

**UNIVERSIDADE REGIONAL DO
NOROESTE DO ESTADO DO RIO GRANDE DO SUL
DEPARTAMENTO DE FÍSICA, ESTATÍSTICA E MATEMÁTICA
PROGRAMA DE PÓS-GRADUAÇÃO EM MODELAGEM MATEMÁTICA**

**FERRAMENTA MATEMÁTICA PARA MODELAGEM
DE FALHAS EM FONTES ININTERRUPTAS DE
ENERGIA USANDO REDES NEURAIS**

DISSERTAÇÃO DE MESTRADO

Denise Prado Kronbauer

**Ijuí, RS, Brasil
2009**

Livros Grátis

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

Milhares de livros grátis para download.

**FERRAMENTA MATEMÁTICA PARA MODELAGEM
DE FALHAS EM FONTES ININTERRUPTAS DE
ENERGIA USANDO REDES NEURAIS**

por

Denise Prado Kronbauer

Dissertação apresentada ao Programa de Pós-Graduação em Modelagem Matemática, da Universidade Regional do Noroeste do Estado do Rio Grande do Sul (UNIJUI, RS), como requisito parcial para obtenção do título de **Mestre em Modelagem Matemática.**

Orientador: **Prof. Dr. Gideon Villar Leandro**
Co-Orientador: **Prof. Dr. Cassiano Rech**

Ijuí, RS, Brasil
2009

*Aos meus pais Hilário e Sônia, minhas irmãs, Daiana e Carla, e ao Roger,
que sempre me acompanharam com carinho e confiança,
incentivando cada nova etapa almejada.*

Dedico-lhes esta conquista.

AGRADECIMENTOS

Ao final de mais uma etapa contei com o apoio de pessoas especiais que ajudaram a alcançar essa vitória, por isso merecem meus agradecimentos, meu respeito e minha admiração.

Primeiramente agradeço a Deus por mais uma etapa vencida. Em especial quero agradecer à minha família: meus pais, Hilário e Sônia, e minhas irmãs, Daiana e Carla, pelo amor, dedicação, apoio irrestrito e total incentivo em qualquer decisão tomada.

Ao Roger, pela paciência, compreensão e amor; ao seu Reinaldo e a Lu, pelos momentos de diversão e apoio durante mais uma fase importante.

Ao meu orientador Prof. Dr. Gideon Villar Leandro, por todos os ensinamentos durante o período de desenvolvimento do trabalho, pelo exemplo de dedicação e seriedade no trabalho, pela paciência e amizade.

Aos amigos e colegas do curso, e aos meninos do curso de Engenharia Elétrica: Gilson e Tadeu, pelos dias de estudo e conversas, pelas descontrações e auxílios, pela amizade e parcerias formadas nesses anos de convívio.

À instituição pela oportunidade de crescimento profissional e pessoal.

E por fim, porém não menos importante, agradeço a CAPES pelo apoio financeiro, sem o qual eu não teria condições de realizar este trabalho.

RESUMO

A utilização de sistemas de alimentação ininterrupta de energia elétrica (*UPS*, *Uninterruptible Power Supply*) tem se tornado cada vez mais comum ao fornecimento de energia elétrica a cargas críticas. Assim, equipamentos eletrônicos comumente ligados diretamente à rede de energia elétrica passam a ter uma proteção efetiva contra as diversas anomalias encontradas nesta distribuição. Porém, como todos os equipamentos estão sujeitos a falhas, inclusive as UPS, uma parada não planejada pode resultar em grandes prejuízos. Diante deste fato, as UPS devem apresentar uma taxa reduzida de falhas, e caso as mesmas ocorram, necessitam ser solucionadas no menor tempo possível, visto que muitos equipamentos eletrônicos oferecem suporte à vida e as paradas não programadas podem ser onerosas e ocasionar custos desnecessários. Neste trabalho, Redes Neurais Artificiais são utilizadas como ferramenta na modelagem de falhas, visando a qualidade na manutenção dos equipamentos. A rede neural proposta é do tipo perceptron multicamadas e utiliza para treinamento e validação dos dados o algoritmo *backpropagation*. Neste algoritmo são empregados os métodos de Levenberg-Marquardt e, do gradiente aonde são utilizados os Algoritmos Genéticos para a obtenção dos valores da taxa de aprendizagem em cada iteração. Com o emprego da metodologia utilizada, tem-se a possibilidade de diminuir o tempo de parada do sistema estudado, pois se pode restringir o campo de busca do local da falha, reduzindo os prejuízos com a manutenção eficiente do equipamento. Os resultados encontrados demonstram a viabilidade do uso da metodologia para o diagnóstico de falhas ocorridas em fontes ininterruptas de energia.

ABSTRACT

The use of systems of uninterrupted feeding of electric power (UPS, Uninterruptible Power Supply) has if turned more and more common to the electric power supply to critical loads. Thus, electronic equipments commonly tied the electric power net directly pass to have an effective protection against the several anomalies found in this distribution. However, as all of the equipments are subject to fail, besides UPS, a stop not drifted can result in great damages. Before this fact, UPS should present a reduced rate of flaws, and case the same ones happen, they need to be solved in the smallest possible time, because many electronic equipments offer support to the life and the stops no programmed they can be onerous and to cause unnecessary costs. In this work, Artificial Neural Network are used as tool in the modelling of defaults, seeking the quality in the maintenance of the equipments. The neural network proposed is of the multilayer perceptron type and it uses for training and validation of the data the backpropagation algorithm. In this algorithm the methods of Levenberg-Marquardt are used and, of the gradient the where the Genetic Algorithms are used for the obtaining of the values of rate of learning each iteration. With the job of the used methodology, the possibility is had of reducing the time of stop of the studied system, therefore she can restrict the field of search of the place of the flaw, reducing the damages with the efficient maintenance of the equipment. The obtained results demonstrate the viability of the use of the methodology for the diagnosis of fail happened in uninterruptible power supply.

SUMÁRIO

LISTA DE FIGURAS	ix
LISTA DE ABREVIATURAS E SÍMBOLOS	xi
INTRODUÇÃO	01
1 FONTES ININTERRUPTAS DE ENERGIA.....	06
1.1 Introdução.....	06
1.2 Aplicações.....	07
1.3 Tipos de UPS.....	08
1.3.1 Passive-standby (off-line).....	08
1.3.2 Line-interactive.....	10
1.3.3 Double-conversion (on-line).....	11
1.4 Tipos de falhas	13
2 REDES NEURAS ARTIFICIAIS	14
2.1 Introdução.....	14
2.2 Um breve histórico.....	15
2.3 Modelo biológico.....	18
2.4 Modelo neural artificial.....	20
2.4.1 Funções de ativação.....	22
2.5 Arquitetura das redes.....	24
2.5.1 Redes feedforward de camada única	24
2.5.2 Redes feedforward de múltiplas camadas.....	25
2.5.3 Redes recorrentes	26
2.6 Aprendizado.....	26
2.6.1 Aprendizado supervisionado.....	27
2.6.2 Aprendizado não supervisionado.....	28
2.6.3 Aprendizado por reforço.....	28
2.7 Modelos de redes neurais	28

2.7.1	Perceptron.....	29
2.7.2	Perceptron multicamadas	29
2.7.3	Mapas auto organizáveis - Redes de Kohonen.....	29
2.7.4	Redes de Hopfield.....	30
2.7.5	Redes de base radial	30
2.8	Aplicações.....	30
3	MODELAGEM MATEMÁTICA DE UPS UTILIZANDO REDES NEURAI	32
3.1	Introdução.....	32
3.2	Descrição do circuito UPS.....	33
3.2.1	Retificador e conversor pré-regulador Boost	33
3.2.2	Conversor bidirecional Buck/Boost.....	34
3.2.3	Inversor CC/CA de saída	35
3.3	Simulações	35
3.4	Identificação de Sistemas.....	38
3.4.1	Modelo NARX	40
3.4.2	Modelo NARMAX.....	41
3.5	Perceptron de múltiplas camadas e o Algoritmo Backpropagation	42
3.6	Algoritmo de treinamento rápido.....	46
3.6.1	Algoritmo Levenberg-Marquardt.....	46
3.6.2	Taxa de aprendizagem adaptativa e algoritmos genéticos.....	47
4	RESULTADOS	50
4.1	Introdução.....	50
4.2	Rede neural artificial.....	50
4.3	Circuito para simulações.....	52
4.4	Resultados das simulações.....	52
4.4.1	Grupo de Falhas 1	53
4.4.2	Grupo de Falhas 2.....	58
4.4.3	Grupo de Falhas 7.....	62
4.5	Análise dos resultados.....	65
	CONCLUSÃO	67
	REFERÊNCIAS BIBLIOGRÁFICAS	70

LISTA DE FIGURAS

FIGURA 1.1 – Configuração básica de uma UPS passive-standby.....	09
FIGURA 1.2 – Configuração básica de uma UPS line-interactive	10
FIGURA 1.3 – Configuração básica de uma UPS double-conversion	11
FIGURA 2.1 – Estrutura básica de um neurônio biológico.....	19
FIGURA 2.2 – Modelo matemático do neurônio.....	20
FIGURA 2.3 – Funções de ativação: (a) Função de limiar, (b) Função linear por partes, (c) Função sigmóide	22
FIGURA 2.4 – Rede alimentada adiante de camada única.....	25
FIGURA 2.5 – Rede alimentada adiante de múltiplas camadas.....	25
FIGURA 2.6 – Rede neural recorrente.....	26
FIGURA 3.1 – Diagrama de blocos da UPS on-line.....	33
FIGURA 3.2 – Circuito utilizado para simulações das falhas.....	36
FIGURA 3.3 – Modelo NARX para identificação de sistemas	40
FIGURA 3.4 – Modelo NARMAX para identificação de sistemas.....	41
FIGURA 4.1 – Circuito utilizado para simulações das falhas.....	53
FIGURA 4.2 – Sinais de entrada (vermelho) e saída (azul) – $G1$	54
FIGURA 4.3 – Saídas apresentadas pela rede neural – $G1$	55
FIGURA 4.4 – Saída apresentada pelo algoritmo Levenberg-Marquardt – modelo NARMAX – $G1$	56
FIGURA 4.5 – Saída apresentada pelo algoritmo da Taxa de Aprendizagem Adaptativa – modelo NARMAX – $G1$	56
FIGURA 4.6 – Erro médio quadrático apresentado pela rede neural – $G1$	57
FIGURA 4.7 – Evolução da taxa de aprendizagem – $G1$	58
FIGURA 4.8 – Sinais de entrada (vermelho) e saída (azul) – Circuito Aberto no diodo D1.....	59

FIGURA 4.9 – Sinais de entrada (vermelho) e saída (azul) – Circuito Aberto no diodo D4.....	59
FIGURA 4.10 – Saídas apresentadas pela rede neural – G2.....	60
FIGURA 4.11 – Erro médio quadrático apresentado pela rede neural – G2.....	61
FIGURA 4.12 – Evolução da taxa de aprendizagem – G2.....	62
FIGURA 4.13 – Sinais de entrada (vermelho) e saída (azul) – G7.....	63
FIGURA 4.14 – Saídas apresentadas pela rede neural – G7.....	63
FIGURA 4.15 – Erro médio quadrático apresentado pela rede neural – G7.....	64
FIGURA 4.16 – Evolução da taxa de aprendizagem – G7.....	65
FIGURA 4.17 – Resumo dos resultados obtidos a partir do treinamento.....	66

LISTA DE ABREVIATURAS E SÍMBOLOS

Adaline	<i>Adaptative Linear Element</i>
AG	Algoritmos Genéticos
AVR	<i>Automatic Voltage Regulation</i>
CA	Corrente Alternada
CC	Corrente Contínua
CCM	<i>Continuous Conduction Mode</i>
CENELEC	Comitê de Normalização Européia
DCM	<i>Discontinuous Conduction Mode</i>
DCS	Sistemas de Controle Distribuídos
ERR	<i>Error Reduction Ratio</i>
IEC	<i>International Electrotechnical Commission</i>
IEEE	<i>Institute of Electrical and Electronics Engineers</i>
INNS	<i>International Neural Networks Society</i>
kVA.	kilo Volt Ampere
Lbb	Volume do Indutor Boost
Madaline	<i>Multiple-Adaline</i>
MATLAB	<i>Mathematical Laboratory</i>
MLP	<i>Multi-Layer Perceptron</i>
NARMAX	<i>Non-linear Auto-Regressive Moving Average with eXogenous inputs</i>
NARX	<i>Non-linear Auto-Regressive with eXogenous inputs</i>
PLC	Controladores Lógico Programáveis
PWM	<i>Pulse Width Modulation</i>
RNA	Redes Neurais Artificiais
UPS	<i>Uninterruptable Power Supply</i>
ZCS	<i>Zero Current Switching</i>
a	Parâmetro de inclinação
b_k	Bias aplicado à camada k
C	Capacitor
c	Constante pré-definida

D	Diodo
d	Saída desejada
E_{med}	Erro Médio Quadrático
e	Erro
F'	Função a ser aproximada
g	Gradiente
$G1$	Grupo de Falhas 1
$G2$	Grupo de Falhas 2
$G3$	Grupo de Falhas 3
$G4$	Grupo de Falhas 4
$G5$	Grupo de Falhas 5
$G6$	Grupo de Falhas 6
$G7$	Grupo de Falhas 7
$G8$	Grupo de Falhas 8
$G9$	Grupo de Falhas 9
$G10$	Grupo de Falhas 10
H	Matriz Hessiana
I	Matriz Identidade
J	Matriz Jacobiana
j	Índice do neurônio
L	Indutor
l	Índice da camada em que o neurônio encontra-se localizado
N	Conjunto de exemplos de treinamento
n	Iteração
Q	Chave do inversor
R	Resistor
S	Chave do conversor Buck/Boost
u	Sinais de entrada
V	Tensão de saída
v_k	Campo local induzido
w_{kj}	Pesos sinápticos da camada k relativos ao neurônio j
x_j	Sinais de entrada do neurônio j
y_k	Sinais de saída

z^{-1}	Atraso unitário
δ_j	Gradiente local
Σ	Função Soma (Somatório)
η	Taxa de aprendizagem
μ	Constante do método de Levenberg-Marquardt
$\varphi(.)$	Função de ativação
$\varphi'(.)$	Derivada da função de ativação

INTRODUÇÃO

O crescente avanço tecnológico verificado nas últimas décadas exige das máquinas e estruturas elétricas, cada vez mais, maiores capacidades de trabalho e velocidade de operação. Por este motivo, têm sido necessários mecanismos que garantam maior segurança e confiabilidade aos mesmos. O que se deseja são componentes e funcionamento que tenham bom desempenho e sejam livres de falhas.

Tendo em vista que equipamentos eletrônicos utilizados em nosso cotidiano são ligados diretamente à rede de energia elétrica, sabe-se que estes estão sujeitos às anomalias apresentadas pela rede como interrupção, ruídos, aumento ou defasagem de frequência e tensão, entre outros. Com isto, equipamentos importantes como computadores, equipamentos de telecomunicações e de suporte a vida, centrais de processamento de dados, entre outros, estão susceptíveis a tal exposição, correndo o risco de um simples mau funcionamento até o sobreaquecimento e conseqüentemente, a queima de motores e maquinários em geral.

Eventuais falhas em componentes de um sistema dinâmico inserido no processo industrial podem acarretar perdas de desempenho não aceitáveis, bem como por em risco os equipamentos e o pessoal envolvido. Portanto, sistemas de detecção e diagnóstico de falhas se tornam importantes, como também os sistemas tolerantes a falhas.

Com o pensamento voltado para a questão de falha no suprimento de energia, as empresas desenvolveram um sistema que deve ser utilizado como interface entre equipamentos eletrônicos e a rede de energia elétrica. Tal sistema é denominado UPS (*Uninterruptable Power Supply*) que em português significa Fonte Ininterrupta de Energia, também conhecido popularmente como *No-Break*. As fontes ininterruptas de energia estão sendo cada vez mais utilizadas para manter a

disponibilidade de alimentação de sistemas e o fornecimento de energia elétrica com qualidade aos equipamentos mesmo com os distúrbios e interrupções da tensão de fornecimento da concessionária de energia elétrica.

Uma variedade de UPS vem sendo desenvolvida no intuito de atender as necessidades do mercado, servindo para diferentes tipos de carga, que vão desde dezenas de watts até vários megawatts. Porém, normalmente uma fonte ininterrupta de energia é formada basicamente de uma unidade retificadora cuja função é converter a corrente alternada em contínua, um sistema armazenador de energia e uma unidade inversora que produz corrente alternada a partir deste elo contínuo. O meio de armazenamento de energia comumente utilizado são baterias, que podem fornecer energia por alguns minutos ou mesmo horas.

De acordo com o exposto, as fontes ininterruptas de energia devem apresentar uma taxa reduzida de falhas e caso as mesmas ocorram, devem ser solucionadas no menor tempo possível. Visto que muitos equipamentos eletrônicos mencionados oferecem suporte à vida, as paradas não programadas podem ser onerosas e ocasionar custos desnecessários. Devido a isto, nesta dissertação é proposto um sistema para detecção e análise de falhas ocorridas em UPS utilizando inteligência artificial, mais especificamente, Redes Neurais Artificiais (RNA).

As redes neurais artificiais são técnicas eficientes de inteligência artificial para lidar com sistemas complexos, não-lineares e multivariáveis, pois as mesmas possuem características como a capacidade de adaptação, aprendizado, reconhecimento de padrões, memorização e aproximação de funções não-lineares que são habilidades fundamentais para tratar de sistemas complexos.

Por apresentarem as características de potencialidade de adaptação e aprendizado, as redes neurais tornam-se ferramentas apropriadas à previsão de comportamento dinâmico. Uma rede satisfatoriamente treinada é capaz de generalizar o sistema quando são apresentados, nas entradas, dados novos, não utilizados na fase de treinamento. Com essa peculiaridade, as redes neurais artificiais se tornam técnicas capazes de estimar sistemas não-lineares com amplo grau de precisão.

Vários pesquisadores buscaram aperfeiçoamento na identificação, isolamento e compensação de falhas. Inicialmente Debebe *et al.* (1991) sugeriu o uso de regras baseadas em sistemas inteligentes para diagnosticar falhas em inversores alimentados em tensão. Através de uma base de dados, de fatos e informações parametrizadas, um mecanismo faz a suposição das condições do sistema, além do *status* do circuito de proteção.

Kastha e Bose (1994) fizeram uma investigação sistemática dos diferentes tipos de falhas em inversores para acionamento de motores de indução. Através deste estudo foram estabelecidas técnicas possibilitando determinar problemas nos componentes e contribuir para a melhoria de projeto de sistemas de proteção.

Outro trabalho utilizando modelo de base de dados foi proposto por Peugeot *et al.* (1998). Este estudo é baseado na análise de trajetórias de vetores de corrente e freqüências instantâneas durante as falhas em Inversores PWM (*Pulse Width Modulation*).

Em 2003, Ribeiro *et al.* contribui com dois trabalhos. O primeiro deles desenvolve um sistema que, além de detectar e isolar as falhas em inversores alimentados em tensão, faz a compensação, reconfigurando o sistema através de uma estratégia de controle tolerante a falhas. No segundo trabalho é realizado um estudo investigativo de diferentes técnicas de detecção e identificação de falhas nos interruptores de potência em acionamento de sistemas alimentados em tensão.

A definição de falha foi estabelecida por Gibilisco (2001), como um defeito em um ponto ou região em um circuito ou componente. Diante desta afirmação, é possível propor a designação de duas categorias de falhas. Uma categoria onde a falha deixa o equipamento ou dispositivo inoperante como um todo, e outra, onde o equipamento continua seu funcionamento de forma inadequada, suprimindo as cargas.

Dambróz *et al.* (2007) desenvolveram um sistema de alerta para falhas em fontes ininterruptas de energia usando GSM. O dispositivo desenvolvido analisa o comportamento do equipamento e descobre alguns tipos de faltas. Depois disso

transmite via mensagem SMS o aviso a uma central, aumentando a confiança no sistema e diminuindo o tempo em que o equipamento opera com defeito.

Novas investigações a respeito de falhas em inversores são apresentadas por Chafei *et al.* (2008). Através de diferentes técnicas propostas, é possível descobrir e identificar o interruptor do inversor em que a falha ocorreu.

O objetivo deste trabalho é propor um sistema de detecção e diagnóstico de falhas baseado em redes neurais artificiais para fontes ininterruptas de energia. Na arquitetura do sistema proposto, uma rede neural é utilizada, sendo que duas técnicas são empregadas para aprendizagem e correção dos pesos: taxa de aprendizagem adaptativa e Levenberg-Marquardt. O modelo de UPS utilizado no estudo é do tipo *on-line*.

Esta dissertação está dividida em cinco capítulos, os quais buscam o bom entendimento da proposta central, através da apresentação da teoria desenvolvida.

O capítulo 1 descreve os principais sistemas UPS existentes com uma breve explicação de suas características, vantagens e desvantagens, aplicações e possíveis falhas que possam ocorrer.

No capítulo 2 é realizado um estudo sobre redes neurais artificiais, desde uma revisão histórica na área; fazendo comparações através do modelo biológico e o modelo artificial de um neurônio; apresentando a seguir sua formulação estrutural, através das funções de ativação, arquitetura, aprendizado e os tipos de redes neurais artificiais.

O capítulo 3 tem a finalidade de apresentar a metodologia utilizada para a aplicação de redes neurais artificiais na identificação de falhas em fontes ininterruptas de energia. Para tanto, é realizado um estudo sobre as redes perceptron multicamadas, fazendo descrição do algoritmo de treinamento *backpropagation*, e as seguintes estratégias de ajuste do coeficiente de aprendizagem da rede neural: através do Algoritmo Genético e do método de Levenberg-Marquardt. A seguir, encontram-se os modelos NARX e NARMAX

utilizados para representação do sistema, o qual pode ser visualizado juntamente com suas especificações e descrições relevantes ao final do capítulo.

No capítulo 4, é realizada a apresentação dos resultados de simulação obtidos a partir da aplicação das redes neurais artificiais na identificação de falhas em fontes ininterruptas de energia, sendo analisada a utilização das diferentes técnicas para ajuste dos pesos e os modelos NARX e NARMAX.

Por fim, é apresentada uma conclusão geral deste trabalho.

1 FONTES ININTERRUPTAS DE ENERGIA

1.1 Introdução

Uninterruptable Power Supply (UPS) é um equipamento eletrônico de potência que apresenta como função principal o fornecimento de energia de forma contínua e de qualidade aos equipamentos eletrônicos na eventual falta parcial ou total da fonte de potência, normalmente a rede elétrica local (Nazário, 2007). Sua configuração baseia-se na utilização de um carregador de baterias que converte energia CA em CC, baterias responsáveis por armazenar a energia, e um inversor capaz de converter energia CC novamente em CA para alimentar os equipamentos. A partir destes elementos, existem diversas configurações que podem ser obtidas de acordo com o grau de exigência da carga (Pinheiro, *et al.*, 2002).

Há duas razões importantes para utilizar a tecnologia de UPS. Primeiro, a continuidade do fornecimento de energia e, segundo, uma provisão limpa e de qualidade, sem impulsos e perturbações de modo comuns (Bell, 2006/07).

Durante uma eventual falta de energia ou má qualidade da tensão da rede, a carga passa a ser alimentada pelo banco de baterias, sem interrupção no fornecimento de energia durante esta transição. A escolha da bateria deve ser feita baseando-se principalmente no espaço físico e nas exigências, no tempo de vida esperado e no tipo de proteção que o equipamento oferece (Carle, 1995).

Neste capítulo serão apresentadas as aplicações e características dos sistemas ininterruptos de energia, bem como as configurações existentes e os principais tipos de falhas que podem ocorrer.

1.2 Aplicações

Segundo Beaudet, Fiorina & Pinon (1999), as UPS apareceram no mercado por volta dos anos setenta, essencialmente com o objetivo de suprir as necessidades de sistemas de computadores grandes em termos de continuidade e qualidade na provisão de potencial elétrico. Atualmente, estes sistemas de energia ininterrupta estão sendo cada vez mais utilizados para manter a disponibilidade da alimentação tanto de equipamentos eletrônicos simples, mas que requeiram continuidade no serviço, quanto de sofisticados equipamentos como, por exemplo, os que dão suporte à vida.

Carle (1995) em seu trabalho cita algumas das aplicações encontradas:

- Iluminação de emergência: pacote com baterias individuais de instalação ou sistemas de iluminação completa em edifícios.
- Dispositivos eletrônicos: computadores pessoais, centrais de processamento de dados e equipamentos de telecomunicações.
- Controle de processos: sistemas de controle distribuídos (DCS) e controladores lógicos programáveis;
- Equipamentos hospitalares: instrumentação, laboratórios, unidades de internação, aparelhos cirúrgicos, etc.

Os equipamentos evoluíram para se adaptar ao vasto aumento no número de cargas sensíveis e à diversificação delas, devido à explosão da tecnologia digital. Como resultado das mudanças, as UPS satisfazem às diversas necessidades de aplicações, que vão desde míni a microcomputadores, processos industriais, instrumentação, telecomunicação, etc. (Beaudet, Fiorina & Pinon, 1999).

1.3 Tipos de UPS

Durante o processo de evolução das UPS, as técnicas empregadas foram as mais diversas, dependendo do tipo de proteção aplicada e nível de potência. Com isso, a descrição utilizada para qualificar os produtos era freqüentemente confundida, causando dúvidas ao usuário.

Beaudet, Fiorina & Pinon (1999) salientam que, por este motivo, a IEC (*International Electrotechnical Commission*) tem estabelecido normas para os diferentes tipos de UPS e os métodos usados para medir seus parâmetros elétricos. O conteúdo da norma também foi adotado pelo CENELEC que é o Comitê de Normalização Européia. A norma IEC 62040-3 e seu equivalente europeu ENV 50091-3 classificaram claramente em três (03) tipos as UPS: *passive-standby (off-line)*, *line-interactive* e *double-conversion (on-line)*.

A seguir são apresentados os tipos unificados de UPS, com as vantagens e desvantagens de cada tipo e seu respectivo campo de aplicação.

1.3.1 Passive-standby (off-line)

A UPS *passive-standby*, também conhecida como UPS do tipo *off-line*, é o tipo mais comum utilizado para computadores pessoais. Consiste de um conversor para carga das baterias, banco de baterias, inversor e uma chave estática, como ilustra a Figura 1.1 (Pinheiro *et al.*, 2002).

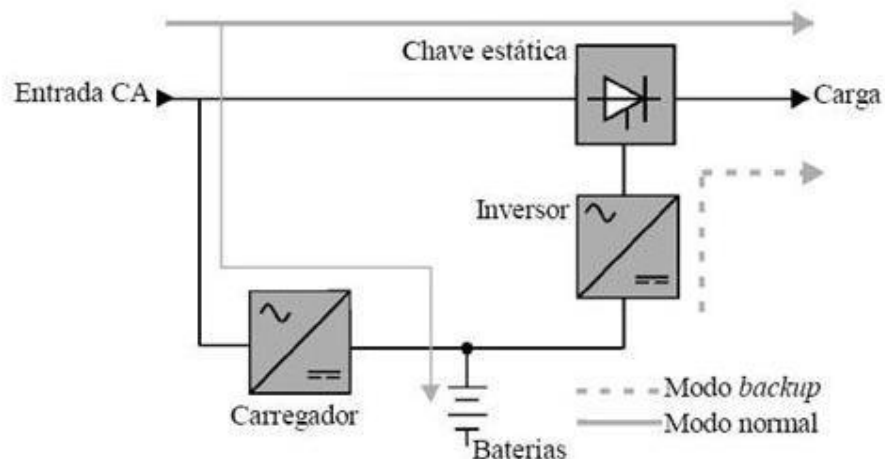


Figura 1.1 – Configuração básica de uma UPS passive-standby.

As UPS deste tipo apresentam somente um estágio de conversão de energia. Quando a rede pública apresentar alguma falha, o elemento armazenador fornecerá energia para a carga. Durante a operação em modo normal, a chave estática permanece fechada. Dessa forma, a carga é alimentada diretamente da rede, sem nenhum processamento de energia. O conversor funciona apenas para o carregamento das baterias, pois não processa a potência demandada pela carga. O inversor é projetado para atender a potência máxima da carga, ficando conectado em paralelo com a rede de alimentação, permanecendo desligado enquanto o modo rede estiver em funcionamento, e só inicia quando há uma falha energética, daí o nome “*standby*” (Rasmussen, 2004). Na operação em modo bateria, ou “*backup*”, a carga é alimentada pela energia acumulada nas baterias através do inversor, até que o período de autonomia seja atingido. Quando a energia elétrica falha, o UPS demora um tempo para detectar a falha e acionar a bateria. Embora esse retardo seja pequeno, pode afetar o funcionamento de equipamentos mais sensíveis.

Este tipo de UPS apresenta fácil projeto, pequena dimensão, maior eficiência e menor custo se comparado com os demais tipos de UPS (Karve, 2000). Porém, a tensão/freqüência de saída é dependente da tensão/freqüência de entrada e apresenta um tempo de transferência entre os diferentes modos de operação. Assim, este tipo de UPS é um compromisso entre um nível aceitável de proteção contra distúrbios e custo, sendo comumente utilizados em baixas potências, menores que 2 kVA.

1.3.2 Line-interactive

As UPS line-interactive consistem de uma chave estática na entrada, um conversor bidirecional (que cumpre papel tanto de conversor CA-CC, quanto CC-CA) e um banco de baterias, conforme Figura 1.2 (Pinheiro *et al.*, 2002).

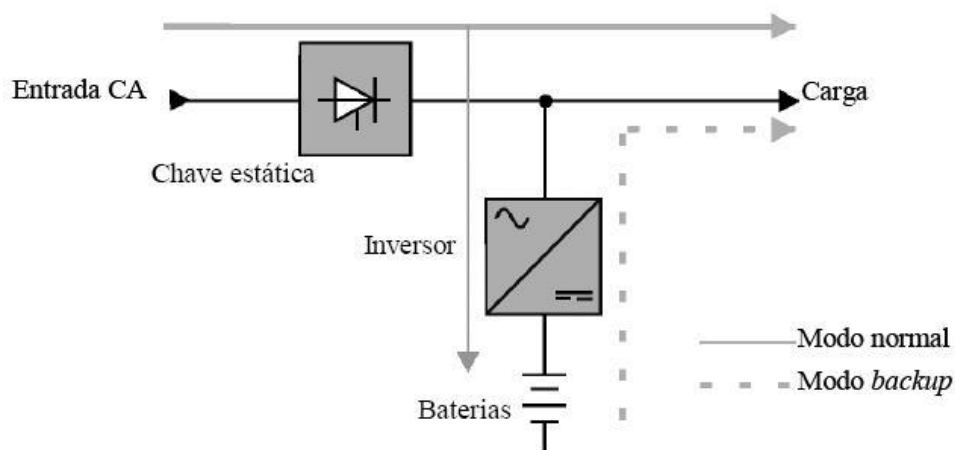


Figura 1.2 – Configuração básica de uma UPS line-interactive

Quando a alimentação CA está operando normalmente, a carga é alimentada diretamente pela rede. Oliveira (2007) destaca que o conversor bidirecional, conectado em paralelo, funciona como um carregador de baterias, como ilustrado na figura anterior. O termo UPS line-interactive provém do fato que o inversor interage com a linha (rede pública) para diminuir, elevar ou substituir a energia conforme requerido para manter a tensão constante para a carga crítica. Quando existir corte da rede de alimentação ou alguma perturbação na entrada, a carga é alimentada no modo bateria (ou “*backup*”). Nesse modo, a chave estática é aberta e a energia acumulada nas baterias é entregue à carga através do conversor bidirecional, que funciona como um inversor. Com o inversor sempre a funcionar e ligado à saída, esta concepção fornece filtragem suplementar e permite uma queda no tempo de transferência da rede para o elemento armazenador de energia, reduzindo o tempo quando comparada com a topologia UPS passive-standby (Pinheiro *et al.*, 2002).

Elevada eficiência, baixo custo e alta confiabilidade, aliados à capacidade de corrigir condições de níveis altos ou baixos de tensão, coloca este tipo de UPS como a dominante na gama de alimentação de 0,5 – 5kVA. As topologias “Boost/Buck”, AVR (*automatic voltage regulation*) e conversão Delta pertencem às UPS line-interactive (Karve, 2000).

1.3.3 Double-conversion (on-line)

O sistema UPS do tipo double-conversion, também conhecida como on-line, é composto de um retificador/carregador, um inversor, um banco de baterias e um circuito de *bypass* e, dependendo da UPS, isolamento galvânico entre entrada e saída através de um transformador. A Figura 1.3 mostra o diagrama do sistema UPS descrito (Pinheiro *et al.*, 2002).

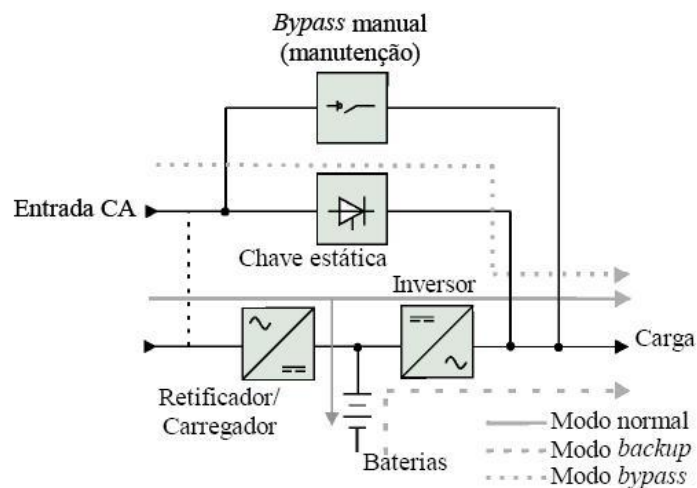


Figura 1.3 – Configuração básica de uma UPS double-conversion

Em seu trabalho, Oliveira (2007) expõe que no caso do sistema descrito anteriormente, o retificador alimenta continuamente o inversor, mesmo durante a ausência de rede ou devido a qualquer distúrbio ocorrido no fornecimento de energia elétrica. O inversor converte corrente contínua em alternada, ajustando continuamente a amplitude e frequência para que, na sua saída, o sistema forneça

sempre uma tensão constante para a carga. Como o inversor é conectado em série entre a rede pública de energia e a carga, e dimensionado para operar tanto em modo rede como em modo bateria, ele proporciona um tempo de transferência praticamente zero na transição entre os dois modos.

Para operação sem a rede elétrica, a UPS conta com um banco de baterias que podem suprir por tempo limitado (dependendo da capacidade das baterias) a energia necessária para as cargas conectadas continuarem funcionando ou até que a rede elétrica seja normalizada. Uma das vantagens deste sistema é que ele não apresenta problemas quanto ao tempo de transferência. Oliveira (2007) enfatiza que outra característica existente é o modo bypass, o qual pode entrar em funcionamento automaticamente dependendo da decisão tomada pela supervisão do sistema, ou manualmente.

As UPS do tipo on-line operam em três modos, sendo eles: o modo normal, o modo backup e o modo bypass, conforme Oliveira (2007):

- *Modo normal:* O sistema provê energia da rede elétrica processando esta energia nos estágios do retificador e do inversor, antes de entregá-la à carga. Neste modo, o banco de baterias é continuamente carregado.
- *Modo backup:* Ao serem detectados níveis de tensão fora dos valores especificados na tensão de rede, a tensão de entrada do retificador é desconectada e, com transferência de tempo zero, o banco de baterias passa a suprir o barramento CC e este, o inversor.
- *Modo bypass:* Entra em funcionamento no momento de falha no inversor. Neste modo de operação, a carga é conectada diretamente à rede elétrica, ficando a mesma sujeita a variação e distúrbios da rede.

Estas UPS apresentam algumas importantes vantagens, como independência da tensão/freqüência de saída com relação à tensão/freqüência de entrada; possibilidade de tempo de transferência nulo; possibilidade de sintetizar diferentes tipos de forma de onda de tensão de saída; possibilidade de correção do fator de potência. Contudo, devido à dupla conversão de energia durante a operação normal,

este tipo de UPS apresenta eficiência reduzida, a que se junta o respectivo aumento de geração de calor e preço elevado por causa da presença de conversores em série que permanentemente processam energia (Rasmussen, 2004).

Assim, esta é a configuração mais completa em termos de proteção da carga, possibilitando regulação e níveis de desempenho. Devido às suas inúmeras vantagens, UPS double-conversion são largamente utilizadas para a proteção de cargas críticas em maiores níveis de potência, acima de 10kVA (Karve, 2000).

1.4 Tipos de falhas

Mesmo que uma UPS seja projetada com robustez e segurança, falhas podem ocorrer durante o seu funcionamento. Embora pequenas, quando elas ocorrem, muitas situações de risco surgem. Caso haja propagação de falhas em computadores ou maquinários em geral, estas podem acarretar prejuízo financeiro para empresas e indústrias. Porém, se a falha acontecer em ambientes cujos equipamentos oferecem suporte à vida encontrados em hospitais e/ou laboratórios, uma vida pode ser prejudicada e até mesmo perdida.

Diversas são as falhas que podem ocorrer no equipamento, desde uma falta de manutenção no banco de baterias até o rompimento de um fusível. Dentre as anomalias que podem ocorrer nos componentes da UPS, algumas falhas são consideradas como relevantes ao estudo em questão, visando à agilidade na manutenção dos equipamentos.

Como exemplos, podem ser mencionados os defeitos encontrados nos diodos retificadores ou nos interruptores do inversor, ou ainda podem ser identificadas anomalias nos componentes do conversor Boost ou do conversor bidirecional, além de falha do barramento CC com o terra ou curto circuito na saída, dentre outros.

2 REDES NEURAIIS ARTIFICIAIS

2.1 Introdução

A grande capacidade de processamento de informações do cérebro humano tem motivado pesquisas no sentido de encontrar modelos que reproduzam suas características computacionais, possibilitando, desta forma, que se realizem certas tarefas de uma maneira semelhante ao cérebro humano.

As redes neurais artificiais (RNA) foram desenvolvidas tomando-se como base o cérebro humano, ou seja, são técnicas computacionais que apresentam um modelo matemático inspirado na estrutura neural de organismos inteligentes e que adquirem conhecimento através da experiência (Rocha, 2006).

Haykin (2001) menciona que uma rede neural é uma “máquina” projetada para modelar, de forma simplificada, a maneira como o cérebro realiza uma tarefa particular ou função de interesse; a rede é normalmente implementada utilizando-se componentes eletrônicos ou é simulada por programação computacional.

As motivações da pesquisa em redes neurais artificiais variam de acordo com a área de interesse. No campo biológico, podem ser mencionadas: a compreensão da estrutura do cérebro para explicar funções e comportamentos, a memória, os estudos de disfunções cerebrais, como a epilepsia e os efeitos causados por drogas. Na engenharia: a construção de sistemas de processamento de informação mais eficientes e a aplicação em controle e identificação de processos. Na ciência da computação: compreensão do processo de tratamento da informação empregado pelo cérebro, visando construir computadores e sistemas de representação eficientes e o uso de novas tecnologias para a resolução de problemas de alto grau de complexidade, como reconhecimento de imagens, recuperação de informação a partir de dados contendo ruídos, aprendizado de máquina.

Assim, o intuito deste capítulo é apresentar, de forma sucinta, as características principais das redes neurais artificiais. Para tanto, inicia-se com um breve histórico da área; em seguida são descritos os modelos de um neurônio biológico e um neurônio artificial. O capítulo continua com a relação das arquiteturas e o aprendizado/treinamento de uma rede neural artificial, apresentando ao final os principais e mais conhecidos tipos de redes.

2.2 Um breve histórico

A história das redes neurais artificiais é relativamente recente. Conta com pouco mais de meio século e sua evolução inicia num período de grande atividade, seguido por anos de estagnação nas pesquisas para, logo a seguir, permitir um processo de ressurgimento do interesse científico como consequência do desenvolvimento de novas tecnologias e fundamentos teóricos.

O primeiro modelo formalizado de redes neurais artificiais foi proposto por McCulloch e Pitts, em 1943. A estrutura criada fazia uma analogia entre células vivas e o processamento eletrônico, abstraindo complicadas características encontradas no corpo de neurônios biológicos. O trabalho mencionado se concentra mais em descrever um modelo artificial de um neurônio e de apresentar as suas capacidades computacionais do que identificar técnicas de aprendizado.

Muitos outros artigos e livros surgiram desde então, porém, poucos resultados foram obtidos. Huamaní (2003) descreve que em 1949, Donald Hebb publicou um livro intitulado "*The Organization of Behavior*" (A Organização do Comportamento), o qual propõe, pela primeira vez, uma lei de aprendizagem específica para as sinapses dos neurônios. Hebb sugere que a aprendizagem do conhecimento representado em uma rede neural seja alcançada pelo fortalecimento das conexões entre neurônios adjacentes, sempre que esses estiverem excitados (Huamaní, 2003).

Este primeiro e corajoso passo serviu de inspiração para que muitos outros pesquisadores seguissem a mesma idéia. E embora muito tenha sido estudado e publicado nos anos posteriores, estes serviram principalmente como base para os desenvolvimentos posteriores.

Em 1958, Frank Rosenblatt, baseado nos estudos anteriores, mostrou em seu livro "*Principles of Neurodynamics*", várias idéias a respeito do modelo pioneiro na área: os *perceptrons*. Huamaní (2003) descreve que neste modelo os neurônios eram organizados em camadas de entrada e saída, onde os pesos das conexões eram adaptados a fim de se atingir a eficiência sináptica. Era um modelo simples, de fácil implementação, e que utilizava os neurônios propostos por McCulloch e Pitts.

Rosenblatt demonstrou que, se fossem acrescentadas sinapses ajustáveis, as redes neurais de McCulloch e Pitts poderiam ser treinadas para classificar padrões em classes linearmente separáveis, convergindo em um número limitado de passos.

Widrow e Hoff em 1960, implementaram uma regra de aprendizado baseada na minimização do erro quadrático o qual foi usado para formular o Adaline (*Adaptative Linear Element*). Posteriormente, Widrow e seus estudantes implementaram uma das primeiras redes neurais em camadas treináveis com múltiplos elementos adaptativos denominada Madaline (*Multiple-Adaline*).

Em 1969, Minsky e Papert, publicaram um artigo denominado "*Perceptron*" no qual realizaram um estudo mais rigoroso do modelo do perceptron proposto por Rosenblatt. Demonstraram matematicamente os limites existentes nos cálculos dos perceptrons de camada única, provando que tais redes não eram capazes de resolver uma ampla classe de problemas devido às restrições de representação. Afirmaram ainda que a versão de múltiplas camadas não iria superar estas limitações, diminuindo de uma maneira brusca as pesquisas neste setor. Como Minsky e Papert eram considerados importantes e renomados pesquisadores, grande parte das pesquisas foram abandonadas e seus estudos omitidos (sem publicá-los) (Fiori, 2007).

Na década de 70 e início dos anos 80, surgiram estudos voltados para modelos com memória associativa. Von der Malsburg em 1973 e Grossberg em 1976, desenvolveram idéias de aprendizado competitivo.

O interesse em redes neurais foi renovado em 1982, quando John Hopfield publica um importante estudo baseado no princípio físico sobre o armazenamento de informação em configurações dinamicamente estáveis. Hopfield publicou seu trabalho sobre redes neurais totalmente recorrentes utilizando a idéia de uma função de energia, sendo este um dos primeiros modelos a introduzir dinâmica em redes neurais. No mesmo ano, Kohonen publicou um artigo descrevendo uma rede neural artificial baseada em auto-organização e nas características de aprendizado adaptativo do cérebro humano. Estes foram os trabalhos que marcaram o ressurgimento das redes neurais artificiais.

Hinton e Seynowsky, em 1983, estenderam o modelo de Hopfield com a incorporação de dinâmica estocástica. Este modelo de rede neural passou a ser conhecido como Máquina de Boltzmann, sendo esta a primeira aplicação bem sucedida de uma rede neural de múltiplas camadas.

Contribuição valorosa foi dada por Rumelhart e McClelland em 1983, Hinton e Williams, em 1986 que apresentaram o algoritmo de retropropagação (*backpropagation*) necessário para o treinamento de redes neurais multicamadas. Werbos, em 1974 já havia aplicado este algoritmo, porém em outro contexto (Fiori, 2007).

Este fato originou uma grande “explosão” na área, fazendo com que pesquisadores de diversos campos passassem a visualizar interessantes aplicações para as redes neurais artificiais.

Em 1987, ocorreu em São Francisco a primeira conferência de redes neurais em tempos modernos, “*IEEE International Conference on Neural Networks*”, sendo formada a “*International Neural Networks Society*” (INNS). A partir destes acontecimentos foi iniciada a publicação do periódico “*Neural Networks*” da INNS em

1989, seguido do “*Neural Computation*” e do “*IEEE Transactions on Neural Networks*”, em 1990.

Até o início dos anos 90, em muitos campos científicos, vários pesquisadores estavam entusiasmados com as possibilidades de aplicação das redes neurais artificiais, especialmente considerando o perceptron multicamadas (*MLP – Multi-Layer Perceptron*). A justificativa para este entusiasmo pode ser atribuída à obtenção de demonstrações da capacidade de aproximação universal do MLP.

Entretanto, dependendo da complexidade do problema, os algoritmos de treinamento tradicionais para redes neurais artificiais apresentam-se computacionalmente ineficientes. Para contornar este problema, Broomhead e Lowe apresentaram em 1988, as funções de base radial como uma alternativa aos perceptrons de múltiplas camadas. Outros autores, como Von Zuben (1996) e Iyoda (2000), empregando técnicas computacionais como estratégias não paramétricas de evolução, colaboraram para o aumento da eficiência dos algoritmos de treinamento.

2.3 Modelo biológico

Conforme relatado anteriormente, as redes neurais artificiais surgiram em consequência da busca por conhecimento a respeito da mente humana. Nesse sentido, houve um grande interesse em pesquisar o funcionamento das estruturas que a compõe.

O sistema nervoso humano é formado por cerca de 100 bilhões de células nervosas (neurônios), onde cada uma recebe e envia informações para várias partes do organismo. Vários neurônios se interconectam para formar uma rede neuronal (o termo neuronal geralmente é utilizado como referência ao neurônio natural, enquanto o termo neural aos neurônios artificiais), onde cada módulo ou área de especialização da rede é responsável pelas tarefas que são realizadas no sistema nervoso, tais como: controle da ação muscular, aquisição e processamento de imagens, sons, etc.

Na Figura 2.1 são mostrados os componentes mais comuns de um neurônio biológico:

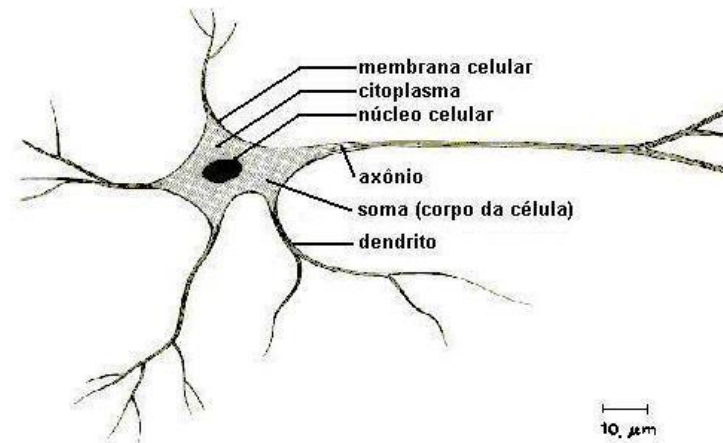


Figura 2.1 – Estrutura básica de um neurônio biológico

Segundo Huamaní (2003), o neurônio biológico é formado por um corpo celular que contém o núcleo da célula; diversos dendritos, através dos quais impulsos elétricos são recebidos, e um axônio, pelo qual impulsos elétricos são enviados. Assim, o neurônio recebe os sinais de entrada através dos dendritos, processa-os no corpo celular, e transmite o resultado do processamento através do axônio e ramificações.

As extremidades do axônio são conectadas com dendritos de outros neurônios pelas sinapses. As sinapses têm um papel fundamental na memorização da informação, ou seja, são como válvulas, sendo capazes de controlar a transmissão de impulsos (fluxo de informação) entre os neurônios.

Com base nos conceitos acima é que as redes neurais artificiais foram concebidas, sendo a seguir apresentada a sua unidade básica de processamento.

2.4 Modelo neural artificial

Assim como o sistema nervoso é composto por bilhões de células nervosas, a rede neural artificial também é formada por pequenos módulos que simulam o funcionamento de um neurônio. Estes módulos devem funcionar de acordo com os elementos em que foram inspirados, recebendo e retransmitindo informações.

O primeiro modelo matemático de um neurônio foi proposto por McCulloch e Pitts, em 1943. O neurônio tinha um número finito de entradas e apenas uma saída, apresentando grandes limitações. Huamaní (2003) descreve que as entradas deste neurônio eram binárias e o funcionamento era descrito intuitivamente da seguinte maneira: se a soma ponderada dos sinais de entrada de um neurônio ultrapassar um determinado limiar, então a saída recebe valor um; se não, recebe valor zero.

Após o modelo de McCulloch e Pitts surgiram outras abordagens, dando flexibilidade aos pesos e maior capacidade à Rede Neural. O modelo geral do neurônio pode ser visto na Figura 2.2.




Figura 2.2 – Modelo matemático do neurônio

Este modelo não mais apresenta unicamente a função limiar utilizada no neurônio de McCulloch e Pitts, mas sim uma função de ativação que pode ser definida de várias formas. Também foi acrescentado um *bias*, representado por b_k , que tem o efeito de aumentar ou diminuir a entrada líquida da função de ativação. O funcionamento deste neurônio, que segue o mesmo princípio de funcionamento do anterior, pode ser descrito matematicamente pelas seguintes equações:

$$v_k = \sum_{j=1}^m w_{kj} \cdot x_j + b_k \quad (2.1)$$

$$y_k = \varphi(v_k) \quad (2.2)$$

onde:

b_k é o bias aplicado à camada k ;

j é o índice de cada uma das m entradas do neurônio;

v_k chamado de campo local induzido, é a saída do combinador linear somado ao bias da camada k ;

w_{kj} são os pesos sinápticos da camada k relativos ao neurônio j ;

x_j são os sinais de entrada do neurônio j ;

y_k é o sinal de saída do neurônio;

$\varphi(.)$ é a função de ativação;

O parâmetro externo bias pode ser incluído na formulação matemática como sendo um peso sináptico associado a uma entrada de valor constante unitário, desta forma, a representação matemática do neurônio pode ser simplificada, conforme a formulação a seguir:

$$v_k = \sum_{j=0}^m w_{kj} \cdot x_j \quad (2.3)$$

$$y_k = \varphi(v_k) \quad (2.4)$$

onde:

$$x_0 = 1 \text{ e } w_{k0} = b_k$$

O processamento de um neurônio inicia quando os sinais são apresentados à entrada; cada sinal é multiplicado por um número ou peso, que indica a sua influência na saída da unidade. Em seguida, é feita a soma ponderada dos sinais. A ativação do neurônio é feita por uma função denominada função de ativação.

2.4.1 Funções de ativação

Segundo Haykin (2001), existem três tipos básicos de função de ativação utilizados em redes neurais artificiais, conforme podem ser vistas na Figura 2.3 e descritas a seguir:




Figura 2.3 – Funções de ativação: (a) Função de limiar, (b) Função linear por partes, (c) Função sigmóide.

(a) Função de limiar ou degrau: utilizada no modelo de McCulloch e Pitts, descreve a propriedade do “tudo-ou-nada” deste neurônio. É expressa da seguinte forma:

$$\varphi(v) = \begin{cases} 1, & \text{se } v \geq 0 \\ 0, & \text{se } v < 0 \end{cases} \quad (2.5)$$

(b) Função linear por partes ou rampa: esta forma de função de ativação pode ser vista como uma aproximação de um amplificador não-linear. Possui a seguinte definição:

$$\varphi(v) = \begin{cases} 1, & \text{se } v \geq \frac{1}{2} \\ v + \frac{1}{2}, & \text{se } -\frac{1}{2} < v < +\frac{1}{2} \\ 0, & \text{se } v \leq -\frac{1}{2} \end{cases} \quad (2.6)$$

(c) Função sigmóide: é a forma mais comum de função de ativação utilizada na construção de redes neurais artificiais, devido a sua capacidade de diferenciabilidade. Ao contrário da função limiar, pode assumir todos os valores entre 0 e 1. A representação mais utilizada para esta função é a função logística, definida por:

$$\varphi(v) = \frac{1}{1 + e^{-av}} \quad (2.7)$$

onde a é o parâmetro de inclinação da função sigmóide.

As funções de ativação apresentadas anteriormente se estendem de 0 a +1. No entanto, dependendo da aplicação, deseja-se que a saída da rede apresente também valores negativos, no intervalo de -1 a +1, assumindo neste caso uma forma anti-simétrica em relação à origem. Especificamente a função de limiar, é definida como:

$$\varphi(v) = \begin{cases} 1, & \text{se } v > 0 \\ 0, & \text{se } v = 0 \\ -1, & \text{se } v < 0 \end{cases} \quad (2.8)$$

a qual normalmente é denominada função sinal. Para a forma correspondente de uma função sigmóide, podemos utilizar a função tangente hiperbólica, definida por:

$$\varphi(v) = a \frac{e^v - e^{-v}}{e^v + e^{-v}} \quad (2.9)$$

onde a é o parâmetro de inclinação da curva.

Apesar de existirem outras funções de ativação para serem empregadas, as anteriormente apresentadas são as mais utilizadas e conhecidas.

2.5 Arquitetura das redes

Conforme mencionado, uma rede neural é constituída por um conjunto de neurônios interligados. A forma como estes se conectam define a arquitetura da rede que em geral pode ser de três classes diferentes, conforme o número de camadas de neurônios e o tipo de conexão entre elas.

Nos itens a seguir, são descritas as três classes de arquiteturas de redes neurais artificiais, conforme Haykin (2001).

2.5.1 Redes feedforward de camada única

Nesta forma mais simples de rede neural os neurônios estão organizados em uma única camada. A rede é dita alimentada adiante, pois a camada de nós de fonte é projetada sobre uma camada de saída de neurônios, sem haver laços de realimentação.




Figura 2.4 – Rede alimentada adiante de camada única

2.5.2 Redes feedforward de múltiplas camadas

Nesta segunda classe de redes neurais, existe a presença de uma ou mais camadas de nós computacionais entre as camadas de entrada e saída, as quais são chamadas de camadas ocultas ou intermediárias. Nas Figuras 2.4 e 2.5, as redes representadas são ditas totalmente conectadas, visto que cada nó da camada anterior está conectado a todos os nós da camada seguinte. As redes que não possuem esta característica são ditas parcialmente conectadas.




Figura 2.5 – Rede alimentada adiante de múltiplas camadas

2.5.3 Redes recorrentes

As redes neurais recorrentes diferem das redes alimentadas adiante por possuírem pelo menos um laço de realimentação, podendo este ser originado dos neurônios ocultos bem como dos neurônios de saída.




Figura 2.6 – Rede neural recorrente

2.6 Aprendizado

Segundo Haykin (2001) a propriedade mais importante das redes neurais é a habilidade de aprender acerca de seu ambiente e, com isso, melhorar o seu desempenho através da aprendizagem. Isto pode ser feito através de um processo iterativo de ajustes aplicados aos pesos sinápticos da rede, chamado de treinamento. O aprendizado ocorre quando a rede neural atinge uma solução generalizada para uma determinada classe de problemas.

O processo de aprendizagem implica a seguinte seqüência de eventos (Haykin, 2001):

1. A rede neural é estimulada por um ambiente;

2. A rede neural sofre modificações nos seus parâmetros livres como resultado desta estimulação;
3. A rede neural responde de uma maneira nova ao ambiente, devido às modificações ocorridas na sua estrutura interna.

Um conjunto de procedimentos preestabelecidos de regras para a solução de um problema é denominado algoritmo de aprendizagem. Existem diversos tipos de algoritmos de aprendizagem, e com isso, tem-se um conjunto de ferramentas, cada qual com suas vantagens e desvantagens. Estes algoritmos diferem pela maneira como o ajuste dos pesos é feito.

Diversos métodos para treinamento de redes foram desenvolvidos, podendo estes ser agrupados em dois paradigmas principais: aprendizado supervisionado e não supervisionado. Outros dois paradigmas bastante conhecidos são os de aprendizado por reforço (caso particular supervisionado) e aprendizado por competição (caso particular não supervisionado).

2.6.1 Aprendizado supervisionado

No aprendizado supervisionado, também chamado aprendizado com um professor, os sinais de entrada e a saída desejados para a rede são fornecidos por um supervisor externo. Assim, compara-se a resposta desejada com a resposta calculada, ajustando-se os pesos das conexões para minimizar o erro existente, tornando ótima a resposta.

Os exemplos mais conhecidos de algoritmos para aprendizado supervisionado são a regra delta e a sua generalização para redes de múltiplas camadas, o algoritmo backpropagation.

2.6.2 Aprendizado não supervisionado

Neste tipo de aprendizado não há um supervisor para acompanhar o processo de aprendizagem. No algoritmo, somente os padrões de entrada estão disponíveis para a rede, sendo que a mesma aprende a ajustar seus parâmetros baseados em tendências estatísticas observadas nos dados de entrada.

No processo de aprendizado, a rede usa os neurônios como classificadores, e as entradas como elementos a serem classificados, utilizando-se para isso um processo de competição e cooperação entre os neurônios da rede. Os algoritmos mais conhecidos neste tipo de aprendizado são: a regra de Hebb e a aprendizagem competitiva.

2.6.3 Aprendizado por reforço

No treinamento por reforço, o aprendizado acontece através do método da tentativa e erro, de modo a otimizar um índice de performance chamado sinal de reforço. A única informação de realimentação fornecida à rede é se uma determinada saída está correta ou não, deixando de forma um tanto quando obscura o ajuste dos parâmetros em direção a minimização dos erros.

Várias são as diferenças entre o treinamento supervisionado e o treinamento por reforço, sendo que a mais importante é a ausência de padrões de treinamento.

2.7 Modelos de redes neurais

Existem diversos modelos de redes neurais artificiais que foram desenvolvidos, sendo que suas aplicações encontram-se nas mais variadas áreas. Dentre os modelos mais conhecidos, destacam-se:

2.7.1 Perceptron

A rede do tipo perceptron foi o modelo pioneiro nesta área: simples, de fácil implementação, utiliza neurônios McCulloch-Pitts. Limitada à classe de problemas linearmente separáveis, pode, no entanto, ser utilizadas em tarefas de classificação simples.

2.7.2 Perceptron multicamadas

É uma extensão do perceptron simples, capaz de trabalhar com problemas não linearmente separáveis. Este avanço foi possível através da utilização de, pelo menos, uma camada entre a entrada e a saída. Estas camadas intermediárias, conhecidas como camadas ocultas, trabalham como um reconhecedor de características que ficam armazenadas nos pesos sinápticos.

2.7.3 Mapas auto organizáveis – Redes de Kohonen

Inspirada nos mapas corticais, a rede de Kohonen utiliza o Aprendizado Competitivo, onde os neurônios competem entre si para responder a um estímulo apresentado. A característica de auto-organização, que dá nome a esta classe de redes neurais, é devida ao fato de utilizarem regras de aprendizado não supervisionado, formam-se agrupamentos de neurônios topologicamente organizados, onde cada grupo é responsável por responder a uma classe de estímulos.

2.7.4 Redes de Hopfield

Também conhecida como Memória Associativa, a Rede de Hopfield armazena padrões que são recuperados a partir de estímulos de entrada. O armazenamento de tais padrões é realizado via Aprendizado Hebbiano. Uma característica importante deste modelo é a chamada recorrência: as saídas ligam-se às entradas por um atraso de tempo; com efeito, a resposta da rede sempre depende de seu estado anterior.

2.7.5 Redes de base radial

Redes neurais com função de base radial são redes compostas por uma camada de entrada, uma única camada escondida associada com funções radiais e uma camada de saída com funções lineares. Para o treinamento de redes neurais de base radial é necessário determinar o centro, a forma e extensão das funções, geralmente baseado em treinamento não-supervisionado, ou computação evolutiva.

2.8 Aplicações

As aplicações de redes neurais são inúmeras e nas mais diversas áreas. O reconhecimento ótico de caracteres é outro tipo de aplicação que já existe e está crescendo. Análise de pesquisa de mercado, controle de processos industriais, aplicações climáticas, são também aplicações com grande sucesso.

Na área médica, as redes neurais estão auxiliando na melhoria de tomada de decisões no diagnóstico médico. Neste caso, em seu aprendizado as redes são submetidas a uma série de diagnósticos de pacientes, de várias características, com vários sintomas e com os resultados de seus testes. Também são fornecidos os diagnósticos médicos para cada doença. Assim, quando forem apresentados os

dados de um novo paciente, com seus sintomas, a rede fornecerá um possível diagnóstico. Isto essencialmente criará um sistema com o conhecimento de vários médicos, e fornecerá um diagnóstico inicial em tempo real a um médico. É importante mencionar que com isso o que se pretende é implementar uma ferramenta de auxílio ao médico, e não um programa que o substitua.

As redes neurais artificiais podem ser aplicadas a diversos problemas da Bioinformática que costumam envolver reconhecimento de padrões. São adequadas aos casos onde há necessidade de manipulação de conhecimento impreciso, além de possibilitarem a construção de modelos a partir de exemplos depositados em bancos de dados.

Devido às características próprias das redes neurais, estas podem realizar alguns tipos de tarefas que não são executadas de forma satisfatória em sistemas computacionais tradicionais, mas que para o ser humano são tarefas triviais. Elas possuem a característica de se adequar as seguintes aplicações:

- Reconhecimento de fala;
- Reconhecimento visual de padrões, como por exemplo, reconhecimento e classificação de imagens para reconhecer: textos, assinaturas, impressões digitais, objetos, etc;
- Processamento adaptativo de sinais e eliminação de ruídos.

Além dessas aplicações, também encontramos referências de uso de redes neurais em aplicações como veículos autônomos, previsão de tempo, memórias associativas, etc.

3 MODELAGEM MATEMÁTICA DE UPS UTILIZANDO REDES NEURAS

3.1 Introdução

A determinação da localização precisa de uma falta em aparelhos eletrônicos é muito vantajosa. Esta informação facilita o trabalho de equipes de manutenção, pois uma vez que estes já possuem uma estimativa da localização da falta, não é necessário realizar uma inspeção em todo equipamento.

Sendo assim, a proposta deste trabalho é a utilização de redes neurais artificiais para diagnóstico de falhas em fontes ininterruptas de energia. O capítulo inicia com a descrição do sistema físico empregado, onde a função principal é a alimentação contínua e de qualidade aos equipamentos de carga crítica. Juntamente com o circuito utilizado durante o estudo, podem ser visualizados os tipos de anomalias a serem identificados durante o instante da falha no sistema.

Para facilitar a estimação de parâmetros em sistemas não lineares, é conveniente que o sistema seja caracterizado por modelos escolhidos de acordo com as características de cada caso. Neste estudo, os modelos NARX (Modelo Auto-regressivo com Entradas Exógenas) e NARMAX (Modelo Auto-regressivo com Média Móvel e Entradas Exógenas) são utilizados na identificação do sistema.

Nesta modalidade de identificação de sistemas a rede neural é o modelo, trabalhando com pares de vetores que são os dados de entrada e saída do sistema. O algoritmo de treinamento para o ajuste dos pesos da rede corresponde ao estágio de estimação de parâmetros e a seleção da arquitetura da rede corresponde ao estágio de seleção do modelo.

3.2 Descrições do sistema UPS

Para o estudo está sendo utilizado um modelo de UPS on-line, ilustrado pela Figura 3.1. O circuito é constituído basicamente por um retificador de entrada, seguido do pré-regulador Boost, um conversor bidirecional Buck/Boost, um banco de baterias e um inversor CC/CA.

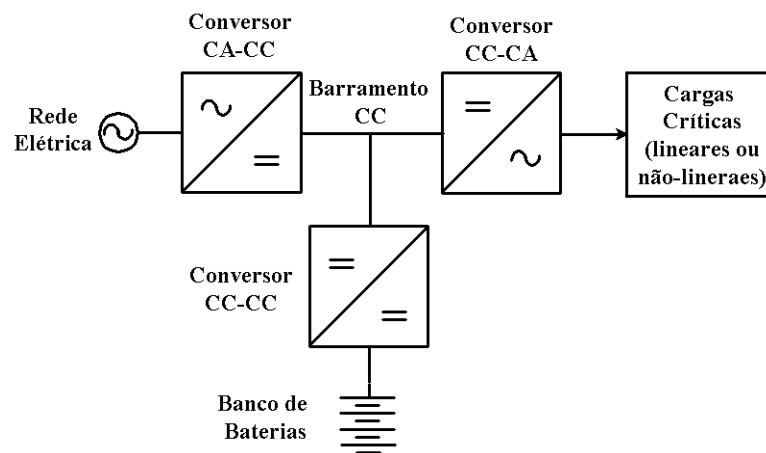


Figura 3.1 – Diagrama de blocos da UPS on-line

3.2.1 Retificador e conversor pré-regulador Boost

A tensão da rede é retificada e passa por um conversor Boost com pré-regulador, o qual tem sido amplamente utilizado para a correção do fator de potência devido, principalmente, a sua simplicidade. O conversor opera em modo DCM (*Discontinuous Conduction Mode*), obtendo assim uma estrutura simples de ser implementada e controlada, caracterizada pela corrente no indutor atingir zero a cada período de chaveamento. Como principais vantagens da operação DCM do conversor Boost, podemos citar: controle simples, alto rendimento, alto fator de potência, baixo custo e baixa distorção harmônica.

O controle do conversor é simples, pois não há necessidade de medir a corrente de entrada para se conseguir um elevado fator de potência, apresentando assim um elevado rendimento. Proporciona ainda: comutação suave em zero de corrente (ZCS) na entrada em condução do interruptor principal e corrente do diodo nula no bloqueio, o que elimina as perdas por recuperação reversa deste elemento. Outra característica da operação do conversor no modo DCM é o volume do indutor Boost (L_{bb}) que é reduzido quando comparado ao conversor Boost operando no modo CCM (*Continuous Conduction Mode*). A obtenção de um elevado fator de potência é feita naturalmente, definindo um tempo de condução constante para a chave, fazendo com que os picos de corrente de entrada naturalmente sigam uma envoltória senoidal.

3.2.2 Conversor bidirecional Buck/Boost

Ao barramento CC é conectado um banco de baterias através de um conversor bidirecional, cujo papel é suprir energia à carga em duas condições operacionais distintas e alternadamente. Quando a rede está funcionando perfeitamente, ele atua como conversor Buck, para recarga do banco de baterias. Quando houver falha na rede, ele opera como um conversor Boost, para elevar a tensão do banco de baterias para a tensão nominal do barramento CC, mantendo assim a carga crítica funcionando. O banco de baterias armazena e fornece energia para a carga crítica, caso necessário.

O conversor bidirecional funciona como Buck e como Boost. Esses dois modos de operação são distintos, apresentando níveis de processamento de potência e níveis de corrente diferentes. Para projetar o conversor deve-se levar em consideração que parte do circuito vai operar com baixa potência (recarga do banco de baterias) e outra com potência significativa (suprir a energia da carga crítica). Para se ter uma adequada relação custo-benefício entre perdas por comutação e o volume/peso do conversor, as frequências de operação dos interruptores devem ser corretamente determinadas, sendo que o conversor de maior potência opera com frequência de chaveamento menor e vice-versa. Com adequada metodologia de

projeto consegue-se reduzir as perdas por comutação sem alterar as especificações impostas ao conversor.

3.2.3 Inversor CC/CA de saída

Para se obter a tensão alternada na carga utiliza-se um inversor CC/CA em ponte completa (*full-bridge*). A comutação das chaves é garantida através do PWM (*Pulse Width Modulation*). Nestes inversores, a tensão de entrada (CC), é essencialmente constante em amplitude; no entanto, o inversor deve controlar a amplitude e a frequência de saída (CA). Para obter-se a tensão senoidal de saída com frequência desejável, é necessário comparar dois sinais de controle senoidal, à frequência desejada (defasados 180° um do outro) com uma forma de onda triangular. A frequência da onda triangular estabelece a frequência de comutação do inversor, obtendo assim uma onda próxima a senoidal, a qual contém componentes harmônicos resultantes da frequência de chaveamento. Para eliminar essas harmônicas é utilizado um filtro passa-baixa, para filtrar as harmônicas geradas pela frequência de chaveamento. Esse filtro é ligado em paralelo à carga.

3.3 Simulações

Para as simulações da UPS é utilizado o simulador Simulink[®], uma ferramenta oferecida pelo software MATLAB 2007a[®], cujo circuito utilizado para detecção de falhas é apresentado a seguir:

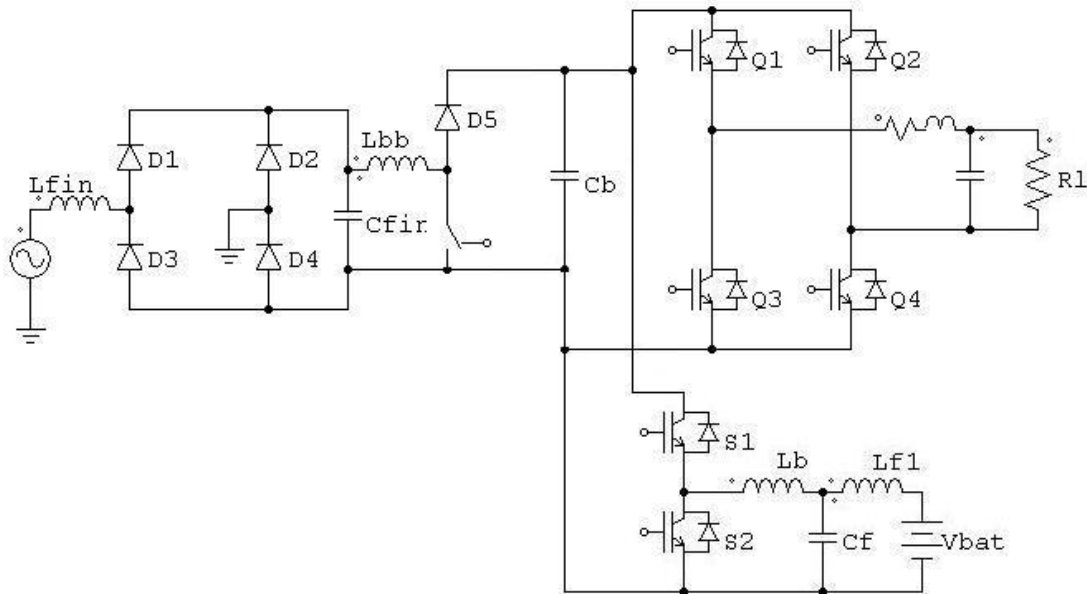


Figura 3.2 – Circuito utilizado para simulação das falhas.

Algumas variáveis foram medidas durante os instantes de falhas e os dados obtidos enviados a uma rede neural que, a partir de um treinamento prévio, identifica o padrão obtido e indica o tipo de falha.

As formas de ondas foram analisadas para cada defeito apresentado pelo sistema, sendo que abaixo estão descritas as falhas que podem ser detectadas pelos modelos propostos:

- Falha em um diodo do retificador, podendo ser curto-circuito ou circuito aberto em cada um dos 4 diodos retificadores;
- Falha no diodo do conversor Boost, igualmente podendo apresentar um curto-circuito ou circuito aberto;
- Falha do barramento CC com o terra;
- Falha no capacitor do barramento CC, esta falha podendo apresentar-se como curto-circuito ou circuito aberto;
- Falha em um interruptor do inversor, podendo ser curto-circuito ou circuito aberto em cada uma das 4 chaves;

- Falha no interruptor do conversor Boost, igualmente podendo apresentar um curto-circuito ou circuito aberto;
- Circuito com operação normal.

Como dados de entrada para treinamento da rede e posterior validação, foram empregados: corrente de entrada e tensão no barramento CC; e como dados de saída, foram utilizados os valores da tensão de saída, todos estes capturados durante os instantes do defeito.

Algumas falhas apresentam comportamentos parecidos, sendo que os gráficos representativos dos dados de entrada e saída aparecem de forma semelhante. Dentre as saídas consideradas similares, 10 grupos diferentes podem ser concebidos:

Grupo de Falhas 1 – Circuito aberto no capacitor;

Grupo de Falhas 2 – Circuito aberto no diodo retificador D1 ou no diodo retificador D4;

Grupo de Falhas 3 – Circuito aberto no diodo retificador D2 ou no diodo retificador D3;

Grupo de Falhas 4 – Curto circuito no diodo D1, ou no diodo D4, ou curto circuito no interruptor do conversor Boost ou circuito aberto no diodo D5;

Grupo de Falhas 5 – Circuito aberto no interruptor do conversor Boost;

Grupo de Falhas 6 – Circuito aberto na chave Q1;

Grupo de Falhas 7 – Circuito aberto na chave Q2, ou na chave Q3 ou na chave Q4;

Grupo de Falhas 8 – Curto circuito no capacitor, ou no diodo D5 ou nas chaves Q1, Q2, Q3 ou Q4;

Grupo de Falhas 9 – Curto circuito no diodo retificador D2 ou diodo retificador D3, ou falha no barramento com o terra;

Grupo de Falhas 10 – Operação normal.

3.4 Identificação de sistemas

Observando os sistemas existentes na natureza, pode-se dizer que a grande maioria (senão todos) é não-linear. Segundo Aguirre (2004), mais do que melhorar a exatidão dos modelos, o uso de representações não-lineares é necessário por possibilitar a representação de certos comportamentos dinâmicos que não são possíveis de serem descritos com os modelos lineares.

O leque de representações disponíveis para sistemas não-lineares é vasto, podendo ser citados, entre outras, os modelos NARX, NARMAX, a série de Volterra, os modelos de Hammerstein e de Wiener, modelos polinomiais contínuos, funções de base radial e redes neurais artificiais. Cada representação possui suas vantagens, desvantagens e gama de aplicações.

Na identificação clássica de sistemas o usuário deve especificar a natureza do relacionamento entre as entradas e saídas, sendo necessários estudos aprofundados do sistema demandando tempo e dinheiro. Na identificação utilizando redes neurais o usuário deve somente especificar a topologia da rede, que é suficiente para descrever o mapeamento entrada-saída (Fiori, 2007).

Redes neurais artificiais são ferramentas para a aproximação de funções, de modo que este paradigma pode ser usado para identificação de sistemas. O problema de identificação de sistemas pode ser dividido em cinco etapas principais: (i) obtenção de dados de experimentação do sistema que se deseja modelar; (ii) aplicação de testes aos dados obtidos para detecção de não-linearidades; (iii) escolha da estrutura que será utilizada para representar o modelo; (iv) estimação dos parâmetros do modelo; (v) validação do modelo obtido (Ljung, 1999).

Na etapa de obtenção dos dados e posterior aplicação dos mesmos em testes, o sistema deve ser experimentado através da aplicação de entradas adequadas e da observação das saídas correspondentes (e/ou das variáveis de estado observáveis). Os dados de identificação assim obtidos serão utilizados na

detecção de não-linearidades e no ajuste dos parâmetros do modelo escolhido. (Aguirre, 2004).

A seleção da estrutura dos modelos é uma das etapas mais importantes do procedimento de identificação de sistemas não-lineares. Por esse motivo, seria interessante que qualquer conhecimento prévio do sistema pudesse ser utilizado para reduzir o conjunto de termos candidatos na identificação (Aguirre, Rodrigues, Jácome, 1998). Nesta etapa, o objetivo é restringir o espaço de busca da seleção de estrutura a determinados agrupamentos de termos, baseando-se em algumas características que se deseja que o modelo identificado tenha. Isso é possível em função do estudo apresentado a respeito da influência dos agrupamentos nas características estáticas do modelo (Aguirre & Corrêa, 2004).

Determinada a estrutura do modelo, devem-se estimar seus parâmetros para aproximar o comportamento dinâmico apresentado pelo sistema original. O que se pretende é garantir que um modelo obtido a partir de dados dinâmicos tenha as características estáticas do sistema, mesmo quando os dados dinâmicos se encontram em uma faixa de operação mais estreita que os dados estáticos (Aguirre & Correa, 2004).

De acordo com os passos descritos, a facilidade encontra-se no fato de que a identificação de sistemas utilizando redes neurais necessita de pouca interferência do usuário, mas por outro lado requer um número consideravelmente maior de pares de entrada e saída em relação às técnicas de identificação de sistemas clássica.

Este trabalho mostra a aplicação de estruturas NARX e NARMAX, onde a diferença básica entre as estruturas encontra-se na modelagem do ruído (Lima, 2000).

3.4.1 Modelo NARX

Os modelos NARX (*Non-linear AutoRegressive with eXogenous inputs*) são modelos discretos no tempo que explicam o valor da saída $y(k)$ em função dos valores prévios dos sinais de saída e de entrada do sistema. Coelho, Aguirre & Corrêa (2002), descrevem que o modelo NARX normalmente é representado da seguinte forma:

$$y(k) = F[y(k-1), \dots, y(k-n_y), u(k-d), \dots, u(k-n_u)] \quad (3.11)$$

sendo $y(t)$ e $u(t)$ respectivamente, a saída e a entrada e do sistema, e n_y, n_u seus atrasos máximos. O tempo morto é representado pela letra d .

O modelo NARX (Figura 3.3) apresenta as seguintes características:

- tem a vantagem de admitir representações adequadas para dinâmicas com resposta lenta;
- modelos NARX geralmente requerem dimensões elevadas para o vetor de entrada.




Figura 3.3 – Modelo NARX para identificação de sistemas

3.4.2 Modelo NARMAX

Segundo Coelho, Aguirre & Corrêa (2002), o modelo NARMAX (*Non-linear AutoRegressive Moving Average with eXogenous inputs*), com estrutura monovariável e período de amostragem normalizado, é dado por:

$$y(t) = F'[y(t-1), y(t-2), \dots, y(t-n_y), u(t-d), u(t-d-1), \dots, u(t-d-n_u+1), e(t-1), e(t-2), \dots, e(t-n_e)] + e(t) \quad (3.10)$$

sendo $y(t)$, $u(t)$ e $e(t)$, a saída, a entrada e o ruído aditivo do sistema, respectivamente, e n_y, n_u, n_e seus atrasos máximos (figura 3.4). Neste sistema o retardo ou tempo morto é representado pela letra d .

A forma da função F' normalmente não é conhecida *a priori*. Assim, a dinâmica do sistema deve ser reconstruída utilizando-se uma aproximação para representar F' . Possíveis aproximações para esta função são os modelos polinomiais e racionais (Coelho, Aguirre & Corrêa, 2002).

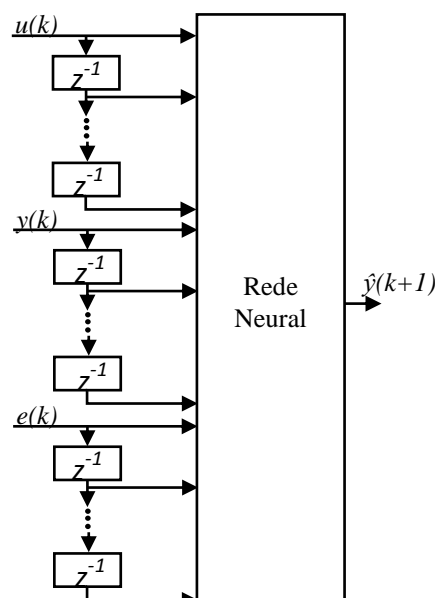


Figura 3.4 – Modelo NARMAX para identificação de sistemas

O uso da representação NARMAX pode ser justificado por várias razões, dentre as quais:

- é uma representação global, permitindo representar a dinâmica global do sistema e não somente em torno de um ponto de equilíbrio;
- tem a vantagem de permitir uma flexibilidade no processo de modelagem do ruído;
- informações analíticas sobre o modelo são fáceis de obter;
- é possível obter modelos NARMAX com bom ajuste aos dados desde que os dados de saída não apresentem variações abruptas;
- algoritmos simples e robustos podem ser utilizados para a estimação de parâmetros.

A taxa de redução do erro ("*error reduction ratio*" ou ERR) é um critério utilizado na detecção de estrutura de modelos NARMAX polinomiais. O ERR de cada termo candidato é um número que indica a melhoria obtida na representação do sistema através da sua inclusão no modelo (Aguirre, Rodrigues & Jácome, 1998).

3.5 Perceptron de Múltiplas Camadas e o Algoritmo Backpropagation

Um perceptron multicamadas (MLP) é constituído de uma ou mais camadas internas de neurônios, sendo capaz de resolver problemas complexos e não linearmente separáveis. Ao contrário do perceptron de camada única, os neurônios que constituem esta arquitetura não são necessariamente binários, podendo possuir uma função de ativação qualquer, por exemplo, sigmóide, tangente hiperbólica ou linear.

A utilização do MLP na solução de problemas complexos está amplamente difundida nas mais diversas áreas de pesquisa. Isso se deve principalmente ao algoritmo de treinamento chamado algoritmo backpropagation (retropropagação).

O algoritmo de aprendizagem por retropropagação do erro é um dos métodos mais utilizados atualmente, pois permite o emprego de arquiteturas sofisticadas com

capacidade de resolução de problemas amplos empregados em sistemas reais (Fiori, 2007). Pode-se dizer que tal algoritmo é uma generalização do algoritmo do mínimo quadrado médio, que utiliza a técnica do gradiente descendente, de forma iterativa, para minimizar a diferença média quadrática entre a saída desejada e a saída real da rede.

Backpropagation é um algoritmo supervisionado que utiliza pares de dados (entrada, saída desejada) para, através de um mecanismo de correção de erros, ajustar os pesos da rede. O treinamento ocorre em duas fases, onde cada fase percorre a rede em um sentido. Estas duas fases são chamadas de *feedforward* e *backforward*.

Na fase feedforward o sinal se propaga camada a camada em sentido progressivo, definindo a saída da rede para um dado padrão de entrada, já na fase backforward os sinais partem da última camada até chegar na camada de entrada, e os nodos da camada atual ajustam seus pesos de forma a reduzir seus erros (Rocha, 2007).

De acordo com Haykin (2001) o algoritmo de retropropagação pode ser resumido nos seguintes passos:

Passo 1: Inicialização: Inicializam-se os pesos sinápticos e níveis de bias com valores aleatórios de uma distribuição uniforme com média zero;

Passo 2: Apresentação dos exemplos de treinamento: Apresenta-se uma época de exemplos de treinamento e para cada exemplo executa-se a computação para frente e para trás, dadas pelos passos 3 e 4.

Passo 3: Computação para frente: Calculam-se os sinais de saída para os neurônios da rede pelas equações 3.1 e 3.2 (as quais são generalizações das equações 2.3 e 2.4).

$$v_j^{(l)}(n) = \sum_{i=0}^m w_{ji}^{(l)}(n) \cdot y_i^{(l-1)}(n) \quad (3.1)$$

$$y_j^{(l)}(n) = \varphi(v_j^{(l)}(n)) \quad (3.2)$$

onde l é o índice da camada em que o neurônio se encontra localizado, variando de 1 (camada de entrada) até L (camada de saída) e j é o índice do neurônio na camada l .

O sinal de erro e é calculado na saída do neurônio j , na iteração n (pertencente à última camada) após o último exemplo de treinamento apresentado, sendo y a saída encontrada pela rede e d a saída desejada, tem-se:

$$e_j(n) = d_j(n) - y_j(n) \quad (3.3)$$

O erro médio quadrático (E_{med}) de um conjunto de N exemplos é obtido pela seguinte equação:

$$E_{med} = \frac{1}{N} \sum_{n=1}^N \left(\frac{1}{2} \sum e_j^2(n) \right) \quad (3.4)$$

A equação 3.4 refere-se à qualidade da aprendizagem, ou seja, é a medida de desempenho utilizada pelo algoritmo, representando a função custo a ser minimizada.

Passo 4: Computação para trás: Calculam-se os gradientes locais da rede pelas equações definidas a seguir:

$$\delta_j(n) = \begin{cases} e_j(n) \cdot \varphi'_j(v_j(n)) \\ \varphi'_j(v_j(n)) \cdot \sum_k e_k(n) \cdot \varphi'_k(v_k(n)) \cdot w_{kj}(n) \end{cases} \quad (3.5)$$

A primeira equação é usada no caso do neurônio estar localizado na camada de saída enquanto a segunda é utilizada se o mesmo estiver na camada oculta l , sendo que $\varphi'_j(v_j(n))$ é a derivada da função de ativação associada.

Atualizam-se os pesos de acordo com a regra delta:

$$\Delta w_{ji}(n) = w_{ji}(n) + \eta \cdot \delta_j(n) \cdot y_i(n) \quad (3.6)$$

onde η é a taxa de aprendizagem.

A taxa de aprendizagem η define a “velocidade” da aprendizagem. Quando pequena, ela gera pequenas variações na mudança dos pesos de uma iteração para a outra, aumentando o tempo e o custo computacional. Porém, quando ela se torna grande com o objetivo de acelerar a convergência corre-se o risco de uma variação muito grande dos pesos gerando uma trajetória oscilatória podendo levar a divergência de valores (Fiori, 2007).

Passo 5: Iteração: Realizam-se os passos 3 e 4 até a apresentação de todos os exemplos de treinamento, em seguida volta-se ao passo 2 apresentando-se os exemplos de treinamento novamente, porém em uma ordem diferente das épocas anteriores. Após cada época, calcula-se o erro médio quadrático e se este estabilizar ou estiver abaixo de um determinado valor, então o algoritmo chegou ao ponto de mínimo, finalizando o processo.

Os critérios de paradas mais utilizados são: encerrar o treinamento após n ciclos de treinamento; encerrar o treinamento após o erro médio quadrático ficar abaixo de uma constante pré-definida c , ou encerrar o treinamento quando a percentagem de classificações corretas estiver acima de uma constante c (Rocha, 2007).

3.6 Algoritmo de treinamento rápido

Existem diversas técnicas que podem ser utilizados para um treinamento mais rápido. Neste trabalho foi implementado o método de Levenberg-Marquardt e a taxa de aprendizagem adaptativa, utilizando os algoritmos genéticos.

3.6.1 Algoritmo Levenberg-Marquardt

Assim como outros métodos eficientes, o algoritmo Levenberg-Marquardt é iterativo, significando que, dado um ponto inicial x_0 , o método produz uma série de vetores x_1, x_2, \dots , que espera-se que vá convergir para x^* , um mínimo local para a função de entrada a ser ajustada.

Enquanto o backpropagation padrão utiliza a descida de gradiente como método de aproximação do mínimo da função erro, o algoritmo Levenberg-Marquardt utiliza uma aproximação pelo método de Newton, que faz uso da matriz Hessiana. Esse algoritmo baseia-se, para aceleração do treinamento, na determinação das derivadas de segunda ordem do erro quadrático em relação aos pesos, diferindo do algoritmo backpropagation tradicional que considera as derivadas de primeira ordem.

O algoritmo Levenberg-Marquardt foi desenvolvido para aproximar velocidade de treinamento de segunda ordem sem ter que calcular a matriz Hessiana. Quando a função erro faz a somatória quadrática, a matriz Hessiana (H) pode ser aproximada como:

$$H = J^T J \quad (3.7)$$

E o gradiente pode ser calculado como:

$$g = J^T e \quad (3.8)$$

onde J é a matriz Jacobiana que contém a primeira derivada dos erros da rede com os respectivos pesos e bias e e é o vetor de erros da rede. A matriz Jacobiana pode ser calculada através da técnica backpropagation padrão.

O algoritmo Levenberg-Marquardt propõe somar uma parcela μI à matriz Hessiana, aproximada pelo método de Gauss-Newton, onde μ é a constante do método de Levenberg-Marquardt e I é a matriz identidade:

$$x_{k-a} = x_k - [J^T J + \mu I]^{-1} g \quad (3.9)$$

Quando o módulo de μ é zero, este é o método de Newton e usa a aproximação da matriz Hessiana. Quando μ é grande, isto faz com que o gradiente descendente tenha um pequeno incremento a cada passo. Os algoritmos que usam os métodos de Newton são tão mais rápidos e mais precisos quanto menor for o erro mínimo desejado no treinamento.

Assim, μ é diminuído depois de cada passo bem sucedido (redução do erro) e só é aumentado quando o erro aumentar. Deste modo, o erro sempre diminuirá a cada iteração do algoritmo, convergindo mais rapidamente quando se trabalha com um número moderado de parâmetros na rede.

3.6.2 Taxa de aprendizagem adaptativa e algoritmos genéticos

Outra técnica anteriormente mencionada, geralmente empregada para acelerar o processo de convergência e aumentar o desempenho da rede é a taxa de aprendizagem adaptativa. Enquanto a taxa de aprendizagem fixa utiliza um mesmo valor para todas as iterações realizadas no processo, a taxa de aprendizagem adaptativa recebe a cada iteração um novo valor, obtendo geralmente um número menor de iterações para satisfazer as especificações desejadas. Para encontrar

uma taxa de aprendizagem que produza bons resultados e seja baseada em princípios científicos, propôs-se então o emprego de algoritmos genéticos para a sua determinação a cada época de treinamento.

Algoritmos Genéticos (AG) são algoritmos de procura baseados nas mecânicas de seleção e genética natural, onde os indivíduos mais fortes e aptos têm probabilidade maior de sobreviver e evoluir. Em vários problemas científicos há a necessidade de se encontrar uma solução ótima ou um conjunto de soluções que melhor representam esse problema, normalmente escrito em forma de função. O conjunto de todos os valores possíveis e suas combinações é chamado de espaço de busca e representa o domínio do problema. Essa busca pela melhor solução é conhecida como problema de otimização onde, normalmente, visa-se maximizar uma função em busca do maior valor possível. Entretanto, podem ocorrer funções não deriváveis, descontínuas ou multimodais que impedem o uso de métodos de otimização baseados em cálculo numérico. Nos problemas dessa natureza é que se justifica a aplicação dos AG, sendo um método probabilístico, mas tendo regras que permitem ao algoritmo evoluir para regiões de prováveis soluções ótimas e possui certa facilidade de fugir dos máximos (ou mínimos) locais (Gomes, 2006; Fiori, 2007).

Uma descrição de algoritmos genéticos é que eles são procedimentos repetitivos que mantêm uma população de indivíduos que são os candidatos à solução ótima para um problema específico. Cada possível solução corresponde a um cromossomo, e cada elemento da solução é chamado de gene.

A cada geração de indivíduos, todos os cromossomos são submetidos a uma função de avaliação para determinar o valor de *fitness* de cada gene, ou seja, é definida uma medida de quão adaptado está o indivíduo ao ambiente. A população atual é avaliada, e assim, uma nova população de soluções candidatas é formada usando operadores genéticos específicos.

Os operadores genéticos são responsáveis pelas mudanças que ocorrem na população, ao passar de uma geração para outra, mudando algumas de suas

características. Os operadores genéticos podem ser resumidamente expressos por: seleção, passagem e mutação.

Na primeira etapa, os indivíduos mais aptos são selecionados para reprodução, gerando cópias que serão submetidas aos próximos operadores, formando uma nova população para a geração seguinte.

A passagem é responsável pela troca de informações entre os cromossomos. Eles recombina suas características permitindo que as próximas gerações herdem suas informações genéticas. Por fim, o operador de mutação opera sobre um único cromossomo de cada vez. A mutação consiste em modificar aleatoriamente um ou mais genes, restaurando a diversidade genética e aumentando a variabilidade da população.

Assim como os outros métodos iterativos, os algoritmos genéticos necessitam de um critério de parada para informar ao programa o momento de parar. Esse critério pode ser o número máximo de iterações ou gerações da população, ou ainda, verificar a evolução do melhor indivíduo após determinado número de gerações. Podendo ainda, fazer combinações entre os vários critérios de parada.

4 RESULTADOS

4.1 Introdução

Este capítulo tem por finalidade apresentar os principais resultados alcançados com a utilização de redes neurais artificiais para a modelagem de falhas em fontes ininterruptas de energia.

A proposta central foi trabalhar com uma rede do tipo perceptron multicamadas, cuja função de ativação utilizada foi a tangente hiperbólica, definida na equação 2.9. O algoritmo backpropagation e as técnicas de Levenberg-Marquardt e taxa de aprendizagem adaptativa foram empregados como algoritmos para treinamento rápido. Juntando-se a estas, encontram-se os modelos NARX e NARMAX aplicados na identificação do sistema apresentado.

Uma análise dos resultados será apresentada, realizando a comparação entre os métodos e os modelos explicitados.

4.2 Rede neural artificial

Cada tipo de falha analisada conta com um total de 166.000 dados, onde apenas 50.000 são utilizados, adquiridos a cada 3 pontos. Para o treinamento, somente um tipo de falha foi utilizado, sendo, portanto, o conjunto de dados composto por 50.000 pontos.

A rede neural utilizada neste trabalho é uma rede perceptron multicamadas com uma camada intermediária (oculta) com cinco neurônios e uma camada de saída composta por apenas um neurônio.

À camada de entrada cabe o ofício de enviar os dados de entrada para a rede. Os pesos iniciais são determinados de forma aleatória a partir da informação da quantidade de neurônios da camada oculta.

Para o sistema em questão foram utilizadas duas arquiteturas de redes neurais sendo que para a camada de entrada foi determinado o número de neurônios conforme o modelo trabalhado. Para o modelo NARX são 4 neurônios de entrada ($u(k-1)$, $u(k-2)$, $y(k-1)$, $y(k-2)$) mais o bias, ou seja, a rede neural treinada com o modelo NARX apresenta duas unidades de atraso nos seus sinais de entrada e duas unidades de atraso na saída. A matriz correspondente à entrada contará com 200 000 dados, e o ajuste de pesos deverá ocorrer em 25 parâmetros entre a entrada e a camada oculta e 6 parâmetros entre a camada oculta e a camada de saída (incluindo o bias).

Para o modelo NARMAX são 6 neurônios de entrada ($u(k-1)$, $u(k-2)$, $y(k-1)$, $y(k-2)$, $e(k-1)$ e $e(k-2)$) mais o bias, sendo que, além de apresentar duas unidades de atraso na entrada e duas unidades na saída, apresenta ainda duas unidades de atraso nos valores encontrados para o ruído (erro). A entrada contará então com 300 000 dados, sendo que o total de pesos a serem ajustados é 41, incluindo os parâmetros correspondentes ao bias.

O algoritmo utilizado na aprendizagem da rede neural (adaptação de pesos sinápticos) é o backpropagation apresentado no capítulo 2. A função de ativação utilizada é a tangente hiperbólica, uma função não-linear que possui a propriedade de definir suas derivadas em função delas mesmas, significando que se pode reutilizar o valor já calculado para a ativação ao se realizar a retropropagação do erro, sem necessidade de novos cálculos complexos. É uma função contínua e tem intervalo entre -1 e 1 , sendo assintótica nos dois ramos.

A escolha dos parâmetros utilizados na rede é realizada através de testes, ou seja, não se utiliza nenhum método determinístico para escolha de tais parâmetros. Esses parâmetros, referentes à rede, ao treinamento e às funções, são ajustados através da análise do comportamento dos resultados.

O Algoritmo Genético empregado para a obtenção da taxa de aprendizagem é decimal com seleção Geométrica Normalizada com parâmetro de pressão seletiva para o ranking geométrico de 3%. Mutação não Uniforme no domínio de busca, com 1% de mutação inicial e 4% de mutação final. O espaço de busca do algoritmo genético para a definição da taxa de aprendizagem foi determinado entre 0 e 1, com um número máximo de 10 gerações.

A seguir, serão apresentados os resultados, gráficos e numéricos, obtidos através da identificação de falhas em fontes ininterruptas de energia, utilizando redes neurais artificiais. Como as redes neurais artificiais são técnicas computacionais, a obtenção dos resultados se torna possível através da simulação do funcionamento da rede neural proposta em ambiente computacional. O Software utilizado para tais simulações é o Matlab versão 2007a.

4.3 Circuito para simulações

A aquisição de dados de faltas em UPS para o treinamento das redes é adquirido através do simulador Simulink, uma ferramenta oferecida também pelo software Matlab 2007a.

A figura 4.1 demonstra o sistema utilizado para a identificação de falhas em fontes ininterruptas de energia. Conforme as simulações realizadas e de acordo com os sinais obtidos, foi possível separar as falhas estudadas em 10 grupos, sendo que os tipos de falhas, partes integrantes do grupo, apresentam características semelhantes. Os defeitos em questão estão localizados nos diversos componentes do sistema, sendo que os mesmos resultam na parada do equipamento.

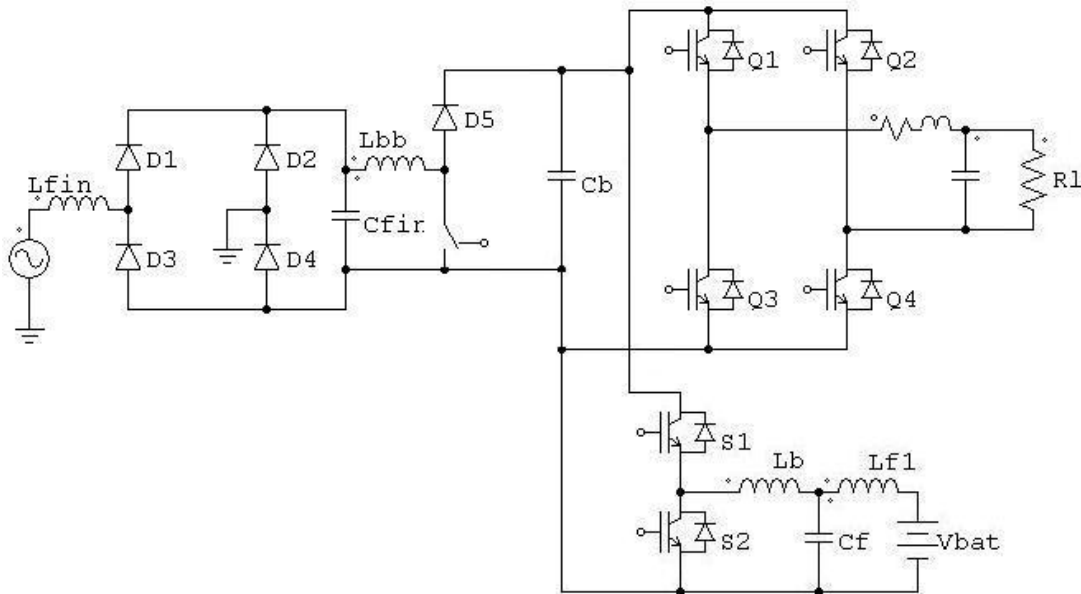


Figura 4.1 – Circuito utilizado para simulação das falhas.

4.4 Resultados das simulações

Conforme mencionado, 10 diferentes grupos de falhas foram proporcionados à rede. Cada grupo apresenta como dados de entrada os valores da corrente e tensão no barramento CC obtidos no instante da falha, e ainda como valores de saída os valores da tensão de saída. Apenas 3 grupos de falhas serão apresentados, visto que os demais resultados obtidos reproduzem as respostas encontradas com as simulações inicialmente realizadas. Os gráficos a seguir exemplificam as falhas, bem como oferecem os resultados encontrados com a validação da rede.

4.4.1 Grupo de Falhas 1

O grupo de falhas 1 é caracterizado por um circuito aberto no capacitor. A figura 4.2 apresenta as formas de ondas obtidas durante as simulações, as quais representam os sinais de entrada (vermelho) e saída (azul) oferecidos à rede para posterior treinamento.




Figura 4.2 – Sinais de entrada (vermelho) e saída (azul) – G1

A figura 4.3 apresenta as saídas encontradas pela rede treinada (vermelho) para comparação com a resposta desejada (azul). Os dois primeiros gráficos representam o algoritmo de Levenberg-Marquardt para os modelos NARX e NARMAX, respectivamente. Os resultados obtidos a partir do algoritmo utilizado pela Taxa de Aprendizagem Adaptativa podem ser visualizados nos dois últimos gráficos da mesma figura, sendo que o modelo NARX aparece primeiro e em seguida o modelo NARMAX.

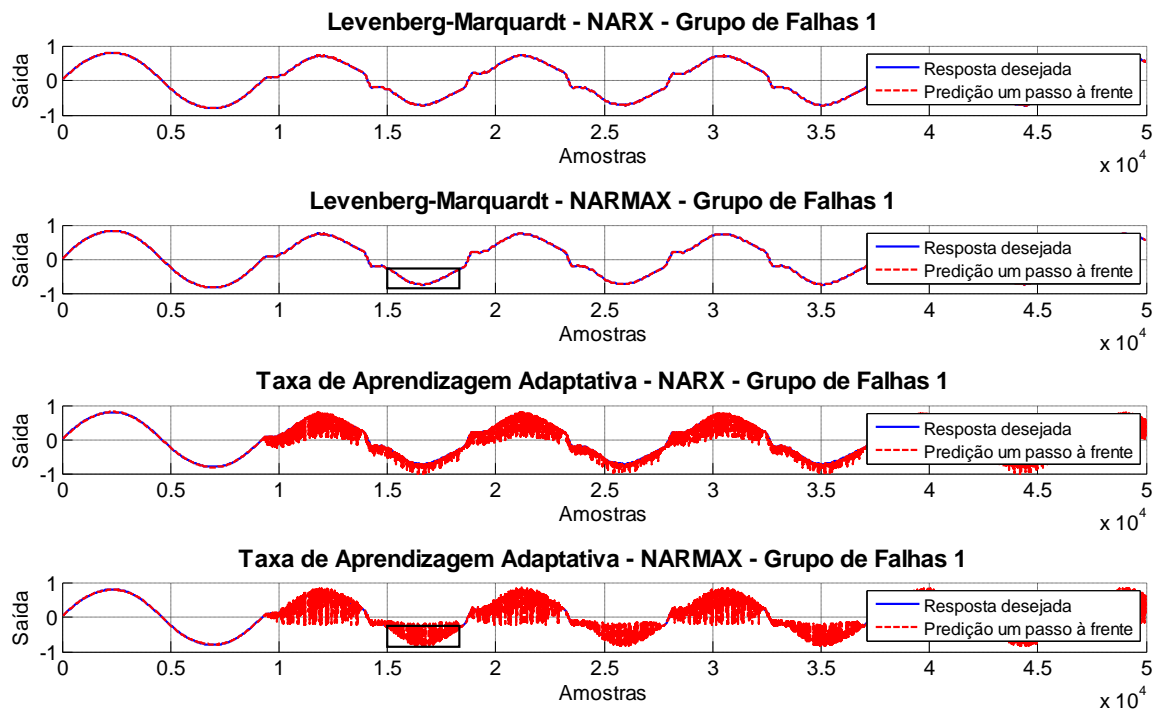


Figura 4.3 – Saídas apresentadas pela rede neural – G1

Nos dois primeiros gráficos da figura 4.3 e no início dos gráficos seguintes, percebem-se sobreposições de formas de onda, indicando a proximidade da saída desejada com a saída resultante do treinamento efetuado pela rede.

As figuras 4.4 e 4.5 apresentam ampliações realizadas no segundo e quarto gráficos, respectivamente, da figura 4.3, a fim de que se perceba a existência das duas trajetórias anunciadas.

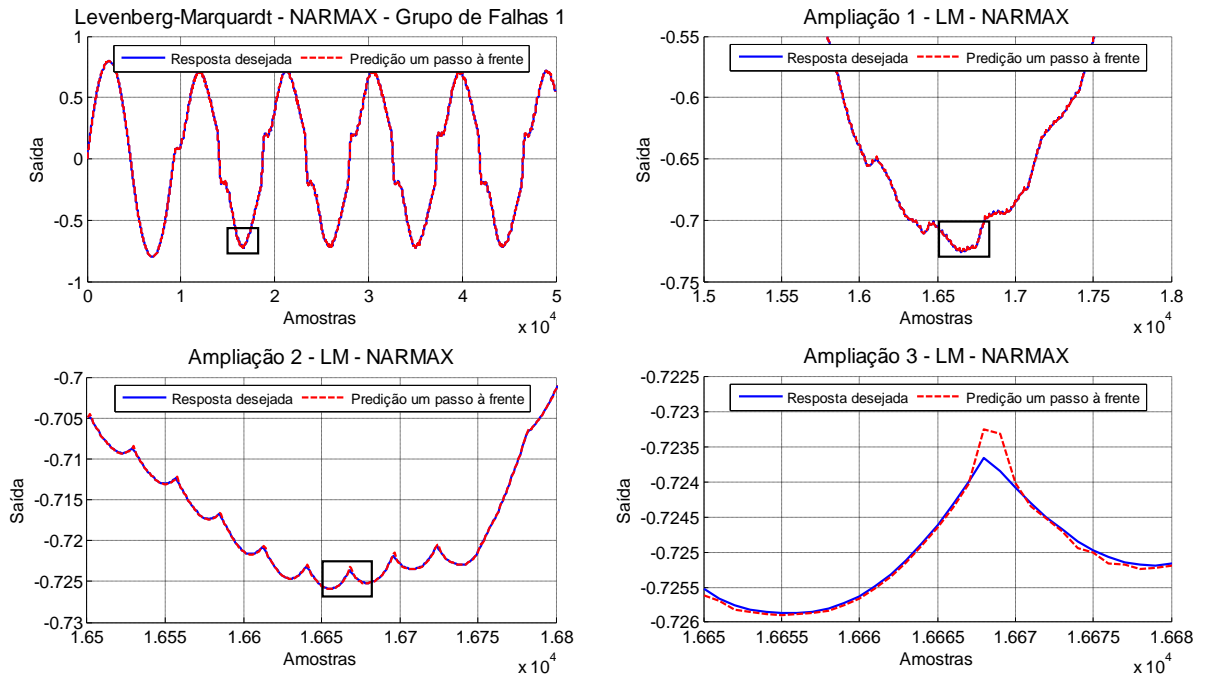


Figura 4.4 – Saída apresentada pelo algoritmo Levenberg-Marquardt - modelo NARMAX – G1

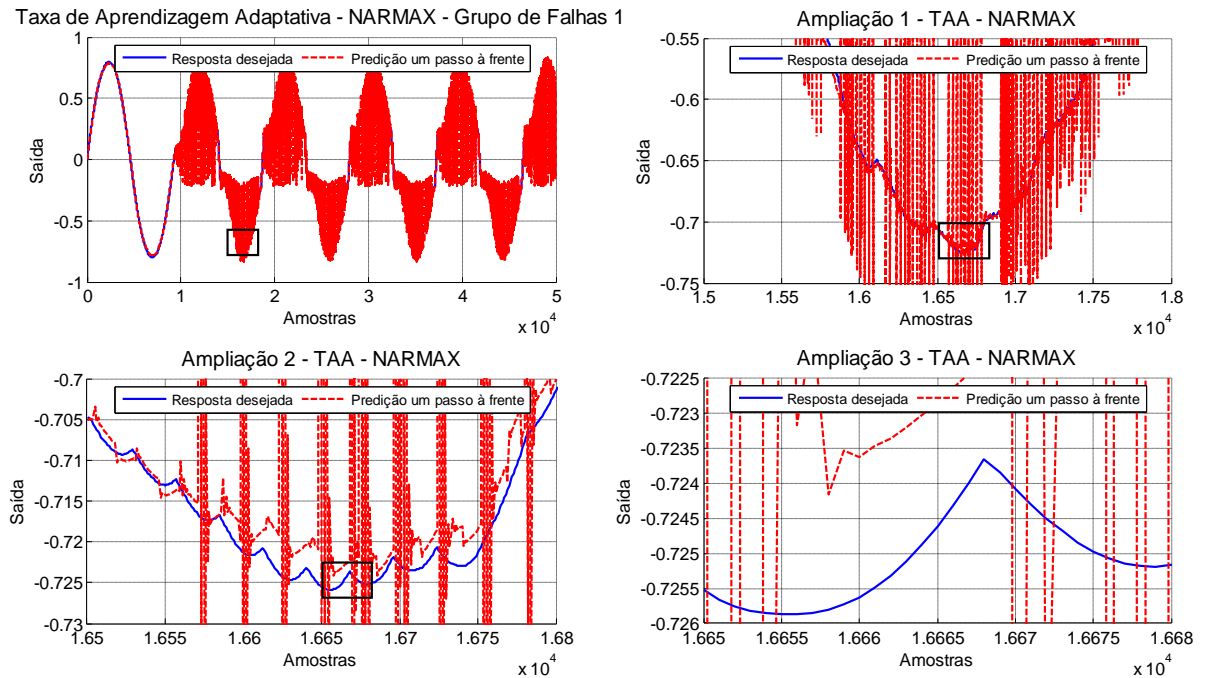


Figura 4.5 – Saída apresentada pelo algoritmo da Taxa de Aprendizagem Adaptativa – modelo NARMAX – G1

Conforme pode ser visualizado, o desempenho alcançado nos dois primeiros gráficos produz uma resposta temporal que praticamente se sobrepõe à saída real, o mesmo não acontecendo, na maioria da trajetória, com a técnica da Taxa de Aprendizagem Adaptativa.

A figura 4.6 apresenta os valores encontrados para o erro médio quadrático em cada uma das trajetórias representadas na figura 4.3.




Figura 4.6 – Erro médio quadrático apresentado pela rede neural – G1

As trajetórias indicadas pelas cores azul, rosa, verde e vermelho representam, respectivamente, as formas de onda obtidas com os métodos de Levenberg-Marquardt – modelo NARX, Levenberg-Marquardt – modelo NARMAX, algoritmo da taxa de aprendizagem adaptativa juntamente com o modelo NARX e por fim o algoritmo da taxa de aprendizagem adaptativa – modelo NARMAX.

Na figura 4.6 a trajetória de cor azul é sobreposta pela de cor rosa, indicando erros médios quadráticos muito próximos. No exemplo utilizado para esta análise,

percebe-se que o método de Levenberg-Marquardt oferece um erro menor se comparado à taxa de aprendizagem adaptativa.

A figura 4.7 apresenta os valores obtidos para a evolução das taxas de aprendizado obtidos através dos modelos NARX e NARMAX. Os “picos” identificados são justificados por uma queda no valor do erro médio quadrático, visualizado na figura 4.6.

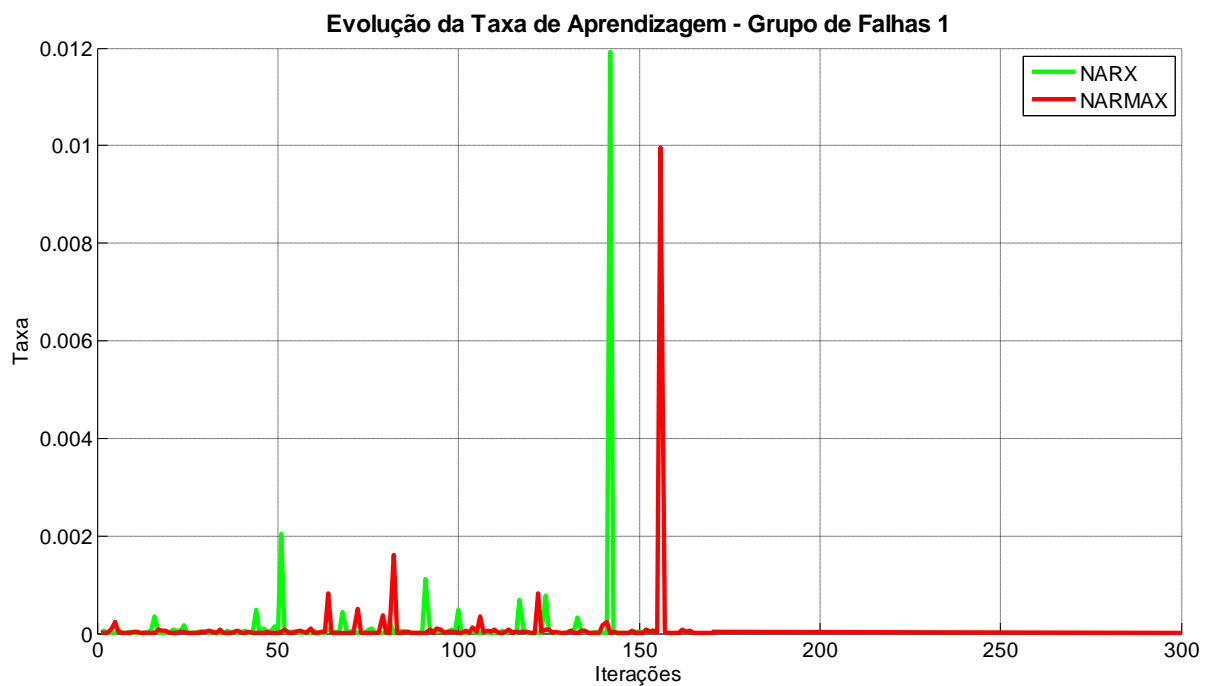


Figura 4.7 – Evolução da taxa de aprendizagem – G1

4.4.2 Grupo de Falhas 2

O grupo de falhas 2 é composto por duas formas de onda semelhantes, ou seja, dois tipos de falhas que apresentam desempenhos semelhantes no instante em que ocorrem, sendo elas: circuito aberto no diodo retificador D1 e circuito aberto no diodo retificador D4.

A fim de que se possa comprovar tal semelhança, as figuras 4.8 e 4.9 apresentam os sinais de entrada e saída para as falhas componentes do grupo de falhas 2.




Figura 4.8 – Sinais de entrada (vermelho) e saída (azul) – Circuito aberto no diodo D1

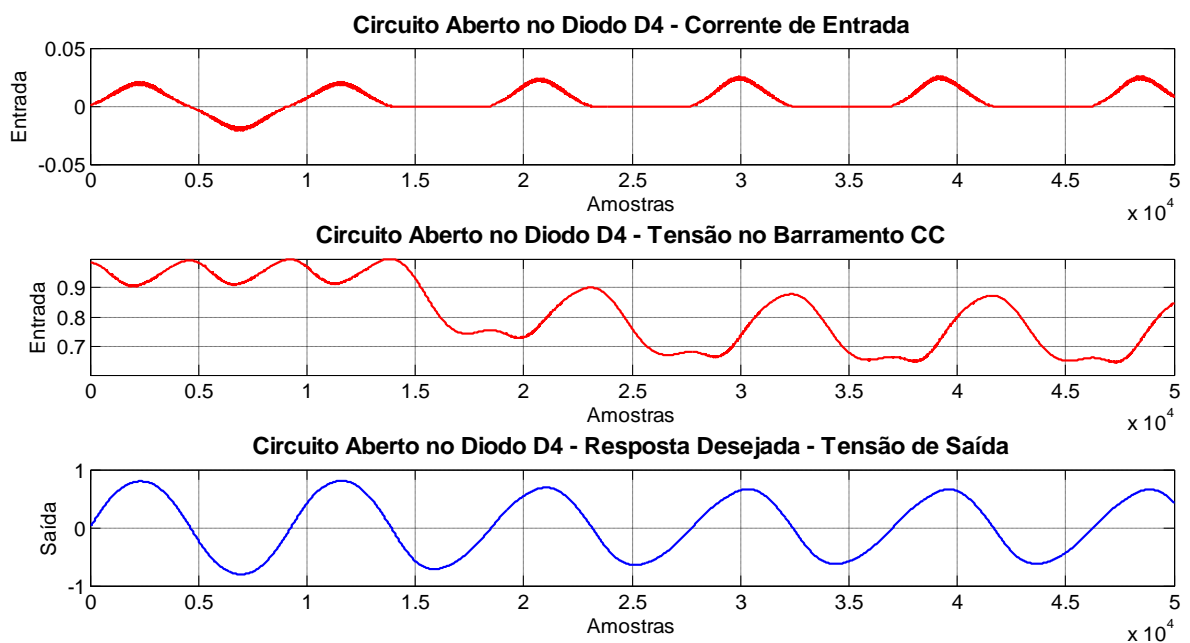


Figura 4.9 – Sinais de entrada (vermelho) e saída (azul) – Circuito aberto no diodo D4

Portanto, o grupo de falhas 2 possui como sinais de entrada e saída, as formas de onda representadas nas figuras 4.8 e 4.9.

As saídas obtidas com os métodos de Levenberg-Marquardt e taxa de aprendizagem adaptativa, são apresentadas na figura 4.10. Ambos os métodos são representados pelos modelos NARX e NARMAX, respectivamente.

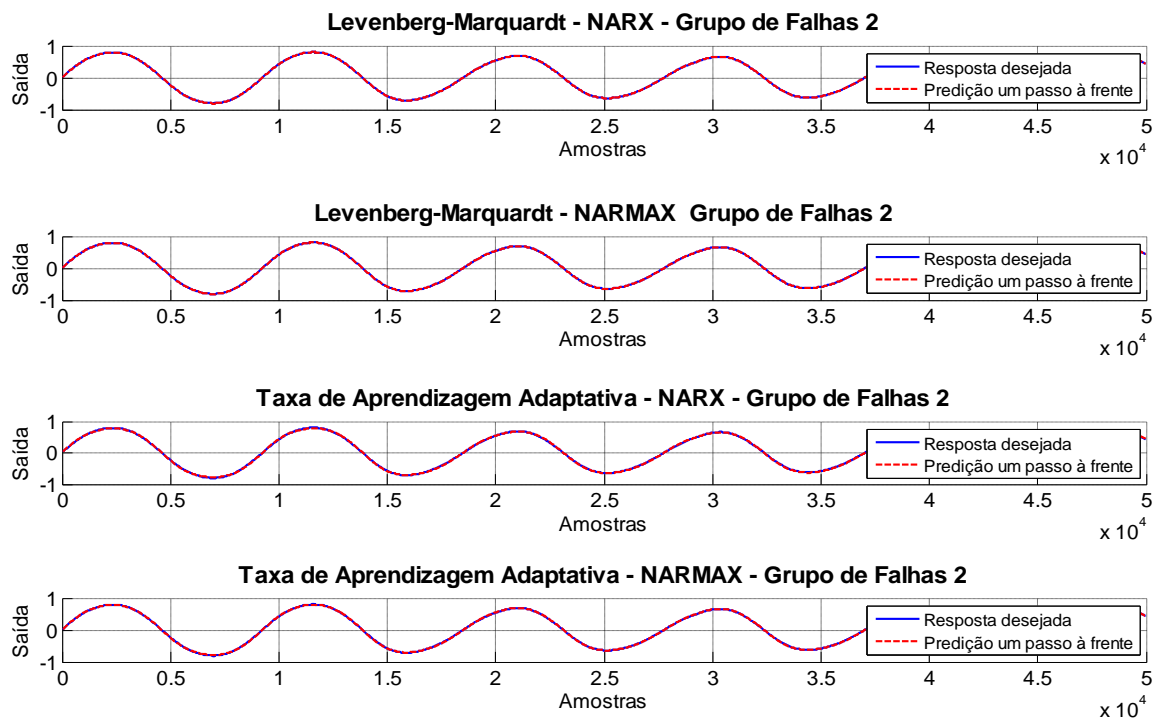


Figura 4.10 – Saídas apresentadas pela rede neural – G2

Conforme se percebe, no grupo de falhas 2 os resultados adquiridos para ambos os algoritmos utilizados reproduzem as formas de onda obtidas durante as simulações. Assim como em parte do grupo de falhas 1, a saída encontrada pela rede neural sobrepõe à saída desejada, indicando erros médios quadráticos pequenos.

Tais afirmações são comprovadas pela figura 4.11, onde se observa as trajetórias obtidas pelo erro médio quadrático de cada algoritmo.




Figura 4.11 – Erro médio quadrático apresentado pela rede neural – G2

Assim como no exemplo demonstrado na figura 4.6, o erro médio quadrático apresentado pelo método de Levenberg-Marquardt continua sendo menor que aquele obtido com a técnica da taxa de aprendizagem adaptativa.

A evolução dos valores da taxa de aprendizagem para os modelos NARX e NARMAX é apresentada no gráfico a seguir.



Figura 4.12 – Evolução da taxa de aprendizagem – G2

O pico maior constituinte da figura 4.12 representa um passo maior realizado na busca da minimização do erro. Tal fato também é observado por uma queda do valor do erro calculado pelo modelo NARMAX na figura 4.11.

4.4.3 Grupo de Falhas 7

Três tipos de falhas estão presentes no grupo de falhas 7, sinais semelhantes são as características dos seguintes defeitos ocorridos: circuito aberto na chave Q2, circuito aberto na chave Q3 e circuito aberto na chave Q4. A figura 4.13 apresenta os sinais de entrada e saída referentes ao grupo de falhas 7.

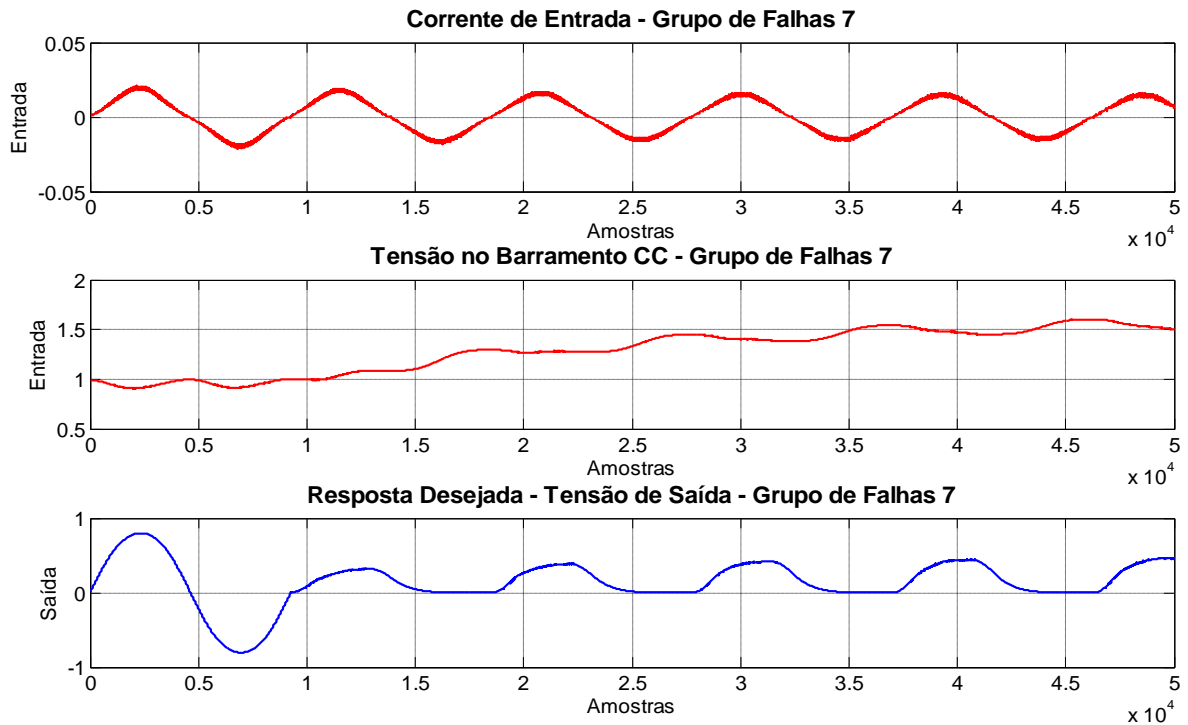


Figura 4.13 – Sinais de entrada (vermelho) e saída (azul) – G7

Na figura 4.14 são apresentadas as saídas referentes às metodologias aplicadas.

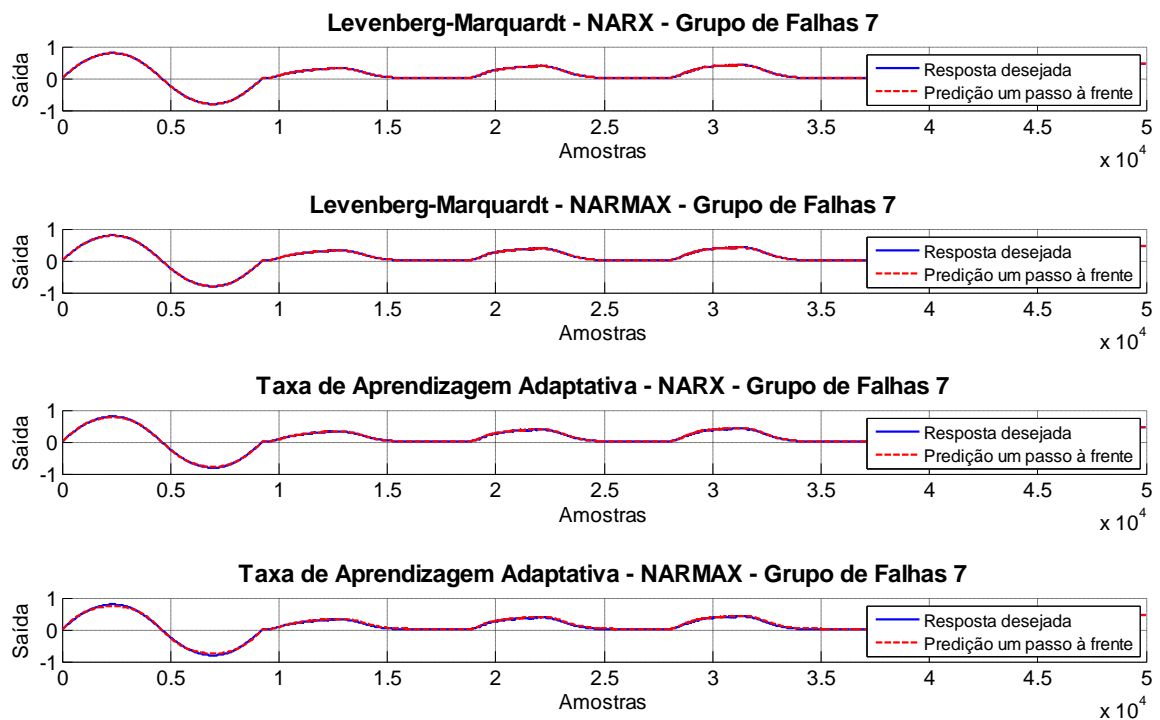


Figura 4.14 – Saídas apresentadas pela rede neural – G7

Com a figura 4.14 pode-se observar a semelhança entre os métodos e a saída real, caracterizando um bom desempenho da rede neural na identificação de falhas. A figura 4.15 comprova tal fato apresentando o erro médio quadrático obtido a partir de cada um dos treinamentos.




Figura 4.15 – Erro médio quadrático apresentado pela rede neural – G7




Figura 4.16 – Evolução da taxa de aprendizagem – G7

Igualmente aos outros grupos de falhas, as quedas observadas nos valores do erro médio quadrático, são obtidos em consequência dos valores encontrados para a taxa de aprendizagem, o que pode ser observado, neste grupo, nas figuras 4.15 e 4.16.

4.5 Análise dos resultados

A Figura 4.17 mostra alguns dos resultados obtidos com as simulações realizadas. O número médio de iterações para o método de Levenberg-Marquardt com o modelo NARX é maior do que para o mesmo método com o modelo NARMAX, o mesmo ocorrendo para a técnica da Taxa de Aprendizagem Adaptativa.

Técnica	Modelo	Tempo	Iterações	Erro
TAA	NARX	00:06:04	192	4.283e-05
LM	NARX	00:01:45	215	1.850e-09
TAA	NARMAX	00:06:05	158	3.685e-05
LM	NARMAX	00:01:51	168	1.843e-09

Figura 4.17 – Resumo dos resultados obtidos a partir do treinamento

Com relação ao tempo de processamento, a técnica da taxa de aprendizagem adaptativa apresenta um tempo médio maior para ambos os modelos se comparado com o método de Levenberg-Marquardt. Porém, o que não se leva em consideração neste trabalho, foi o tempo necessário para encontrar uma taxa fixa que melhor se adequasse ao modelo proposto e à técnica de Levenberg-Marquardt, iniciando a contagem de tempo a partir do treinamento.

Outro aspecto interessante é o erro médio quadrático atingido por ambos os métodos ao final do treinamento. Enquanto que o método de Levenberg-Marquardt alcança a faixa de 10^{-9} , a técnica utilizada com taxa de aprendizagem adaptativa obtém um erro 10^{-5} , sendo ambos excelentes resultados.

CONCLUSÃO

O trabalho desenvolvido nesta dissertação apresentou uma metodologia para modelagem de falhas em fontes ininterruptas de energia. Foram utilizadas redes neurais do tipo perceptron multicamadas juntamente com o algoritmo backpropagation com o objetivo de modelar as formas de onda simuladas e agilizar a manutenção destes equipamentos, conseqüentemente diminuindo o tempo de parada.

Juntamente com o algoritmo proposto, duas técnicas foram empregadas na busca por uma convergência dos resultados mais rápida: o método de Levenberg-Marquardt e a técnica da taxa de aprendizagem adaptativa. Ao final do processo de simulação estas se mostraram eficientes metodologias para identificação de falhas, obtendo bons resultados.

As falhas identificadas neste estudo foram agrupadas de acordo com a semelhança entre os sinais de entrada e saída encontrados no instante de ocorrência das mesmas. Num total de 10 grupos, 24 tipos de casos podem ser identificados, sendo 23 defeitos encontrados nos diversos componentes do sistema e um representando a operação normal do circuito.

No primeiro grupo de falhas apresentado, a rede treinada com taxa de aprendizagem adaptativa teve uma dificuldade para prever e acompanhar o sinal de saída, enquanto a rede com Levenberg-Marquardt previu e acompanhou o sinal de saída quase sem erros, conforme apresentado na figura 4.3. Tal acontecimento não foi observado para os outros grupos de falhas, onde ambas as técnicas obtiveram resultados semelhantes, convergindo para resposta desejada.

Quanto à implementação computacional das duas técnicas, a rede treinada com o método Levenberg-Marquardt é mais simples e com treinamento mais rápido. A rede com taxa de aprendizagem adaptativa, por sua vez, possui um algoritmo de

treinamento mais complexo, maior e mais lento para o processamento dos dados encontrados, isto é, para este caso, observa-se que nem sempre um modelo mais complexo garante uma melhor solução do problema.

Conforme descrito na Figura 4.42, de um modo geral, o tempo médio de processamento da rede com a técnica da taxa de aprendizagem adaptativa é maior se comparado ao tempo de treinamento utilizado pela rede neural com o método de Levenberg-Marquardt. Porém, o tempo utilizado para encontrar uma taxa de aprendizagem fixa que melhor se adequasse ao método de Levenberg-Marquardt não está incluso no tempo médio representado na figura em questão. Tal valor foi obtido através de tentativas e erros, verificando os resultados alcançados.

Para ambos os métodos estudados, observa-se que modelo NARX necessita de um número médio de iterações maior que o modelo NARMAX para atingir o critério de parada. Tal ocorrência pode ser esclarecida pelo fato do modelo NARMAX apresentar um número maior de elementos a fim de representar melhor o sistema proposto.

Graficamente visualiza-se que a técnica de Levenberg-Marquardt atinge erros médios quadráticos menores do que a rede com taxa de aprendizagem adaptativa, tanto os erros observados no início do processo iterativo quanto os erros ao final do mesmo.

Assim, observa-se a qualidade superior da rede treinada com o método de Levenberg-Marquardt sobre a técnica da taxa de aprendizagem adaptativa para o diagnóstico de falhas em fontes ininterruptas de energia. Isto pode ser observado através dos gráficos e das comparações descritas.

Com o emprego da metodologia utilizada, tem-se a possibilidade de diminuir o tempo de parada do sistema estudado, pois se pode restringir o campo de busca do local da falha, reduzindo os prejuízos com a manutenção eficiente do equipamento.

Portanto, o uso de redes neurais artificiais para a solução de problemas relativos à identificação de faltas se mostrou uma alternativa promissora, ocorrendo o acoplamento dos sinais de saída, atingindo com isso, o objetivo deste estudo.

REFERÊNCIAS BIBLIOGRÁFICAS

AGUIRRE, Luiz Antônio. **Introdução à identificação de sistemas: Técnicas lineares e não lineares aplicadas a sistemas reais**. 2. ed. Belo Horizonte: Ed. UFMG, 2004.

AGUIRRE, Luiz Antônio; RODRIGUES, Giovani G.; JÁCOME, Cristiano R. F. Identificação de sistemas não lineares utilizando modelos NARMAX polinomiais - Uma revisão e novos resultados. **SBA Controle & Automação**, v. 9, n. 2, p. 90- 106, 1998.

BELL, Tony. The UPS in critical application. **IET Power Engineer**, p. 34-37, December/January 2006/07.

BEUADET, J. P.; FIORINA, J. N.; PINON, O. UPS topologies and standards. **Merlin Gerin (MGE) UPS Systems**, 1999.

CARLE, Richard H. UPS applications: A mill perspective. **IEEE Industry Applications Magazine**, p. 12-17, November/December 1995.

CHAFEI, S.; ZIDANI, F.; NAIT-SAID, R.; BOUCHERIT, M. S. Fault detection and diagnosis on a PWM inverter by different techniques. **Journal of Electrical Systems**, v. 4, n. 2, p. 1-12, 2008.

COELHO, M. C.; AGUIRRE, L. A. CORRÊA, M.V. Metodologia para representação de modelos NARX polinomiais na forma de Hammerstein e Wiener. **SBMAC Tendências em Matemática Aplicada e Computacional**, v. 3, n. 1, 2002.

CORRÊA, Marcelo V.; AGUIRRE, Luiz Antônio. Identificação não linear caixa cinza: uma revisão e novos resultados. **SBA Controle & Automação**, v. 15, n. 2, 2004.

DAMBROZ, C.; CAMPOS, M. de; SALVATORI, F.; RECH, C.; CAMARGO, R.F.; LEANDRO, G. V.; LEMOS, J. W. Development of a low cost diagnosis and alerts system for faults in electronic UPS systems using GSM Link. **9º Congresso Brasileiro de Eletrônica de Potência**. Blumenau: 2007.

DEBEBE, K.; RAJAGOPALAN, V.; SANKAR, T.S. Expert systems for fault diagnosis of VSI AC drives. **IEEE Industry Applications Society Annual Meeting**, v. 1, p. 368-373, 1991.

FIORI, Elaine Maria G. **Identificação de sistemas não lineares utilizando redes neurais artificiais**. Dissertação de Mestrado. Ijuí: UNIJUÍ, 2007.

GIBILISCO, S. **The illustrated dictionary of electronics**. 8.ed. McGraw-Hill, 2001.

GOMES, Moacir Carlos. **Identificação de sistemas utilizando algoritmos genéticos para estimação de parâmetros**. Dissertação de Mestrado. Ijuí: UNIJUÍ, 2005.

HAYKIN, S. **Redes neurais princípios e práticas**. 2 ed. Porto Alegre: Bookman, 2001.

HUAMANÍ, Ivette Luna. **Redes neurais fuzzy aplicadas em identificação e controle de sistemas**. Dissertação de Mestrado. Campinas: UNICAMP, 2003.

KARVE, Shri. Three of a Kind. **IEE Review**, pp. 27-32, March 2000.

KASTHA, D.; BOSE, B. K. Investigation of fault modes of voltage-fed inverter system for induction motor drive. **IEEE Transactions on Industry Applications**, v. 30, n. 4, p. 1028-1038, July/August 1994.

LIMA, Clodoaldo Aparecido de Moraes. **Emprego de teoria de agentes no desenvolvimento de dispositivos neurocomputacionais híbridos e aplicação ao controle e identificação de sistemas dinâmicos**. Dissertação de Mestrado. Campinas: UNICAMP, 2000.

LJUNG, Lennart. **System identification: Theory for the user**. 2 ed. New Jersey: Prentice-Hall, 1999.

NAZÁRIO, Cristiano Z. **Controle por realimentação linear de variáveis de estado com modelo interno aplicado a fontes ininterruptas de energia**. Dissertação de Mestrado. Porto Alegre: PUC/RS, 2007.

OLIVEIRA, Halisson A. **Sistema ininterrupto de energia de dupla conversão isolado de 6 kVA**. *Dissertação de Mestrado*. Fortaleza: UFC, 2007.

PEUGET, R.; COURTINE, S.; ROGNON, J. Fault detection and isolation on a PWM inverter by knowledge-based model. **IEEE Transactions on Industry Applications**, v. 34, n. 6, November/December 1998.

PINHEIRO, J. R.; SCHUCH, Luciano; RECH, Cassiano; MARTINEZ, Mauricio M.; SILVA, Estevan G. da. Relatório sobre UPS's Monofásicas. **Grupo de Eletrônica de Potência e Controle**. Santa Maria: CT/UFSM, 2002.

RASMUSSEN, Neil. Os diferentes tipos de sistemas UPS. **APC – American Power Conversion**, 2004.

RIBEIRO, R.L.A.; JACOBINA, C.B.; et al. Fault detection of open-switch damage in voltage-fed PWM motor drive systems. **IEEE Transactions on Power Electronics**, v. 18, n. 2, March 2003.

_____. Sistema de acionamento de máquinas com estratégia de controle tolerante a faltas. **Revista da Sociedade Brasileira de Eletrônica de Potência SOBRAEP**, v. 9, n.1, p.45-52, Junho de 2004.

ROCHA, Fabiano L. **Identificação de sistemas não lineares multivariáveis usando redes neurais perceptron multicamadas e função de base radial**. Dissertação de Mestrado. Curitiba: PUC/PR, 2006.

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](#)