

Universidade de São Paulo – USP
Escola de Engenharia de São Carlos – EESC
Departamento de Engenharia Elétrica

Fernando Bambozzi Bottura

**Um método alternativo e inteligente para o
monitoramento remoto das variações de tensão de
curta duração em um sistema de distribuição de
energia elétrica**

São Carlos

2010

FERNANDO BAMBOZZI BOTTURA

**UM MÉTODO ALTERNATIVO E
INTELIGENTE PARA O
MONITORAMENTO REMOTO DAS
VARIAÇÕES DE TENSÃO DE CURTA
DURAÇÃO EM UM SISTEMA DE
DISTRIBUIÇÃO DE ENERGIA
ELÉTRICA.**

Trabalho de Conclusão de Curso apresentado à
Escola de Engenharia de São Carlos, da
Universidade de São Paulo

Curso de Engenharia Elétrica com ênfase em
Sistemas de Energia e Automação

ORIENTADOR: Prof. Dr. Mário Oleskovicz

São Carlos
2010

AUTORIZO A REPRODUÇÃO E DIVULGAÇÃO TOTAL OU PARCIAL DESTE TRABALHO, POR QUALQUER MEIO CONVENCIONAL OU ELETRÔNICO, PARA FINS DE ESTUDO E PESQUISA, DESDE QUE CITADA A FONTE.

Ficha catalográfica preparada pela Seção de Tratamento
da Informação do Serviço de Biblioteca – EESC/USP

B751m

Bottura, Fernando Bambozzi
Um método alternativo e inteligente para o monitoramento remoto das variações de tensão de curta duração em um sistema de distribuição de energia elétrica / Fernando Bambozzi Bottura ; orientador Mário Oleskovicz . -- São Carlos, 2010.

Trabalho de Conclusão de Curso (Graduação em Engenharia Elétrica com ênfase em Sistemas de Energia e Automação) -- Escola de Engenharia de São Carlos da Universidade de São Paulo, 2010.

1. Sistemas elétricos de potência. 2. Sistemas elétricos de distribuição. 3. Qualidade da energia elétrica. 4. Monitoramento remoto. 5. Variações de tensão de curta duração. 6. Redes neurais artificiais.
I. Título.

Aos meus pais, Herbert e Maria Teresa e à minha irmã Eleonora, por sempre estarem presentes em minha vida.

Agradecimentos

Ao Professor Dr. Mário Oleskovicz, pela confiança a mim conferida para a realização deste trabalho de conclusão de curso, por sua dedicada atenção e profissionalismo exemplares.

Ao Hermes Manoel Galvão Castelo Branco, pela intensa contribuição efetuada em todas as etapas deste trabalho que levaram à sua finalização, sempre com seu raciocínio objetivo e espírito crítico extremamente construtivo.

A todos os demais integrantes do Laboratório de Sistemas de Energia Elétrica (LSEE) que contribuíram para a elaboração deste trabalho, em especial ao Renato Machado Monaro, pelas importantes opiniões e sugestões.

Quero também, prestar meus agradecimentos a todos os professores do Departamento de Engenharia Elétrica que contribuíram de maneira valiosa à minha formação profissional.

Sumário

Agradecimentos	IX
Lista de figuras	XIII
Lista de tabelas	XV
Resumo	XVII
Abstract.....	XIX
Capítulo 1 – Introdução	1
1.1 – Objetivos do trabalho.....	3
1.2 – Apresentação deste documento	3
Capítulo 2 – Revisão bibliográfica	5
Capítulo 3 – Redes neurais artificiais	15
3.1 – Modelo não linear de um neurônio artificial	15
3.2 – Representações gráficas de uma RNA	17
3.3 – Funções de ativação.....	18
3.3.1 – Função de limiar ou função de Heaviside	18
3.3.2 – Função linear por partes.	19
3.3.3 – Função sigmóide.....	20
3.3.4 – Função sinal e tangente hiperbólica.....	21
3.4 – Arquiteturas de redes neurais artificiais	22
3.4.1 – Redes de camada única.....	22
3.4.2 – Redes de múltiplas camadas	26
3.4.3 – Treinamento de retropropagação de erro (<i>back-propagation</i>).	27
3.4.4 – Treinamento Levenberg-Marquardt	29
Capítulo 4 – O sistema elétrico de distribuição em análise	31
4.1 – Modelagem computacional do sistema de distribuição	31
Capítulo 5 – Base de treinamento para a RNA e estratégia de monitoramento da tensão	37
5.1 – Obtenção da base de dados de treinamento para a RNA	37
5.1.1 - Simulação das situações de defeitos.....	37
5.1.2 – Pré-processamento dos dados resultantes das simulações.....	38
5.2 – Estratégia proposta para monitoramento da tensão	41
5.2.1 – Treinamento da RNA com o algoritmo <i>back-propagation</i>	42
5.2.2 – Treinamento da RNA com o algoritmo <i>Levenberg-Marquardt</i>	47
5.2.3 – Análise sobre a arquitetura e o tipo de treinamento adotados	52
5.3 – Análise do desempenho da RNA escolhida.....	52
5.3.1 – Aplicação de falta, exemplo 1	53
5.3.2 – Aplicação de falta, exemplo 2	55
5.3.3 – Aplicação de falta, exemplo 3	56

5.3.4 – Índice de acertos das RNAs.....	58
Capítulo 6 – Conclusões.....	61
Referências bibliográficas	63

Lista de figuras

Figura 1 - Classificação das variações encontradas sobre o valor eficaz da tensão de fornecimento.....	7
Figura 2 - Curva de tolerância de tensão CBEMA, adaptado de Kyei et al. (2002)	7
Figura 3 - Curva de tolerância de tensão ITIC, adaptado de Kyei et al. (2002).....	8
Figura 4 - Representação esquemática simplificada de um neurônio biológico.	16
Figura 5 - Modelo não linear de um neurônio artificial.	16
Figura 6 - Grafo de fluxo de sinal de um neurônio	17
Figura 7 - Grafo arquitetural de um neurônio.....	18
Figura 8 - Comportamento da função de ativação do tipo limiar ou Heaviside.....	19
Figura 9 - Comportamento da função de ativação do tipo linear por partes.	20
Figura 10 - Comportamento da função de ativação do tipo sigmóide.....	20
Figura 11 - Comportamento da função de ativação do tipo sinal.....	21
Figura 12 - Comportamento da função de ativação do tipo tangente hiperbólica.....	22
Figura 13 - Diagrama arquitetural de uma rede de camada única alimentada adiante	23
Figura 14 - Representação de uma fronteira de decisão para um problema bidimensional	24
Figura 15 – Fronteira de decisão: (a) As linhas tracejada e contínua ilustram possíveis fronteiras de decisão; (b) A linha contínua representa a única fronteira de decisão possível ..	26
Figura 16 - Arquitetura de uma rede de múltipla camada alimentada adiante.....	27
Figura 17 - Ilustração do problema XOR	27
Figura 18 - Disposição geográfica dos alimentadores pertencentes a uma subestação de uma concessionária de energia regional sob estudo.	31
Figura 19 - Aspecto da modelagem computacional dos alimentadores da concessionária de energia regional realizada via interface gráfica do <i>ATPDraw</i>	32
Figura 20 - Visão geral dos pontos de aplicação da falta e de monitoramento da tensão.	38
Figura 21 – Aspecto do processo de janelamento.	40
Figura 22 - Figura esquemática representando a RNA empregada em uma das fases do sistema trifásico.	42
Figura 23 – Resultado da comparação entre saída esperada e saída gerada pela RNA da fase A, para o primeiro exemplo.....	53
Figura 24 – Resultado da comparação entre saída esperada e saída gerada pela RNA da fase B, para o primeiro exemplo.....	54
Figura 25 – Resultado da comparação entre saída esperada e saída gerada pela RNA da fase	

<i>C</i> , para o primeiro exemplo	54
Figura 26 – Resultado da comparação entre saída esperada e saída gerada pela RNA da fase A, para o segundo exemplo	55
Figura 27 – Resultado da comparação entre saída esperada e saída gerada pela RNA da fase B, para o segundo exemplo	55
Figura 28 – Resultado da comparação entre saída esperada e saída gerada pela RNA da fase C, para o segundo exemplo	56
Figura 29 – Resultado da comparação entre saída esperada e saída gerada pela RNA da fase A, para o terceiro exemplo	56
Figura 30 – Resultado da comparação entre saída esperada e saída gerada pela RNA da fase B, para o terceiro exemplo	57
Figura 31 – Resultado da comparação entre saída esperada e saída gerada pela RNA da fase C, para o terceiro exemplo	57
Figura 32 – Histograma relacionando a quantidade de casos de testes com a magnitude dos erros entre resposta esperada e resposta gerada pela RNA da fase A	58
Figura 33 – Histograma relacionando a quantidade de casos de testes com a magnitude dos erros entre resposta esperada e resposta gerada pela RNA da fase B	58
Figura 34 – Histograma relacionando a quantidade de casos de testes com a magnitude dos erros entre resposta esperada e resposta gerada pela RNA da fase C	59

Lista de tabelas

Tabela 1 - Características da fonte de tensão do SEP utilizada.....	33
Tabela 2 - Parâmetros do modelo RL mutuamente acoplado, disposto em série com a fonte de tensão do equivalente elétrico.....	33
Tabela 3 - Características do modelo do transformador de potência.	33
Tabela 4 - Parâmetros do modelo empregado para a modelagem dos bancos de capacitores. 34	34
Tabela 5 – Exemplos de dados de carga do sistema de distribuição.	34
Tabela 6 – Tabela contendo parâmetros de dois trechos de condutores dos alimentadores para sequência zero.....	35
Tabela 7 – Tabela contendo parâmetros de dois trechos de condutores dos alimentadores para sequência positiva.....	35
Tabela 8 - Configuração para a obtenção da base de treinamento para a RNA.	40
Tabela 9 – Resultados do treinamento <i>back-propagation</i> para RNA da fase A com arquitetura 6-10-5-1.....	43
Tabela 10 – Resultados do treinamento <i>back-propagation</i> para RNA da fase A com arquitetura 6-14-7-1.....	43
Tabela 11 – Resultados do treinamento <i>back-propagation</i> para RNA da fase A com arquitetura 6-15-10-1.....	44
Tabela 12 – Resultados do treinamento <i>back-propagation</i> para RNA da fase A com arquitetura 6-20-10-1.....	44
Tabela 13 – Resultados do treinamento <i>back-propagation</i> para RNA da fase A com arquitetura 6-20-15-1.....	44
Tabela 14 – Resultados do treinamento <i>back-propagation</i> para RNA da fase A com arquitetura 6-25-15-1.....	45
Tabela 15 - Resultados do treinamento <i>back-propagation</i> para RNA da fase A com arquitetura 6-30-20-1.....	45
Tabela 16 – Resultados do treinamento <i>back-propagation</i> para RNA da fase A com arquitetura 6-40-30-1.....	45
Tabela 17 - Resultados do treinamento <i>back-propagation</i> para RNA (20.000 épocas de treinamento) da fase A com arquitetura 6-25-15-1.....	46
Tabela 18 – Resultados do treinamento <i>back-propagation</i> para RNA (20.000 épocas de treinamento) da fase B com arquitetura 6-25-15-1.....	46
Tabela 19 - Resultados do treinamento <i>back-propagation</i> para RNA (20.000 épocas de	

treinamento) da fase <i>C</i> com arquitetura 6-25-15-1.....	47
Tabela 20 – Resultados do treinamento <i>Levenberg-Marquardt</i> para RNA da fase <i>A</i> com arquitetura 6-10-5-1.....	47
Tabela 21 – Resultados do treinamento <i>Levenberg-Marquardt</i> para RNA da fase <i>A</i> com arquitetura 6-14-7-1.....	48
Tabela 22 – Resultados do treinamento <i>Levenberg-Marquardt</i> para RNA da fase <i>A</i> com arquitetura 6-15-10-1.....	48
Tabela 23 – Resultados do treinamento <i>Levenberg-Marquardt</i> para RNA da fase <i>A</i> com arquitetura 6-20-10-1.....	48
Tabela 24 – Resultados do treinamento <i>Levenberg-Marquardt</i> para RNA da fase <i>A</i> com arquitetura 6-20-15-1.....	49
Tabela 25 – Resultados do treinamento <i>Levenberg-Marquardt</i> para RNA da fase <i>A</i> com arquitetura 6-25-15-1.....	49
Tabela 26 – Resultados do treinamento <i>Levenberg-Marquardt</i> para RNA da fase <i>A</i> com arquitetura 6-25-20-1.....	49
Tabela 27 – Resultados do treinamento <i>Levenberg-Marquardt</i> para RNA da fase <i>A</i> com arquitetura 6-30-20-1.....	50
Tabela 28 – Resultados do treinamento <i>Levenberg-Marquardt</i> para RNA da fase <i>B</i> com arquitetura 6-15-10-1.....	50
Tabela 29 – Resultados do treinamento <i>Levenberg-Marquardt</i> para RNA da fase <i>B</i> com arquitetura 6-25-20-1.....	51
Tabela 30 – Resultados do treinamento <i>Levenberg-Marquardt</i> para RNA da fase <i>C</i> com arquitetura 6-15-10-1.....	51
Tabela 31 – Resultados do treinamento <i>Levenberg-Marquardt</i> para RNA da fase <i>C</i> com arquitetura 6-25-20-1.....	51
Tabela 32 – Comparação do desempenho entre duas arquiteturas de RNA.....	52

Resumo

BOTTURA, F. B. **Um método alternativo e inteligente para o monitoramento remoto das variações de tensão de curta duração em um sistema de distribuição de energia elétrica.** 2010. p. 85. Trabalho de Conclusão de Curso (Engenharia Elétrica com Ênfase em Sistemas de Energia e Automação) – Escola de Engenharia de São Carlos (EESC), Universidade de São Paulo, São Carlos – SP, 2010.

Este trabalho tem por objetivo apresentar um método de monitoramento remoto dos níveis de tensão em um determinado ponto de interesse de um sistema de distribuição de energia. A partir de um sistema de distribuição previamente modelado, foi possível obter uma base de treinamento para as três redes neurais artificiais. Após o processo de treinamento, estas devem fornecer uma estimativa para os níveis de tensão das três fases no ponto de interesse a ser monitorado remotamente. O desenvolvimento desta estratégia permitirá o monitoramento da qualidade da energia elétrica no que diz respeito aos níveis de tensão, sem a necessidade de se introduzir medidores adicionais no sistema de distribuição, o que pode proporcionar economia no âmbito financeiro às concessionárias de energia elétrica. O desempenho das três redes neurais foi validado e constatou-se que o método de monitoramento remoto dos níveis de tensão pode se tornar uma aplicação tecnicamente viável.

Palavras Chave: Sistemas elétricos de distribuição, qualidade da energia elétrica, monitoramento remoto, variações de tensão de curta duração e redes neurais artificiais.

Abstract

BOTTURA, F. B. **An intelligent alternative method for remote monitoring of short duration voltage variations in a power distribution system.** 2010. 85 f. Trabalho de Conclusão de Curso (Engenharia Elétrica com Ênfase em Sistemas de Energia e Automação) – Escola de Engenharia de São Carlos (EESC), Universidade de São Paulo, São Carlos – SP,2010.

The aim of this work is to present a method for the remote voltage levels monitoring at a particular point in a power distribution system. From a power distribution system previously modeled, a data set for the learning process of three artificial neural networks was obtained. After the training process, they might be able to provide the estimation of the voltage levels in the three phases at a particular point remotely monitored. This methodology allows the power quality monitoring related to the voltage levels, without introducing additional measuring instruments in the power distribution system, which could provide savings to the energy company. The three neural networks performance was validated and it was found that the remote monitoring method of the voltage levels can be technically viable.

Keywords: Power distribution system, power quality, remote monitoring, short duration voltage variations and artificial neural networks.

Capítulo 1 – Introdução

A Qualidade da Energia Elétrica (QEE) é caracterizada pela disponibilidade da energia na forma de uma onda senoidal pura, sem alterações em amplitude e freqüência (Dugan et al. 2003). Entretanto, um Sistema Elétrico de Potência (SEP) está sujeito a diversos fenômenos que comprometem a QEE, freqüentemente ocasionando a má operação de equipamentos e, em alguns casos, perda de processos industriais. Entre os fenômenos que comprometem a QEE destacam-se, pela freqüência de ocorrência, os afundamentos de tensão, dado que 87% de todas as ocorrências de fenômenos relacionados à QEE dizem respeito a este tipo de distúrbio (Oleskovicz, 2007). Estes eventos, na grande maioria das vezes, são consequências da ocorrência de faltas ao longo do SEP, dado que o afundamento de tensão no ponto da falta se propaga ao longo da linha.

Neste contexto, cargas sensíveis alocadas em diferentes pontos de um sistema elétrico de potência podem operar inadequadamente quando submetidas a certas variações de tensão, decorrentes de distintas situações de faltas incidentes sobre o sistema elétrico (Bollen et al. 2006). Estas variações podem resultar em níveis de tensão abaixo do exigido (como afundamentos de tensão) que por sua vez, devem ser avaliados e, quando não extinguidos por completo, amenizados. Torna-se então de extrema importância o conhecimento da área de vulnerabilidade destas cargas frente às possíveis operações não desejadas sobre o sistema elétrico. Por área de vulnerabilidade entende-se a região ao redor de uma carga na qual a ocorrência de faltas causa, nesta carga e nas suas proximidades, uma variação de tensão suficiente para prejudicar a operação das mesmas.

A tendência de uma exigência mais rígida em termos da QEE fornecida, seja por parte dos consumidores ou das concessionárias de energia elétrica, tem sido crescente. Equipamentos como o caso de computadores, controladores lógico programáveis, robôs industriais, máquinas elétricas, dentre outros, que são partes integrantes das etapas que agregam valor aos processos industriais, em geral, possuem baixa tolerância quando submetidos aos possíveis distúrbios advindos da rede de energia elétrica. Portanto, quando estes equipamentos são acometidos por distúrbios de QEE possivelmente desencadearão prejuízos financeiros consideráveis.

Assim como os consumidores industriais, os consumidores comerciais e residenciais estão cada vez mais cientes de seu direito de serem supridos por uma energia elétrica de qualidade, uma vez que se observa o surgimento e consolidação de normatizações (em âmbitos nacionais e internacionais) que visam assegurar a QEE aos consumidores. Fica claro que a preocupação com os distúrbios de QEE possuem implicações econômicas e legais evidentes, configurando-se como um campo de pesquisa importante e promissor.

Uma condição necessária na tarefa de se manter níveis aceitáveis da qualidade da energia elétrica é a metodologia empregada no monitoramento dos distúrbios sobre a mesma. Em geral este

monitoramento se revela como sendo um procedimento não trivial e de investimento financeiro relativamente elevado. As dificuldades podem ter início logo no instante de se eleger o melhor local em que o equipamento de monitoramento será instalado, pois muitas vezes não se tem conhecimento prévio sobre quais os pontos que poderão fornecer a melhor visão da situação de operação do sistema de energia elétrica, sob o ponto de vista da QEE. Além desta dificuldade inicial, a ocorrência dos distúrbios de QEE possui caráter estocástico, de forma que não se deve apenas levar em consideração a topologia do sistema, necessitando-se incluir a abordagem de outros parâmetros menos controláveis (Dugan et al. 2003).

Com o objetivo de se desenvolver metodologias mais eficientes a serem aplicadas ao monitoramento dos distúrbios, vários pesquisadores têm estudado os fenômenos relacionados à QEE. Atualmente constata-se, por exemplo, o uso de ferramentas de inteligência artificial, como é o caso das Redes Neurais Artificiais (RNAs), Lógica *Fuzzy* (LF), e de ferramentas matemáticas como, por exemplo, o caso da Transformada de *Fourier* e Transformada *Wavelet* (Bollen et al. 2006). Estas ferramentas são utilizadas principalmente na etapa de pré-processamento das informações e extração de características relevantes, ou para a classificação dos distúrbios. Cabe relembrar que a principal motivação das pesquisas desenvolvidas atualmente, além de ampliar os conhecimentos neste campo e realizar contribuições acadêmicas muito relevantes, é minimizar as perdas econômicas decorrentes de distúrbios de QEE, nos processos de produção de bens que utilizem a energia elétrica como insumo.

Tendo em vista a dificuldade para se realizar o monitoramento dos distúrbios relativos à QEE, o alto custo de implantação de medidores de QEE e a crescente demanda por níveis cada vez mais exigentes da qualidade da energia elétrica fornecida, propõe-se o desenvolvimento de um método alternativo para a medição e monitoramento dos níveis de tensão em pontos de um sistema de distribuição de energia elétrica, pela utilização de uma ferramenta de inteligência artificial, em particular, pela aplicação de RNAs. Como anteriormente comentado, o interesse em se monitorar a tensão de alimentação de um determinado ponto do sistema, advém do fato de que os afundamentos de tensão representam cerca de 87% dos distúrbios referentes à QEE.

Pela metodologia proposta, a partir de dados coletados por um monitor de QEE instalado na subestação de um sistema de distribuição de energia elétrica, será possível estimar o nível de tensão em um (ou mais) ponto(s) deste sistema. Desta maneira, pretende-se apresentar uma alternativa que seja confiável e atrativa do ponto de vista financeiro.

Para este estudo inicial, cabe salientar que o monitoramento de um determinado consumidor poderá ser realizado da forma proposta, fornecendo uma estimativa muito próxima das reais condições de operação a que o consumidor está sendo submetido, sem a necessidade de se dispor de um medidor de QEE instalado permanentemente no ponto de conexão do cliente.

1.1 – Objetivos do trabalho

Este trabalho tem como objetivo o desenvolvimento de uma estratégia que, tomando por base valores de tensão medidos em uma subestação de um sistema de distribuição de energia elétrica, quantifique valores da variação da tensão em pontos de interesse ao longo deste sistema de distribuição de energia elétrica. Deste monitoramento da variação da tensão, será possível mapear níveis de sensibilidade, no que se diz respeito aos níveis de tensão de fornecimento, delimitando áreas de vulnerabilidade no sistema em análise para um determinado ponto de interesse.

Para o desenvolvimento deste trabalho, foram simuladas diferentes situações de falta ao longo de um sistema de distribuição de energia elétrica, previamente modelado dispondo do “software” ATP (“*Alternative Transients Program*”) (Rule Book, 1987) utilizando parâmetros reais de uma concessionária local. Por meio destas simulações gerou-se os dados que foram fornecidos para o treinamento de uma RNA utilizada para o monitoramento remoto da tensão em um ponto específico do sistema. O desenvolvimento da arquitetura da RNA em questão foi efetuado com o auxílio da ferramenta computacional “*Neural Network Toolbox*” do Matlab® (Demuth et al. 2007).

Sendo assim, com o desenvolvimento da estratégia proposta, apresenta-se uma alternativa para a realização do monitoramento dos níveis de tensão em determinado ponto de interesse do sistema de distribuição, além da verificação da sensibilidade do sistema devido a faltas incidentes nas vizinhanças deste ponto.

Pelos resultados até então encontrados, vale comentar que fica evidente a possibilidade de expansão deste monitoramento para outros pontos de interesse sobre o sistema em análise.

Por fim, pretende-se alcançar um aprofundamento dos conhecimentos relativos à QEE e à sistemas inteligentes, em particular, sobre RNAs.

1.2 – Apresentação deste documento

Diante da introdução apresentada, este documento possui mais cinco capítulos. O capítulo dois trás uma revisão bibliográfica contendo conceitos relacionados à QEE e pesquisas realizadas atualmente nesta área. Em seguida, o capítulo três trata sobre as RNAs, apresentando os principais fundamentos teóricos da área. Logo após, o sistema de distribuição de energia elétrica em estudo, previamente modelado computacionalmente é apresentado no capítulo quatro. No capítulo cinco, apresenta-se a metodologia proposta e os resultados por ela obtidos.

O capítulo seis trás as conclusões obtidas com a realização deste trabalho e possíveis temas para a continuidade desta pesquisa.

Capítulo 2 – Revisão bibliográfica

Os estudos acerca da QEE são, atualmente, de suma importância para a garantia de um serviço de distribuição da energia elétrica que esteja dentro das especificações exigidas pelas normas, instigando, portanto, o interesse de diversos setores da economia.

A preocupação com a conformidade dos níveis de tensão se faz presente, sendo que um dos principais distúrbios referentes à QEE é a variação de tensão. Uma variação de tensão é caracterizada pela permanência do nível de tensão fora da faixa nominal durante um determinado intervalo de tempo. As variações de tensão estão subdivididas em: variações de tensão de longa duração (VTLD) e variações de tensão de curta duração (VTCD).

Quando os fenômenos de variação de tensão se prolongam por períodos de tempo superiores a 1 minuto são classificados como sendo VTLD. Neste caso, quando a tensão se eleva para valores entre 1,1p.u. e 1,2p.u. em relação à tensão nominal, tem-se o que se denomina sobretensão, já quando um fenômeno remete à uma tensão remanescente que permaneça abaixo de 0,9p.u. da nominal, este é classificado como sendo subtensão (Dugan et al. 2003). As VTLD são fenômenos decorrentes, em geral, de variações na carga do sistema, chaveamentos sobre o mesmo, além de poderem estar relacionadas às situações de faltas sustentadas. Este tipo de variação de tensão pode acarretar em efeitos indesejáveis como a redução da vida útil de equipamentos, bem como causar a parada dos mesmos. A sobretensão é geralmente resultante do processo de desligamento de grandes cargas ou da energização de bancos de capacitores. Conforme mencionado, a vida útil dos equipamentos pode ser seriamente afetada quando sobretensões acometem o sistema. Por outro lado, a subtensão pode ter sua origem, por exemplo, no excesso de carregamento dos circuitos alimentadores e pela entrada de cargas no sistema. Este distúrbio tem efeitos negativos como: interrupção da operação de equipamentos eletrônicos, elevação do tempo de partida de máquinas de indução, potencializando os efeitos indesejáveis que ocorrem durante este processo, dentre outras consequência danosas. Num caso mais grave de VTLD tem-se a presença da interrupção sustentada, em que a tensão de fornecimento permanece em zero por um tempo maior do que um minuto.

Já os fenômenos de VTCD estão relacionados às durações inferiores a 1 minuto, e são subdivididas em variações instantâneas (0,5 a 30 ciclos), momentâneas (30 ciclos a 3 segundos) e temporárias (3 segundos a 1 minuto). Em se tratando da magnitude da tensão, uma VTCD pode ser classificada como: interrupção, afundamento e elevação de tensão. Quando há a incidência de faltas elétricas sobre o sistema elétrico, estas podem causar a completa interrupção do fornecimento da tensão (interrupção), em alguns casos, acarretar em um aumento no valor nominal da tensão (elevação), ou provocar afundamentos de tensão. Em se tratando de VTCD, as interrupções recebem a denominação de interrupções de curta duração, e são detectadas quando a tensão de fornecimento ou a corrente de carga apresentem um valor remanescente de 0 (zero) a 0,1p.u., em relação aos valores nominais, por um período de tempo inferior a 1 minuto (Dugan et al. 2003). Cabe ressaltar que em um

sistema de energia elétrico, a duração de uma falta está relacionada com o tempo de atuação dos dispositivos de proteção utilizados pelas concessionárias de energia, uma vez que estes terão a função de eliminá-las, ou de isolá-las do restante do sistema (Oleskovicz, 2007). O aumento no valor nominal da tensão, em intervalos de tempo inferior a 1minuto é denominado de elevação de tensão, que é definida, de acordo com Dugan et al. (2002), como sendo um aumento entre 0,1p.u. e 0,8p.u. sobre o valor nominal da tensão de fornecimento. Conforme mencionado anteriormente, este tipo de distúrbio é causado, principalmente, por faltas elétricas incidentes sobre o sistema, podendo ser originado também pelo desacoplamento de cargas de grande porte do mesmo.

Dentre os distúrbios referentes à QEE, o afundamento de tensão é um dos que desperta maior interesse, principalmente devido seu maior grau de ocorrência e possíveis prejuízos decorrentes. O afundamento de tensão é definido como sendo qualquer decréscimo cuja magnitude remanescente apresenta-se entre 0,9 a 0,1p.u. da tensão nominal em um intervalo de tempo, entre meio ciclo a um minuto (Dugan et al. 2003), considerando-se a freqüência nominal do sistema (60 Hz). Conforme já mencionado, os afundamentos de tensão se enquadram na classe de fenômenos de VTCD sendo, portanto, classificados como: instantâneos, momentâneos e temporários. Conforme Dugan et al. (2002), os afundamentos instantâneos possuem duração típica de 0,5 a 30 ciclos, já os momentâneos são aqueles que apresentam duração de 30 ciclos a 3 segundos, e finalmente, os temporários compreendem o intervalo de 3 segundos a 1min.

Cabe colocar que o módulo 8 do PRODIST (“procedimentos de distribuição de energia elétrica”) (ANEEL, 2009) no sistema elétrico brasileiro, que trata em especial da QEE, normatiza intervalos diferentes daqueles típicos encontrados na literatura, ampliando o intervalo de tempo dos afundamentos de tensão para até a 3 minutos. Este documento estabelece que o afundamento momentâneo de tensão compreende um intervalo de tempo superior ou igual a 1 ciclo e inferior ou igual a 3 segundos. Já temporário em uma faixa de tempo superior a 3 segundos e inferior a 3 minutos, desconsiderando, portanto, a classificação de afundamentos momentâneos citada acima. Esta é uma classificação menos rígida no que diz respeito a assegurar a qualidade da tensão, uma vez que afundamentos mesmo inferiores a 1 ciclo podem ser danosos ao sistema, como por exemplo, causando perdas de informações devido à operação inadequada de um equipamento microprocessado.

Este tipo de perturbação pode ser causado, em geral, pela partida de grandes motores e/ou outras cargas elétricas de grande porte que solicitem alta corrente de partida, por curtos-circuitos incidentes no sistema e por chaveamentos da concessionária de energia elétrica sobre determinado sistema (Kagan et al., 2009). Para sintetizar as classificações referentes às variações de curta e longa duração apontadas, é apresentada a Figura 1.

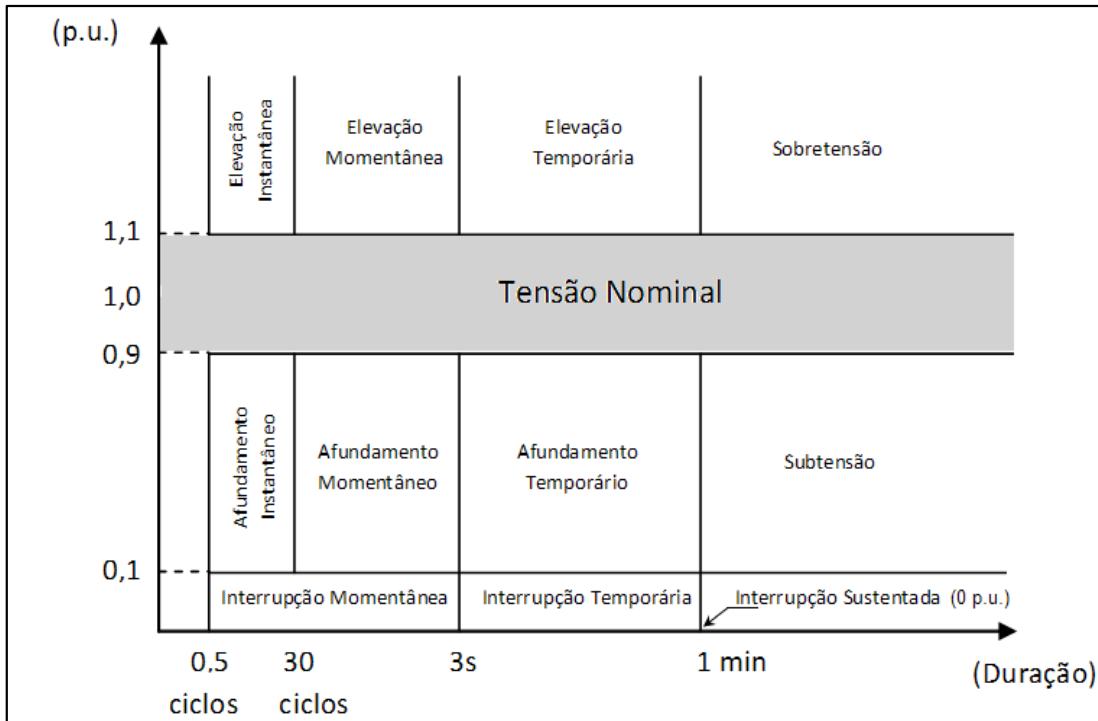


Figura 1 - Classificação das variações encontradas sobre o valor eficaz da tensão de fornecimento.

Em vista à preocupação das consequências danosas aos equipamentos sensíveis, resultantes dos fenômenos de VTCD, curvas de sensibilidades foram desenvolvidas para se especificar zonas de tolerância dos equipamentos microprocessados às variações de tensão, relacionando suas magnitudes com o respectivo tempo de ocorrência das mesmas. A curva CBEMA (*Computer Business Manufacturers Associations*) (Dugan et al. 2003) foi a primeira destas curvas e foi desenvolvida pelos fabricantes de computadores eletrônicos, tornando-se referência para a especificação de tolerância de equipamentos microprocessados. Esta curva está mostrada na Figura 2.

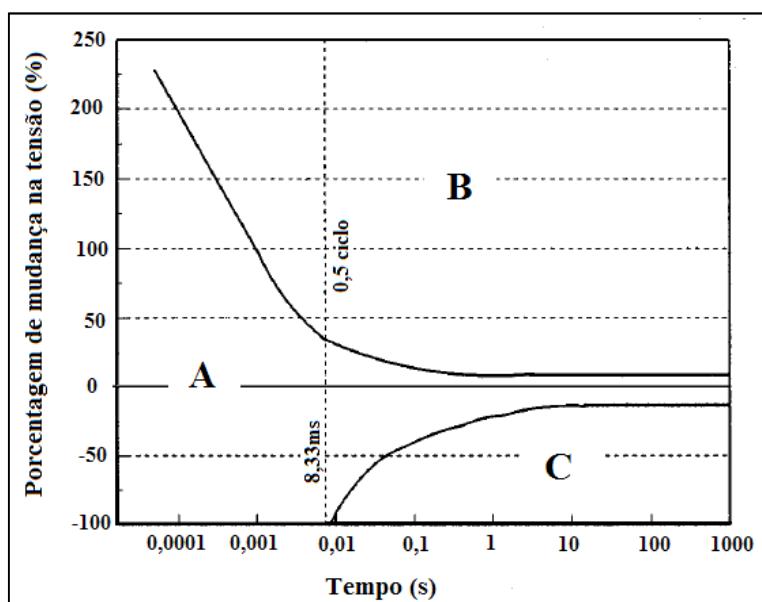


Figura 2 - Curva de tolerância de tensão CBEMA, adaptado de Kyei et al. (2002)

A Figura 2 mostra três regiões distintas associadas às letras *A*, *B* e *C*; as mesmas representam: *A* – região normal de trabalho, considerada aceitável para determinada situação de operação; *B* – região perigosa de trabalho, com possibilidade de ruptura da isolação dos equipamentos (perda de *hardware*); *C* – região perigosa de trabalho, com possibilidade de paralisação de alguns equipamentos (disfunções).

Posteriormente, como uma ampliação do emprego da curva CBEMA, surgiu a curva ITIC (*Information Technology Industry Council*) que apresenta níveis mais rígidos quanto à magnitude e duração das variações de tensão de curta duração (Dugan et al. 2003). Na Figura 3, a curva ITIC é apresentada.

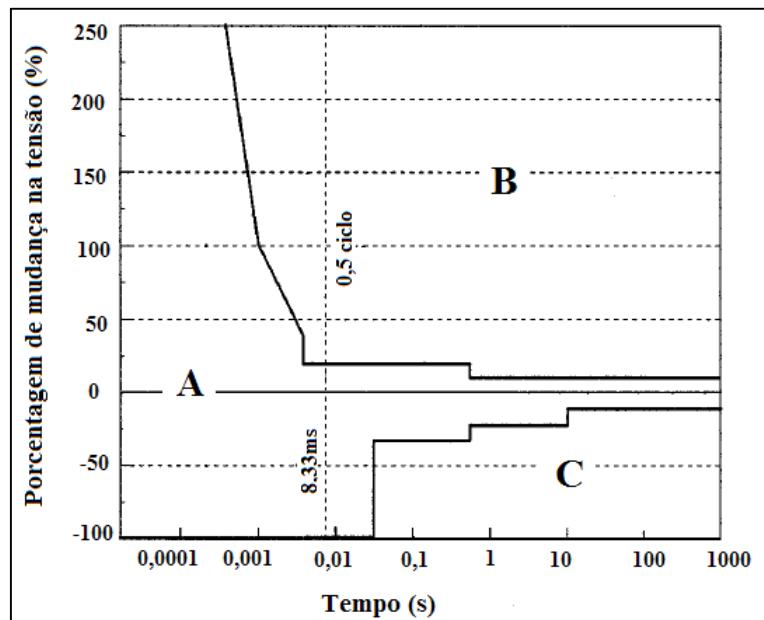


Figura 3 - Curva de tolerância de tensão ITIC, adaptado de Kyei et al. (2002)

O comportamento nas regiões determinadas pelas curvas é o mesmo, tanto para a curva CBEMA, quanto para a ITIC. Os pontos que caírem abaixo da curva inferior (região *C*) podem causar o desligamento ou mau funcionamento da carga sensível. Os pontos acima da curva superior (região *B*) poderão causar um mau funcionamento devido à falha de isolação ou desligamento por sobretensão, entre outros. A região *A*, configura a região de operação normal.

Outros conceitos relacionados com a robustez do sistema e com os fenômenos de QEE já mencionados no presente trabalho, também merecem destaque nesta seção de revisão bibliográfica. São eles: a área de vulnerabilidade e, por consequência, a área afetada.

Em Goswami et al. (2008), a área de vulnerabilidade é definida como sendo toda a porção do circuito do sistema elétrico de potência (barramentos e segmentos de linha) que, quando acometida por defeitos (falhas) pode provocar afundamentos de tensão em um dado barramento. Estes afundamentos possuem magnitudes abaixo da tensão mínima de operação (limiar de tensão) de uma carga elétrica sensível. Já a área afetada, como exposto por Goswami et al. (2008), é entendida como sendo o

conceito complementar de área de vulnerabilidade, ou seja, dado a incidência de uma falta elétrica em um determinado barramento do sistema, define-se qual a porção do sistema elétrico que terá sua tensão reduzida para níveis menores do que a tensão mínima de operação.

Sobre este escopo inicialmente apresentado, estudos relacionados revelam o surgimento de novas interpretações relativas ao diagnóstico de QEE. Como por exemplo, tem-se a pesquisa de Won et al. (2005), onde os autores propõem um método para uma nova abordagem sobre a caracterização de afundamentos de tensão utilizando-se uma função de aproximação ao perfil de afundamento de tensão, do tipo raiz k -ésima. Esta função, segundo os autores, representaria o perfil do afundamento de tensão em determinada carga. O método permite eliminar a superestimação da duração dos afundamentos de tensão detectados pelos monitores de QEE, onde o perfil do evento não é retangular devido às características dinâmicas inerentes da carga em análise, como, por exemplo, no afundamento provocado pela reaceleração de um motor elétrico de indução de grande porte após uma queda de sua tensão na alimentação (Bollen, 1995 *apud* Won et al. 2005). Segundo relatado, a função descrita é capaz de aproximar o perfil do afundamento de tensão usando apenas os dados padrões fornecidos por medidores de QEE. O parâmetro (k) é obtido experimentalmente por aproximações sucessivas. O método parece ser capaz de caracterizar de maneira prática e mais exata o verdadeiro efeito de um afundamento de tensão.

Seguindo na mesma linha de estudo, Kyei et al. (2002) ressaltam a importância de se investigar os fenômenos relacionados aos afundamentos de tensão. Para tanto, os autores propõem um método para a obtenção de curvas de tolerância de tensão para uma carga em particular, como um complemento à utilização das curvas padrões CBEMA e ITIC (Dugan et. al. 2002), empregadas de maneira generalizada aos diversos tipos de cargas não lineares em operação. Pela pesquisa, os autores foram capazes de modelar um evento de afundamento de tensão em um sistema de distribuição de energia através do estudo de um retificador monofásico de tensão, em que a entrada do mesmo representa a tensão (V_{AC}) fornecida pela rede de energia elétrica, e a tensão retificada (V_{DC}) representa a tensão fornecida à carga. Pela solução temporal da equação diferencial associada a este retificador em termos da saída (V_{DC}), mostra-se que é possível obter uma resposta similar à curva CBEMA no plano ($V_{DC} \times T$), onde T é o tempo de duração do afundamento de tensão, obtendo-se a curva de sensibilidade da carga. Cabe salientar que a análise pode ser estendida ao caso trifásico. Além da tensão, os mesmos demonstram que é possível referenciar a sensibilidade de um equipamento por meio de outros parâmetros de interesse, como, por exemplo, a velocidade ou o torque em uma carga rotativa, ampliando assim o conceito de curva de sensibilidade antes apenas referido à curva CBEMA ou ITIC.

A preocupação em se considerar os parâmetros de sensibilidade das cargas em operação também é observado no artigo publicado por Lee et al. (2004). Os autores discutem a importância de se obter um índice de QEE que seja capaz de associar um custo financeiro à gravidade dos danos causados na carga de interesse por afundamentos e interrupção de tensão de diferentes classes (k) de

magnitude e duração, provenientes da rede de distribuição de energia elétrica. A quantificação da gravidade dos danos na carga é expressa por uma média $[E(k)]$ que leva em consideração a frequência e a energia dos afundamentos de tensão e interrupção na operação da carga, de cada classe (k). Ao se levar em consideração a sensibilidade de diversos tipos de carga em estudo, o artigo cita a obtenção de suas respectivas curvas de tolerância, salientando a semelhança das mesmas com a curva CBEMA, conforme explicitado em Kyei et al. (2002). Nestas curvas, são introduzidas subdivisões no eixo das abscissas (tempo), relativas às classes (k), definidas pelo padrão IEEE Std 1159-1995, com o objetivo de se prever possíveis danos na carga. O cálculo do custo é realizado com base em registros estatísticos do sistema elétrico para uma conhecida taxa de defeito do mesmo, e no fator C_k , que reflete a média de custo financeiro em uma determinada classe (k) de afundamento e interrupção de tensão. Este índice pode ser muito útil para o consumidor e fornecedor da energia elétrica, uma vez que é capaz de refletir em um aspecto financeiro os efeitos negativos advindos de uma má qualidade no fornecimento da energia elétrica.

Em Bollen et al. (2008) os autores enfatizam a importância de se aprofundar os estudos sobre a elaboração de uma curva, que pode ser traduzida como uma curva de compartilhamento de responsabilidade (*responsability-sharing curve*), ressaltando as responsabilidades cabíveis tanto às concessionárias de energia como aos próprios usuários no que diz respeito, principalmente, aos afundamentos de tensão. Esta curva, embora semelhante às curvas já bem conhecidas como a CBEMA e a ITIC, traz a tona, segundo os autores, o que já existe em algumas normas internacionais, como é o caso da África do Sul, em que a norma NRS 048-2, (NRS 048-2:2003, 2003 *apud* Bollen et al, 2008) estabelece que o consumidor é responsável por afundamentos com tensões remanescentes acima de 0,7 p.u. com duração de até 150ms, acima de 0,8 p.u. com duração de até 600ms e aqueles que sejam de maior duração com tensões remanescentes de 0,85 p.u. da tensão nominal. É proposto no artigo que se utilize a norma internacional IEC Std. 61000-4-11 (IEC Std. 61000-4-11, 2001 *apud* Bollen et al, 2008), como parâmetro para a escolha da curva de responsabilidade para afundamentos de tensão. Os próprios autores salientam sobre as peculiaridades e características locais das regiões de distribuição de energia elétrica, o que acaba por influenciar a elaboração de regulamentações locais. Neste sentido, a tentativa de uma generalização normativa pode ser prematura, entretanto, o artigo deixa claro que uma maior discussão e aperfeiçoamento das normas concernentes à qualidade da tensão fornecida são válidos.

Mais uma vez, tomando-se por base registros estatísticos de eventos relacionados com a QEE, é cabível citar Wang et al. (2005), pelos quais se apresenta uma solução, baseada em uma análise estatística, para a estimativa do comportamento de afundamentos de tensão em um sistema de distribuição de energia elétrica, predizendo sua magnitude e duração. Os autores propõem a implementação de algoritmos computacionais para se obter esta solução, eliminando dessa maneira a necessidade de se realizar medições extensivas e caras ações de monitoramento. Através de uma tabela da densidade de probabilidade da ocorrência de afundamentos de tensão, obtida por uma função que

pondera diversos aspectos do sistema elétrico de potência, conforme apresentado pelos autores, é possível mapear a probabilidade da incidência de um afundamento de tensão em uma carga sensível conectada em um determinado ponto do sistema em análise. Este ponto é o local onde se pretende predizer se um afundamento de tensão será capaz de danificar ou não a carga conectada ao mesmo, observando-se aqui uma relação com o conceito de área de vulnerabilidade (Dugan et. al. 2002). Para se verificar a gravidade do afundamento de tensão, é necessário confrontar os dados da tabela com a curva de tolerância da carga (Kyei et al. 2002). O método proposto pode ser utilizado para se planejar tanto a minimização como a mitigação dos efeitos indesejáveis provocados pelo afundamento de tensão sobre um determinado equipamento.

O conceito de área de vulnerabilidade também é trabalhado por Myo Thu et al. (2004), que analisa a influência de diferentes funções de distribuição de probabilidade de defeitos (curtos-circuitos) em uma linha de transmissão de energia elétrica, e na predição de afundamentos de tensão em dois barramentos (escolhidos ao acaso) de um sistema de distribuição genérico, através de uma aproximação estocástica baseada em simulação computacional.

Conforme ressaltado pelos autores, a obtenção de uma base de dados de registros dos distúrbios de QEE que contenha informações relevantes para proporcionar uma correta análise estatística do desempenho de um sistema elétrico de potência, frente a estes distúrbios, consiste em uma tarefa de difícil execução. Para, tanto seria necessário executar o monitoramento da operação do sistema ao longo de anos. Visando eliminar dos estudos relacionados a estes distúrbios a forte dependência destes registros estatísticos, dois principais métodos são propostos na literatura: o método da posição da falta (*fault-position – FP*) e o método da distância crítica (*critical distance – CD*), conforme se encontra em Carpinelli et al. (2009). O método da distância crítica leva em consideração o princípio do divisor de tensão aplicado ao ponto de acoplamento comum, local este onde está instalada a carga que se deseja monitorar a tensão no instante da ocorrência de uma falta. Isto é realizado conhecendo-se o valor da tensão de fornecimento (fonte), a impedância da fonte vista do ponto de acoplamento comum e a impedância entre o local de ocorrência da falta e o ponto de acoplamento comum. Já o método da posição da falta, é capaz de fornecer uma matriz que contém as tensões de todos os barramentos do sistema durante a ocorrência de uma falta, chamada matriz de afundamento. Sua obtenção se dá a partir da matriz de impedâncias (Z_{bus}) do sistema elétrico de distribuição em questão. Este método é implementado computacionalmente seguindo três principais passos: (i) simulação de curto-circuito para a ocorrência de uma falta em determinado local do sistema; (ii) cálculo de todas as tensões remanescentes nos barramentos do sistema devido à falta aplicada; (iii) construção da matriz de afundamentos. Os passos de (i) a (ii) devem ser repetidos para diversas posições de faltas, considerando-se, por exemplo, todas as barras do sistema e alguns pontos no decorrer de todas as linhas do mesmo. Por fim, no passo (iii), o resultado das tensões remanescentes efetuados em (ii) são armazenados na matriz de afundamentos.

Por fornecer mais informações acerca das tensões do sistema elétrico através da matriz de

afundamentos, o método de posição da falta se revela como sendo o que proporciona uma visão mais ampla da situação de operação do sistema elétrico durante a ocorrência da falta como será discutido na seqüência.

Goswami et al. (2008), em sua pesquisa, apresentam um método analítico para se prever afundamentos de tensão e se obter áreas de vulnerabilidade de interesse em um sistema de distribuição de energia elétrica. O estudo tem seu equacionamento formulado, considerando-se curtos-circuitos trifásicos simétricos, para obtenção de uma matriz chamada matriz de afundamento de tensão (V_{SM}), calculada a partir da matriz de impedâncias (Z_{BUS}) do sistema pelo método de posição da falta. Ao se interpretar a matriz (V_{SM}) em linhas e se representar graficamente estas informações no diagrama unifilar do sistema elétrico, determina-se a área de vulnerabilidade de interesse, ou seja, uma dada linha (m) da matriz de afundamentos de tensão identifica um barramento no sistema elétrico, e, além disso, representa o potencial de afundamento de tensão que uma carga conectada a este barramento (m) está sujeita em consequência de defeitos incidentes no sistema. Os resultados mostram que é possível obter a área de vulnerabilidade para um barramento do sistema utilizando-se apenas da matriz (V_{SM}) obtida originalmente a partir da matriz (Z_{BUS}) do sistema, sem a necessidade de se empregar técnicas estatísticas que requerem extensa coleta de dados relativos à incidência de falhas no sistema. Vale comentar que uma análise mais cuidadosa no caso de curtos trifásicos assimétricos se faz necessário. Entretanto, o método apresentado pode ser muito útil quando uma análise preliminar é considerada.

Em Carpinelli et al. (2009), os autores obtém uma matriz de afundamentos de tensão (*during fault voltage matrix* - DFV) que mostra todas as tensões de pós falta do sistema, de maneira semelhante ao que se encontra em Goswami et al. (2008). Esta matriz foi obtida através do método de posição da falta, acrescentando-se desta vez uma combinação das magnitudes dos afundamentos contidos na DFV com os dados estatísticos referentes à taxa de falha do sistema considerado, para se tentar obter um resultado mais condizente possível com o real. O artigo de Carpinelli et al. (2009) sugere uma interpretação gráfica desta matriz, implementando uma escala graduada em cores que quantifica a intensidade do afundamento de tensão, proporcionando uma rápida inspeção visual da situação das tensões remanescentes nos barramentos do sistema após a ocorrência da falta elétrica. Um ponto muito importante explicitado pelos autores acerca da robustez do sistema elétrico em estudo, advém do cálculo da capacidade de curto-círcuito dos barramentos do sistema (Kagan et al. 2005), e da relação estabelecida com a matriz de afundamentos de tensão (DFV), obtida via método de posição da falta. Com o estudo efetuado pelos autores, nota-se que quanto maior a capacidade de curto-círcuito de uma barra, maiores serão os afundamentos de tensão causados ao restante do sistema em decorrência da incidência de uma falta sobre a mesma. Em contrapartida, quanto menor a capacidade de curto-círcuito da barra em questão, mais susceptível ela estará a afundamentos em virtude da ocorrência de faltas em outros pontos do sistema que possuam maior capacidade de curto-círcuito. Além disso, esta barra de menor capacidade de curto circuito, quando acometida por uma falta, levará

a afundamentos no restante do sistema que será sentido por uma menor quantidade de barras. Nota-se, portanto, que o emprego do método de posição da falta é capaz de fornecer uma visão mais ampla acerca da situação das tensões dos barramentos do sistema quando uma falta acomete determinado ponto do mesmo, e uma simples análise via método da distância crítica, pode levar a interpretações equivocadas, uma vez que este método não agrupa informações a respeito do comportamento das demais barras do sistema.

Atualmente, constata-se que o emprego de ferramentas inteligentes, em particular RNAs, atuando em conjunção com técnicas de extração de características, como o uso da Transformada *Wavelet* (TW), acaba por enriquecer os estudos relativos à QEE, apresentando novas soluções ao monitoramento. Em Devaraj et al. (2006), por exemplo, busca-se um processo automático para o monitoramento da QEE com o uso de RNAs e da TW. Neste processo é realizada a classificação dos seguintes eventos: afundamentos de tensão, elevações de tensão, transitórios e distorções harmônicas. Com a determinação da energia contida nos coeficientes *wavelet* da onda em estudo, e tomando-se como referência uma onda senoidal pura, determina-se o desvio entre as distribuições de energia do sinal analisado e do sinal de referência em cada nível de decomposição. Alguns parâmetros estatísticos também são calculados, tais como: média, desvio padrão, valor RMS, fator de crista, dentre outros. Estes parâmetros, referenciados a cada tipo de distúrbio, são utilizados para se treinar uma RNA. Através de um SEP de quatro barramentos, simulado computacionalmente no *software Matlab*®, os autores ilustram a eficiência da RNA, simulando eventos como: faltas, chaveamentos e harmônicos devido às cargas não lineares. As amostras referentes ao treinamento da RNA são obtidas em diferentes localizações do sistema elétrico, gerando diferentes medidas, numa tentativa de se obter uma maior abrangência relativa aos diferentes pontos de monitoramento. A eficiência da RNA é apresentada através de um diagrama do qual se depreende que o índice de acerto da RNA é de 100%.

A classificação de distúrbios elétricos relacionados à QEE, incluindo sua ausência, também é pesquisado por Lira et al. (2004), em que os autores utilizam as seguintes técnicas: RNAs, TW e Análise de Componentes Principais (ACP). Inicialmente os dados de tensão coletados do sistema de monitoração da CHESF (Companhia Hidrelétrica do São Francisco), foram pré-processados em duas etapas. A primeira utilizando-se da Transformada *Wavelet* Discreta (TWD) e a segunda, empregando-se a ACP. Em ambas as etapas o objetivo é o de se alimentar a RNA que classificará os distúrbios com uma entrada pré-avaliada, visando-se aumentar seu índice de acerto. A resposta da RNA foi codificada de modo a existirem seis saídas correspondentes aos seis tipos de eventos a serem classificados. Nos ensaios foram empregadas redes *MLP (Multi-Layer Perceptron)* de uma camada intermediária. Na apresentação dos resultados foram geradas três bases de conhecimento em função dos coeficientes *wavelets*, decorrentes da primeira etapa do pré-processamento do sinal. Para cada base foram treinadas três redes distintas, gerando-se três casos diferentes a serem analisados. A resposta combinada das três redes revela sua importância quando o objetivo é a classificação de fenômenos que concentram simultaneamente componentes de altas (transitórios) e de baixas freqüências (afundamentos). Nesta

situação foram combinadas as respostas das redes dos casos 2 e 3, proporcionando um índice de acerto de 99,3%.

Além dos estudos referentes à classificação dos distúrbios da QEE, as RNAs e a TW são aplicadas quando o objetivo é a detecção de defeitos elétricos. Em Silva et al. (2006), o método desenvolvido tem por objetivo a detecção e classificação de faltas em um sistema de distribuição, também da CHESF, onde se utiliza de RNAs e da TW para distingui-las de outros fenômenos relacionados à QEE e inerentes à operação do sistema elétrico, tais como: afundamentos de tensão e transitórios. O método possui dois módulos: módulo de detecção e módulo de classificação. No primeiro, através de um sistema interligado com registradores digitais de falta, é realizada a aquisição de amostras da forma de onda de corrente e tensão. Em seguida, ainda no primeiro módulo, é calculada a TW (no seu primeiro nível de decomposição) e, finalmente, efetuado o cálculo da energia de seus coeficientes. Este processo possibilita a detecção do momento em que o curto ocorreu, bem como a determinação de sua duração, antes da atuação do dispositivo de proteção do sistema elétrico. No segundo módulo, após a identificação das amostras de corrente e tensões correspondentes ao defeito, estas são reamostradas (preservando as características relevantes do sinal), e a partir de então, a RNA é alimentada por padrões de entrada gerados por janelas cujo tamanho corresponde ao tempo de duração da falta calculado no módulo de detecção. O artigo mostra o emprego de uma rede neural MLP cujo treinamento foi realizado através de diferentes situações de falta empregando-se dados reais e simulados computacionalmente pelo *software* ATP. Os resultados mostram um alto índice de acerto da RNA (98,83%) ao classificar as situações de defeito incidentes na linha.

Outro estudo que demonstra a aplicação de RNAs e da TW para se classificar faltas em um sistema elétrico de potência pode ser encontrado em Upendar et al. (2008). O método toma por base as informações colhidas pelos relés digitais e pelos registradores digitais. O tratamento destes dados se dá inicialmente através da decomposição do sinal (50 Hz) pela TW até o seu nono nível de decomposição, utilizando-se dois ciclos completos com 512 amostras. Desses nove níveis de decomposição, dá-se especial atenção para o sétimo nível em que se encontram os segundo e terceiro harmônicos. Vários índices relacionados ao sétimo nível de decomposição da corrente nas três fases foram calculados e usados posteriormente para se alimentar a entrada de uma RNA. Para se encontrar a arquitetura da RNA, treiná-la e verificar seu índice de acerto, foram gerados diversos cenários de operação, variando-se o tipo de falta, o ângulo de inserção (de 0° a 360°), o valor das impedâncias de faltas e diferentes localizações das mesmas. Com as diversas combinações entre os parâmetros apontados e um sistema elétrico de potência concebido para se realizar as simulações, desenvolveu-se uma arquitetura para a RNA cujo índice geral de acerto foi de (99,88%).

Estes foram alguns dentre os vários e importantes trabalhos reportados que dizem respeito, ou que apresentam alguma relação com o tema principal deste trabalho de conclusão de curso.

Para o próximo item, reservam-se alguns apontamentos conceituais sobre RNAs. Técnica inteligente sobre a qual todo o trabalho foi concebido.

Capítulo 3 – Redes neurais artificiais

Os estudos acerca das redes neurais artificiais (RNA) tiveram sua origem na neurobiologia com a investigação do funcionamento do cérebro humano. A capacidade do cérebro de processar informações altamente complexas de maneira paralela, o coloca em posição vantajosa em relação à forma de processamento seqüencial de informações de um computador digital, conferindo-lhe assim uma maior velocidade em certos processamentos (Haykin, 2001). Visando modelar esta forma peculiar do cérebro humano em resolver problemas específicos de alta complexidade, surgem as redes neurais artificiais, implementadas via componentes eletrônicos ou programação computacional.

Uma RNA tem a capacidade, assim como o cérebro humano, de armazenar conhecimento adquirido através de um processo de aprendizagem, modificando as interconexões existentes entre suas unidades de processamento (neurônios) na medida em que interage com o meio através de um algoritmo de aprendizagem. Estes algoritmos são capazes de modificar os pesos sinápticos que interligam as unidades de processamento até que se alcance um objetivo de projeto. O conhecimento armazenado por meio das ligações sinápticas confere às RNAs a capacidade de generalização, uma de suas mais intrigantes habilidades. Isto é, a rede é capaz de produzir saídas adequadas para entradas que não estavam presentes durante o processo de aprendizagem.

Outra importante propriedade de um RNA é a tolerância a falhas, pois seu desempenho se degrada suavemente em função de condições de operações adversas, o que a torna um sistema com certa robustez. Em suma, a rede neural fornece o modelo implícito do ambiente na qual está inserida e realiza a função de processamento da informação de interesse (Haykin, 2001).

3.1 – Modelo não linear de um neurônio artificial

O neurônio artificial constitui a unidade fundamental de processamento da informação em uma RNA. Segundo Haykin, (2001) o modelo não linear de um neurônio artificial, é constituído por três elementos básicos: pesos sinápticos, somador e uma função de ativação. Na Figura 4 é possível observar uma representação esquemática simplificada de um neurônio biológico, e, na Figura 5, a representação do modelo do neurônio não linear. Nesta última, os sinais de entrada de x_1 até x_m constituem o vetor de sinal de entrada, ou padrão de ativação, para o neurônio que antes de serem submetidos ao combinador linear, estarão sujeitos a uma ponderação através dos respectivos pesos sinápticos. Ainda na Figura 5, tem-se o destaque para o *bias* que é representado por uma entrada fixa ($x_0 = +1$) de modo que o peso sináptico associado defina sua magnitude (b_k), isto é, $w_{k0} = b_k$. A função do *bias* é a de introduzir um limiar de ativação para o neurônio, ou seja, dependendo do valor b_k a saída do combinador linear poderá aumentar ou diminuir a entrada líquida da função de ativação, o que acabará por influenciar a saída do neurônio.

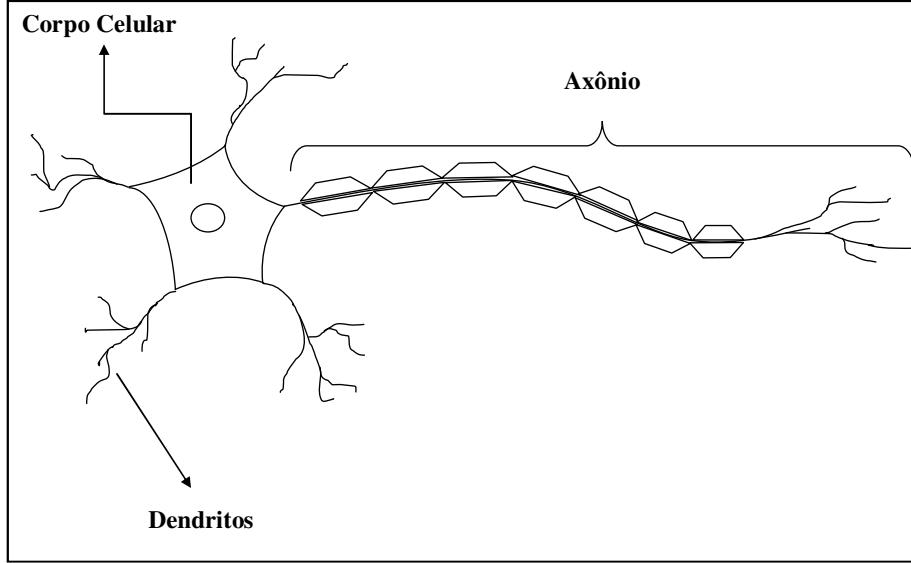


Figura 4 - Representação esquemática simplificada de um neurônio biológico.

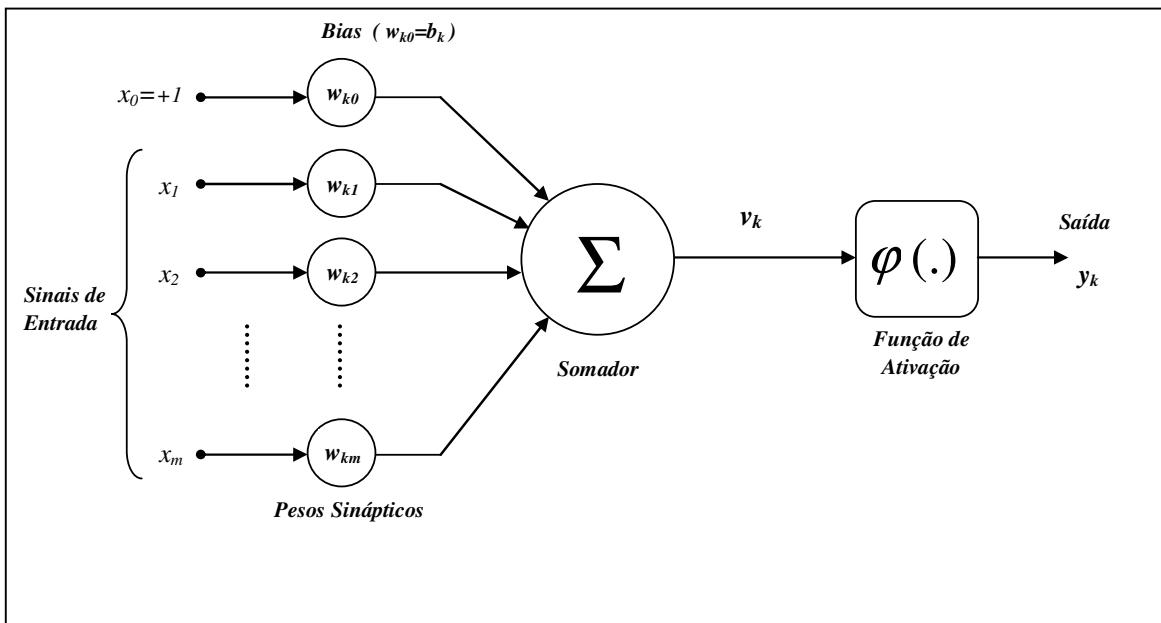


Figura 5 - Modelo não linear de um neurônio artificial.

O fluxo da informação se dá pelo seguinte percurso: um sinal (x_j) na entrada da sinapse (j) conectada ao neurônio (k) é multiplicado pelo peso sináptico (w_{kj}), sendo ($w_{kj} > 0$) ou ($w_{kj} < 0$). Em seguida, o sinal ponderado encontra um combinador linear (somador) produzindo o sinal (v_k) que recebe o nome de campo local induzido ou potencial de ativação. O campo local induzido é dado por:

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

Finalmente, uma função de saturação chamada de função de ativação $\varphi(\cdot)$, limita o valor da saída do neurônio (k) em um valor finito em termos do campo local induzido, isto é:

$$y_k = \varphi(v_k) \quad (2)$$

O processo de aprendizagem em uma rede neural implica na modificação dos parâmetros livres da rede, ou seja, os pesos sinápticos e níveis de bias, de tal forma que ela seja capaz de gerar uma saída desejada para um determinado padrão de ativação (vetor de entrada).

3.2 – Representações gráficas de uma RNA

Uma possível representação gráfica de uma RNA se dá através de grafos orientados de fluxo de sinal, constituindo uma rede de elos (ramos) orientados que são interligados em certos pontos (nós) (Haykin, 2001). Esta representação é uma alternativa ao modelo de blocos funcionais apresentado na Figura 5, e fornece uma perspectiva mais clara e objetiva do funcionamento de uma RNA. Com este tipo de representação é possível examinar o fluxo de um determinado sinal, tanto de um neurônio para outro, como em cada neurônio individualmente. A Figura 6 mostra o modelo de um neurônio sob o ponto de vista de grafos de fluxo de sinal. O tratamento do elo de ativação, que representa uma transmitância não linear, é feito mais adiante no item 3.3.

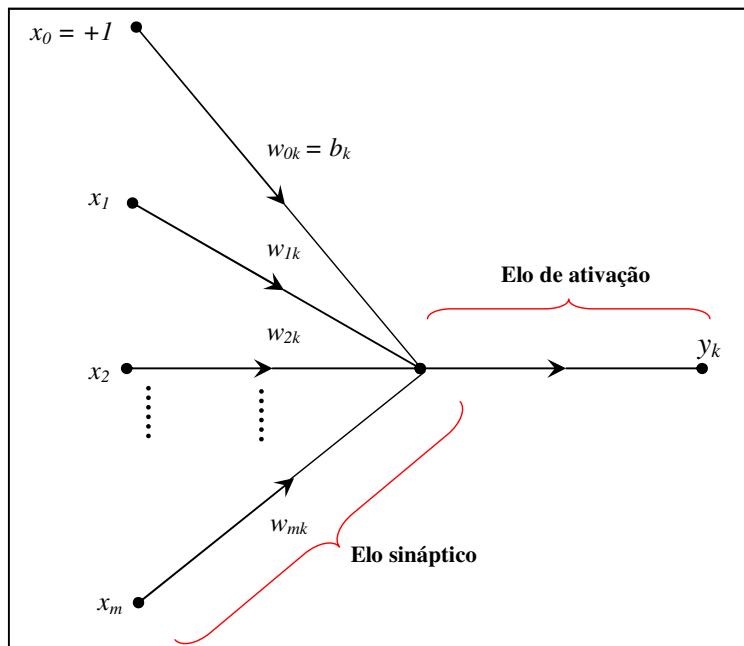


Figura 6 - Grafo de fluxo de sinal de um neurônio

Uma variante da representação gráfica mencionada acima é a representação por grafo arquitetural, como mostrado na Figura 7. Quando a apresentação de uma determinada arquitetura de uma RNA se faz necessária, este tipo de representação pode se tornar conveniente uma vez que o foco

é a maneira como os neurônios estão interconectados, ou seja, como se dá a topologia da RNA. Neste caso, o fluxo do sinal interno ao próprio neurônio se torna implícito e a representação do modelo neuronal é novamente simplificada sem perda de generalidade. Um grafo arquitetural apresenta três elementos: (1) nós de fonte, que fornecem os sinais de entrada; (2) nó computacional, que é a representação do neurônio; (3) elos de comunicação, que realizam a conexão dos nós de fonte com os nós computacionais.

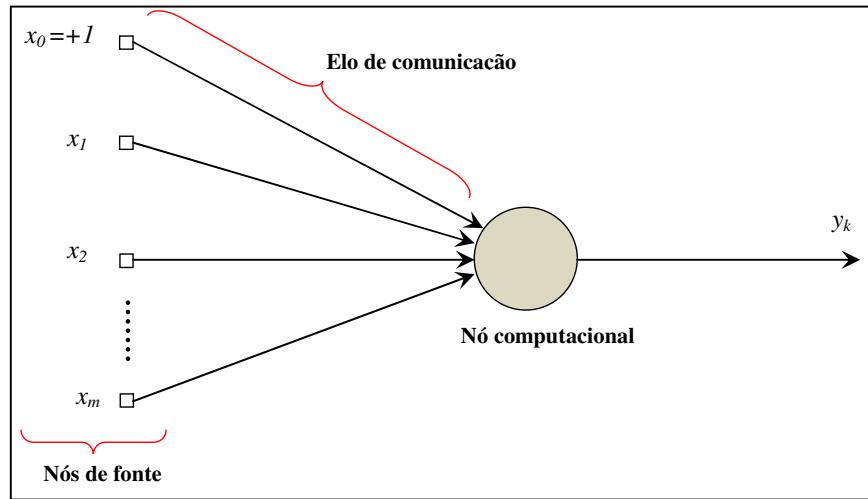


Figura 7 - Grafo arquitetural de um neurônio.

3.3 – Funções de ativação

Conforme mencionado anteriormente, uma função de ativação determinará a saída (y_k) de um neurônio em termos do campo local induzido (y_k), de acordo com a Equação (2). Na representação por grafos orientados de fluxo de sinal, a função de ativação é a transmitância não linear presente no elo de ativação da Figura 6. Cinco dos principais tipos de funções de ativação são apresentadas a seguir.

3.3.1 – Função de limiar ou função de Heaviside

A função de ativação do tipo limiar fornece à saída (y_k) do neurônio a característica da *propriedade do tudo ou nada*. Um neurônio não linear contendo a função de ativação do tipo limiar é referido na literatura como sendo o modelo de McCulloch-Pitts (Haykin, 2001). Neste modelo, a saída (y_k) assume valor ($y_k = 1$) se o campo local induzido for maior ou igual a zero, e assume valor ($y_k = 0$) se o campo local induzido for menor do que zero. Sendo assim, tem-se a definição da função de ativação descrita dado um potencial de ativação (v), conforme a Equação (3). O seu comportamento pode ser observado na Figura 8.

$$\varphi(v) = \begin{cases} 1, & \text{se } v \geq 0 \\ 0, & \text{se } v < 0 \end{cases} \quad (3)$$

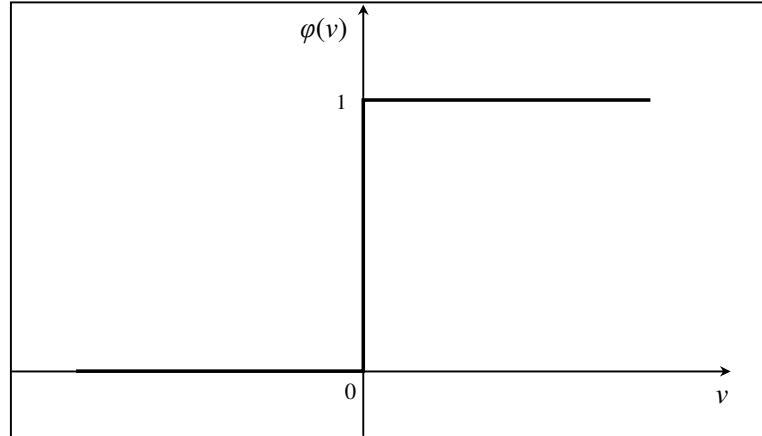


Figura 8 - Comportamento da função de ativação do tipo limiar ou Heaviside.

Por fim, como uma consequência da Equação (3), a saída do neurônio (k) cujo campo local induzido vale ($v = v_k$) estará dentro dos seguintes limites:

$$y_k = \begin{cases} 1, & \text{se } v_k \geq 0 \\ 0, & \text{se } v_k < 0 \end{cases} \quad (4)$$

3.3.2 – Função linear por partes.

Esta função de ativação se assemelha a uma função do tipo rampa, obedecendo a uma dada inclinação (α) no intervalo em que $|v_k| \leq V$, onde $V \in \mathbb{R}$. Fora deste intervalo a função assume valor unitário para ($v_k > V$) e valor nulo para ($v_k < -V$). Dessa forma a função de ativação linear por partes é definida formalmente como sendo:

$$\varphi(v) = \begin{cases} 1, & \text{se } v \geq V \\ \alpha v, & \text{se } -V < v < V \\ 0, & \text{se } v < -V \end{cases} \quad (5)$$

Pode-se notar que quando o fator de ganho (α) é suficientemente grande, a função de ativação linear por partes se aproxima da função de limiar. A Figura 9 ilustra o comportamento da função de ativação do tipo linear por partes, definida na Equação (5).

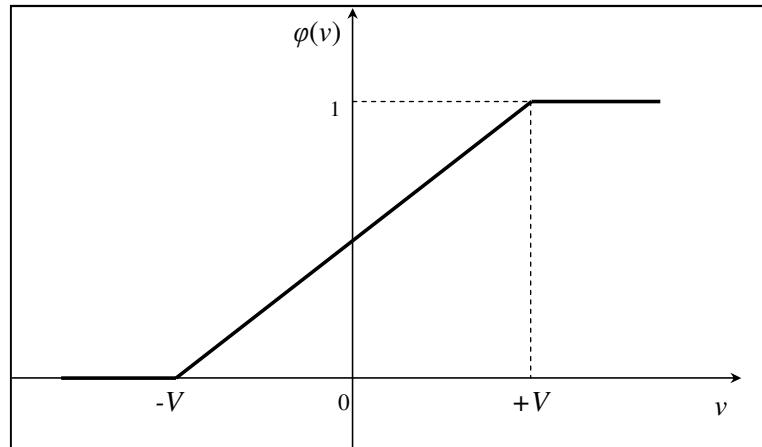


Figura 9 - Comportamento da função de ativação do tipo linear por partes.

3.3.3 – Função sigmóide

A função de ativação do tipo sigmóide, segundo Haykin, (2001) é a função comumente encontrada em configurações de redes neurais artificiais. Ela representa um equilíbrio entre o comportamento de uma função linear e o de uma função não linear. Além disso, o fato de ser diferenciável em todo o seu domínio contribui para questões técnicas, como por exemplo, no desenvolvimento da teoria de redes perceptron de múltiplas camadas. A seguir, tem-se a definição de uma função de ativação sigmóide:

$$\varphi(v) = \frac{1}{1 + e^{-av}} \quad , \quad (6)$$

na qual (a) é o parâmetro de inclinação da função. O comportamento da função de ativação definida pela Equação (6) é apresentado na Figura 10.

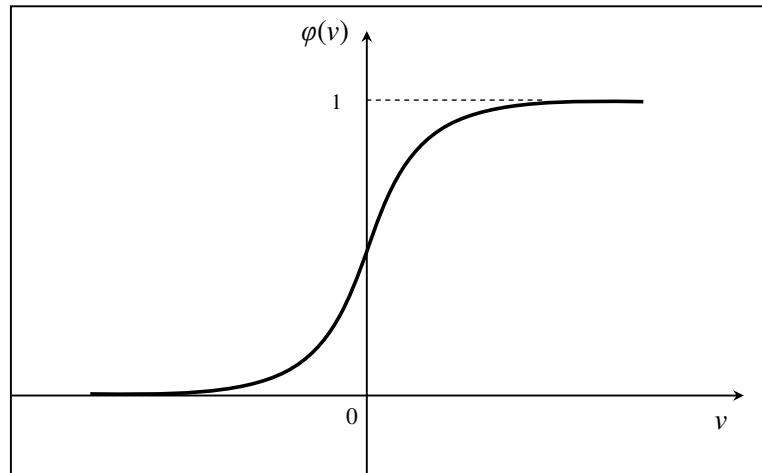


Figura 10 - Comportamento da função de ativação do tipo sigmóide.

3.3.4 – Função sinal e tangente hiperbólica

Em geral, é desejável que a função de ativação $\varphi(\cdot)$ assuma valores entre -1 e 1, tornando-se uma função ímpar do campo local induzido, conforme se observa na Equação (7). A esta função se denomina função sinal, cuja característica auxiliará na capacidade da RNA em separar os padrões de entrada em classes de forma mais conveniente. O comportamento da função sinal dada pela Equação (7) está ilustrado na Figura 11.

$$\varphi(v) = \begin{cases} 1, & \text{se } v \geq 0 \\ -1, & \text{se } v < 0 \end{cases} \quad (7)$$

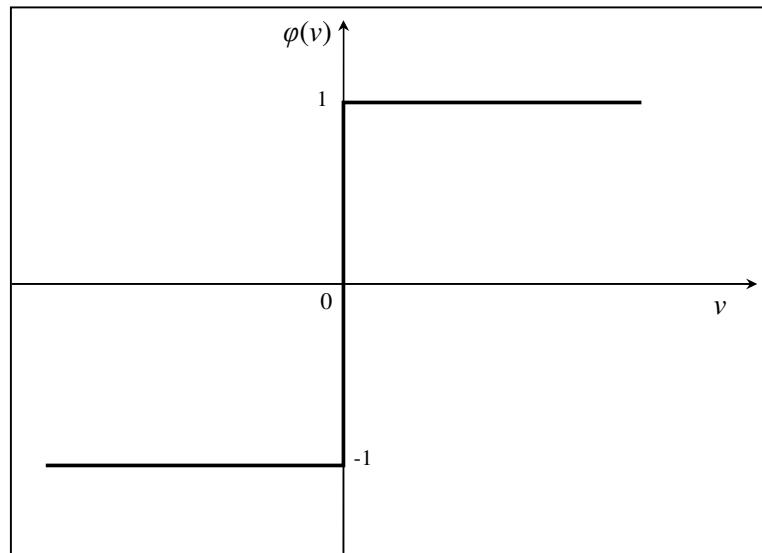


Figura 11 - Comportamento da função de ativação do tipo sinal.

Da mesma maneira como a função sinal se dá como uma função ímpar do campo local induzido, tem-se também, a função tangente hiperbólica, expressa pela Equação (8):

$$\varphi(v) = \tanh(v) \quad (8)$$

Esta função possui papel importante no processo de treinamento de uma rede perceptron de múltiplas camadas via algoritmo de retropropagação, uma vez que pode ser capaz de acelerar a convergência do mesmo, no que se diz respeito ao número de iterações. (Haykin, 2001). A função tangente hiperbólica tem seu comportamento ilustrado na Figura 12.

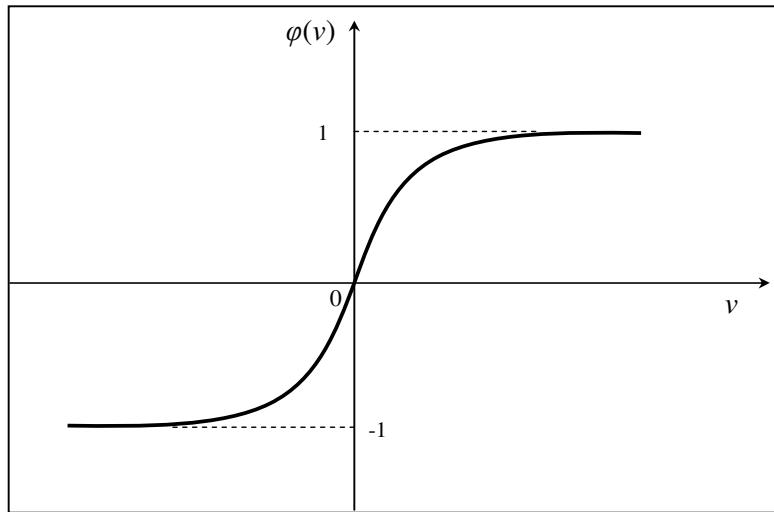


Figura 12 - Comportamento da função de ativação do tipo tangente hiperbólica.

3.4 – Arquiteturas de redes neurais artificiais

A arquitetura de uma RNA está relacionada com a maneira pela qual os neurônios estão distribuídos topologicamente, isto é, a maneira pela qual eles estão interconectados. As redes neurais artificiais podem ser divididas em duas principais categorias: as redes de camada única e redes de mais de uma camada, denominadas redes de múltiplas camadas. Além disso, a arquitetura de uma RNA também está intimamente ligada ao seu tipo de treinamento, uma vez que o algoritmo de treinamento dependerá do modo como estão distribuídas as conexões entre os neurônios da rede.

3.4.1 – Redes de camada única

A arquitetura de camada única alimentada adiante (*feedforward*) apresenta uma camada de entrada (nós de fonte) e uma camada de saída, ou seja, a camada que contém os nós computacionais é a própria camada de saída da RNA, conforme mostra a Figura 13. Como exemplos de redes de camada única existentes citam-se a rede *Perceptron* e a ADALINE (*adaptative linear element*) (Kovács, 1996). Ambas são capazes de tratar apenas problemas linearmente separáveis, executando tarefas como, por exemplo, reconhecimento de padrões linearmente separáveis.

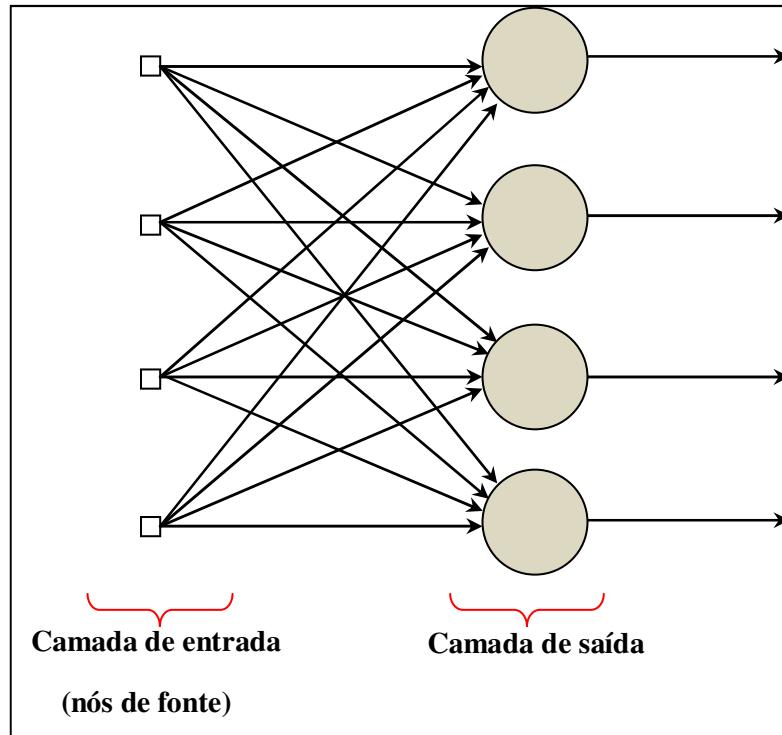


Figura 13 - Diagrama arquitetural de uma rede de camada única alimentada adiante

3.4.1.1 – Perceptron

Conforme pesquisado em Haykin, (2001), o *Perceptron* de Rosenblatt, ou simplesmente *Perceptron* é concebido utilizando-se o modelo de neurônio não linear de McCulloch-Pitts contendo uma função de ativação do tipo limiar ou sinal, isto é, limitando abruptamente a saída do neurônio. Assumindo-se que a função de ativação utilizada seja a função sinal dada pela equação (7), a saída do *Perceptron* será $y = +1$ se o campo local induzido do neurônio resultar em valor positivo ($v > 0$), e, analogamente, será $y = -1$ para $v < 0$, estabelecendo-se assim uma regra para se discriminar os estímulos de entrada em duas classes, tomando-se os dois diferentes tipos de saídas produzidas pelo perceptron. Conforme a Equação (2) tem-se a representação para a saída da rede neural como segue:

$$y = \varphi(v) = \varphi\left(\sum_{j=1}^m w_j x_j + b\right) \quad , \quad (9)$$

por esta equação, (m) é a dimensão do vetor de estímulos de entrada $\underline{x}(n) = (x_1, x_2, \dots, x_m)$ apresentados ao *perceptron* pertencentes ao n -ésimo padrão de entrada de treinamento.

Segundo Kovács, (1996) a Equação (9) representa um hiperplano (fronteira de decisão) que divide o espaço euclidiano m -dimensional (\mathbb{R}^m), definido pelos (m) estímulos de entrada, em duas

regiões (A e B) de tal maneira que $\bar{x} \in A$ se $y > 0$ e, no caso complementar, $\bar{x} \in B$ caso $y < 0$. Em um caso bidimensional ($m=2$), o hiperplano se resume a uma reta que separa o plano definido pelas variáveis x_1 e x_2 , conforme ilustra a Figura 14.

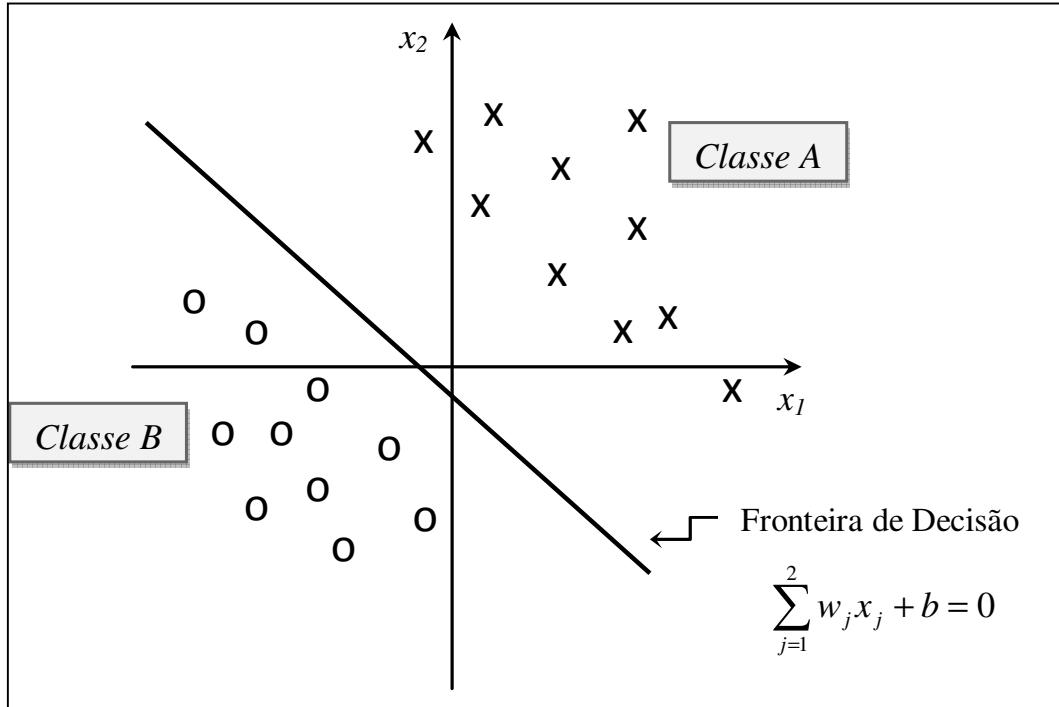


Figura 14 - Representação de uma fronteira de decisão para um problema bidimensional

O perceptron é treinado segundo o princípio de aprendizado de Hebb, em que a atualização dos seus pesos sinápticos é realizada por um incremento (Δw) dado por:

$$\Delta w_j = \eta(d(n) - y) \cdot x_j(n) \quad , \text{ para } j = 1, 2, \dots, m \quad (10)$$

Pela Equação (10) é possível constatar que a alteração dos pesos sinápticos é dependente do produto entre a entrada $x(n)$, do sinal de erro proveniente da diferença entre a saída desejada e a saída produzida pelo *Perceptron* ($d(n) - y$), e pelo parâmetro (η) que define a taxa de aprendizagem. Se os padrões de entrada forem linearmente separáveis, então a atualização dos pesos sinápticos cessará quando o sinal de erro for nulo para todo o conjunto de treinamento ($n=N$). Conforme demonstrado por Haykin, (2001), isto ocorrerá para um número finito de iterações, o que garante a convergência do treinamento do perceptron.

3.4.1.2 – Adaptive Linear Element (ADALINE).

Contemporaneamente a Rosenblatt, Widrow desenvolveu a rede ADALINE realizando

importante contribuição ao desenvolvimento dos estudos em RNA, introduzindo o princípio de aprendizado denominado *regra delta* (Kovács, 1996). Este processo de aprendizagem consiste em um algoritmo supervisionado para minimizar o erro quadrático médio entre a saída do combinador linear (campo local induzido) e a saída desejada, obtendo um ponto de mínimo através de um processo de iteração local. O erro quadrático médio neste caso é dado como uma função dos parâmetros da rede da seguinte forma:

$$E(\underline{w}) = \frac{1}{2} \sum_{n=1}^N (d(n) - v(n))^2 \quad (11)$$

Uma vez que o campo local induzido de um neurônio é dado pela Equação (1), obtém-se:

$$E(\underline{w}) = \frac{1}{2} \sum_{n=1}^N \left[d(n) - \left(\sum_{j=1}^m w_{kj} x_j + b_k \right) \right]^2 = \frac{1}{2} \sum_{n=1}^N \left[d(n) - (\underline{w}^T \cdot \underline{x}(n) + b_k) \right]^2 \quad (12)$$

O ponto de mínimo da Equação (12) é um ponto (\underline{w}^*) que pode ser obtido realizando-se ajustes sucessivos do vetor peso (\underline{w}) na direção oposta ao vetor gradiente de $E(\underline{w})$ em relação ao vetor de pesos (\underline{w}) , uma vez que este aponta para a direção e sentido em que o crescimento da função $E(\underline{w})$ é maior. Sendo assim tem-se:

$$\Delta \underline{w} = -\eta \vec{\nabla} E(\underline{w}) = -\eta \frac{\partial E(\underline{w})}{\partial \underline{w}} = \eta \sum_{n=1}^N (d(n) - (\underline{w}^T \cdot \underline{x}(n) + b_k)) \cdot \underline{x}(n) \quad (13)$$

Reescrevendo-se a Equação (13) em uma forma mais simples, obtém-se:

$$\Delta \underline{w}(n) = \eta (d(n) - v(n)) \cdot \underline{x}(n) \quad , \text{para } n = 1, 2, \dots, N \quad (14)$$

A Equação (14) é a chamada regra delta, mostrada na forma em que os pesos são ajustados após cada padrão (n) de treinamento ter sido apresentado à rede neural artificial. O parâmetro (η) é a taxa de aprendizagem e representa o tamanho do passo em direção à descida do vetor gradiente. Pelo processo matemático envolvido, a regra delta também é conhecida como *método do gradiente*.

Cabe salientar que a principal diferença entre a rede perceptron e a ADALINE está no fato de que a última faz a minimização das distâncias dos padrões classificados em relação a uma única fronteira de decisão a ser determinada no espaço euclidiano m -dimensional. O *Perceptron* por sua vez, a cada execução do algoritmo de aprendizagem, estará sujeito a encontrar uma fronteira de decisão diferente, dependendo da inicialização dos pesos sinápticos. Na Figura 15(a), a linha contínua e

tracejada ilustra duas possíveis fronteiras de decisão que podem ser encontradas pelo *Perceptron*. Já na Figura 15(b), verifica-se que linha contínua é a única fronteira de decisão a ser determinada pelo ADALINE.

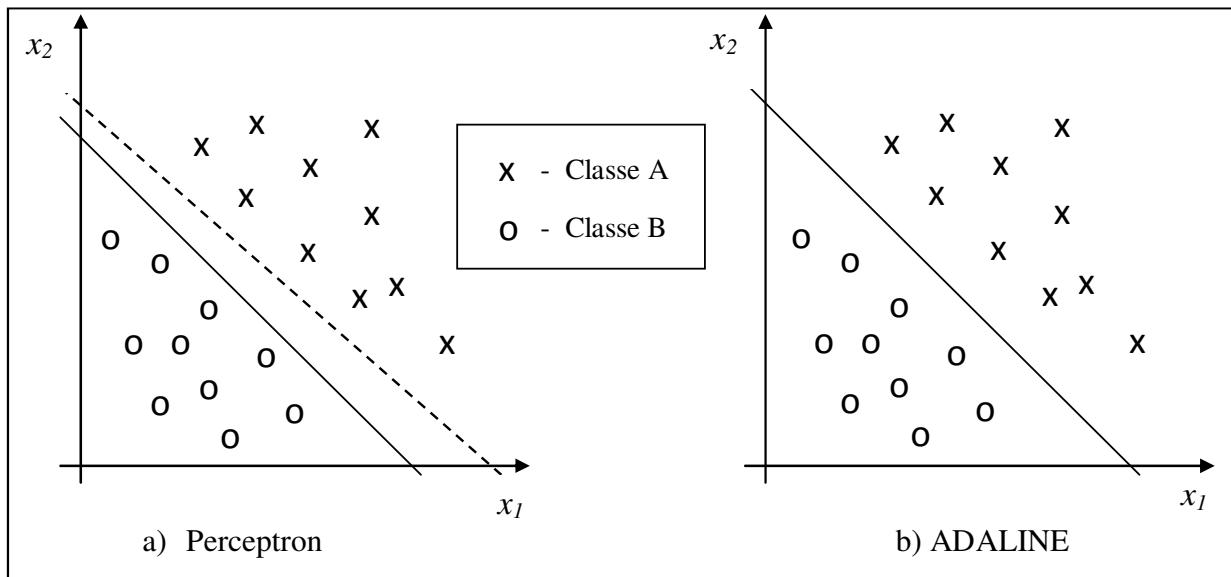


Figura 15 – Fronteira de decisão: (a) As linhas tracejada e contínua ilustram possíveis fronteiras de decisão; (b) A linha contínua representa a única fronteira de decisão possível

3.4.2 – Redes de múltiplas camadas

Neste tipo de arquitetura os neurônios estão organizados em camadas, com a presença de uma ou mais camadas intermediárias entre a camada de entrada e saída, chamadas de camadas ocultas. Este tipo de configuração aumenta a capacidade da RNA em modelar um problema de complexidade elevada, sendo uma alternativa às redes de camada única que são mais simples. A Figura 16 exibe o grafo arquitetural de uma rede de múltiplas camadas. Pode-se citar como um exemplo desse tipo de arquitetura as redes *Perceptron Multi-Camadas* (PMC) ou *Multilayer Perceptron* (MLP).

As redes MLP surgiram da necessidade de se classificar padrões que não são linearmente separáveis, como o caso do clássico problema *XOR* (Haykin, 2001). Neste caso, o *Perceptron* elementar (de camada única) deveria ser capaz de executar a tarefa de traçar duas retas como fronteiras de decisão com o objetivo de se resolver a função booleana do OU exclusivo, ou seja, separando os padrões de saída desta função, conforme ilustra a Figura 17.

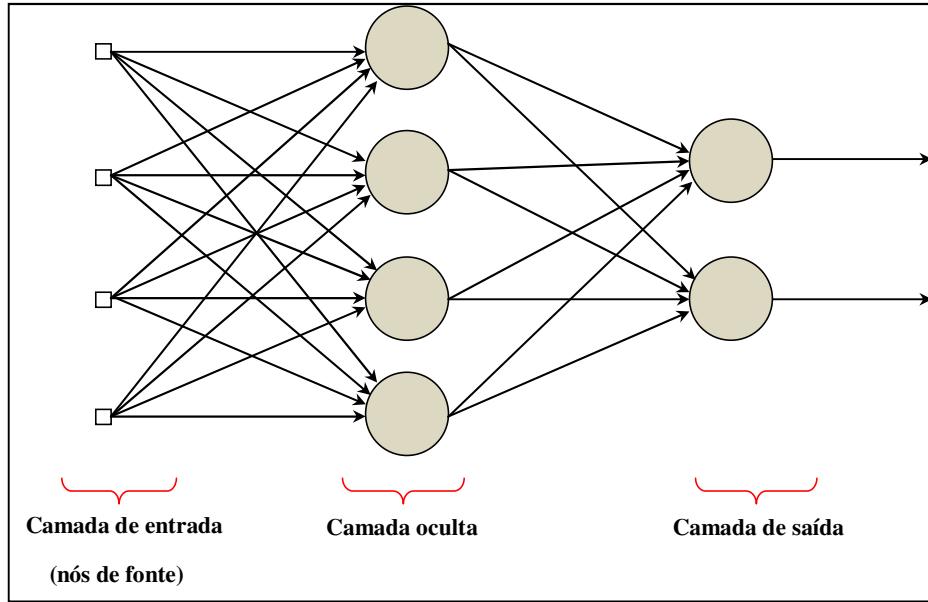


Figura 16 - Arquitetura de uma rede de múltipla camada alimentada adiante.

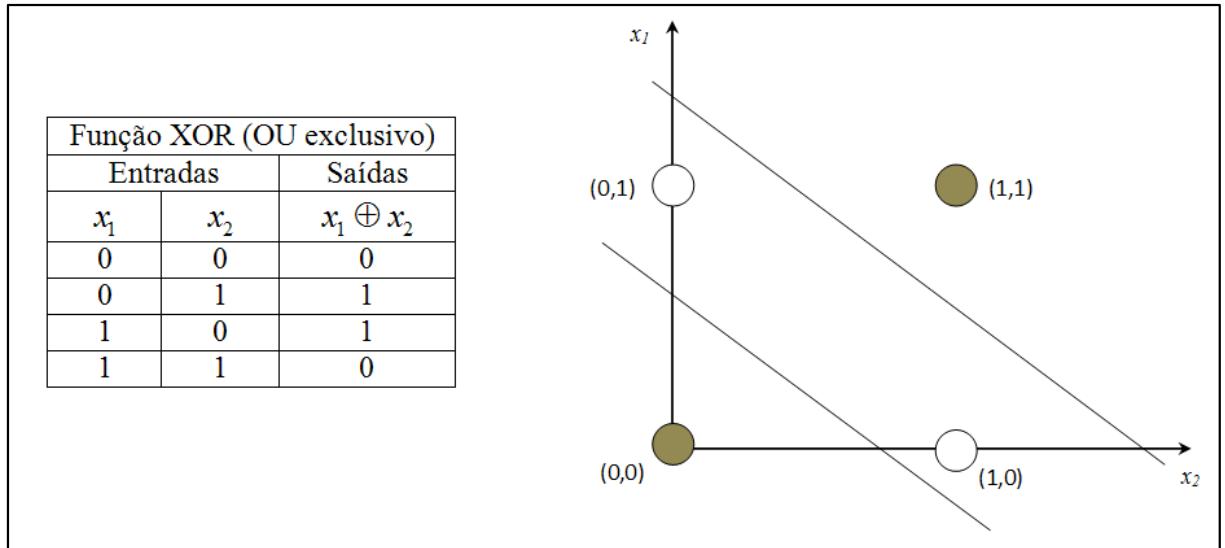


Figura 17 - Ilustração do problema XOR

O *perceptron* elementar, devido suas limitações, não é indicado para a resolução de problemas não linearmente separáveis, como o caso do problema XOR, sendo necessário o uso de redes de múltiplas camadas para a realização desta tarefa (Haykin, 2001).

3.4.3 – Treinamento de retropropagação de erro (*back-propagation*).

Em Haykin, (2001), o autor cita a ampla utilização do algoritmo de treinamento supervisionado de retropropagação de erro (*back-propagation*) para se treinar RNAs do tipo MLP.

Este algoritmo consiste de dois passos: (1) propagação (*forward*) e (2) retropropagação (*backward*). No primeiro passo um padrão de entrada é aplicado aos nós de fonte da RNA que permeia todas as camadas ocultas até encontrar a camada de saída. Nesta fase, não há a modificação de quaisquer pesos sinápticos. Já no segundo passo, a resposta produzida na fase de propagação é subtraída da resposta desejada gerando um sinal de erro, que será propagado em sentido reverso, contrário às direções naturais das conexões sinápticas. Neste momento, os pesos sinápticos são atualizados de modo que a rede retorne uma resposta mais próxima da desejada.

Sejam os índices (*i*) e (*j*) correspondentes a neurônios pertencentes a camadas subseqüentes, ou seja, o neurônio (*j*) está em uma camada à direita da camada a que pertence o neurônio (*i*). Desta maneira o sinal de erro, na apresentação do *n*-ésimo padrão de treinamento, quando o neurônio (*j*) é um nó de saída, é dado por:

$$e_j(n) = d_j(n) - y_j(n) \quad (15)$$

Ao se tomar todo o conjunto dos neurônios da camada de saída, que são exatamente aqueles sobre os quais é possível se calcular o erro quadrático médio, pois são os únicos visíveis da RNA, tem-se:

$$E(n) = \frac{1}{2} \sum_j (e_j(n))^2 \quad (16)$$

O objetivo do algoritmo de retropropagação é o de ajustar os pesos sinápticos de maneira a minimizar o erro quadrático médio (\bar{E}) relativo a todos os padrões de treinamento, normalizando-os em relação ao tamanho deste conjunto, obtendo-se:

$$\bar{E} = \frac{1}{N} \sum_{n=1}^N E(n) \quad (17)$$

O referido ajuste dos pesos sinápticos é divido em dois casos: (i) o caso para o qual o neurônio (*j*) é um nó de saída (pertencente à camada de saída); (ii) o caso em que é um nó oculto precedendo um neurônio (*k*) da camada de saída.

(i) Ajuste dos pesos sinápticos da camada de saída

Neste caso, similarmente à linha de raciocínio empregada para a derivação da regra delta através da descida do vetor gradiente, conforme demonstrado por Haykin (2001), o algoritmo de retropropagação aplica uma correção ao vetor de pesos do elo sináptico do neurônio (*j*) que é dado por:

$$\Delta \underline{w}_{ji}(n) = -\eta \frac{\partial E(n)}{\partial \underline{w}_{ji}} = \eta \delta_j(n) y_i \quad , \quad (18)$$

em que o parâmetro (η) é agora a taxa de aprendizagem do algoritmo de retropropagação e $\delta_j(n)$ é o gradiente local que aponta para o ajuste necessário ao vetor de pesos, definido como sendo:

$$\delta_j(n) = e_j(n) \varphi'(v_j(n)) \quad (19)$$

(ii) Ajustes dos pesos sinápticos das camadas ocultas

Em se tratando de camada oculta, a resposta alvo para a saída de cada neurônio a ela pertencente acaba se tornando indefinida, impossibilitando o uso da Equação (19) para se determinar o gradiente local. Sendo assim, pelo desenvolvimento realizado por Haykin (2001), tem-se uma redefinição do gradiente local para neurônios das camadas ocultas, obtendo-se uma fórmula de retropropagação para o mesmo como sendo:

$$\delta_j(n) = \varphi'_j(v_j(n)) \sum_k \delta_k(n) w_{kj}(n) \quad (20)$$

Ao se analisar a Equação (20), observa-se que a ponderação dos gradientes locais das camadas subseqüentes (δ_k) contribui para a constituição do gradiente local do neurônio (j) pertencente à camada oculta.

De maneira geral, o algoritmo de retropropagação de erro, seguirá a regra delta, ajustando os pesos sinápticos de cada neurônio (j) em função da taxa de aprendizagem (η), do gradiente local (δ_j), respeitando as restrições para cada caso apresentadas anteriormente, e, finalmente do sinal de entrada de cada neurônio (j) advindo do neurônio (i) da camada precedente.

3.4.4 – Treinamento Levenberg-Marquardt

Uma alternativa ao treinamento executado pelo algoritmo de retropropagação de erro é o treinamento *Levenberg-Marquardt*. Este tipo de treinamento tem suas bases no algoritmo *back-propagation*, porém, apresenta algumas vantagens. O algoritmo *back-propagation* é fundamentado no método da descida do gradiente, já o algoritmo de *Levenberg-Marquardt* tem como base a técnica dos mínimos quadrados. Conforme exposto por Fernandes (2009) o treinamento por retropropagação de erro guiado pela descida do gradiente, necessita de um número considerável de iterações para convergir. Além disso, apresenta certa ineficiência em localizar o ponto de mínimo global da superfície de erro para problemas mais complexos. Por sua vez, o treinamento *Levenberg-Marquardt*,

em virtude de se ser baseado em um método de segunda ordem, possui uma convergência significativamente mais acelerada quando comparada ao treinamento *back-propagation*, mesmo para problemas mais complexos.

Durante o treinamento de *Levenberg-Marquardt*, toda a etapa *forward* do algoritmo de retropropagação do erro permanece inalterada. Já na etapa de *backward*, os cálculos para ajustes de peso são realizados de forma diferente do *back-propagation*, pois a função de ajuste dos pesos representa uma aproximação ao método de Newton.

Segundo demonstração realizada por Fernandes (2009) o algoritmo de ajuste dos pesos de *Levenberg-Marquardt* pode ser derivado do método de Newton, com o objetivo de se minimizar o erro quadrático médio relativo a todas as (N) entradas de treinamento da rede neural, expresso pela equação (17), que pode ser reescrita em sua forma vetorial como segue:

$$\bar{E} = \frac{1}{2N} \sum_{n=1}^N \sum_j (e_j(n))^2 = \frac{1}{2N} \sum_{n=1}^N \mathbf{e}(n)^T \cdot \mathbf{e}(n) \quad (21)$$

A equação (21) pode ser vista como sendo um vetor de erros que é função dos pesos sinápticos (W) da rede, referentes aos (N) padrões de treinamento apresentados à RNA:

$$\bar{E} = \underline{e}(W) = (e_1(W) + e_2(W) + \dots + e_N(W)) \quad (22)$$

A equação iterativa obtida para o método de treinamento de *Levenberg-Marquardt* que ajustará os parâmetros da rede é:

$$\Delta W = (J^T(W) \cdot J(W) + \mu I)^{-1} \cdot J^T(W) \cdot \underline{e}(W) \quad , \quad (23)$$

sendo (J) a matriz jacobiana derivada do desenvolvimento realizado via método de Newton; (μ) é o parâmetro de ajuste da taxa de convergência do algoritmo e (I) é simplesmente a matriz identidade. A equação (23) constitui o análogo à etapa *backward* do algoritmo de retropropagação do erro.

Capítulo 4 – O sistema elétrico de distribuição em análise

Para o desenvolvimento da estratégia de monitoramento da tensão em pontos específicos do sistema de distribuição de energia elétrica de uma concessionária local, empregando redes neurais artificiais, utilizou-se de uma modelagem computacional, realizada no “software” ATP (*Alternative Transients Program*) (Rule Book, 1987). Esta modelagem resulta de estudos e de uma interação de uma equipe do Laboratório de Sistemas de Energia Elétrica (LSEE) da Escola de Engenharia de São Carlos (EESC-USP), com uma concessionária de energia regional. Na Figura 18, é possível visualizar a disposição geográfica dos dois alimentadores que constituem o sistema elétrico em estudo neste trabalho. Apesar de não ficar explícito na figura, cabe salientar os alimentadores partem da mesma subestação.

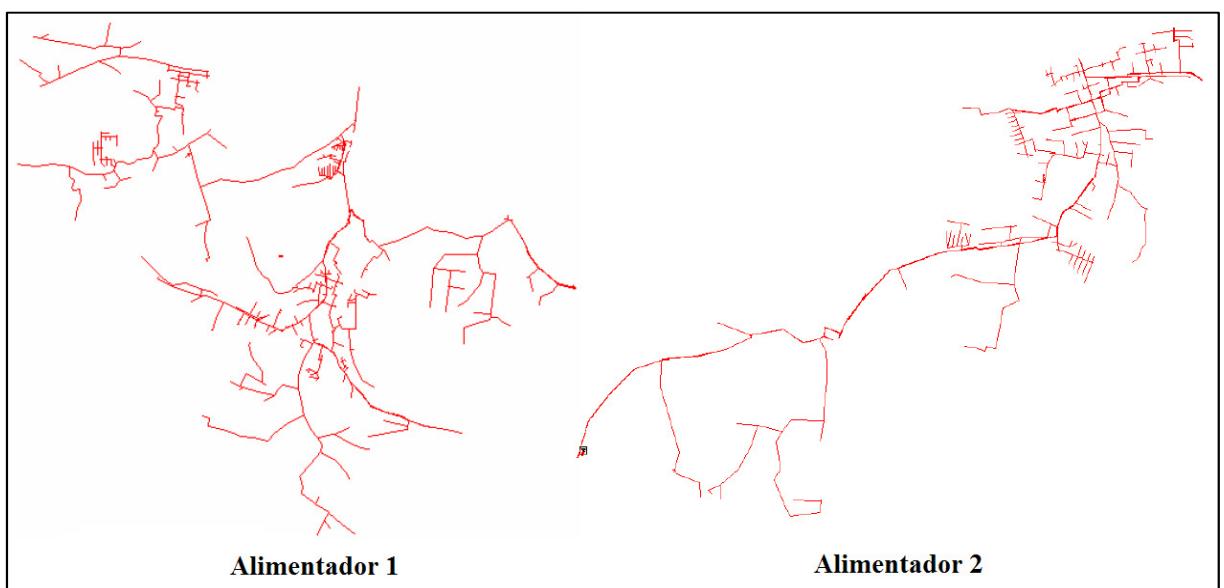


Figura 18 - Disposição geográfica dos alimentadores pertencentes a uma subestação de uma concessionária de energia regional sob estudo.

Neste capítulo serão apresentados alguns aspectos referentes à modelagem dos alimentadores do referido sistema elétrico de distribuição. Ressalta-se que uma abordagem aprofundada a respeito da modelagem do sistema elétrico não é pertinente aos objetivos iniciais propostos neste trabalho. Entretanto, por ser de suma importância para a formação da base de dados utilizada para a implementação computacional e validação do algoritmo proposto, aspectos gerais serão abordados.

4.1 – Modelagem computacional do sistema de distribuição

O sistema de distribuição utilizado neste trabalho foi previamente modelado utilizando-se de parâmetros de um sistema de distribuição real pertencente a uma concessionária local. Os dois

alimentadores ilustrados na Figura 18 foram modelados dispondo do “software” ATP, via interface gráfica do *ATPDraw* (Prikher et al. 2001), sendo esta modelagem ilustrada na figura 19.

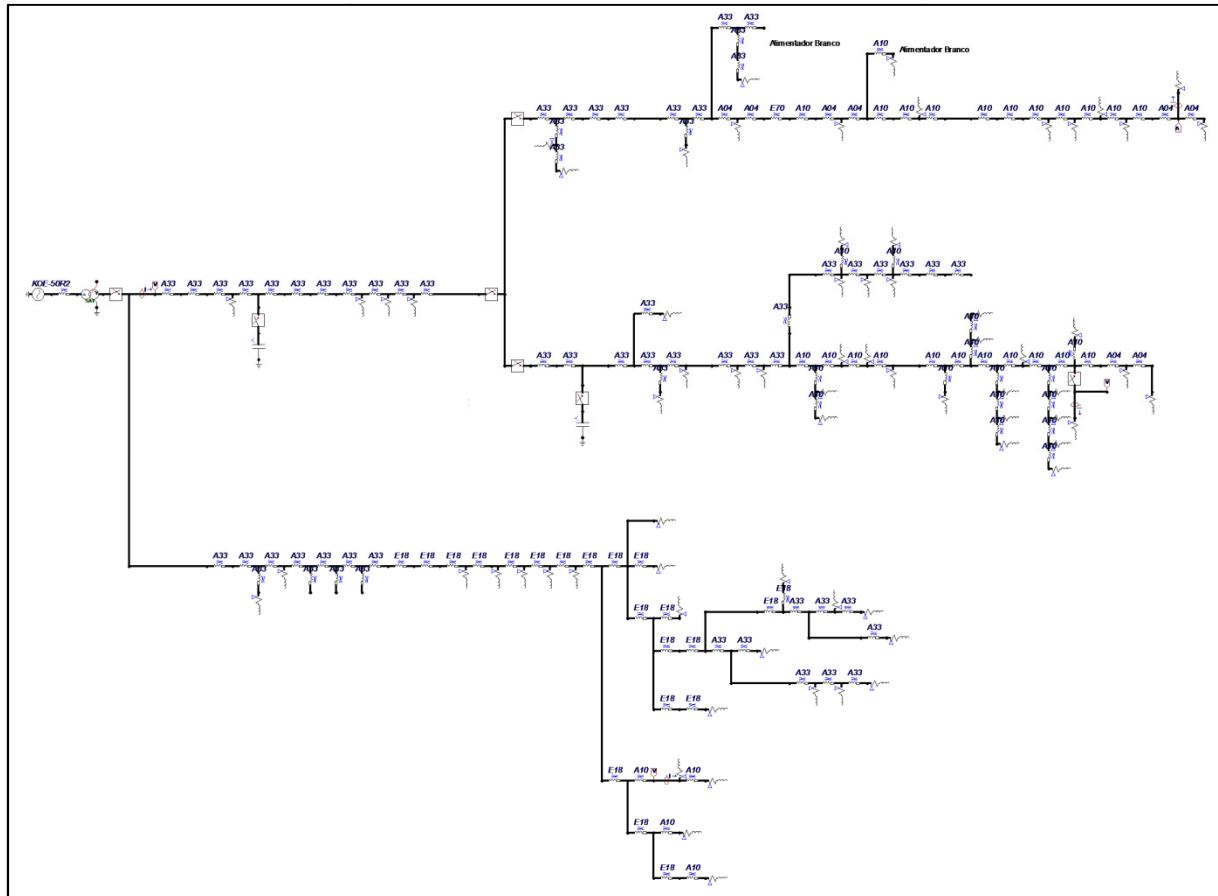


Figura 19 - Aspecto da modelagem computacional dos alimentadores da concessionária de energia regional realizada via interface gráfica do *ATPDraw*.

Para a realização desta modelagem, foi necessária a obtenção junto a concessionária dos seguintes dados: equivalente do sistema; dados do transformador de potência da subestação; parâmetros dos condutores utilizados; dados das cargas alocadas no alimentador, entre outros. A seguir, serão apresentadas as principais características do sistema de distribuição que proporcionaram sua respectiva modelagem computacional.

A fonte de tensão utilizada é uma fonte senoidal trifásica do tipo 14 (Rule Book, 1987), cujas características para a fase A estão apresentadas na Tabela 1. O sistema adotado é o ABC, a partir do qual, as relações das demais fases pode ser derivada.

Tabela 1 - Características da fonte de tensão do SEP utilizada

Parâmetro	Valor
Amplitude	71.851,699 V
Freqüência	60Hz
Fase	0°

Para se completar o modelo do equivalente elétrico do sistema, adicionou-se uma impedância em série com a fonte de tensão, conforme o modelo RL mutuamente acoplado (Rule Book, 1987) cujos parâmetros para as fases *A*, *B* e *C* estão apresentados na Tabela 2 como segue:

Tabela 2 - Parâmetros do modelo RL mutuamente acoplado, disposto em série com a fonte de tensão do equivalente elétrico.

Parâmetro	Valor
Resistência de seqüência zero	20,805 Ω/m
Indutância de seqüência zero	203,721 mH/m
Resistência de seqüência positiva	4,062 Ω/m
Resistência de seqüência positiva	52,5397 mH/m

Para simular o transformador existente na subestação de distribuição, utilizou-se o modelo de um transformador trifásico saturável com dois enrolamentos (Rule Book, 1987), conforme os dados que constam da Tabela 3.

Tabela 3 - Características do modelo do transformador de potência.

Parâmetro	Valor
Potência nominal	15/20 MVA
Relação de transformação (a)	3,809524
Corrente nominal do primário (I_p)	131,215970 A
Corrente nominal do secundário (I_s)	499,870363 A
Ligaçāo do primário	Estrela
Ligaçāo do secundário	Delta
Deslocamento angular	30°
Resistência do primário	0,054695 Ω
Resistência do secundário	0,79376 Ω
Indutância do primário	1,628 mH
Indutância do secundário	23,6258 mH
Resistência de magnetização	1 MΩ

No sistema de distribuição da concessionária, consta a presença de dois bancos de capacitores utilizados para melhorar o perfil da tensão. Estes dois bancos de capacitores foram modelados como um elemento capacitivo concentrado não acoplado, do tipo zero, conectado em estrela (Rule Book, 1987), cujos parâmetros estão mostrados na Tabela 4.

Tabela 4 - Parâmetros do modelo empregado para a modelagem dos bancos de capacitores.

Parâmetro	Valor
Capacitância fase A	5,96521 μF
Capacitância fase B	5,96521 μF
Capacitância fase C	5,96521 μF

As cargas alocadas nos alimentadores apresentados foram modeladas como potências constantes, via um elemento RL concentrado não acoplado do tipo zero, conectado em delta (Rule Book, 1987). Devido à extensa quantidade de consumidores presentes nos alimentadores, serão apresentadas as características de apenas alguns consumidores, dentre estes, as da carga referente ao ponto de monitoramento de interesse deste trabalho. A tabela 5 trás estas informações.

Tabela 5 – Exemplos de dados de carga do sistema de distribuição.

Carga	Resistência (Ω)	Indutância (mH)
Ponto 1	8179,90	$9,243 \cdot 10^{-3}$
Ponto 2	2944,76	$3,328 \cdot 10^{-3}$
Ponto de Monitoramento	2453,97	$2,773 \cdot 10^{-3}$

Por fim, para completar a modelagem do sistema elétrico de distribuição, têm-se os dados referentes aos condutores existentes no mesmo. Cada trecho dos alimentadores foi modelado por valores de resistência e indutância, através de um elemento RL mutuamente acoplado, dos tipos 51, 52 e 53 (Rule Book, 1987). Os condutores pertencentes ao sistema elétrico são de alumínio sem alma de aço com bitolas de 336,4 MCM, 04 AWG, 1/0 AWG, e cabo de rede compacta com 185mm^2 . Cada trecho do sistema, dos vários existentes, do sistema possui característica própria adequadamente representada para o correto funcionamento modelo computacional. As Tabela 6 e 7 contêm parâmetros de dois trechos dos alimentadores para a sequência zero e sequência positiva, respectivamente.

Tabela 6 – Tabela contendo parâmetros de dois trechos de condutores dos alimentadores para sequência zero.

Trecho	Distância (m)	Cabo	R_0 (Ω)	L_0 (mH)
I	124,2	336,4 MCM	0,045972	0,251375
II	573,4	1/0 AWG	0,449227	1,18634

Tabela 7 – Tabela contendo parâmetros de dois trechos de condutores dos alimentadores para sequência positiva.

Trecho	Distância (m)	Cabo	R_1 (Ω)	L_1 (mH)
I	124,2	336,4 MCM	0,023995	0,038526
II	573,4	1/0 AWG	0,347767	0,20367

Capítulo 5 – Base de treinamento para a RNA e estratégia de monitoramento da tensão

Conforme anteriormente apresentado, este trabalho tem por objetivo o monitoramento remoto dos níveis de tensão de um determinado ponto da rede de distribuição por uma RNA. Tal monitoramento se dará a partir de informações obtidas com o monitoramento da subestação. Todos os procedimentos que foram realizados para se alcançar este objetivo são explicitados neste capítulo.

Primeiramente, serão apresentados os procedimentos realizados, empregando-se o sistema elétrico de distribuição sob análise, para a obtenção da base de dados utilizada. Posteriormente, apresenta-se a RNA que foi empregada para realizar o monitoramento, e em seguida, os resultados obtidos pela metodologia de monitoramento proposta.

5.1 – Obtenção da base de dados de treinamento para a RNA

5.1.1 - Simulação das situações de defeitos

Para a obtenção da base de treinamento da RNA que irá monitorar os níveis da tensão eficaz no ponto de interesse, foram simuladas várias situações de faltas monofásicas, envolvendo a fase A do sistema modelado (Figura 20). Para tanto, foram selecionados vinte pontos de falta dispostos ao longo do sistema de distribuição. Esses pontos foram selecionados de forma a possibilitar uma boa variedade de distâncias de falta em relação ao ponto a ser monitorado. Para cada ponto de falta, variou-se a impedância e o ângulo de falta, medindo-se a tensão resultante na subestação e no ponto a ser monitorado via RNA. A Tabela 8 ilustra os parâmetros variados nas simulações. Deve-se salientar que a última coluna da Tabela 8 representa o número de situações de curtos-circuitos simulados em cada ponto resultante da combinação dos parâmetros das outras colunas.

Na Figura 20 estão explicitados os pontos de aplicação das faltas (realçados em vermelho), e os locais de monitoramento de tensão, na subestação e no ponto a ser monitorado remotamente pela RNA (realçado em verde). O ponto a ser monitorado, realçado na Figura 20, diz respeito a uma carga com características peculiares, apontada segundo estudos anteriormente realizados pelo grupo de pesquisas do LSEE (EESC-USP). Sua distância considerável em relação à subestação o faz ser mais suscetível à influência da operação do restante do sistema, e torna a regulação de tensão mais complicada.

Cabe salientar que um estudo mais apurado para uma melhor escolha dos pontos de aplicação das faltas pode ser realizado, o que resultará em uma melhor representatividade do sistema como um todo, gerando uma base de dados mais completa para o treinamento das RNAs responsáveis pelo monitoramento da tensão no ponto remoto.

5.1.2 – Pré-processamento dos dados resultantes das simulações

Após as simulações de cada situação de falta, conforme o procedimento anteriormente explicado, procedeu-se à formação dos padrões de entrada da RNA, obtidos a partir das tensões e correntes trifásicas na subestação, e das respectivas saídas associadas, que por sua vez são obtidas das tensões trifásicas no ponto de monitoramento remoto. Inicialmente, parte destes dados será utilizada para o treinamento da RNA e, posteriormente, diferentemente dos utilizados para o treinamento, a outra parte será empregada para a validação e teste da metodologia proposta.

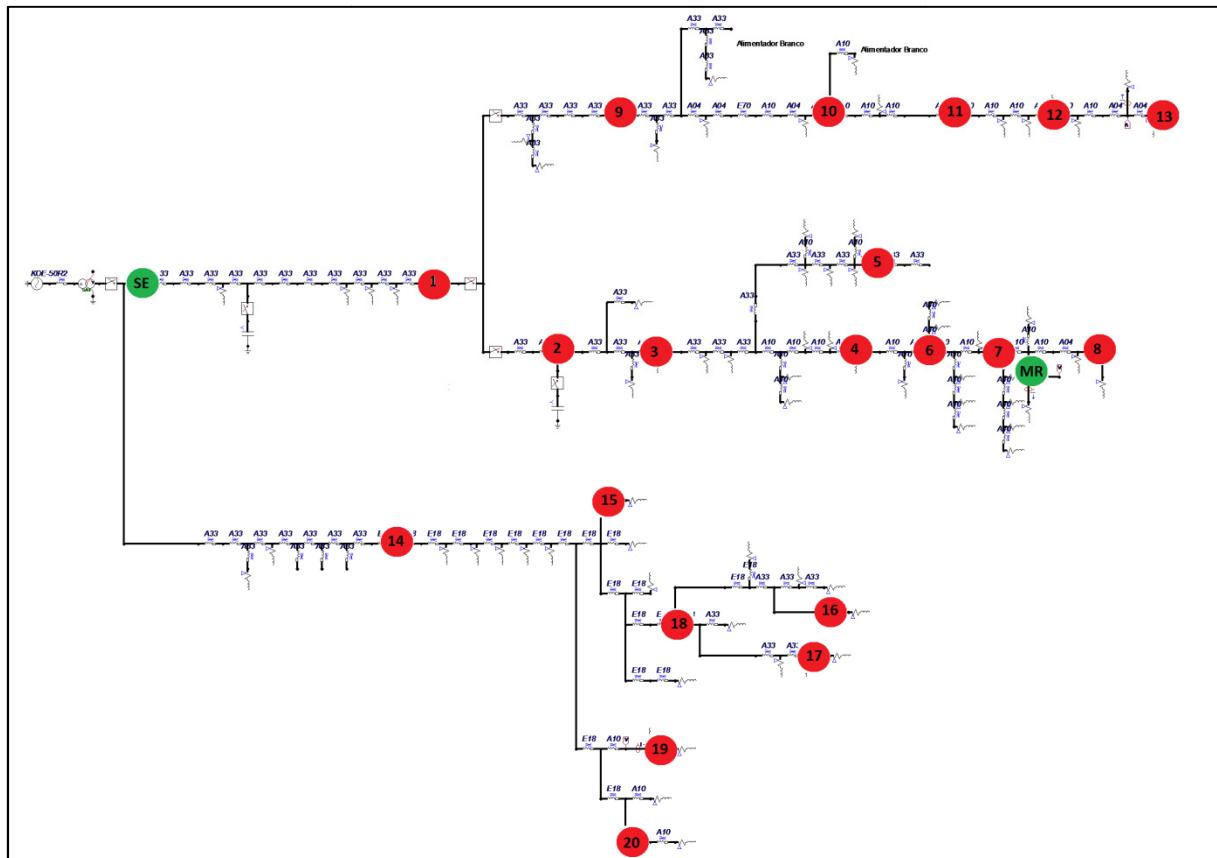


Figura 20 - Visão geral dos pontos de aplicação da falta e de monitoramento da tensão.

Para a formação dos padrões de entrada, foram selecionados três ciclos precedentes e seis ciclos subseqüentes ao instante de início de cada defeito dos sinais de tensão e corrente em cada uma das fases do sistema trifásico, medidos na subestação. Sobre estes sinais, amostrados a uma taxa de 128 amostras por ciclo na freqüência fundamental do sistema (60 Hz), utilizou-se uma janela deslizante de dimensão de um ciclo, com deslocamento de meio ciclo (64 amostras). A cada

deslocamento da janela, foram calculados os respectivos valores eficazes (rms) da tensão e corrente nas três fases, resultando assim, em seis valores (três de tensão e três de corrente) de entrada. Deste modo, os eventos de QEE da forma como são percebidos na subestação, foram apresentados como padrão de entrada à RNA.

Para exemplificar o processo de janelamento referido, considere um sinal amostrado com 16 amostras por ciclo, considerando 60Hz como a freqüência fundamental, conforme mostrado na Figura 21. Nesta figura observa-se um deslocamento de meio ciclo da janela sobre a forma de onda, ou seja, os pontos delimitados pelo retângulo verde representam um deslocamento de meio ciclo da janela em relação aos pontos delimitados pelo retângulo vermelho. Cada retângulo contém 16 amostras, e o deslocamento da janela deslizante é de meio ciclo, isto é, de 8 amostras. Este processo de deslocamento é realizado sucessivamente até o fim do sinal, de modo que para 2 ciclos, neste exemplo, serão obtidas 3 janelas, e, consequentemente, 3 padrões de valores eficazes. Observe que neste exemplo, obtém-se os padrões para apenas uma entrada da rede. Na estratégia de monitoramento proposta neste trabalho, este procedimento será realizado para 6 formas de onda (três de tensão e três de corrente), conforme dito anteriormente.

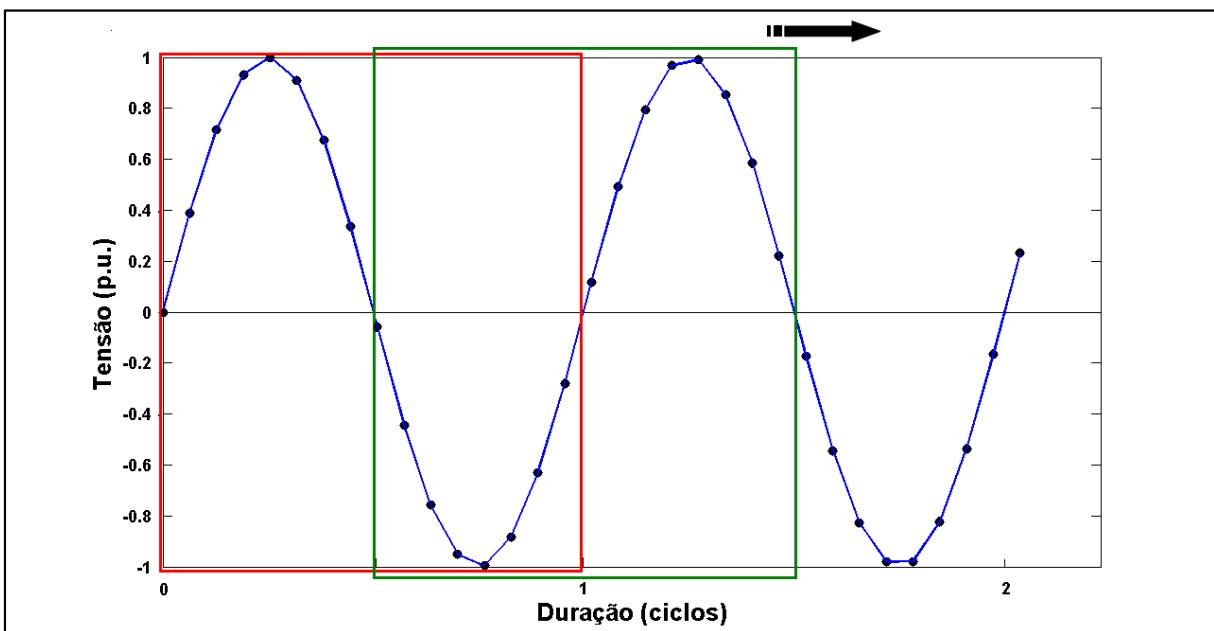
A escolha de 3 ciclos de pré-falta pode ser justificada pelo fato de que o sistema simulado opera em condições de regime, e uma maior amostragem dos sinais durante este período poderia se caracterizar como desnecessária. Já para o período de pós-falta, foram amostrados mais ciclos (6 ciclos), uma vez que se espera um comportamento transitório do sistema elétrico após o instante de aplicação da falta. Em geral, da análise das simulações efetuadas, o comportamento transitório cessa pouco antes do término dos 6 ciclos de pós-falta, indicando que nos demais ciclos o comportamento dos sinais tende a se estabilizar.

Da maneira como foram simuladas, entre o instante de início de cada curto-círcuito até o seu fim, tem-se um total de 9 ciclos, obtendo-se então, 17 padrões de entrada (valores eficazes resultantes da janela deslizante) a serem apresentados à RNA decorrentes de cada situação de defeito simulada. Dessa maneira, com 200 casos de faltas simuladas, o banco de dados construído possui 3.400 padrões de entrada.

Para a obtenção dos padrões de saída, aplicou-se o mesmo procedimento utilizado para a obtenção das entradas aos sinais de tensão das três fases sobre o ponto de monitoramento remoto, obtendo-se os respectivos 3.400 padrões de saída. Do total de padrões obtidos (3.400 padrões), 2.380 (70%) foram utilizados para o treinamento da RNA e 1.020 (30%) diferentes padrões, foram reservados para validação.

Tabela 8 - Configuração para a obtenção da base de treinamento para a RNA.

Ponto de aplicação da falta	Impedâncias de falta (Ω)	Ângulo de falta (°)	Total
1	0; 10; 20; 30 e 40	0 e 90	10 casos
2	0; 10; 20; 30 e 40	0 e 90	10 casos
3	0; 10; 20; 30 e 40	0 e 90	10 casos
4	0; 10; 20; 30 e 40	0 e 90	10 casos
5	0; 10; 20; 30 e 40	0 e 90	10 casos
6	0; 10; 20; 30 e 40	0 e 90	10 casos
7	0; 10; 20; 30 e 40	0 e 90	10 casos
8	0; 10; 20; 30 e 40	0 e 90	10 casos
9	0; 10; 20; 30 e 40	0 e 90	10 casos
10	0; 10; 20; 30 e 40	0 e 90	10 casos
11	0; 10; 20; 30 e 40	0 e 90	10 casos
12	0; 10; 20; 30 e 40	0 e 90	10 casos
13	0; 10; 20; 30 e 40	0 e 90	10 casos
14	0; 10; 20; 30 e 40	0 e 90	10 casos
15	0; 10; 20; 30 e 40	0 e 90	10 casos
16	0; 10; 20; 30 e 40	0 e 90	10 casos
17	0; 10; 20; 30 e 40	0 e 90	10 casos
18	0; 10; 20; 30 e 40	0 e 90	10 casos
19	0; 10; 20; 30 e 40	0 e 90	10 casos
20	0; 10; 20; 30 e 40	0 e 90	10 casos
Total	---	---	200 casos

**Figura 21 – Aspecto do processo de janelamento.**

5.2 – Estratégia proposta para monitoramento da tensão

O monitoramento da tensão no ponto de interesse se dará com a utilização de três RNAs distintas, uma para cada fase. Cada uma das três RNAs utilizadas recebe como padrão de entrada os valores eficazes dos sinais de tensão e corrente das três fases conforme explicitado na Seção 5.1.2, ou seja, cada uma das RNAs recebe seis valores de entrada. Cada uma das RNAs fornece como saída o valor eficaz de tensão em uma das fases no ponto de monitoramento remoto, ou seja, uma RNA é responsável por estimar o valor da tensão para a fase A no ponto remoto, outra é responsável pela estimativa da fase B e outra pela fase C. Desta forma não será necessária a instalação de medidores para se monitorar a situação das tensões no ponto de interesse, pois estas serão estimadas pelas RNAs a partir dos valores medidos na subestação. A Figura 22 ilustra mais claramente esta configuração.

É necessário ressaltar que na Figura 22 está ilustrada apenas uma das três RNAs empregadas para o monitoramento remoto das três fases do sistema trifásico. Esta configuração é utilizada para as três fases do sistema, de modo que seja possível o monitoramento da tensão conforme anteriormente explicado.

Sendo assim, a RNA de uma dada fase receberá como entrada os sinais de tensão e corrente eficazes medidos na subestação, devendo fornecer o valor eficaz de tensão para a respectiva fase no ponto remotamente monitorado. Este arranjo é considerado para as demais fases, de modo que se obtenham as tensões eficazes das três fases no ponto remoto, através de três RNAs. Além disso, os índices dos neurônios das camadas ocultas representados na Figura 22 indicam, respectivamente, a camada e seu neurônio associado, de acordo com a arquitetura adotada (6 entradas, 15 neurônios na primeira camada oculta, 10 neurônios na segunda camada oculta e 1 neurônio na camada de saída).

As redes neurais mencionadas são redes PMC, possuindo as três, a mesma arquitetura. A escolha da melhor arquitetura foi feita através de uma investigação do desempenho geral de diversas arquiteturas de RNAs, variando-se o número de neurônios das camadas ocultas e o algoritmo de treinamento. Esta investigação foi realizada inicialmente para a RNA que monitora a fase A até se encontrar a arquitetura que apresentasse as melhores respostas para esta fase. O treinamento das RNAs responsáveis pelo monitoramento das demais fases (B e C) foi realizado com base na arquitetura encontrada durante a investigação efetuada para a fase A. A seguir, apresenta-se a investigação realizada para encontrar a melhor arquitetura utilizando-se inicialmente o algoritmo de treinamento *back-propagation* e em seguida o algoritmo *Levenberg-Marquardt* será também empregado com os mesmos propósitos.

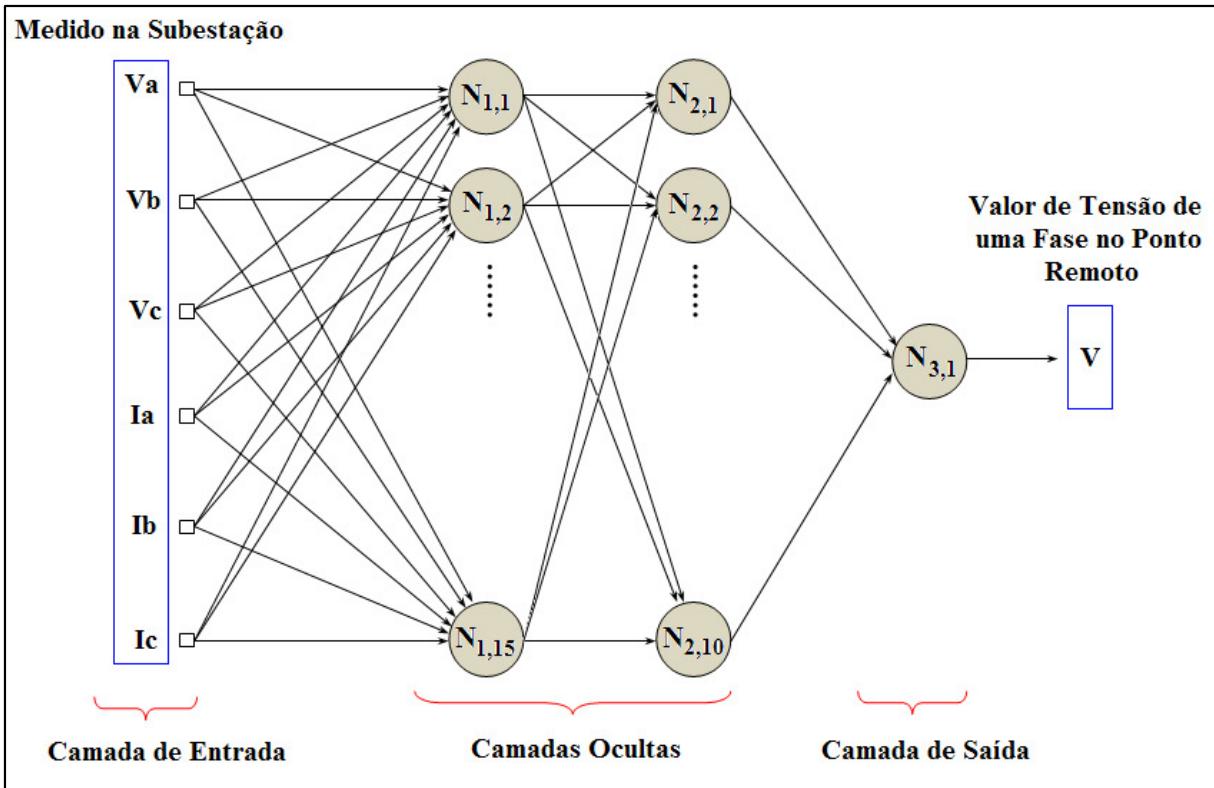


Figura 22 - Figura esquemática representando a RNA empregada em uma das fases do sistema trifásico.

5.2.1 – Treinamento da RNA com o algoritmo *back-propagation*.

Inicialmente, a investigação em busca da melhor arquitetura para as redes neurais em questão, foi realizada treinando-se a RNA para a fase A com o algoritmo de retropropagação de erro (*back-propagation*). Cada arquitetura de rede investigada foi treinada cinco vezes (ensaios de 1 a 5), adotando-se como critérios de parada atingir um erro médio quadrático (EQM) menor do que 10^{-6} , ou o número de épocas de treinamento superior a 6.000 épocas. Este procedimento foi necessário na medida em que a inicialização aleatória dos pesos sinápticos pode levar a desempenhos diferenciados. As Tabelas de 9 a 16, apresentam as porcentagens dos erros relativos aos casos de teste, tomados com relação ao valor eficaz da tensão desejada (esperada) no ponto de monitoramento remoto, para as seguintes faixas de erro:

- (i) abaixo de 0,005p.u. (ou 0,5%);
- (ii) acima de 0,005p.u (0,5%) e abaixo de 0,015p.u.(1,5%);
- (iii) acima de 0,015p.u. (1,5%) e abaixo de 0,025 p.u. (2,5%);
- (iv) abaixo de 0,03p.u. (ou 3%).

Para a Tabela 9, os erros se referem à resposta apresentada por uma arquitetura PMC sendo

alimentada com os seis (6) valores eficazes (tensões e correntes trifásicas), contendo duas camada ocultas (intermediárias) com 10 e 5 unidades de processamento nas camadas ocultas, e uma (1) unidade como saída. Para as demais tabelas (8 a 14), a mesma notação será empregada.

Na Tabela 9, por exemplo, para o ensaio de número 1, 3,73% dos casos de teste analisados apresentaram um erro no valor eficaz desejado menor do 0,005p.u. Já para 8,63% dos casos, o erro apresentado foi maior ou igual a 0,005p.u. e menor do que 0,015p.u. Para a faixa do erro maior ou igual a 0,015p.u. e menor ou igual a 0,025p.u., 9,41% dos casos foram incidentes. Para 21,76% de todos os casos de testes que foram avaliados, uma resposta com erro de até 0,03p.u. foi apresentada. Cabe afirmar que a magnitude do maior erro observado para este ensaio foi de 0,346p.u., como relatado na última coluna desta tabela. Logo, conclui-se que para este ensaio, esta arquitetura deixou a desejar na precisão das respostas apresentadas. Ainda na Tabela 9, observa-se que a melhor resposta decorre do ensaio 5, visto que 65,39% de todos os casos avaliados apresentaram uma resposta com um erro menor do que 0,03p.u. para o valor da tensão eficaz monitorada.

Esta compreensão dos valores apresentados se estende aos demais ensaios (2 a 5) e Tabelas (10 a 16).

Tabela 9 – Resultados do treinamento *back-propagation* para RNA da fase A com arquitetura 6-10-5-1.

Ensaio	Erro<0,005p.u. (%)	0,005≤Erro<0,015p.u. (%)	0,015≤ Erro≤0,025p.u. (%)	Erro ≤0,030p.u. (%)	Magnitude do maior erro (p.u.)
1	3,73	8,63	9,41	21,76	0,346
2	10,1	46,57	6,96	63,63	0,31
3	31,47	4,02	8,14	43,63	0,314
4	32,94	9,8	20,59	63,33	0,257
5	40,39	9,71	15,29	65,39	0,372
Médias	23,73	15,75	12,08	51,55	0,32

Tabela 10 – Resultados do treinamento *back-propagation* para RNA da fase A com arquitetura 6-14-7-1.

Ensaio	Erro<0,005p.u. (%)	0,005≤Erro<0,015p.u. (%)	0,015≤ Erro≤0,025p.u. (%)	Erro ≤0,030p.u. (%)	Magnitude do maior erro (p.u.)
1	42,55	17,35	9,71	69,61	0,702
2	35,49	16,37	7,65	59,51	0,389
3	5,88	41,57	10,49	57,94	0,395
4	35,69	20,39	11,47	67,55	0,263
5	39,12	15,69	12,94	67,75	0,49
Médias	31,75	22,27	10,45	64,47	0,448

Tabela 11 – Resultados do treinamento *back-propagation* para RNA da fase A com arquitetura 6-15-10-1.

Ensaio	Erro<0,005p.u. (%)	0,005≤Erro<0,015p.u. (%)	0,015≤ Erro≤0,025p.u. (%)	Erro ≤0,030p.u. (%)	Magnitude do maior erro (p.u.)
1	39,02	18,04	13,63	70,69	0,472
2	36,37	11,08	11,86	59,31	0,59
3	10,69	50,1	8,63	69,41	0,52
4	6,57	49,41	13,24	69,22	0,725
5	41,08	18,73	10,98	70,78	0,31
Médias	26,75	29,47	11,67	67,88	0,523

Tabela 12 – Resultados do treinamento *back-propagation* para RNA da fase A com arquitetura 6-20-10-1.

Ensaio	Erro<0,005p.u. (%)	0,005≤Erro<0,015p.u. (%)	0,015≤ Erro≤0,025p.u. (%)	Erro ≤0,030p.u. (%)	Magnitude do maior erro (p.u.)
1	45,49	15,59	8,53	69,61	0,594
2	39,02	18,04	13,63	70,69	0,472
3	36,37	11,08	11,86	59,31	0,590
4	10,69	50,1	8,63	69,41	0,520
5	6,57	49,41	13,24	69,22	0,725
Médias	27,63	28,84	11,18	67,65	0,580

Tabela 13 – Resultados do treinamento *back-propagation* para RNA da fase A com arquitetura 6-20-15-1.

Ensaio	Erro<0,005p.u. (%)	0,005≤Erro<0,015p.u. (%)	0,015≤ Erro≤0,025p.u. (%)	Erro ≤0,030p.u. (%)	Magnitude do maior erro (p.u.)
1	12,45	43,04	9,9	65,39	0,343
2	43,73	18,14	7,55	69,41	0,67
3	40,78	16,18	11,86	68,82	0,432
4	42,84	13,24	10,69	66,76	0,565
5	39,61	15,88	8,04	63,53	0,673
Médias	35,88	21,29	9,61	66,78	0,536

Tabela 14 – Resultados do treinamento *back-propagation* para RNA da fase A com arquitetura 6-25-15-1.

Ensaio	Erro<0,005p.u. (%)	0,005≤Erro<0,015p.u. (%)	0,015≤ Erro≤0,025p.u. (%)	Erro ≤0,030p.u. (%)	Magnitude do maior erro (p.u.)
1	44,41	16,96	11,86	73,24	0,315
2	36,08	16,86	14,31	67,25	0,62
3	35,59	18,92	14,8	69,31	0,401
4	36,86	22,65	13,53	73,04	0,888
5	43,43	14,61	14,9	72,94	0,231
Médias	39,27	18	13,88	71,16	0,491

Tabela 15 - Resultados do treinamento *back-propagation* para RNA da fase A com arquitetura 6-30-20-1.

Ensaio	Erro<0,005p.u. (%)	0,005≤Erro<0,015p.u. (%)	0,015≤ Erro≤0,025p.u. (%)	Erro ≤0,030p.u. (%)	Magnitude do maior erro (p.u.)
1	34,71	19,12	10,88	64,71	0,466
2	41,76	14,71	15,39	71,86	0,436
3	42,84	18,24	10,88	71,96	0,51
4	43,53	20,39	9,71	73,63	0,448
5	42,94	19,71	5,2	67,84	0,411
Médias	41,16	18,43	10,41	70	0,454

Tabela 16 – Resultados do treinamento *back-propagation* para RNA da fase A com arquitetura 6-40-30-1.

Ensaio	Erro<0,005p.u. (%)	0,005≤Erro<0,015p.u. (%)	0,015≤ Erro≤0,025p.u. (%)	Erro ≤0,030p.u. (%)	Magnitude do maior erro (p.u.)
1	21,37	30,78	13,43	65,59	0,272
2	44,51	18,53	10,10	73,14	0,93
3	37,25	14,22	12,94	64,41	0,526
4	33,63	19,9	13,33	66,86	0,567
5	32,84	22,75	14,51	70,1	0,307
Médias	21,37	30,78	13,43	65,59	0,272

É possível observar que da Tabela 9 até a 11, o desempenho geral da rede melhorou na medida em que se aumentou a quantidade de neurônios nas camadas ocultas. Ou seja, a porcentagem de erros menores do que 0,03p.u. aumentou com o número crescente de neurônios nas camadas ocultas.

Nas tabelas de 12 a 15, observa-se que o desempenho permaneceu praticamente constante, ou apresentou uma melhora pouco considerável. Por fim na tabela 16, que possui a maior quantidade de neurônios, constata-se a diminuição do desempenho geral da rede.

Mediante ao observado, elegeu-se a arquitetura da tabela 14, que foi a que obteve melhor

desempenho, para analisar qual seria a influência de um aumento da quantidade de épocas de treinamento no desempenho geral. Desta forma, estabeleceu-se como critério de parada para o novo treinamento para esta arquitetura, o EMQ ser menor do que 10^{-6} , e/ou um número máximo de treinamento de 20.000 épocas. O resultado deste treinamento deu-se como segue na Tabela 17.

Tabela 17 - Resultados do treinamento *back-propagation* para RNA (20.000 épocas de treinamento) da fase A com arquitetura 6-25-15-1.

Ensaio	Erro<0,005p.u. (%)	0,005≤Erro<0,015p.u. (%)	0,015≤ Erro≤0,025p.u. (%)	Erro ≤0,030p.u. (%)	Magnitude do maior erro (p.u.)
1	41,57	13,24	17,35	72,16	0,447
2	43,04	22,84	7,06	72,94	0,611
3	42,35	19,8	11,67	73,82	0,218
4	47,55	17,94	10,1	75,59	0,578
5	34,9	24,12	16,47	75,49	0,666
Médias	41,88	19,59	12,53	74	0,504

Observa-se, portanto, que mesmo com 14.000 épocas de treinamento a mais do que o treinamento inicial, o desempenho geral teve pouca melhoria.

Apesar do baixo desempenho apresentado com este último treinamento para os resultados relativos à fase A, aplicou-se a mesma arquitetura para realizar o treinamento das redes responsáveis pelo monitoramento das fases B e C. Esta arquitetura (6 – 25 – 25 – 1), com 20.000 épocas de treinamento como critério de parada, foi reproduzida para as demais redes pois apresentou o melhor desempenho dentre todos os testes realizados. Os resultados obtidos para as demais fases são apresentados nas Tabelas 18 e 19.

Tabela 18 – Resultados do treinamento *back-propagation* para RNA (20.000 épocas de treinamento) da fase B com arquitetura 6-25-15-1.

Ensaio	Erro<0,005p.u. (%)	0,005≤Erro<0,015p.u. (%)	0,015≤ Erro≤0,025p.u. (%)	Erro ≤0,030p.u. (%)	Magnitude do maior erro (p.u.)
1	42,75	24,22	9,9	76,86	0,184
2	45,39	20,98	14,8	81,18	0,284
3	47,55	13,24	15,39	76,18	0,264
4	40,39	25,88	14,8	81,08	0,195
5	45,69	17,45	13,73	76,86	0,239
Médias	44,35	20,35	13,73	78,43	0,230

Tabela 19 - Resultados do treinamento *back-propagation* para RNA (20.000 épocas de treinamento) da fase C com arquitetura 6-25-15-1.

Ensaio	Erro<0,005p.u. (%)	0,005≤Erro<0,015p.u. (%)	0,015≤ Erro≤0,025p.u. (%)	Erro ≤0,030p.u. (%)	Magnitude do maior erro (p.u.)
1	51,47	24,51	10,49	86,47	0,240
2	57,84	18,92	9,51	86,27	0,174
3	46,47	26,76	11,47	84,71	0,2
4	47,16	26,18	13,14	86,47	0,278
5	60,29	18,33	9,51	88,14	0,163
Médias	52,65	22,94	10,82	86,41	0,211

Percebeu-se que o desempenho também não foi satisfatório para o monitoramento das fases B e C, e que o aumento do número máximo de épocas de treinamento possibilitou ganho moderado no desempenho das redes. Mediante os testes realizados, concluiu-se que um novo tipo de treinamento deveria ser utilizado a fim de verificar se ocorreria uma melhora no desempenho da RNA. O treinamento realizado foi através do algoritmo de *Levenberg-Marquardt* que será apresentado na próxima seção.

Uma atenção especial aos erros que se situaram abaixo de 0,03p.u. se fez necessária de modo a tornar possível a observação do índice geral de acerto das RNAs. Tomando-se as outras faixas de erro, constata-se que a correlação existente entre o aumento do número de neurônios nas camadas ocultas e o aumento do índice de acerto se faz menos presente, o que dificulta a investigação acerca da melhor arquitetura de rede a ser adotada.

5.2.2 – Treinamento da RNA com o algoritmo *Levenberg-Marquardt*

De maneira análoga ao procedimento realizado para o treinamento *back-propagation*, realizou-se o treinamento de *Levenberg-Marquardt*, adotando como critérios de parada um o EMQ menor do que 10^{-6} e/ou um número total de épocas de treinamento superior a 800 épocas. As Tabelas de 20 a 27 revelam os resultados obtidos para os vários testes realizados com o intuito de se encontrar a melhor arquitetura da RNA para a fase A.

Tabela 20 – Resultados do treinamento *Levenberg-Marquardt* para RNA da fase A com arquitetura 6-10-5-1.

Ensaio	Erro<0,005p.u. (%)	0,005≤Erro<0,015p.u. (%)	0,015≤ Erro≤0,025p.u. (%)	Erro ≤0,030p.u. (%)	Magnitude do maior erro (p.u.)
1	70,2	18,43	5,88	94,51	3,696
2	70,29	18,63	5,98	94,9	0,336
3	69,61	18,82	5,29	93,73	0,621
4	69,41	20,2	3,53	93,14	0,974
5	73,53	11,37	8,53	93,43	0,362
Médias	70,61	17,49	5,84	93,94	1,198

Tabela 21 – Resultados do treinamento *Levenberg-Marquardt* para RNA da fase A com arquitetura 6-14-7-1.

Ensaio	Erro<0,005p.u. (%)	0,005≤Erro<0,015p.u. (%)	0,015≤ Erro≤0,025p.u. (%)	Erro ≤0,030p.u. (%)	Magnitude do maior erro (p.u.)
1	70,78	15,29	4,31	90,39	0,56
2	76,27	12,25	2,35	90,88	0,62
3	78,04	12,16	4,02	94,22	0,346
4	76,86	12,84	2,84	92,55	1,495
5	80,29	11,27	2,45	94,02	0,479
Médias	78,58	12,06	2,65	93,28	0,987

Tabela 22 – Resultados do treinamento *Levenberg-Marquardt* para RNA da fase A com arquitetura 6-15-10-1.

Ensaio	Erro<0,005p.u. (%)	0,005≤Erro<0,015p.u. (%)	0,015≤ Erro≤0,025p.u. (%)	Erro ≤0,030p.u. (%)	Magnitude do maior erro (p.u.)
1	81,27	11,08	3,04	95,39	0,863
2	82,06	11,67	1,67	95,39	4,365
3	78,92	11,67	1,86	92,45	0,56
4	75,78	12,75	3,14	91,67	0,694
5	81,76	10,2	1,96	93,92	5,757
Médias	79,96	11,47	2,33	93,76	2,448

Tabela 23 – Resultados do treinamento *Levenberg-Marquardt* para RNA da fase A com arquitetura 6-20-10-1.

Ensaio	Erro<0,005p.u. (%)	0,005≤Erro<0,015p.u. (%)	0,015≤ Erro≤0,025p.u. (%)	Erro ≤0,030p.u. (%)	Magnitude do maior erro (p.u.)
1	78,14	11,86	4,61	94,61	3,301
2	78,43	9,12	3,73	91,27	0,8
3	78,63	11,08	3,92	93,63	0,569
4	77,94	11,18	2,25	91,37	0,56
5	84,41	7,35	2,84	94,61	1,929
Médias	79,51	10,12	3,47	93,1	1,432

Tabela 24 – Resultados do treinamento *Levenberg-Marquardt* para RNA da fase A com arquitetura 6-20-15-1.

Ensaio	Erro<0,005p.u. (%)	0,005≤Erro<0,015p.u. (%)	0,015≤ Erro≤0,025p.u. (%)	Erro ≤0,030p.u. (%)	Magnitude do maior erro (p.u.)
1	82,55	5,29	2,55	90,39	1,028
2	80,59	10,69	3,14	94,41	1,185
3	78,53	9,71	4,61	92,84	1,874
4	77,65	15,98	1,47	95,1	1,784
5	75,29	13,92	2,55	91,76	0,733
Médias	78,92	11,12	2,86	92,9	1,321

Tabela 25 – Resultados do treinamento *Levenberg-Marquardt* para RNA da fase A com arquitetura 6-25-15-1.

Ensaio	Erro<0,005p.u. (%)	0,005≤Erro<0,015p.u. (%)	0,015≤ Erro≤0,025p.u. (%)	Erro ≤0,030p.u. (%)	Magnitude do maior erro (p.u.)
1	77,75	13,04	2,16	92,94	1,921
2	83,24	7,55	3,14	93,92	3,364
3	77,35	13,04	5	95,39	1,73
4	80,69	8,63	1,96	91,27	1,75
5	79,9	10,88	2,65	93,43	1,702
Médias	80,29	9,75	2,3	92,35	1,726

Tabela 26 – Resultados do treinamento *Levenberg-Marquardt* para RNA da fase A com arquitetura 6-25-20-1.

Ensaio	Erro<0,005p.u. (%)	0,005≤Erro<0,015p.u. (%)	0,015≤ Erro≤0,025p.u. (%)	Erro ≤0,030p.u. (%)	Magnitude do maior erro (p.u.)
1	80,1	12,16	1,76	94,02	0,556
2	80,98	9,22	3,43	93,63	4,582
3	77,84	9,8	5,2	92,84	1,499
4	82,45	8,82	2,16	93,43	0,759
5	81,18	9,12	3,73	94,02	0,585
Médias	81,81	8,97	2,94	93,73	0,672

Tabela 27 – Resultados do treinamento *Levenberg-Marquardt* para RNA da fase A com arquitetura 6-30-20-1.

Ensaio	Erro<0,005p.u. (%)	0,005≤Erro<0,015p.u. (%)	0,015≤ Erro≤0,025p.u. (%)	Erro ≤0,030p.u. (%)	Magnitude do maior erro (p.u.)
1	80,78	9,22	1,96	91,96	4,18
2	81,96	11,47	1,86	95,29	0,47
3	78,33	10,88	4,71	93,92	3,18
4	79,22	9,8	5,2	94,22	0,74
5	78,33	10,88	4,71	93,92	3,18
Médias	79,73	10,45	3,69	93,86	2,35

Em geral, na grande maioria dos testes realizados, observou-se que este treinamento propiciou resultados melhores, quando comparados com o treinamento *back-propagation*. É possível depreender das Tabelas 22 e 26 que tanto a arquitetura 6–15–10–1 como a 6–25–20–1, apresentaram os melhores desempenhos, com 93,76% e 93,72% dos erros menores do que 0,03 p.u. (ou 3%). Observa-se então que o aumento de neurônios nas camadas ocultas pouco influencia o resultado geral da rede, como se nota nos resultados da Tabela 27.

Por esta razão, ambas as arquiteturas foram treinadas para as redes das fases B e C, afim de se verificar qual o melhor resultado englobando-se as três fases. Além disso, vê-se claramente a influência do treinamento de *Levenberg-Marquardt*, mostrando-se ser mais adequado do que o *back-propagation* para o problema abordado. As Tabelas de 28 a 31 apresentam os resultados obtidos para as fases B e C com as duas arquiteturas selecionadas (6–15–10–1 e 6–25–20–1) para a nova etapa de teste.

Tabela 28 – Resultados do treinamento *Levenberg-Marquardt* para RNA da fase B com arquitetura 6-15-10-1.

Ensaio	Erro<0,005p.u. (%)	0,005≤Erro<0,015p.u. (%)	0,015≤ Erro≤0,025p.u. (%)	Erro ≤0,030p.u. (%)	Magnitude do maior erro (p.u.)
1	85,59	9,22	2,75	97,55	0,43
2	85	11,47	1,57	98,04	0,768
3	81,76	10,88	1,67	94,31	7,661
4	85,59	8,82	2,45	96,86	0,228
5	81,86	13,73	1,67	97,25	1,963
Médias	83,96	10,82	2,02	96,8	2,21

Tabela 29 – Resultados do treinamento *Levenberg-Marquardt* para RNA da fase B com arquitetura 6-25-20-1.

Ensaio	Erro<0,005p.u. (%)	0,005≤Erro<0,015p.u. (%)	0,015≤ Erro≤0,025p.u. (%)	Erro ≤0,030p.u. (%)	Magnitude do maior erro (p.u.)
1	86,67	6,37	3,33	96,37	4,83
2	79,31	9,9	6,37	95,59	0,667
3	81,67	9,02	6,08	96,76	1,192
4	81,86	12,65	2,35	96,86	0,652
5	82,65	9,41	3,24	95,29	1,026
Médias	82,43	9,47	4,27	96,18	1,673

Tabela 30 – Resultados do treinamento *Levenberg-Marquardt* para RNA da fase C com arquitetura 6-15-10-1.

Ensaio	Erro<0,005p.u. (%)	0,005≤Erro<0,015p.u. (%)	0,015≤ Erro≤0,025p.u. (%)	Erro ≤0,030p.u. (%)	Magnitude do maior erro (p.u.)
1	87,65	6,47	2,06	96,18	0,431
2	85,78	8,24	1,37	95,39	1,652
3	87,45	7,16	3,14	97,75	0,274
4	87,16	7,94	1,27	96,37	0,476
5	84,41	7,55	3,14	95,1	0,938
Médias	86,49	7,47	2,2	96,16	0,754

Tabela 31 – Resultados do treinamento *Levenberg-Marquardt* para RNA da fase C com arquitetura 6-25-20-1.

Ensaio	Erro<0,005p.u. (%)	0,005≤Erro<0,015p.u. (%)	0,015≤ Erro≤0,025p.u. (%)	Erro ≤0,030p.u. (%)	Magnitude do maior erro (p.u.)
1	88,33	5,59	1,18	95,1	0,364
2	87,65	8,14	1,57	97,35	0,58
3	88,33	5,59	1,18	95,1	0,364
4	88,14	7,94	1,27	97,35	0,476
5	87,94	7,55	2,55	98,04	0,704
Médias	88,08	6,96	1,55	96,59	0,497

Novamente, ambas as arquiteturas apresentam desempenhos semelhantes. Entretanto a arquitetura 6-15-10-1 apresenta ser ligeiramente melhor quando se analisa a porcentagem de erro ≤0,030 p.u.

5.2.3 – Análise sobre a arquitetura e o tipo de treinamento adotados

A comparação entre o desempenho das redes das três fases indica que o algoritmo de treinamento *Levenberg-Marquardt* é mais adequado ao treinamento das redes neurais, afim de que se possa realizar com certa segurança o monitoramento remoto de tensão no ponto de interesse. As arquiteturas (6–15–10–1) e (6–25–20–1), apresentaram desempenhos muito próximos, conforme mostra a Tabela 32, ao se observar a porcentagem de erros menores do que 0,03p.u., para ambas as redes nas três fases.

Tabela 32 – Comparação do desempenho entre duas arquiteturas de RNA

Arquitetura da RNA	Fase A $e \leq 0,030\text{pu}$ (%)	Fase B $e \leq 0,030\text{pu}$ (%)	Fase C $e \leq 0,030\text{pu}$ (%)
(6–15–10–1)	93,76	96,8	96,16
(6–25–20–1)	93,72	96,18	96,59

Diante deste cenário, optou-se pela rede que possui menor quantidade de neurônios, tendo em vista que esta exigirá menor esforço computacional para sua eventual operação. Cabe ressaltar que esta escolha não prejudica o objetivo proposto para este trabalho, uma vez que a variação de desempenho entre as duas redes é mínima.

5.3 – Análise do desempenho da RNA escolhida

Após escolhida a arquitetura para as três redes correspondentes às três fases, uma análise mais detalhada acerca do desempenho das mesmas foi efetuado. Para tanto, foram escolhidos 3 casos de curtos-circuitos dentro do conjunto de testes de modo a demonstrar, através destes exemplos, o grau de acerto desenvolvido pelas três redes RNA.

Com a construção de gráficos que mostram superpostas a saída de teste e a resposta fornecida pela RNA, é possível verificar a validação da mesma em termos do desempenho esperado. Se a resposta fornecida pela RNA estiver condizente, dada uma faixa de tolerância, com a saída desejada para a RNA (saída de teste), então se pode afirmar que a rede obteve sucesso após sua etapa de treinamento.

A seguir, ilustram-se três exemplos de situações distintas para o monitoramento remoto da tensão no ponto de interesse. Com estes exemplos, é possível se obter uma perspectiva da eficácia das respostas geradas pelas redes neurais das fases *A*, *B* e *C* treinadas via algoritmo de *Levenberg-Marquardt*. Nas figuras seguintes, a resposta fornecida pela RNA é representada pela linha vermelha, sendo a saída desejada, ou saída de teste, representada pela linha azul, conforme indicado nas legendas

de cada gráfico. Após a apresentação de cada exemplo, serão exibidos 3 histogramas que visam complementar a avaliação do desempenho das RNAs.

5.3.1 – Aplicação de falta, exemplo 1

No primeiro exemplo, compreendendo as amostras de uma situação de falta simulada, afirma-se que a saída da fase A da RNA, deve caracterizar uma elevação de tensão. Para estas mesmas amostras, as fases *B* e *C* da respectiva RNA devem caracterizar afundamentos de tensão.

Na Figura 23, apresenta-se a saída para esta situação da fase A, ou seja, para a elevação de tensão.

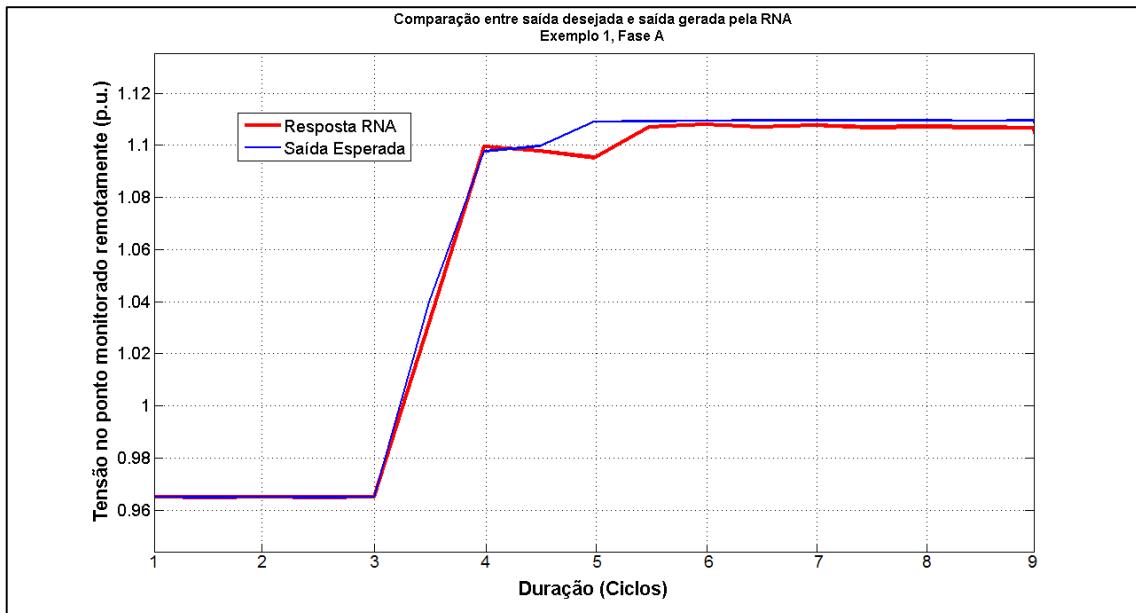


Figura 23 – Resultado da comparação entre saída esperada e saída gerada pela RNA da fase A, para o primeiro exemplo.

Ao observarmos o comportamento da resposta fornecida pela RNA da fase A, constata-se que ela foi capaz de estimar com significativa precisão o perfil da variação da tensão no ponto de monitoramento remoto. O mesmo pode se verificado para as redes das fases *B* e *C* (para os afundamentos), conforme mostram as Figuras 24 e 25.

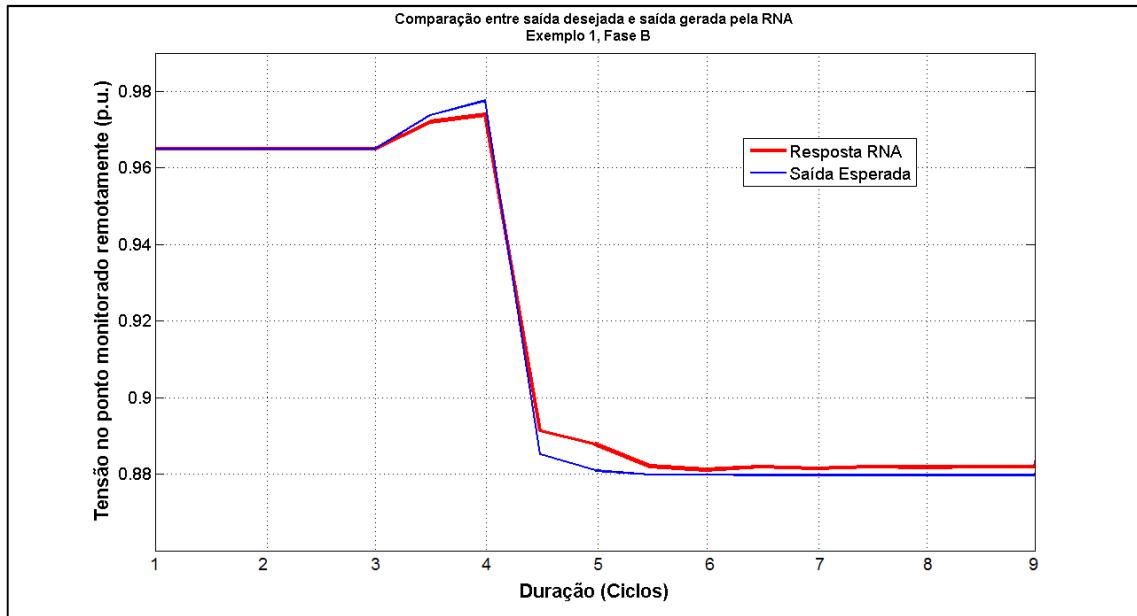


Figura 24 – Resultado da comparação entre saída esperada e saída gerada pela RNA da fase B, para o primeiro exemplo.

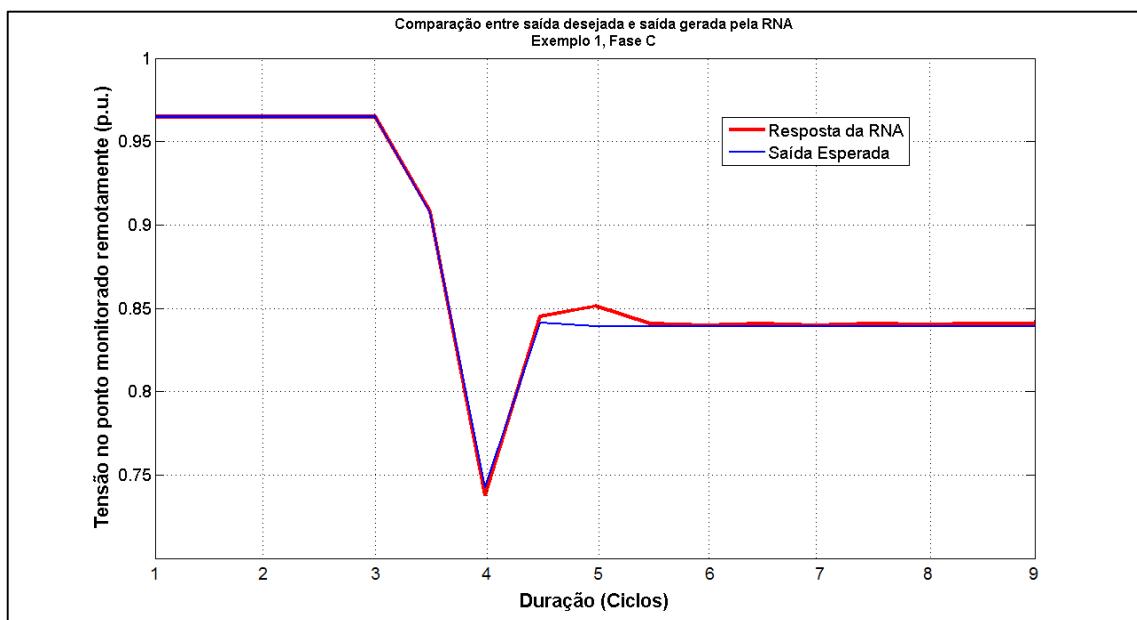


Figura 25 – Resultado da comparação entre saída esperada e saída gerada pela RNA da fase C, para o primeiro exemplo.

Constata-se que para algumas (esporádicas) amostras, a RNA acaba se equivocando e fornecendo resultados diferentes do esperado. Entretanto, afirma-se que este erro é na maioria das vezes da ordem de 0,02 p.u.

5.3.2 – Aplicação de falta, exemplo 2

Neste segundo exemplo, afirma-se que as saídas para as fases *A* e *B* devem caracterizar elevações de tensão acima de 1,1p.u. e, para a fase *C*, uma interrupção da tensão (níveis de tensão próximos de 0p.u.). Este panorama está exposto nas Figuras de 26 a 28.

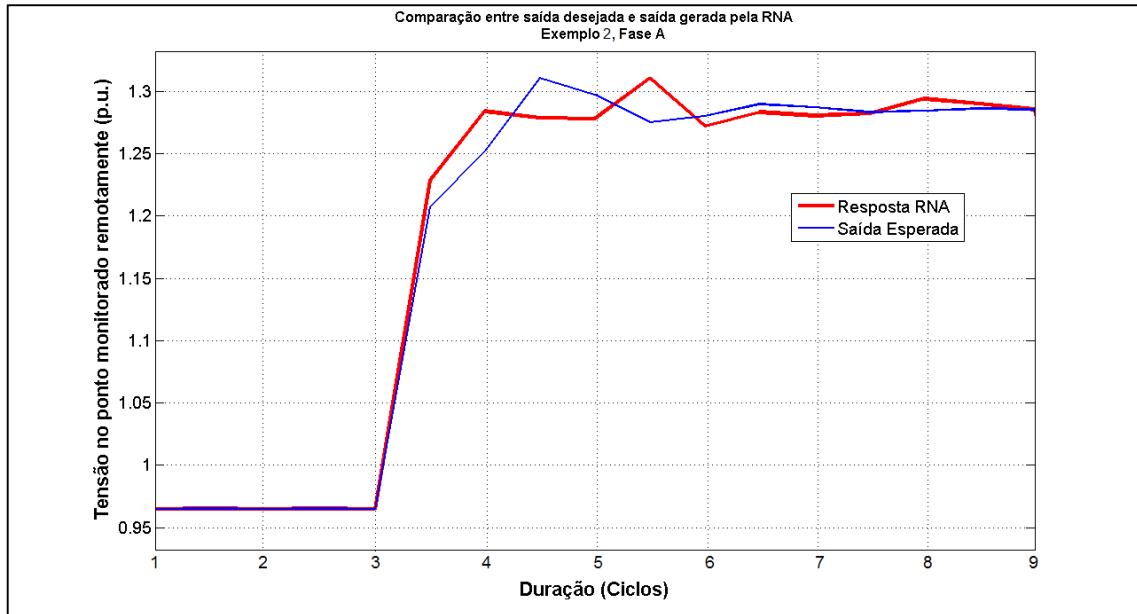


Figura 26 – Resultado da comparação entre saída esperada e saída gerada pela RNA da fase A, para o segundo exemplo.

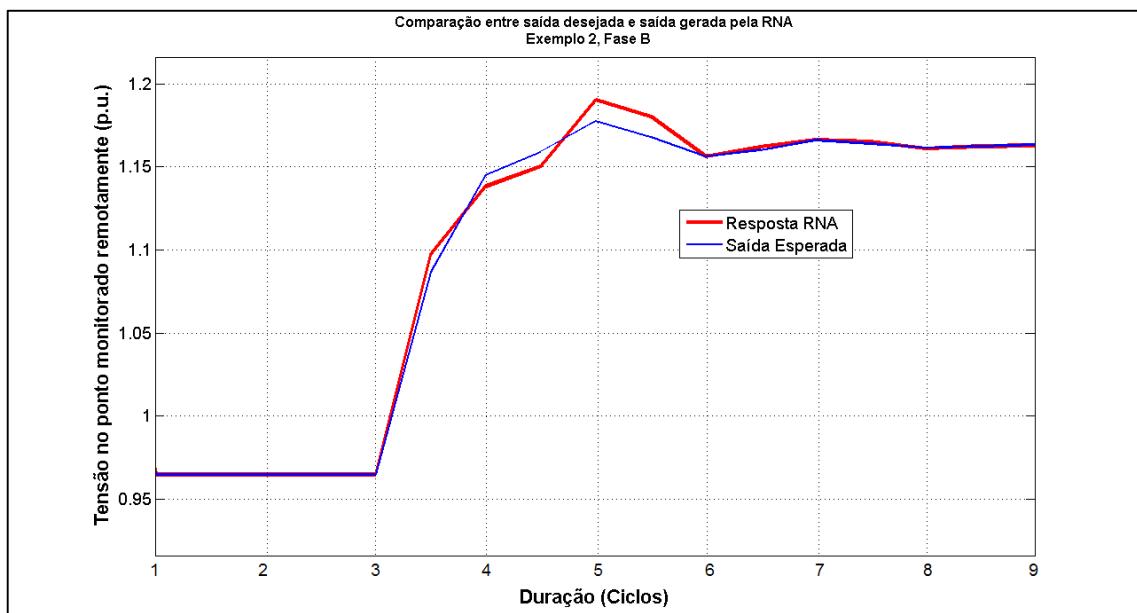


Figura 27 – Resultado da comparação entre saída esperada e saída gerada pela RNA da fase B, para o segundo exemplo.

Embora as RNAs para as fases *A* e *B* tenham oscilado um pouco mais em relação ao primeiro

exemplo, o desempenho da RNA da fase *C* demonstra que a estratégia de monitoramento remoto também é capaz de detectar variações de tensão de magnitudes elevadas com significativa precisão, conforme revela a Figura 28 a seguir.

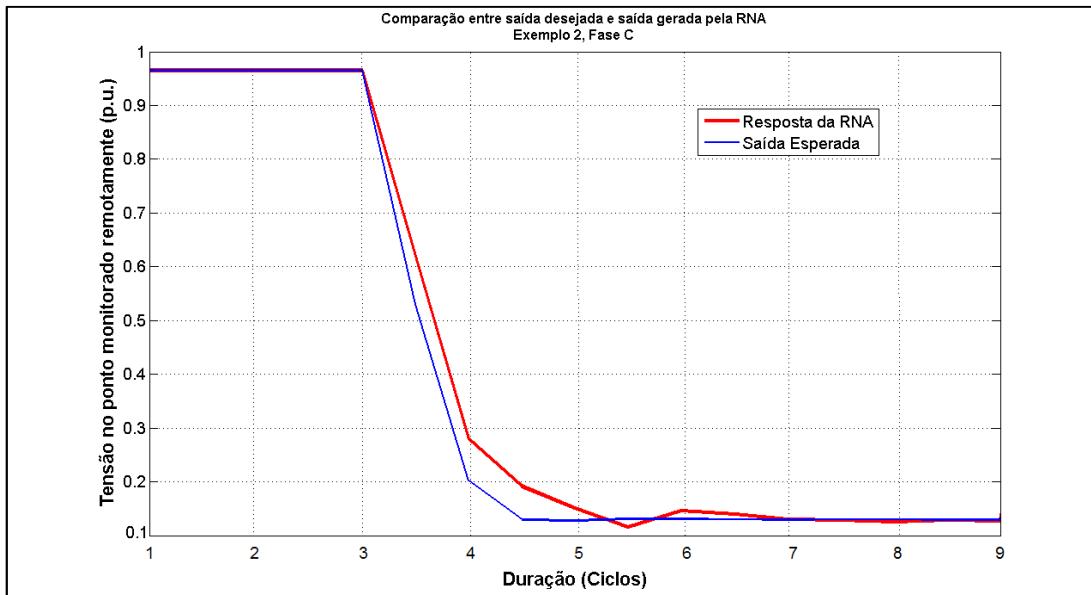


Figura 28 – Resultado da comparação entre saída esperada e saída gerada pela RNA da fase *C*, para o segundo exemplo.

5.3.3 – Aplicação de falta, exemplo 3

Para o exemplo 3, afirma-se que a saída para a fase *A* deve apontar um afundamento de tensão. Já a fase *B* deve caracterizar elevações de tensão acima de 1,1p.u. e, a fase *C*, um afundamento de tensão. Esta situação está exposta nas Figuras de 29 a 31.

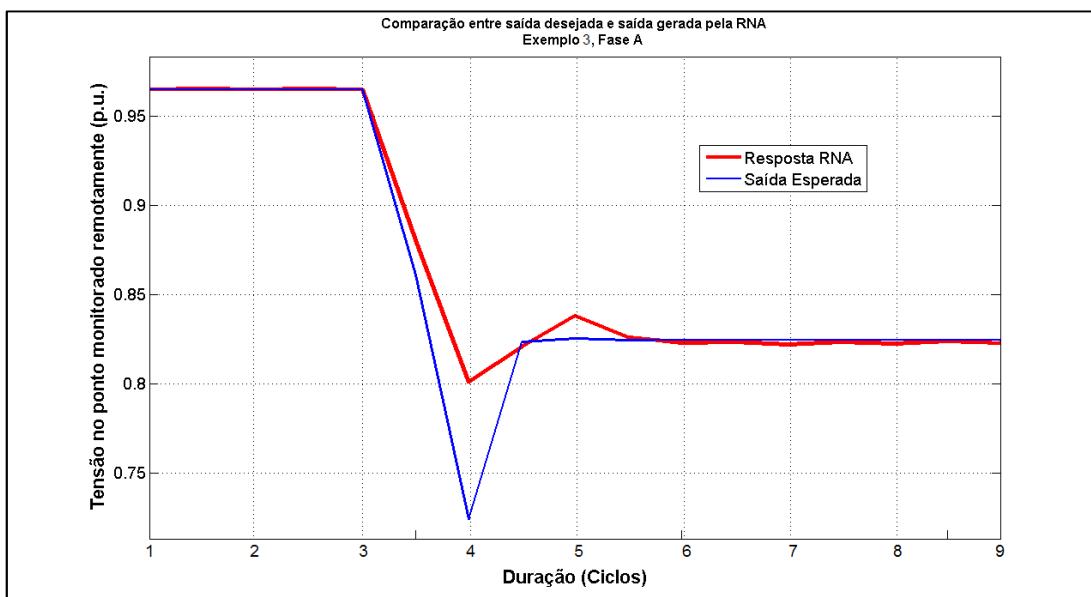


Figura 29 – Resultado da comparação entre saída esperada e saída gerada pela RNA da fase *A*, para o terceiro exemplo.

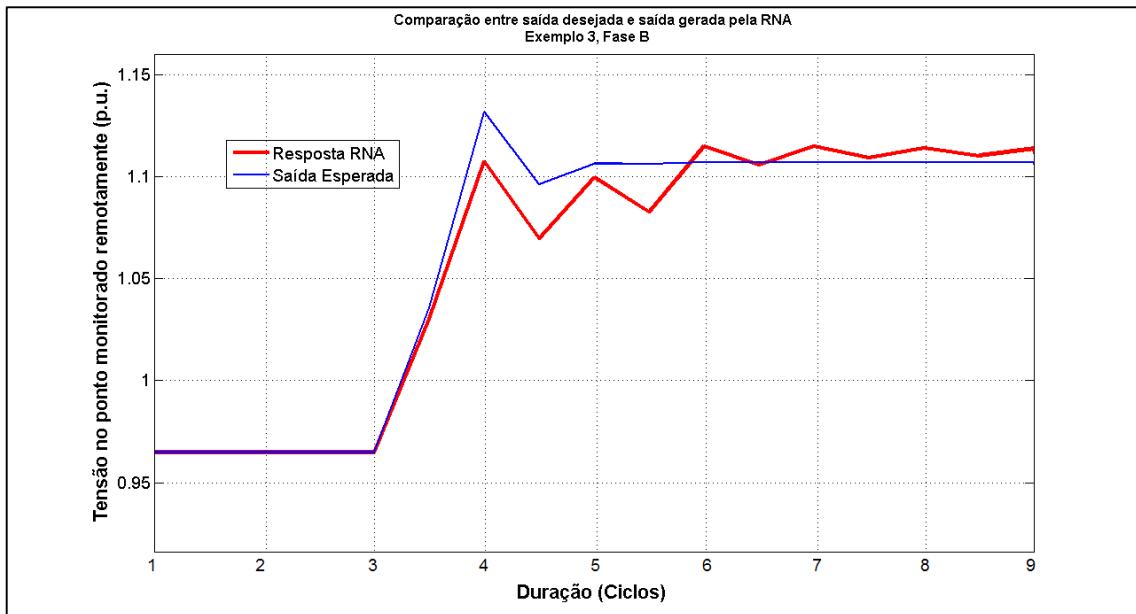


Figura 30 – Resultado da comparação entre saída esperada e saída gerada pela RNA da fase B, para o terceiro exemplo.

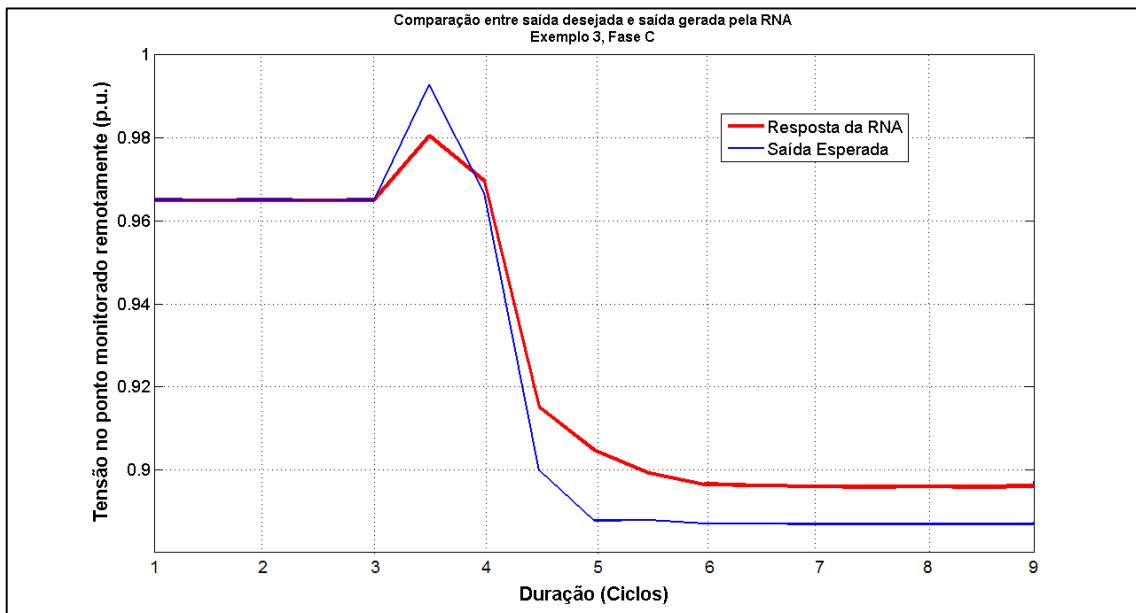


Figura 31 – Resultado da comparação entre saída esperada e saída gerada pela RNA da fase C, para o terceiro exemplo.

Neste terceiro exemplo, é possível verificar da Figura 29, que na fase A, a rede forneceu uma saída com um erro ligeiramente mais elevado, situando-se por volta de 0,07p.u., sendo que a partir do sexto ciclo (condição de pós-falta), esta voltou a gerar valores praticamente idênticos ao esperado. Para as demais fases, o desempenho foi semelhante aos exemplos anteriormente apresentados.

5.3.4 – Índice de acertos das RNAs.

Os histogramas apresentados nesta seção relacionam o índice de acerto das RNAs com as amostras de treinamento. As figuras de 32 a 34 trazem os histogramas das RNAs do sistema trifásico para erros menores do que 0,05p.u.

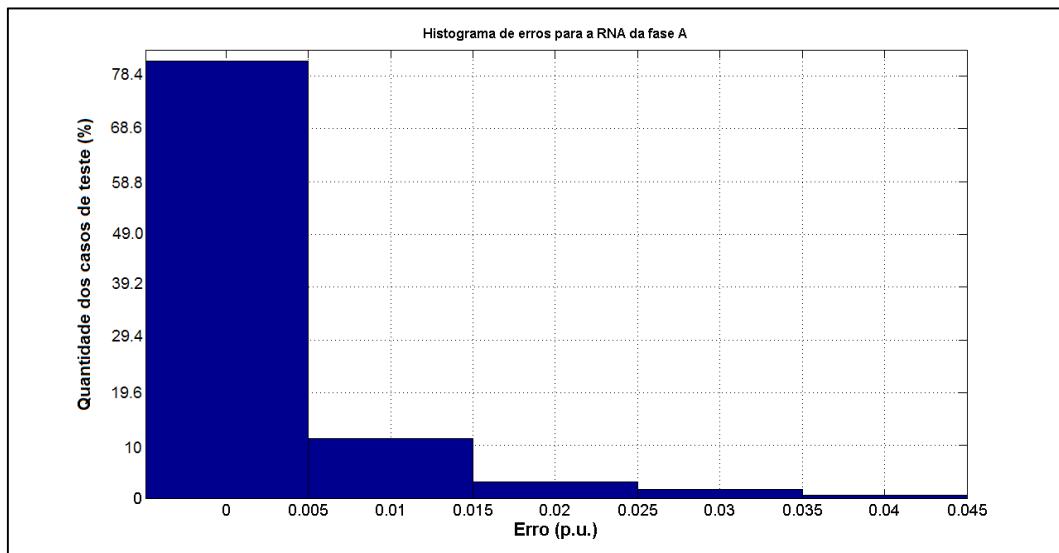


Figura 32 – Histograma relacionando a quantidade de casos de testes com a magnitude dos erros entre resposta esperada e resposta gerada pela RNA da fase A

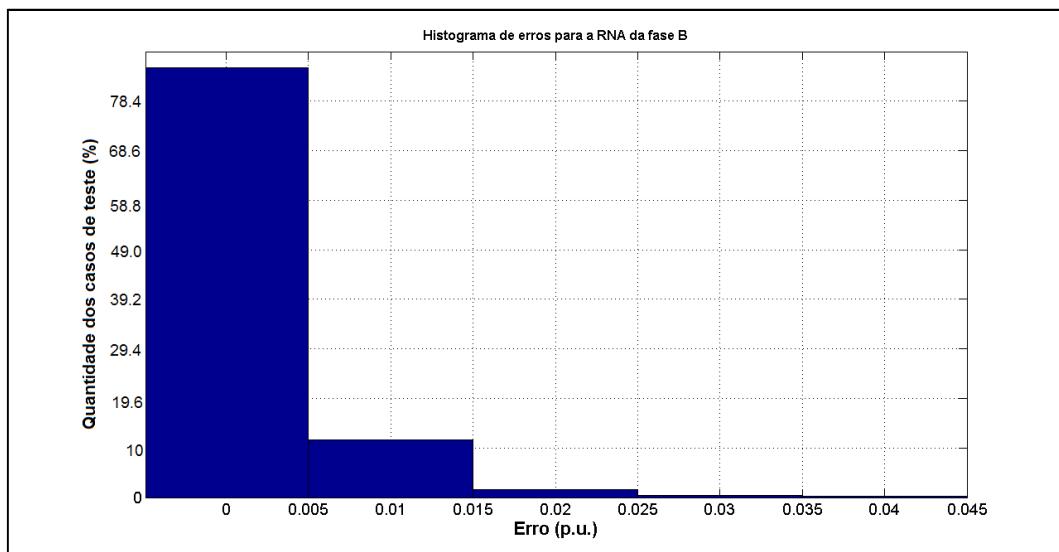


Figura 33 – Histograma relacionando a quantidade de casos de testes com a magnitude dos erros entre resposta esperada e resposta gerada pela RNA da fase B

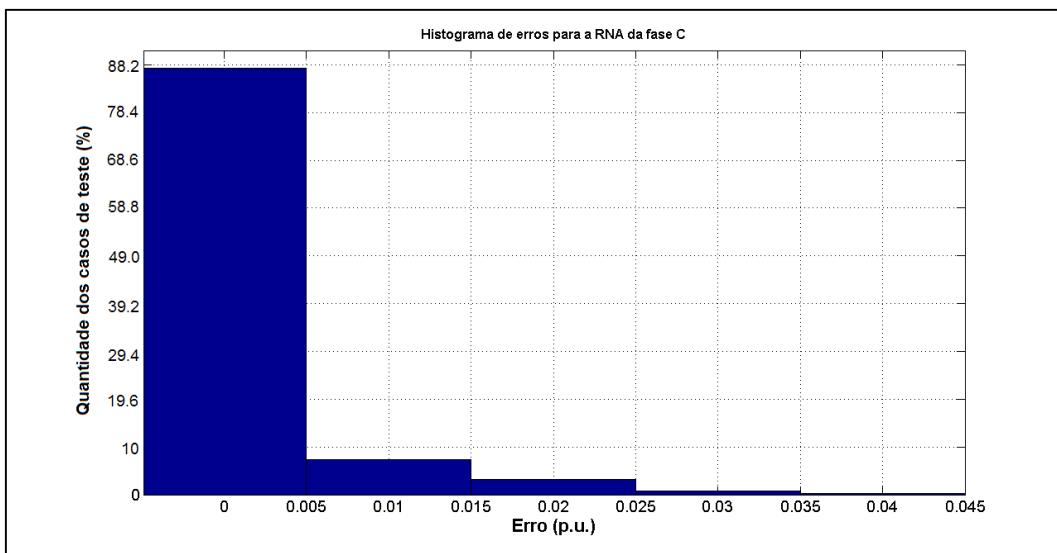


Figura 34 – Histograma relacionando a quantidade de casos de testes com a magnitude dos erros entre resposta esperada e resposta gerada pela RNA da fase C

Os resultados observados, quando se analisou os erros entre a resposta esperada e a resposta fornecida pelas RNAs para magnitudes menores do que 0,05p.u. (ou 5%), revelam que 97,45% dos casos de teste para a fase A, 98,82% para a fase B e 98,72% para a fase C, apresentaram erros menores do que 0,05p.u. As RNAs apresentaram, portanto, um índice de acerto significativo. Entretanto, um estudo preliminar acerca da obtenção de uma faixa de erro que represente fielmente o desempenho das três RNAs, quando uma possível aplicação real é considerada, não deve ser descartado, devendo ser incluído considerações referentes a um melhor condicionamento dos sinais em análise.

Capítulo 6 – Conclusões

Com este trabalho, foi possível apresentar uma estratégia alternativa de monitoramento de tensão em um determinado ponto de interesse no sistema elétrico. Esta estratégia tem como base a ferramenta inteligente de RNAs. Através do monitoramento das formas de onda de tensão e corrente das três fases do sistema, através do medidor presente na subestação, foi mostrado que existe a possibilidade de se monitorar remotamente os valores eficazes das tensões em pontos distantes do medidor da subestação, sem a necessidade de se empregar medidores extras para esta tarefa.

Um sistema de distribuição real, previamente modelado computacionalmente foi de vital importância ao desenvolvimento e validação da estratégia proposta. A obtenção da base de treinamento das RNAs, presentes no monitoramento de cada uma das fases do ponto remoto de interesse, procedeu de maneira a se obter uma boa representação das características do sistema de distribuição, sendo para tanto simuladas diversas condições de falta em vários pontos do sistema. Com os dados provenientes destas condições de faltas, formou-se uma base de treinamento para as RNAs. Durante os estudos, o principal desafio foi o de se encontrar uma maneira adequada para apresentar os padrões de treinamento às RNAs de tal forma que o sistema elétrico em questão fosse mais bem representado. A melhor maneira encontrada foi a de se fornecer valores eficazes das tensões e correntes das três fases como entrada para a RNA. O cálculo destas grandezas foi feito utilizando-se uma técnica de janelamento dos sinais de tensão e corrente provenientes das simulações de falta.

O treinamento das RNAs em questão prosseguiu utilizando-se dois tipos de algoritmos de treinamento. Sendo estes o algoritmo *back-propagation* e o algoritmo de *Levenberg-Marquardt*. Dentre os dois métodos de treinamento, verificou-se que o treinamento de *Levenberg-Marquardt* se configurou como o mais adequado para o emprego da técnica proposta.

Com a arquitetura da RNA eleita, verificou-se que o índice de acerto das RNAs das três fases foi superior a 97%, sendo que a magnitude dos erros, para esta porcentagem, é inferior a 0,05p.u. Este fato confirma que as RNAs empregadas na estratégia de monitoramento remoto, possuem significativo índice de acerto de acordo com a faixa de erro adotada. Entretanto, uma análise mais aprofundada deve ser considerada para se computar os erros envolvidos no condicionamento dos sinais, de modo a se obter um referencial mais preciso para a análise do desempenho geral das três RNAs.

Para complementar o estudo é recomendado uma análise para os demais tipos de falta e a inclusão da taxa de falhas das linhas do sistema de distribuição.

Além do que foi apresentado acima, este trabalho de conclusão de curso possibilitou um aprofundamento dos conhecimentos relacionados às RNAs e à QEE, proporcionando também o desenvolvimento de certas habilidades de investigação e posicionamento crítico.

Contudo, cabe ressaltar que alguns objetivos iniciais como a obtenção de áreas de vulnerabilidades associadas ao sistema elétrico em estudo necessitam de maior aprofundamento em pesquisa, podendo ser o objeto de um trabalho futuro. Além disso, é plausível considerar o

desenvolvimento de uma metodologia para a localização de faltas ao longo do sistema de distribuição estudado utilizando RNAs.

Acredita-se que o objetivo principal foi alcançado, e o desenvolvimento de uma estratégia de monitoramento remoto da tensão se revelou viável, tanto do ponto de vista técnico como econômico.

Referências bibliográficas

AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA – ANEEL, **Procedimentos de Distribuição de Energia Elétrica no Sistema Elétrico Nacional - PRODIST: Módulo 8 – Qualidade da Energia Elétrica.** [S.l.: s.n.], 2009.

BOLLEN, M.H.J; GU, I.Y.H . **Signal Processing of Power Quality Disturbances.** Hoboken, John Wiley & Sons, Inc, 2006, 861p.

BOLLEN, M.H.J. The Influence of Motor Reacceleration on Voltage Sags. **IEEE Transactions on Industry Applications**, v.31, 4, p. 667-674, julho/agosto, 1995.

BOLLEN, M.H.J; VERDE, P. A Framework for Regulation of RMS Voltage and Short-Duration Under and Overvoltages. **IEEE Transactions on Power Delivery**, v. 23, 4, p. 2105-2112, outubro, 2008.

CARPINELLI, G.; PERNA, D. C.; CARAMIA, P.; VARILONE, P.; VERDE, P. Methods for Assessing the Robustness of Electrical Power Systems Against Voltage Dips. **IEEE Transactions on Power Delivery**, v.24, 1, p. 43-51, janeiro, 2009.

DEMUTH, H.; BEALE, M.; HAGAN, M. **Neural Network Toolbox 5 User's Guide.** [S.l.], The MathWorks, Inc, 2007.

DEVARAJ, D.; RHADIKA, P.; SUBASRI, V.; KANAGAVALLI, R. Power Quality Monitoring using Wavelet Transform and Artificial Neural Networks. In: INDIA INTERNATIONAL CONFERENCE ON POWER ELECTRONICS, 2006, Chennai, 2006, p. 425-430.

DUGAN, R. C.; MCGRANAGHAN, M. F.; SANTOSO, S.; BEATY, H. W. **Electrical Power Systems Quality.** 2.ed. Nova Iorque, McGraw-Hill, 2003, 568p.

FERNANDES, R. A. S. **Identificação de Fontes de Correntes Harmônicas por Redes Neurais Artificiais.** 2009. 105f. Dissertação (Mestrado em Engenharia Elétrica) – Escola de Engenharia de São Carlos (EESC), Universidade de São Paulo, São Carlos – SP, 2009.

GOSWAMI, A. K.; GUPTA, C. P.; SINGH, G. K. Area of Vulnerability for Prediction of Voltage Sags by an analytical Method in Indian Distribution Systems. In: ANNUAL IEEE INDIA CONFERENCE, 2008, Kanpur, vol.2, p. 406 – 411.

INSTITUTE OF ELECTRICAL AND ELECTRONIC ENGINEERS – IEEE, **Recommended Practice for Monitoring Electric Power Quality**: IEEE Std. 1159-1995. [S.l.: s.n.], 1995.

INTERNATIONAL ELECTROTECHNICAL COMMISSION – IEC, **Voltage Dips, Short Interruptions and Voltage Variations Immunity Tests**: IEC Std. 61000-4-11. [S.l.: s.n.], 2001.

KAGAN, N.; ROBBA, E. J.; SCHMIDT, H. P. **Estimação de Indicadores de Qualidade da Energia Elétrica**. 1ed. São Paulo, Edgard Blücher, 2009.

KAGAN, N.; OLIVEIRA, C. B. D.; ROBBA, E. J. **Introdução aos Sistemas de Distribuição de Energia Elétrica**. 1ed. São Paulo, Edgard Blücher, 2005.

KYEI, J.; AVYANAR, R.; HEYDT, G.; THALLAN, R.; BLEVINS, J.; The Design of Power Acceptability Curves. **IEEE Transactions on Power Delivery**, v.17, 3, p. 828-833, julho, 2002.

LEE, G.; M. ALBU, M.; T. HEYDT, Gerald. A Power Quality Index Based on Equipment Sensitivity, Cost, and Network Vulnerability. **IEEE Transactions on Power Delivery**, v.19, 3, p. 1504-1510, julho, 2004.

LIRA, M. M. S.; JUNIOR, M. A. C.; AQUINO, R. R. B.; VALENÇA, M. J. S.; LEITÃO, J. J. A. L. Classificação de Distúrbios Elétricos Utilizando Wavelets, Componentes Principais e Redes Neurais Artificiais. In: XV CONGRESSO BRASILEIRO DE AUTOMÁTICA, 2004, Gramado, RS, Brasil.

MYO, T. A.; MILANOVIĆ, J. V.; GUPTA, C.P. Propagation of Asymmetrical Sags and the Influence of Boundary Crossing Lines on Voltage Sag Prediction. **IEEE Transactions on Power Delivery**, v.19, 4, p. 1819-1827, outubro, 2004.

NRS PROJECT MANAGEMENT AGENCY, **Electricity Supply - Quality of Supply Part 2**: Minimum Standards for Application by the National Electricity Regulator: NRS 048-2:1996. [S.l.: s.n.], 1996.

OLESKOVICZ, M. **Apostila do Curso de Qualidade da Energia Elétrica**. EESC – USP, São Carlos – SP, 2007.

PRIKLER, L.; HOIDALEN H.K. **ATP Draw Version 3.5 for Windows 9x/NT/2000/XP – User’s Manual**. Sinef Energy Research, Trondheim, Noruega, 2002.

RULE BOOK – ALTERNATIVE TRANSIENTS PROGRAM. [S.I], Leuven EMTP Center, 1987.

SILVA, K. M.; SOUZA, B.A.; BRITO, N. S. D. Fault Detection and Classification in Transmission Lines Based on Wavelet Transform and ANN. **IEEE Transactions on Power Delivery**, v. 21, 4, p. 2058-2063, outubro, 2006.

UPENDAR, J. GUPTA, C. P., SINGH, G. K. ANN Based Power System Fault Classification. In: TENCON 2008 – 2008 IEEE REGION 10 CONFERENCE, 2008, Hyderabad, p.1 – 6.

WANG, J.; CHEN, S.; LIE, T. T. System Voltage Sag Performance Estimation. **IEEE Transactions on Power Delivery**, v.20, 2, p. 1738-1747, abril, 2005.

WON, D.; AHN, S.; MOON, S. A Modified Sag Characterization Using Voltage Tolerance Curve for Power Quality Diagnosis. **IEEE Transactions on Power Delivery**, v.20, 4, p. 2638-2643, outubro, 2005.