$s = x_0 (x_0 = 1) w_0 = w_0 \quad (3.2.2.5)$$

Conclui-se, então, que (s) passa pela origem se e somente se $w_0 = 0$. Deste modo, o termo *bias* produz um deslocamento do hiperplano de comutação com relação à origem, enquanto os pesos W determinam as inclinações do hiperplano. Portanto, o termo *bias* tem a função de ampliar a capacidade de realização do neurônio.

Com $w_0 = 0$ não é possível realizar uma das funções lógicas mais simples (duas entradas), como é o caso da função AND.

A função lógica NOR EXCLUSIVO somente poderá ser realizada com neurônios adaptativos lineares (McCulloch-Pitts), através de interligações de pelo menos três neurônios dispostos em duas camadas. Desta forma, para a realização de funções mais complexas, surge a necessidade de trabalhar com estruturas neuronais interligadas como mostra-se a seguir.

3.3. ESTRUTURA DE REDES NEURONAIS

Uma Rede Neuronal Artificial é composta por elementos de processamento (neurônios) dispostos em camadas e suas interligações (sinapses). Cada neurônio pode conter várias entradas e somente uma saída. Porém, cada saída pode ser utilizada como entrada a vários neurônios através das interligações, assim como, cada neurônio pode receber várias entradas procedentes de outros neurônios.

Na estrutura formada por neurônios com não-linearidades tipo relé, se a soma das entradas ponderadas de um determinado neurônio exceder a um valor limite, o neurônio "dispara" e assim é enviado um sinal para os demais. Cada interligação entre neurônios possui um peso que determina sua contribuição na decisão de disparo, controlando, deste modo, os estímulos. Para outros tipos de não linearidades os princípios de funcionamento são semelhantes.



As redes neuronais podem ser classificadas em dois tipos: redes recorrentes e redes não-recorrentes.

DEFINIÇÃO 1: Rede Recorrente. Uma rede é definida como recorrente se ela contém laços de realimentação, ou seja, contém conexões através das saídas de uma determinada camada para a entrada da mesma ou de camadas anteriores.

DEFINIÇÃO 2: Rede Não-Recorrente. Uma rede é definida como não-recorrente ou *feedforward* se ela não contém laços de realimentação.

Redes não-recorrentes não têm memória; sua saída é exclusivamente determinada em função da entrada e dos valores dos pesos.

Ressalta-se, porém, que a finalidade deste trabalho é a aplicação de redes neuronais no diagnóstico da estabilidade transitória de SEE, portanto, neste caso, a rede a ser utilizada é do tipo não-recorrente. Na Figura 3 mostra-se uma estrutura de redes neuronais *feedforward* considerando-se os neurônios tipo McCulloch-Pitts.

3.4.TREINAMENTO DE REDES NEURONAIS

O treinamento ou aprendizado de redes neuronais consiste em ajustar os pesos correspondentes às interligações dos neurônios que compõem a rede. Em redes neuronais existem, basicamente, dois tipos de treinamento: supervisionado e não-supervisionado.






FIGURA 3. Estrutura de uma rede neuronal não-recorrente.

DEFINIÇÃO 3. Treinamento Supervisionado. Treinamento Supervisionado consiste no ajuste de pesos de uma rede neuronal para fornecer saídas desejadas, considerando-se o conjunto de padrões de entrada.

O treinamento supervisionado necessita de um par de cada vetor entrada com um vetor alvo representando a saída desejada; juntos eles são chamados de um par treinado.

DEFINIÇÃO 4. Treinamento Não-Supervisionado. Treinamento Não-Supervisionado consiste num mecanismo de ajuste de pesos de uma rede neuronal, levando-se em conta somente o conjunto de padrões de entrada.

O treinamento não-supervisionado, desenvolvido por Kohonen ([22], [23]) e muitos outros, não necessita de um alvo para as saídas, e portanto, nenhuma comparação é necessária para respostas pré-determinadas. O conjunto treinado consiste exclusivamente de vetores entradas. O processo de treinamento extrai as propriedades estatísticas de um conjunto treinado e grupos de vetores similares em classes.

Para o problema específico de análise de estabilidade transitória, a rede neuronal será, como mencionado anteriormente, do tipo não-recorrente e treinamento supervisionado. O treinamento supervisionado será adotado devido ao tipo de problema a ser tratado, que consiste em armazenar a informação baseada em estímulos entrada-saída. A entrada é formada pelos parâmetros mais importantes do modelo do sistema, *e.g.*, potência mecânica, tensões nodais e dados sobre a topologia da rede e de falta, enquanto que a saída corresponde, no caso deste trabalho, ao tempo crítico para uma determinada contingência do sistema. Este item será abordado no Capítulo 4.

O treinamento para este tipo de rede tem sido feito, na maioria dos trabalhos da área, através do algoritmo B-P (*Back-Propagation*) ([6], [9], [25], [32], [44] - [49]). O algoritmo B-P foi desenvolvido por Werbos ([47]) e, efetivamente notabilizado por Rumelhart ([44], [45]). Neste trabalho será utilizado o B-P para o treinamento utilizado como descrito a seguir.

DEFINIÇÃO 5. BACK-PROPAGATION. O algoritmo *Back-Propagation* é um procedimento para treinamento de redes neurais *feedforward*, cujos pesos são adaptados através da propagação do sinal de erro do sentido da saída para a entrada.



3.5. TREINAMENTO ATRAVÉS DO ALGORITMO *BACK-PROPAGATION*

O algoritmo B-P é um procedimento sistemático de adaptação de pesos de redes neurais baseado no método gradiente descendente, que geralmente tem um custo computacional elevado, em vista da necessidade da limitação da magnitude do passo, como forma de controle da estabilidade de convergência, da possibilidade de ocorrência de paralisia (ajuste nulo de parâmetros) sob certas circunstâncias, etc., porém, é bastante preciso. Esta técnica será adotada neste trabalho, com devidas alterações, que a tornam bastante competitiva, se comparada à formulação convencional ([44], [45], [49]).

O algoritmo B-P consiste na adaptação de pesos tal que é minimizado o erro (diferença entre o valor desejado e saída) quadrático da rede. A soma do erro quadrático instantâneo de cada neurônio alocado na última camada (saída da rede) é dada por ([49]):

$$\varepsilon^2 = \sum_{i=1}^{ns} \varepsilon_i^2 \quad (3.5.1)$$

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, o ajuste de pesos pode ser formulado do seguinte modo ([49]):

$$V_i(h+1) = V_i(h) + \mu [-\nabla_i(h)] \quad (3.5.2)$$



sendo:

μ = parâmetro de controle da estabilidade do processo iterativo;

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 (3.5.2) a direção adotada para se minimizar a função objetivo do erro quadrático corresponde à direção contrária ao gradiente.

O gradiente $\nabla_i(h)$ pode ser expresso por:

$$\nabla_i(h) = \partial[(\epsilon_i)^2] / \partial V_i(h) = 2 \epsilon_i \partial \epsilon_i / \partial V_i \quad (3.5.3)$$

Tendo em vista que o problema a ser abordado corresponde à determinação de tempos críticos em SEE, a função não-linear a ser utilizada é a função sigmóide definida por:

$$y_i = 1 / [1 + \exp(-\lambda s_i)] \quad (3.5.4)$$

sendo:

λ = constante que determina a inclinação da curva.

$$s_i = (U_i)^T V_i. \quad (3.5.5)$$



Para se trabalhar com modelos binários devem-se adotar valores grandes (maiores que 1) para o parâmetro λ , enquanto que para modelos contínuos é recomendado adotá-lo considerando-se valores de menor magnitude (menores que 1).

Considerando-se a função sigmóide, dada pela equação (3.5.4), o gradiente do erro ϵ_i com relação ao vetor peso V_i , pode ser expresso por:

$$\partial \epsilon_i / \partial V_i = - \text{sgm}'(s_i) \partial s_i / \partial V_i \quad (3.5.6)$$

em que:

$\text{sgm}'(s_i)$ = derivada parcial de y_i com relação a s_i .

Da equação (3.5.5), obtém-se:

$$\partial s_i / \partial V_i = U_i. \quad (3.5.7)$$

Substituindo-se (3.5.7) na equação (3.5.6), resulta em:

$$\partial \epsilon_i / \partial V_i = - \text{sgm}'(s_i) U_i \quad (3.5.8)$$

Finalmente, substituindo-se (3.5.8) em (3.5.3) e, em seguida, substituindo-se o resultado em (3.5.2), obtém-se ([49]):

$$V_i(h+1) = V_i(h) + 2 \mu \epsilon_i \text{sgm}'(s_i) U_i \quad (3.5.9)$$

A derivada parcial de (s_i) com relação a V_i , considerando-se a função sigmóide (3.5.4), pode ser expressa por:



$$\text{sgm}'(s_i) = \lambda y_i (1 - y_i) . \quad (3.5.10)$$

Nas Figuras (4) e (5), respectivamente, mostram-se as formas da função sigmóide (3.5.4) e de $\text{sgm}'(s_i)$ (3.5.10).




FIGURA 4. Comportamento da função sigmóide (y_i) para λ igual a 1.

Numa forma simples, o treinamento, via B-P, inicia-se 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 saída). O próximo passo consiste na determinação do erro propagado no sentido inverso, através da rede associada à derivada




FIGURA 5. Comportamento da derivada parcial ($\text{sgm}'(s_i)$) de s_i com relação a V_i para λ igual a 1.

parcial do erro quadrático de cada elemento com relação aos pesos e, finalmente, ajustando os pesos de cada elemento. Um novo padrão é apresentado — o processo é repetido e assim por diante. Os pesos iniciais são normalmente adotados como números randômicos ([49]), visto que a inicialização nula, em redes multi-fileiras, via B-P, quase sempre proporciona baixa convergência.

3.5.1. BACK-PROPAGATION COM MOMENTO

O algoritmo B-P é abordado na literatura sob várias formas com o propósito de torná-lo mais rápido computacionalmente. Uma formulação bastante interessante é o algoritmo B-P COM MOMENTO ([49]). A adaptação de pesos, neste caso, pode ser formulado da seguinte forma ([49]):

$$v_{ij}(h+1) = v_{ij}(h) + \Delta v_{ij}(h) \quad (3.5.1.1)$$

sendo:

$$\Delta v_{ij}(h) = 2\mu(1 - \eta)\beta_j x_i + \eta\Delta v_{ij}(h-1). \quad (3.5.1.2)$$

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

η = constante momento. ($0 \leq \eta < 1$) ([49]).

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

$$\beta_j = \sigma_j \varepsilon_j \quad (3.5.1.3)$$

em que:

$$\begin{aligned}\sigma_j &= \text{derivada da função sigmóide com relação a } s_j \\ &= \lambda y_j (1 - y_j).\end{aligned}$$

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

$$\beta_j = \sigma_j \sum_{k \in R(j)} w_{jk} \beta_k \quad (3.5.1.4)$$

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 μ que serve como controle de estabilidade do processo iterativo é dependente de λ . Para λ igual a 1, μ pode ser arbitrado de modo semelhante ao problema do treinamento de redes *feedforward* com não-linearidades tipo relé, considerando-se os seguintes limites como um indicativo para o caso de redes sigmoidais ([49]):

$$0 < \mu < 1 / \text{traço} [\mathbf{H}] \quad (3.5.1.5)$$

em que:

$$\mathbf{H} = E [\mathbf{X} \mathbf{X}^T]$$

E = valor esperado.

Valores de λ menores (maiores) para sistemas com o parâmetro μ pode ser relaxado (menos restritivo), se comparado à especificação fornecida pela equação (5.5.14).

Em síntese, o treinamento da rede, basicamente, é efetuado em neurônios alocados na última camada e demais camadas, como é mostrado nos esquemas apresentados nas Figuras 6 e 7, respectivamente.






FIGURA 6. Treinamento de um neurônio situado na última camada.




FIGURA 7. Treinamento de um neurônio alocado na primeira até a penúltima camada.

3.6. O ALGORITMO *BACK-PROPAGATION*

Os pesos da rede devem ser inicializados randomicamente considerando-se o intervalo $\{0,1\}$.

O treinamento via B-P pode ser efetuado, basicamente, de duas formas. A primeira 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 à uma tolerância pré-especificada para os padrões considerados. A segunda é idêntica à primeira, porém, fazendo-se somente uma iteração (ajuste de pesos) por padrão.

A primeira e segunda formas serão designadas neste trabalho, respectivamente, **CONVERGÊNCIA POR PADRÃO** e **UMA ITERAÇÃO POR PADRÃO**.

3.7. PROBLEMAS DO TREINAMENTO

Uma rede neuronal quando treinada através do algoritmo B-P, pode apresentar alguns problemas que afetam decisivamente o seu desempenho, *e.g.*, mínimos locais, paralisia e baixa ou não convergência quando a magnitude do passo (μ) não for adequadamente calibrado. Estes problemas serão apresentados e discutidos a seguir.

3.7.1. PARALISIA DA REDE

Quando a rede está sendo treinada, os pesos podem ser ajustados para valores muito grandes. Isto pode forçar com que todos ou muitos dos neurônios operem com valores grandes na saída, na região onde a derivada da função erro quadrático é



muito pequena. Como o erro propagado no sentido inverso é proporcional à esta derivada, o processo de treinamento poderá se tornar ineficiente ou estagnado. Existe pouco entendimento teórico sobre este problema. Geralmente evita-se promovendo-se a redução do tamanho do passo. Entretanto, neste caso, poderá aumentar, conseqüentemente, o tempo de treinamento.

3.7.2. MÍNIMOS LOCAIS

A função erro total de uma rede neuronal *feedforward* com sigmóide pode ser vista como uma hiper-superfície que poderá conter um número considerável de pontos de equilíbrio. O objetivo do treinamento é a obtenção de um ponto de equilíbrio correspondente a um mínimo global. O algoritmo *Back-Propagation* emprega um tipo de gradiente descendente, *i.e.*, ele segue a direção na superfície de erro, ajustando constantemente os pesos até encontrar um ponto mínimo. Se este ponto for um mínimo local, a tendência do algoritmo é permanecer neste ponto, como ocorre na maioria dos procedimentos determinísticos de otimização. Para se evitar este problema, deve-se utilizar outras abordagens que permitam o escape dos mínimos locais, *e.g.*, os métodos de treinamento estatísticos como tratados nas máquinas de Boltzmann e Cauchy ([46]). Entretanto, o treinamento destas máquinas tende a ser lento. Wasserman ([46]) propôs uma metodologia que combina o método estatístico da máquina de Cauchy com o gradiente descendente do *Back-Propagation* para produzir um esquema que encontre um mínimo global, com custo computacional competitivo, se comparado ao *Back-Propagation* convencional.

3.7.3. TAMANHO DO PASSO

Por questões de convergência no processo de treinamento da rede, como abordado anteriormente, o parâmetro μ (controle da estabilidade) deve ser arbitrado,



criteriosamente, de modo a garantir a estabilidade. Para tanto, o seu valor deve ser adotado pequeno. Neste caso, o treinamento tende a se tornar lento.

3.8. CONCLUSÃO

Neste capítulo foram apresentados os principais conceitos de redes neuronais artificiais e os modelos do neurônio biológico e artificial (proposto por McCulloch-Pitts ([26])) no contexto de uma estrutura neuronal. Foi apresentado, ainda, o método *Back-Propagation*, versão com momento. Finalmente, foram discutidos os principais problemas encontrados no treinamento.

No próximo Capítulo será proposta uma abordagem de análise de Estabilidade Transitória (determinação de tempos críticos) através de redes neuronais artificiais com treinamento via *Back-Propagation*.



CAPÍTULO 4

REDE NEURONAL PROPOSTA

4.1. INTRODUÇÃO

Neste Capítulo apresenta-se a estrutura da rede neuronal proposta destinada ao estudo de estabilidade transitória de Sistemas de Energia Elétrica correspondente a determinação de tempos críticos para contingências tipo curto-circuito. Trata-se de uma rede não-recorrente, basicamente composta por três camadas (entrada, intermediária e saída) e neurônios tipo sigmoidais com inclinações suaves (λ pequeno) – utilizadas como forma de reduzir o custo computacional do treinamento. Os estímulos entrada-saída são definidos considerando-se a entrada formada pela potência ativa nodal e dados da falta, apresentados em código binário, e a saída correspondendo aos tempos críticos, para uma lista de contingências pré-definida, fornecidos por um programa computacional híbrido (simulação / método direto de Liapunov) ([10], [29]).

4.2. DIMENSIONAMENTO DA REDE

O dimensionamento da rede consiste na definição do número de camadas e número de neurônios por camada, em função dos vetores padrões que compõem o conjunto de treinamento e da qualidade da solução desejada. Deve-se a isto, a necessidade da separabilidade de padrões. Portanto, a definição da topologia da rede depende do volume



de informações a serem armazenadas. Existe na literatura um grande número de estudos a respeito de projetos topológicos de redes neuronais, porém, todos eles são propostos de modo empírico. Desta forma, a seguir serão discutidos alguns indicativos sobre o dimensionamento das redes não-recorrentes.

4.2.1. NÚMERO DE CAMADAS

Quanto maior for o número de camadas, melhor será o desempenho qualitativo da rede. Ressalta-se, porém, que o custo computacional necessário para a execução do treinamento da rede cresce em função do número de camadas, número de neurônios e, principalmente, em função do número de padrões a ser armazenado. Em vista disto, na maioria das referências encontradas na literatura, são adotadas TRÊS CAMADAS como uma boa estimativa.

4.2.2. NÚMERO DE NEURÔNIOS POR CAMADA

O número de neurônios na primeira e última camadas deve ser idêntico à dimensão dos vetores padrões e dimensão da saída, respectivamente. Com isto, falta, então, a definição da quantidade de neurônios das camadas intermediárias (escondidas).

O número de neurônios nas camadas intermediárias pode ser definido a critério do usuário. Porém, deve-se lembrar que é preciso que se estabeleça um certo grau de redundância, ou seja, deve-se arbitrar um número de neurônios maior do que o necessário.



4.3. FUNÇÃO SIGMÓIDE

O problema a ser abordado neste trabalho consiste na determinação de tempos críticos de eliminação de defeitos tipo curto-circuito seguido da perda do elemento sob defeito. O tempo crítico é uma grandeza positiva. Neste caso, a não-linearidade mais apropriada corresponde à função sigmóide definida pela equação (3.5.3):

$$y_i = (1 + \exp(-\lambda s_i))^{-1} \quad (4.3.1)$$

Nota-se que y_i é definida no intervalo $\{0,1\}$, ou seja, é uma grandeza positiva, permitindo, deste modo, modelar o problema da análise de estabilidade ora abordado.

Para se trabalhar com modelos binários deve-se adotar valores grandes para o parâmetro λ , enquanto que para modelos contínuos é recomendável adotá-los em valores de menor magnitude.

Nas figuras 8 e 9 são mostrados o comportamento da função sigmóide ($y(s)$) e sua derivada ($sgm'(s)$) para λ igual a 0.5, 1 e 2, respectivamente.




FIGURA 8. Comportamento da função sigmóide para λ igual a 0.5, 1 e 2.




FIGURA 9. Comportamento da derivada da função sigmóide para λ igual 0.5, 1 e 2.

A derivada $sgm'(s)$ tem forte semelhança com a curva de distribuição normal (de Gauss). Constitui-se de um CORPO CENTRAL e suas laterais designadas, como forma de simplificação, CAUDAS ESQUERDA e DIREITA. Nota-se a partir das figuras 8 e 9, que a diminuição de λ produz uma suavização na função sigmóide ($y(s)$), enquanto que sua derivada ($sgm'(s)$) tende a diminuir a amplitude da curva e alongar as caudas.

No algoritmo *back-Propagation*, a adaptação de pesos que concorrem a cada neurônio é efetuada utilizando-se, basicamente, o erro propagado no sentido inverso, multiplicado por $sgm'(s)$ e pela entrada no referido neurônio. Deste modo, os pesos têm efetivo ajuste somente para valores de (s) situados no corpo central da função $sgm'(s)$. À medida que os pesos se tornarem significativos, há desaceleração dos ajustes dos mesmos, tendendo para a completa paralisia, justamente onde se encontram os terminais das caudas tanto direita como esquerda.

Em vista disto, no caso específico do problema de determinação de tempos críticos, propõe-se a utilização da função sigmóide com λ relativamente pequeno (inferior a 1), proporcionando caudas mais longas. Isto permitirá escolha de pesos da rede de forma menos restritiva, se comparada às adotadas na bibliografia, que de certo modo diminui a possibilidade da ocorrência de paralisia e aumenta a velocidade de convergência do

algoritmo B-P. Porém, com a diminuição de λ , a magnitude dos pesos tende a crescer. Por conseguinte, a escolha de λ deve ser feita com critério, levando-se em conta a experiência no treinamento.

Este tipo de procedimento tem o mesmo significado, respeitadas as diferenças, o que ocorre na máquina de Cauchy ([44], [47]) em comparação à máquina de Boltzmann ([44], [47]). Na máquina de Cauchy o treinamento é consideravelmente mais rápido do que o da máquina de Boltzmann. Estas duas máquinas são idênticas em termos de concepção, porém, a máquina de Cauchy, como diz o próprio nome, utiliza a distribuição de Cauchy que é menos restritiva (possui caudas mais longas), cuja variância é infinita (indefinida). A máquina de Cauchy, assim como a máquina de Boltzmann, são muito utilizadas em otimização, busca em grafos, reconhecimento de padrão, processamento de imagens e voz, usam uma combinação do aprendizado de Hebb ([46]) e do conceito *simulated annealing* (aprendizado estocástico).

4.4. ESTÍMULOS ENTRADA-SAÍDA

Cada vetor padrão adotado na referência [45] é composto pelas posições angulares calculadas no instante da eliminação de defeito, acelerações angulares calculadas no instante inicial da falta e as energias individuais de aceleração das máquinas síncronas referentes ao instante de eliminação de defeito, portanto, este vetor tem dimensão igual a $3n_g$ (n_g = número de máquinas síncronas do sistema). Na referência [35] a dimensão do vetor padrão é igual a $5n_g$.

Neste trabalho, propõe-se uma RNA cujo vetor padrão é definido por ([27]):

$$\mathbf{X} = [\mathbf{P}^T \mathbf{Bin}^T]^T \quad (4.4.1)$$



sendo:

$\mathbf{X}$ = vetor padrão

$\mathbf{P} = [P_1 \ P_2 \ \dots \ P_p]^T$

P_i = potência ativa da i -ésima barra do sistema

$\mathbf{Bin}$ = vetor contendo o número da contingência representado em código de modo idêntico ao código binário.

Cada componente do vetor $\mathbf{Bin}$ corresponde a 1 *bit* da representação em código binário. Os dados foram estabelecidos em código binário e são tratados, no treinamento, como dados analógicos.

A representação binária tomando-se como base (+1; -1) é preferível sobre a representação (+1; 0), isto porque não haverá ajuste de pesos correspondentes às entradas 0, correspondentes ao *bit* 0.

O vetor padrão $\mathbf{X}$ é n -dimensional,

em que:

$$n = \rho + nb \quad (4.4.2)$$

sendo:

ρ = número de barras do sistema

nb = número de *bits* correspondente ao número da contingência.

Neste caso, considerando-se o modelo clássico, necessita-se somente do vetor de potência ativa das barras do sistema para a avaliação da Estabilidade Transitória de SEE (determinação de tempos críticos), tendo em vista a suposição de que a topologia,



as tensões nodais e demais parâmetros do modelo (constantes de inércias e as reatâncias transitórias, etc.) se mantêm inalterados, embora, a tensão poderá sofrer pequenas variações em função da mudança do perfil de geração / carga do sistema.

Como o número de *bits* (*nb*) é consideravelmente menor que ρ , então, a rede proposta é significativamente menor se comparada àquelas apresentadas nas referências [35] e [45]. Isto significa uma grande redução na dimensão da rede e, conseqüentemente, uma economia no custo computacional para o seu treinamento, principalmente para sistemas de grande porte.

Na Figura 10, apresentam-se as componentes do vetor padrão – formado pela potência mecânica e código binário referente à identificação do defeito.



FIGURA 10. Composição do vetor padrão.

As saídas desejadas (tempos críticos) são dados extraídos dos estudos de estabilidade transitória (simulação), considerando vários níveis de geração / carga. Para cada perfil é efetuada a análise considerando-se as principais contingências. Os tempos críticos foram obtidos através do programa computacional apresentado na referência [29] - versão para computadores IBM PC ou compatíveis. O *software* denominado SIMUL determina os tempos críticos para uma lista de contingências (curto-circuito) pré-especificada de modo sistematizado, via método de energia, por processo iterativo, proposto na referência [10], baseado no conceito PEBS (*Potential Energy Boudary*



Surface) ([5]). Detalhes sobre esta metodologia e sua implementação são encontrados no Apêndice A.

4.5. CONCLUSÃO

Foi apresentado neste Capítulo a especificação da rede neuronal para o estudo de estabilidade transitória de Sistemas de Energia Elétrica. Os principais pontos sugeridos foi a definição dos estímulos entrada-saída e a utilização de neurônios com não-linearidade tipo sigmóide com inclinações suaves, ou seja, λ pequeno (menor que 1). Este conjunto de medidas proporciona uma rede de menor dimensão e custo computacional reduzido, se comparada às proposições apresentadas na literatura.



CAPÍTULO 5

RESULTADOS

5.1. INTRODUÇÃO

A seguir serão apresentados os resultados da análise de estabilidade transitória de Sistemas de Energia Elétrica através do uso de Redes Neurais, como proposto nos capítulos anteriores, considerando-se um sistema teste composto por 8 máquinas síncronas, 23 linhas de transmissão e 17 barramentos. Estes resultados serão comparados aos obtidos, em termos de precisão, via simulação.

5.2. RESULTADOS

Consideram-se defeitos tipo curto-circuito trifásico, com tempo de eliminação de defeito igual a 0,10 s, seguidos da perda de linha de transmissão. O diagrama unifilar e os dados do sistema sob estudo encontram-se na Figura 11 e nas Tabelas 1, 2 e 3, respectivamente. Este sistema é composto por 8 máquinas síncronas, 23 linhas de transmissão e 17 barras. No sistema de transmissão são desconsideradas as admitâncias *shunt*. A simbologia $r(l-m)$ contida na primeira coluna da Tabela 4 significa a ocorrência de um curto-circuito na barra r com saída da linha de transmissão entre os nós l e m .



As saídas desejadas (tempos críticos) são dados extraídos dos estudos de estabilidade transitória (simulação), considerando vários níveis de geração / carga, correspondentes à carga leve, caso base e dois níveis de carga pesada, respectivamente, 80, 100, 120 e 140% do caso base. Neste caso, no vetor padrão, pode-se excluir o sub-vetor potência ativa das barras do sistema, como definido na equação (4.4.1), considerando-se apenas, em seu lugar, o coeficiente de proporcionalidade de geração / carga do sistema. Para cada perfil é efetuada a análise considerando as principais contingências (10 contingências). Portanto, totalizando 40 vetores padrão e 40 saídas desejadas. Os tempos críticos são obtidos através do programa computacional desenvolvido na referência [29]. Um resumo deste método e detalhes de sua implementação computacional encontram-se no Apêndice A.

TABELA 2. Dados dos barramentos do sistema.

BARRA No.	(CASO BASE)			TENSÃO (pu)
	POTÊNCIA MECÂNICA (pu)	CARGA (pu)		
		ATIVA	REATIVA	
01	3,2000	-	-	1,1200
02	2,0000	-	-	1,1400
03	0,6000	-	-	1,0500
04	1,0000	-	-	1,0600
05	0,9000	-	-	1,0400
06	1,4000	-	-	1,0300
07	0,9000	-	-	1,0550
08	REFERÊNCIA	-	-	1,1000
09	-	1,0000	0,1400	-
10	-	0,0000	0,0000	-
11	-	2,2000	0,6000	-
12	-	0,8000	0,0200	-
13	-	0,8000	0,0200	-
14	-	0,7000	0,0500	-
15	-	2,0000	0,1000	-
16	-	1,3000	0,0200	-
17	-	2,2000	0,4000	-



TABELA 3. Dados do sistema de transmissão em pu.

LINHA DE TRANSMISSÃO	NÓ INICIAL	NÓ TERMINAL	ADMITÂNCIA SÉRIE	
			G	B
01	02	09	0,8512	-6,8238
02	01	02	0,8201	-6,0503
03	09	10	3,4502	-18,2514
04	02	03	2,2252	-12,0582
05	10	11	0,8124	-5,5304
06	03	11	1,4461	-10,8820
07	01	11	3,9314	-17,8245
08	01	06	0,8484	-6,7188
09	04	11	1,1238	-8,5249
10	04	12	3,4721	-20,2824
11	12	13	1,5176	-11,5938
12	13	14	0,9396	-11,7171
13	14	15	1,2250	-12,6364
14	05	11	1,5076	-12,5743
15	05	06	0,7253	-7,8066
16	06	07	2,5142	-18,1357
17	14	16	1,1208	-8,9422
18	08	16	1,0922	-9,6419
19	08	17	0,0699	-6,4136
20	07	17	0,8237	-6,8307
21	06	16	1,5023	-9,3937
22	06	08	0,8154	-7,3277
23	08	15	1,0096	-9,5269



TABELA 4. Códigos referentes à definição dos defeitos.

FALTA	CÓDIGO			
01(01 - 02)	+1	-1	-1	-1
01(01 - 06)	-1	+1	-1	-1
01(01 - 11)	-1	-1	+1	-1
02(02 - 09)	-1	-1	-1	+1
02(02 - 03)	+1	+1	-1	-1
06(06 - 07)	+1	-1	+1	-1
06(06 - 08)	+1	-1	-1	+1
06(06 - 16)	-1	+1	+1	-1
04(04 - 11)	-1	+1	-1	+1
08(06 - 08)	-1	-1	+1	+1

A Rede Neuronal adotada é composta por 03 fileiras, contendo, respectivamente, 05, 20 e 01 neurônios. O treinamento via B-P é efetuado considerando-se um erro máximo admissível ($\epsilon_{\text{máx}}$).

Na Tabela 5 é mostrado o desempenho do algoritmo *Back-Propagation* considerando-se várias situações estabelecidas em função dos parâmetros e formas de treinamento da rede.

A Tabela 5 é constituída por 7 colunas. Na primeira coluna são enumeradas as situações simuladas (60 ao todo). Na segunda e terceira colunas constam, respectivamente, os diversos valores de μ e η adotados nas simulações. Na coluna "CONVERGÊNCIA POR PADRÃO" o ajuste dos pesos da rede (considerando-se todas as camadas) é efetuado fazendo-se com que haja convergência para cada padrão, até que se complete a total convergência, *i.e.*, o erro quadrático seja inferior à tolerância pré-especificada para o conjunto de padrões. A coluna "UMA ITERAÇÃO POR PADRÃO" segue o mesmo procedimento, porém, fazendo-se somente uma iteração (ajuste de pesos) por vez por padrão. O processo deve ser repetido até que ocorra a convergência final. O termo "No. DE APRESENTAÇÕES" empregado na coluna 6 significa o número de vezes que o conjunto de vetores padrão é aplicado na entrada da rede. O tempo mostrado na

última coluna da Tabela 5 é dado em horas, minutos e segundos, nesta ordem, separados por (:).

As simulações efetuadas são apresentadas em blocos considerando-se λ (constante que determina a inclinação da curva sigmóide) igual a 0,3; 0,5 e 1. Em cada bloco, são, então, analisadas as várias alternativas através da variação de μ (0,5; 1; 2 e 3), η (0; 0,2 e 0,8) e formas de aprendizado (UMA ITERAÇÃO POR PADRÃO / CONVERGÊNCIA POR PADRÃO). Para $\lambda = 1$, os resultados das simulações correspondentes a μ maior que 1 foram omitidos por apresentarem efeito de estagnação na adaptação dos pesos (paralisia), ou não houve convergência.

Nota-se na Tabela 5 que a diminuição de λ , como mencionado anteriormente, reduz o tempo de treinamento. Com a redução de λ pode-se aumentar a magnitude de μ (controle da estabilidade), obtendo-se, deste modo, maior rapidez do treinamento. Porém, este parâmetro deve ser estabelecido com critério, pois para valores muito alto o processo tende a não convergir (vide na Tabela 5 – situações 16, 39 e 40). Nota-se, ainda, que o desempenho da rede tem melhorado arbitrando-se a constante momento (η) em torno de 0,8. Valores maiores e menores que 0,8 têm proporcionado problemas de convergência e aumento do tempo de treinamento, respectivamente. Deve-se ressaltar que o desempenho do treinamento depende, basicamente, da combinação destes três fatores. Por exemplo, o melhor desempenho foi obtido através da adoção de λ , μ e η iguais a 0,3; 3,0 e 0,8, respectivamente.

Observa-se então, na Tabela 5, que o melhor desempenho foi obtido para $\lambda = 0,3$; $\mu = 3,0$ e $\eta = 0,8$ com treinamento realizado em 119 apresentações, considerando-se uma iteração por padrão, com tempo de processamento correspondente a 1 minuto e 39 segundos em um computador IBM 486/50 MHz – situação 12. Se adotado λ igual a 1 ou superior, o número de apresentações cresce consideravelmente. Assim, pode-se concluir que, com a diminuição de λ tem-se uma redução do tempo de cálculo necessário ao treinamento. Porém, com a diminuição de λ , a magnitude dos pesos v_{ij} tende a crescer. Em vista disto, a fixação de λ deve ser feita com critério, levando-se em conta a experiência com este tipo de rede.



TABELA 5. Desempenho do *Back-Propagation* em função de várias alternativas operativas.

SITUAÇÃO	μ	η	UMA ITERAÇÃO POR PADRÃO	CONVER- GÊNCIA POR PADRÃO	No DE APRE- SENTAÇÕES	TEMPO
$\lambda = 0.3$						
01	0.5	-	X		809	0:10:57
02	1.0	-	X		477	0:06:24
03	2.0	-	X		164	0:02:17
04	3.0	-	X		185	0:02:41
05	0.5	0.2	X		794	0:10:48
06	1.0	0.2	X		448	0:06:03
07	2.0	0.2	X		213	0:02:55
08	3.0	0.2	X		142	0:02:00
09	0.5	0.8	X		714	0:09:51
10	1.0	0.8	X		360	0:04:58
11	2.0	0.8	X		166	0:02:18
12	3.0	0.8	X		119	0:01:39
13	0.5	-		X	374	0:10:06
14	1.0	-		X	286	0:06:13
15	2.0	-		X	154	0:03:15
16	3.0	-		X	não convergiu	-
17	0.5	0.2		X	298	0:09:06
18	1.0	0.2		X	234	0:05:31
19	2.0	0.2		X	151	0:03:11
20	3.0	0.2		X	120	0:02:50
21	0.5	0.8		X	118	0:06:35
22	1.0	0.8		X	81	0:03:39
23	2.0	0.8		X	34	0:01:50
24	3.0	0.8		X	34	0:01:49
$\lambda = 0.5$						
25	0.5	-	X		809	0:10:57
26	1.0	-	X		352	0:04:43
27	2.0	-	X		maior que 1000	-
28	3.0	-	X		maior que 1000	-
29	0.5	0.2	X		794	0:10:48
30	1.0	0.2	X		448	0:06:05



TABELA 5. – Continuação

SITUAÇÃO	μ	η	UMA ITERAÇÃO POR PADRÃO	CONVER- GÊNCIA POR PADRÃO	No DE APRE- SENTAÇÕES	TEMPO
31	2.0	0.2	X		213	0:02:56
32	3.0	0.2	X		142	0:02:00
33	0.5	0.8	X		714	0:09:49
34	1.0	0.8	X		302	0:04:05
35	2.0	0.8	X		166	0:02:19
36	3.0	0.8	X		119	0:01:39
37	0.5	-		X	374	0:10:07
38	1.0	-		X	286	0:06:13
39	2.0	-		X	não convergiu	-
40	3.0	-		X	não convergiu	-
41	0.5	0.2		X	511	0:09:21
42	1.0	0.2		X	276	0:05:01
43	2.0	0.2		X	151	0:03:10
44	3.0	0.2		X	120	0:02:51
45	0.5	0.8		X	137	0:04:39
46	1.0	0.8		X	70	0:02:50
47	2.0	0.8		X	59	0:02:41
48	3.0	0.8		X	48	2:02:05
$\lambda = 1.0$						
49	0.5	-	X		672	0:08:56
50	1.0	-	X		352	0:04:43
51	0.5	0.2	X		675	0:08:56
52	1.0	0.2	X		354	0:04:43
53	0.5	0.8	X		535	0:07:11
54	1.0	0.8	X		302	0:04:03
55	0.5	-		X	527	0:09:37
56	1.0	-		X	313	0:05:52
57	0.5	0.2		X	511	0:09:21
58	1.0	0.2		X	276	0:05:01
59	0.5	0.8		X	137	0:04:37
60	1.0	0.8		X	75	0:02:50



TABELA 6. Estudo comparativo da análise de estabilidade transitória.

FALTA	TEMPO CRÍTICO (segundos)							
	70 %		90 %		110 %		130 %	
	CASO BASE		CASO BASE		CASO BASE		CASO BASE	
	SIMU- LAÇÃO	RNA	SIMU- LAÇÃO	RNA	SIMU- LAÇÃO	RNA	SIMU- LAÇÃO	RNA
1(01-02)	0,2700	0,2563	0,2350	0,2270	0,2050	0,2013	0,1800	0,1791
1(01-06)	0,2900	0,2715	0,2400	0,2361	0,2050	0,2065	0,1750	0,1823
1(01-11)	0,2850	0,2744	0,2400	0,2398	0,2200	0,2112	0,1950	0,1879
2(02-09)	0,2400	0,2495	0,2050	0,2101	0,1800	0,1798	0,1600	0,1568
2(02-03)	0,2350	0,2387	0,2000	0,2025	0,1750	0,1748	0,1550	0,1539
6(06-07)	0,3600	0,3496	0,3150	0,3167	0,2800	0,2865	0,2500	0,2592
6(06-08)	0,3600	0,3541	0,3150	0,3138	0,2800	0,2782	0,2550	0,2471
6(06-16)	0,3600	0,3636	0,3150	0,3211	0,2800	0,2842	0,2500	0,2526
4(04-11)	0,4400	0,4187	0,3750	0,3697	0,3250	0,3235	0,2800	0,2817
8(06-08)	0,3850	0,3711	0,3200	0,3173	0,2700	0,2728	0,2350	0,2368

Na Tabela 6 mostra-se um estudo comparativo dos resultados obtidos através de simulação e do uso da RNA (considerando-se os parâmetros da rede que apresentaram melhor desempenho — λ , μ e η iguais a 0,3; 3,0 e 0,8, respectivamente). A análise de Estabilidade Transitória do sistema refere-se aos níveis de geração / carga iguais a 70, 90, 110 e 130% do caso base. A simbologia $r(l-m)$ apresentada na primeira coluna da Tabela 6 significa a ocorrência de um curto-circuito na barra r com saída da linha de transmissão entre os nós l e m .

Observa-se na Tabela 6, que os resultados da análise através de Redes Neurais encontram-se muito próximos dos resultados obtidos via simulação.

Os tempos para a determinação da análise, utilizando-se o mesmo equipamento computacional (IBM 486/50 MHz), através de simulação e rede neuronal, respectivamente, são:



☐ **Por simulação:** 37 minutos e 28 segundos

O tempo de execução corresponde à determinação do tempo e energia crítica considerando-se as 10 contingências e 4 níveis de carregamento apresentados na Tabela 6, totalizando 40 simulações. Ressalta-se que nas simulações considera-se o modelo clássico definido pelas equações (2.2.5) e (2.2.6).

☐ **Através da rede neuronal proposta:** em torno de 1 segundo.

Este tempo corresponde à leitura, análise e impressão dos resultados, levando-se em conta as mesmas contingências (40 ao todo).

Verifica-se, deste modo, que o tempo de análise, via rede neuronal, é consideravelmente menor se comparado à simulação. Esta característica também é observada quando comparada com outras metodologias de análise abordadas na literatura.

5.3. CONCLUSÃO

Foi apresentado, neste trabalho, uma aplicação de Redes Neurais em análise de estabilidade transitória de Sistemas de Energia Elétrica com treinamento efetuado através do método *Back-Propagation*. Os tempos críticos (saídas desejadas) para fins de treinamento da rede, foram gerados através de simulação via computador tipo PC. Os resultados obtidos com Redes Neurais são comparáveis à simulação, conforme observou-se em um exemplo apresentado (sistema composto por 08 máquinas síncronas, 23 linhas de transmissão e 17 barras). A rede neuronal sugerida apresenta dimensão inferior às apresentadas nas referências bibliográficas. Obtém, então, como resultado, uma redução considerável do custo computacional utilizado no treinamento. A adoção da função sigmóide com baixa inclinação (λ pequeno) na formulação do algoritmo *Back-Propagation* proporcionou uma economia considerável do tempo de cálculo na execução do treinamento, em comparação aos resultados apresentados na literatura.



CAPÍTULO 6

CONCLUSÃO E SUGESTÕES PARA TRABALHOS FUTUROS

6.1. CONCLUSÃO

Este trabalho teve por objetivo a investigação do uso de Redes Neurais Artificiais para a determinação de tempos críticos de eliminação de defeitos tipo curto-circuito em Sistemas de Energia Elétrica.

A Rede Neuronal empregada foi do tipo multi-fileiras, não-recorrente, com funções de ativação tipo sigmóide e treinamento efetuado através do algoritmo *Back-propagation* com momento, escolhido tendo em vista que esta técnica representa, hoje, o maior e principal aplicativo de treinamento de redes neurais.

A principal contribuição do trabalho consistiu no projeto de uma rede neuronal de dimensão inferior àquelas apresentadas na literatura, tendo como resultado, uma redução considerável do custo computacional utilizado no treinamento. A adoção da função sigmóide atenuada (λ pequeno) na formulação do algoritmo *Back-Propagation* tem proporcionado uma economia considerável do tempo de cálculo destinado à execução do treinamento, se comparado aos resultados apresentados na literatura.

Foi apresentada uma aplicação da rede considerando-se um Sistema de Energia Elétrica composto por 08 máquinas síncronas, 23 linhas de transmissão e 17 barras. Os resultados da análise obtidos através da rede neuronal proposta encontram-se muito próximos, em termos de precisão, aos obtidos via simulação.



O tempo de análise através de rede neuronal, considerando-se o sistema em estudo (composto por 8 máquinas síncronas, 23 linhas e 17 barras), foi bastante inferior ao da simulação.

6.2. SUGESTÕES PARA TRABALHOS FUTUROS

Considerando-se os resultados obtidos nesta Dissertação, são sugeridos os seguintes tópicos para trabalhos futuros:

- estudo e implementação de novas melhorias neste algoritmo, tornando-o mais eficiente em termos de resultados e, principalmente, com relação à redução do custo computacional;
- estudo de estabilidade transitória de Sistemas de Energia Elétrica considerando-se modelos mais elaborados, *e.g.*, o modelo completo de Park;
- emprego e/ou desenvolvimento de técnicas de treinamento de redes que apresentem, eventualmente, superior desempenho ao *Back-Propagation*; principalmente, com relação ao custo computacional;
- desenvolvimento de uma técnica de treinamento combinando-se o algoritmo *Back-Propagation* com técnicas estatísticas, como por exemplo, a máquina de Cauchy, visando-se, deste modo, melhorar o desempenho do treinamento frente aos problemas de mínimos locais.



CAPÍTULO 7

REFERÊNCIAS BIBLIOGRÁFICAS

- [01] AGGARWAL, R. K.; JOHNS, A. T.; SONG, Y. H.; DUNN, R. W.; FITTON, D. S. "Neural-Network Based Adaptive Single-Pole Autoreclosure Technique for EHV Transmission Systems", **IEE Proceeding Generations, Transmission and Distribution**, Vol. 141, No. 2, pp. 155-160, March 1994.
- [02] AGGOUNE, M.; EL-SHARKAWI; PARK II, D. C.; DAMBORG, M. J. and MARKS II, R. J. "Preliminary Results on Using Artificial Neural Networks For Security Assessment", **IEEE Transactions on Power Systems**, Vol. 6, No.2, pp. 890-896, May 1991.
- [03] AMARI, S-I. "Mathematical Foundations of Neurocomputing", **Proceedings of The IEEE**, Vol. 78, No. 9, pp. 1443-1463, Sept. 1990.
- [04] ANDERSON, P. M. and FOUAD, A. "Power System Control And Stability", 1977, IOWA State University Press, USA.
- [05] ATHAY, T. ; SHERKET, V. R. ; PODMORE, R. ; VIRMANI, S. ; PUECH, C. "Transient Energy Stability Analysis". **Conference on System Engineering For Power**, Davos, Switzerland, 1979. Also U. S. Department of Energy, publication No. Conf-790904 - PL1980.
- [06] CARPENTER, G. A. "Neural Network Model For Pattern Recognition And Associative Memory", **Neural Networks**, Vol. 2, pp. 243-257, 1989.
- [07] CHANG, C. S.; SRINIVASAN, D.; LIEW, A. C. "A Hibrid Model For Transient Stability Evaluation of Interconnected Longitudinal Power

- Systems Using Neural Network/Pattern Recognition Approach", **IEEE Transactions on Power Systems**, Vol. 9, No. 1, pp. 85-92, February 1994.
- [08] DJUKANOVIC, M.; BABIC, B.; SOBAJIC, D.J.; PAO, Y. H. "Unsupervised/Supervised Learning Concept For 24-Hour Load Forecasting", **IEE Proceedings-C**, Vol. 40, No. 4, pp. 311-318, July 1993.
- [09] EBERHART, R. C. & DOBBINS, R. W. "Neural Network PC Tolls: A Practical Guide". N. York, Academic Press, Inc., 1990.
- [10] FONSECA, L. G. S. and DECKER, I. C. "Iterative Algorithm For Critical Energy Determination in Transient Stability of Power System", **IFAC - Symposium Planning & Operation in Electric Energy System**, 1985, Rio de Janeiro - RJ, Brazil, pp. 483-489.
- [11] GUTTA, S. V. R.; RANNA, M. V.; RAMAKRISHNA, N. "Neural System", **IEEE Potentials**, October 1993, pp. 19-20.
- [12] HAMMERSTROM, D., "Neural Networks at Work", **IEEE Spectrum**, June 1993, pp. 26-32.
- [13] HARTANA, R. K. and RICHARDS, G. G. " Harmonic Source Monitoring And Identification Using Neural Networks", **IEEE Transactions on Power Systems**, Vol. 5, No. 4, pp. 1098-1104, Nov. 1990.
- [14] HECHT-NIELSEN, R. " Counterpropagation Networks". **Applied Optics**, No. 26, pp. 4979-4984, 1987.
- [15] HECHT-NIELSEN, R. "Neurocomputing: Picking the Human Brain", **IEEE Spectrum**, March 1988.
- [16] HO, K. L.; HSU, Y. Y. "Short Term Load Forecasting Using a Multilayer Neural Network With an Adaptive Learning Algorithm", **IEEE/PES 1991 Summer Meeting**, San Diego, California, July 28 - August 1, 1991. PAPER 94 WM 209-7 PWS.



- [17] HSU, Y. Y. and YANG, C. C. "Design of Artificial Neural Networks For Short-Term Load Forecasting. Part I: Self-Organizing Feature Maps For Day Type Identification", **IEE Proceedings-C**, Vol. 138, No. 5, September 1991, pp. 407-412.
- [18] HSU, Y. Y.; CHEN, C. R.; SU, C. C. "Analysis of Electromechanical Modes Using an Artificial Neural Network". **IEE Proceeding-Generation, Transmission and Distribution**, Vol. 141, No. 3, May 1994, pp. 198-204.
- [19] KANDIL, N.; SOOD, V. K.; KHORASANI, K. and PATEL, R. V. "Fault Identification in an AC-DC Transmission System Using Neural Networks", **IEEE PICA - 91**, pp. 285-291.
- [20] KIM, H.; KO, Y.; JUNG, K. H. "Artificial Neural-Network Based Feeder Reconfiguration For Loss Reduction in Distribution Systems", **IEEE/PES 1992 Summer Meeting**, Seattle, WA, July 12-16, 1992. PAPER 92 SM 503-3 PWRD
- [21] KIM, K. O. and PARK, J. K. "Application of Hierarchical Neural Networks to Fault Diagnosis of Power Systems", **Electrical Power & Energy systems**, Vol. 15, No. 2, pp. 65-70, 1993.
- [22] KOHONEN, T. "Self-organization and Associative Memory". **Series in Information Sciences**, Vol. 8, Berlin, Springer-Verlag, 2nd edition, 1988.
- [23] KOHONEN, T. "The Self-Organizing Map", **Proceeding of the IEEE**, Vol. 78, No. 9, September 1990, pp. 1464-1480.
- [24] KU, B. Y.; THOMAS, R.J.; CHIOU, C. Y. and LIN, C.J. "Power System Dynamic Load Modeling Using Artificial Neural Networks", **IEEE /PES 1993 Summer Meeting**, Vancouver, B. C., Canada, July 18-22, 1993. PAPER 93 SM 461-4 PWRD.



- [25] LIPPMANN, R. P. "An Introduction to Computing With Neural Nets", **IEEE ASSP Magazine**, April - 1987, pp. 4-22.
- [26] McCULLOCH, W. S. & PITTS, W. "A Logical Calculus of the Ideas Immanent in Nervous Activity". **Bulletin of Mathematical Biophysics**, No. 9, pp. 127-147, 1943.
- [27] MINUSSI, C. R. e SILVEIRA, M. C. G., "Análise de Estabilidade Transitória de Sistemas de Energia Elétrica através de Redes Neurais", **Trabalho Aceito Para Apresentação e Publicação no CEDE' 94**, Buenos Aires, Argentina, 28-nov. a 02-dez. 94.
- [28] MINUSSI, C. R., TEIXEIRA, M. C. M. e OKI, N. "Estabilidade Transitória e Sistemas de Energia Elétrica: Uma Abordagem de Análise Utilizando Redes Neurais Artificiais". **LATINCON - IEEE**, Agosto 1992, Santiago -Chile, pp. 51-55.
- [29] MINUSSI, C. R. and PEREIRA, M. "Um Programa Computacional Para o Ensino de Análise de Estabilidade Transitória de Sistemas de Energia Elétrica", **19º Congresso Brasileiro de Ensino de Engenharia**, João Pessoa, 1991, Vol. 1, pp. 113-122.
- [30] MINUSSI, C. R. "Controle de Segurança Dinâmica de Sistemas de Energia Elétrica", Tese DSc. UFSC, Brasil, Nov. 1990.
- [31] MORI, H.; TAMARU, Y. and TSUZUKI, S. "An Artificial Neural-Net Based Technique For Power System Dynamic Stability With The Kohonen Model". pp. 293-301.
- [32] NARENDRA, K. S. and PARTHASARATHY, K. "Gradient Methods For The Optimization of Dynamical Systems Containing Neural Networks", **IEEE Transactions on NEURAL NETWORKS**, Vol. 2, No. 2, pp. 252-262, March 1991.



- [33] OSOWSKI, S. "Neural Network For Estimation of Harmonic Components in a Power System", **IEE Proceedings-C**, Vol. 139, No. 2, March 1992, pp. 129-135.
- [34] PAI, M. A. "Power System Stability - Analysis by The Direct Method of Liapunov", Vol. 3, 1981, North-Holland Publishing Company.
- [35] PAO, Y. H. and SOBAJIC, D. J. "Combined Use of Unsupervised And supervised Learning For Dynamic Security Assessment", **IEEE PICA - 91**, pp. 278 - 284.
- [36] PAPALEXOPOULOS A. D.; HAO, S.; PENG, T. M. "An Implementation of a Neural Based Load Forecasting Model For The EMS", **IEEE/PES 1994 Winter Meeting**, New York, New York, January 30 - February 3, 1994. PAPER 94 WM 209-7 PWRS.
- [37] PARK, D. C.; EL-SHARKAWI, M. A.; MARKS II, R. J.; ATLAS, L. E. and DAMBORG, M. J. "Electric Load Forecasting Using an Artificial Neural Network", **IEEE Transactions on Power Systems**, Vol. 6, No. 2, pp. 442-449, May 1991.
- [38] PARK, J. H.; KIM, Y. S.; EOM, I. K.; LEE, K. Y. "Economic Load Dispatch For Piecewise Quadratic Cost Function Using Hopfield Neural Network", **IEEE/PES 1992 Summer Meeting**, Seattle, WA, July 12-16, 1992. PAPER 92 SM 412-7 PWRS.
- [39] RIBBENS-PAVELLA, M. and EVANS, P. J. "Direct Methods For Studying Dynamics of Large-Scale Electric Power Systems - A Survey", **Automatica**, Vol. 21, 1985, pp. 1-21.
- [40] RUMELHART, D. E.; HINTON, G. E. & WILLIAMS, R. J. "Learning Representations by Back-propagating Errors". **NATURE**, Vol. 323, No. 9, pp. 533-536, 1986.



- [41] RUMELHART, D. E. and McCLELLAND, D. E. "Parallel Distributed Processing: Explorations in the Microstructure", Volume I - Foundations, 1988, **Massachusetts Institute of Technology Press**.
- [42] SADIKU, M. and MAZARRA, M. "Computing With Neural Networks", **IEEE Potentials**, October 1993, pp. 14-16.
- [43] SASAKI, H.; WATANABE, M.; YOKOYAMA, R. "A Solution Method of Unit Commitment by Artificial Neural Networks", **Transactions on Power Systems**, Vol. 7, No. 3, August 1992, pp. 974-981.
- [44] SIMPSOM, P. K. "Artificial Neural Systems: Foundations, Paradigms, Applications, And Implementations", N. York, **Pergamon Press**, 1989.
- [45] SOBAJIC, D. J. and PAO, Y-H. "Artificial Neural-Net Based Dynamic Security Assessment For Electric Power Systems, **IEEE Trans. on Power Systems**, Vol. 4, No. 1, Feb. 1989, pp. 220-227.
- [46] SZTIPANOVITS, J. "Dynamic Backpropagation Algorithm For Neural Network Controlled Resonator-Bank Architecture", **IEEE Transactions on Circuits And systems-II: Analog And Digital Signal Processing**, Vol. 39, No. 2, February 1992, pp. 99-108.
- [47] WASSERMAN, P. D. "Neural Computing - Theory And Practice", Van Nostrand Reinhold, 1989, New York, USA
- [48] WERBOS, P. J. "Beyond Regression: New Tools For Prediction And Analysis in The Behavioral Sciences", Master Thesis, Harvard University, 1974.
- [49] WERBOS, P. J. "Backpropagation Through Time: What It Does And How to do it", **Proceedings of the IEEE**, Vol. 78, No. 10, September 1990, pp. 1550-1560.
- [50] WIDROW, B. and LEHR, M. A., "30 Years of Adaptive Neural Networks: Perceptron, Madaline, and Backpropagation", **Proceeding of the IEEE**, Vol. 78, No. 9, September 1990, pp. 1415-1442.



- [51] ZHOU, Q.; DAVIDSON, J.; FOUAD, A. A. "Application of Artificial Neural Networks in Power System Security And Vulnerability Assessment", **IEEE Transaction on Power Systems**, Vol. 9, No. 1, February 1994, pp. 525-532.



APÊNDICE A

DETERMINAÇÃO DE TEMPOS CRÍTICOS

1. IMPLEMENTAÇÃO COMPUTACIONAL

A análise de estabilidade transitória de Sistemas de Energia Elétrica será efetuada , combinando-se o Método Direto de Liapunov e a resolução das equações diferenciais, considerando-se defeitos tipo curto-circuito com saída de operação de linha de transmissão ([10]). Esta combinação é empregada como forma de se obter maior precisão, se comparada ao Método Direto de Liapunov. A função de Liapunov adotada será do tipo energia. Neste caso, a análise da estabilidade é efetuada comparando-se à energia adquirida durante o transitório com uma energia crítica. A energia crítica corresponde a 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 de PEBS (*Potencial Energy Boundary Surface* ([5])), cujo algoritmo empregado corresponde ao apresentado na referência [10]. Este algoritmo tem sido adotado, tendo em vista a precisão comparável à simulação, com custo computacional consideravelmente inferior.

O conceito energia para o diagnóstico da estabilidade transitória pode ser empregado mediante o critério da margem de segurança ([10], [29], [30]):

$$M_r = (E_{crit_r} - E_{e_r}) / E_{crit_r} \quad (A.1)$$



sendo:

r = índice de falta sob análise;

E_{crit_r} = energia total crítica do sistema;

E_{e_r} = energia total correspondente ao tempo de eliminação de defeito;

$$E(\theta, \omega) = E_c + E_p \quad (A.2)$$

= energia total do sistema;

$$E_c(\theta) = \frac{1}{2} \sum_{i=1}^{ng} M_i \omega_i^2 \quad (A.3)$$

$$E_p(\theta) = - \sum_{i \in N} \int_{\theta_i^p}^{\theta_i} g_i(\theta) d\theta_i . \quad (A.4)$$

Então pode-se concluir sobre a estabilidade do sistema, mediante o seguinte critério ([10], [29], [30]):

Se $M_r > (\leq) 0$, o sistema associado à i -ésima contingência é considerado estável (instável) do ponto de vista da estabilidade transitória.

A derivada direcional da energia potencial pode ser expressa de modo similar ao apresentado nas referências [5] e [10], por:

$$D(\theta) = - \langle g(\theta), (\theta - \theta^p) \rangle / \|\theta - \theta^p\| \quad (A.5)$$

sendo: $\langle ., . \rangle$ = produto interno de dois vetores n -dimensionais.

A derivada direcional $D(\theta)$ possui a propriedade de se manter sempre positiva para trajetórias (soluções das equações diferenciais) estáveis([5], [10]). Os pontos $\theta \in \mathbb{R}^m$ correspondentes aos zeros da derivada direcional, que primeiro são alcançados quando se percorre uma direção radial, a partir da origem, determinam uma superfície definida como sendo Superfície Limite de Energia Potencial ou PEBS ([10], [30]).

Por conseguinte, o procedimento de determinação da energia e tempo crítico apresentado na referência [10] 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 os resultados apresentados acima, pode-se descrever o algoritmo através dos seguintes passos([29]):

Passo 1. Leitura de dados.

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

Passo 3. Inicialização do contador de contingências (r)

Passo 4. Contador de contingências: $r \leftarrow r + 1$.

Passo 5. Cálculo das matrizes reduzidas às barras internas de geração para as configurações sob e pós-defeito.

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 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 (2.2.5) e (2.2.6);
- (b) energia e tempo crítico determinados utilizando-se o algoritmo proposto na referência [10]. A função de Liapunov tipo energia é avaliada de acordo com as expressões (A.2), (A.3) e (A.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.

O programa foi desenvolvido em linguagem FORTRAN para uso em computadores IBM PC-XT / PC-AT ou compatíveis.

O programa é auto-explicativo. Permite a construção de banco de dados com instruções e dispositivos para críticas, evitando deste modo, a inclusão de dados errados ou incompatíveis e, conseqüentemente, interrupção do processamento. O relatório apresenta um resumo dos principais resultados e uma tabela contendo a energia crítica, o tempo crítico e a margem de segurança para cada contingência. Durante o processamento o usuário poderá acompanhar, através do monitor, os principais cálculos efetuados, em destaque, o processo iterativo referente à determinação da energia / tempo crítico.



DEPARTAMENTO DE ENGENHARIA ELÉTRICA
AV. BRASIL, 56 - CAIXA POSTAL 31
15378-000 ILHA SOLTEIRA - SP

