

UNIVERSIDADE DE SÃO PAULO  
Escola de Engenharia de São Carlos  
Departamento de Engenharia Elétrica e de Computação

Fabício Silva Pires de Camargo

**Uma estimação alternativa, remota e continuada das  
variações de tensão em um sistema de distribuição  
utilizando redes neurais artificiais**

São Carlos

2012



**FABRÍCIO SILVA PIRES DE CAMARGO**

**Uma estimação alternativa, remota e continuada das  
variações de tensão em um sistema de distribuição  
utilizando redes neurais artificiais**

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

2012

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

C172u      Camargo, Fabrício Silva Pires de  
              Uma estimação alternativa, remota e continuada das  
variações de tensão em um sistema de distribuição  
utilizando redes neurais artificiais / Fabrício Silva  
Pires de Camargo; orientador Mário Oleskovicz. São  
Carlos, 2012.

Monografia (Graduação em Engenharia Elétrica com  
ênfase em Sistemas de Energia e Automação) -- Escola de  
Engenharia de São Carlos da Universidade de São Paulo,  
2012.

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

# FOLHA DE APROVAÇÃO

Nome: Fabricio Silva Pires de Camargo

Título: “Uma estimação alternativa, remota e continuada das variações de tensão em um sistema de distribuição utilizando redes neurais artificiais”

*Trabalho de Conclusão de Curso defendido e aprovado  
em 26/11/2012,*

*com NOTA 10,0 (dez, zero), pela Comissão Julgadora:*

**Prof. Dr. Mário Oleskovicz (Orientador)**  
**SEL/EESC/USP**

**Prof. Dr. José Carlos de Melo Vieira Júnior**  
**SEL/EESC/USP**

**Dr. Ulisses Chemin Netto**  
**SEL/EESC/USP**

**Coordenador da CoC-Engenharia Elétrica - EESC/USP:**  
**Prof. Associado Homero Schiabel**



À minha mãe, Helena, pelo apoio,  
dedicação, incentivo, investimento e por  
sempre acreditar nessa realização.





## **Agradecimentos**

Ao Professor Dr. Mário Oleskovicz, por aceitar o desafio da realização deste trabalho e também por acreditar no sucesso do trabalho confiando em meus esforços.

Ao Fernando Bambozzi Bottura por todo o apoio e suporte ao longo das etapas de desenvolvimento deste trabalho. Foi peça fundamental transmitindo conhecimento e experiências, incentivando mudanças, inovações e aplaudindo os acertos.

Ao Gabriel Rogatto pelo suporte, pelas diversas dicas e incentivo. E principalmente, pela amizade de longos anos.

Ao Rafael Atique Claudio pelas discussões filosóficas, divagações e pensamento crítico que foram fundamentais na elaboração desse trabalho.

Ao Marcos Vinícius Galli Casseb pelo companheirismo, pela amizade, pelo apoio e discussões fundamentais para o desenvolvimento constante.

A toda a equipe do Laboratório de Sistemas de Energia (LSEE) que contribuiu com cortesia, fornecendo soluções, ideias e incentivo.

A todos os professores, de todos os departamentos, que contribuíram para a minha formação acadêmica ao longo dos últimos anos.



## Sumário

Agradecimentos .....	IX
Lista de Figuras .....	XIII
Lista de Tabelas.....	XV
Resumo .....	XVII
Abstract.....	XIX
1. Introdução .....	1
1.1. Objetivos do trabalho.....	3
1.2. Apresentação do documento .....	3
2. Revisão Bibliográfica .....	5
2.1. Qualidade da energia elétrica .....	5
2.2. Redes neurais artificiais e ferramentas matemáticas aplicadas na análise de QEE ..	10
3. Redes neurais artificiais .....	15
3.1. Introdução às redes neurais artificiais.....	15
3.2 Principais arquiteturas de redes neurais artificiais supervisionadas .....	18
3.2.1 Redes de camada única .....	19
3.2.2 Redes de múltiplas camadas .....	20
3.3. Treinamento de Levenberg-Marquardt .....	22
4. Estimação do valor eficaz da tensão de uma carga de um sistema de distribuição por meio de redes neurais artificiais .....	25
4.1. Estimação do valor eficaz da tensão em uma carga (ponto de interesse) do SD via RNA .....	25
4.2 Procedimento para estimar a tensão eficaz em demais pontos de carga alocados no sistema de distribuição .....	29
5. Sistema elétrico de distribuição modelado.....	31
6. Compilação dos conjuntos de treinamento e validação das RNA .....	35
7. Desempenho da metodologia e monitoramento remoto inteligente das variações de tensão .....	41

7.1. Tensão eficaz medida no ponto MR1 .....	50
7.2. Tensão eficaz medida no ponto MR2 .....	51
7.3. Tensão eficaz medida no ponto MR3 .....	52
7.4. Tensão eficaz medida no ponto MR4 .....	53
7.5. Tensão eficaz medida no ponto MR5 .....	54
7.6. Tensão eficaz medida no ponto MR6 .....	55
Conclusão.....	57
Referências Bibliográficas.....	59
Anexo .....	61
Anexo 1 - Código de permuta aleatória das matrizes .....	61

## Lista de Figuras

Figura 1 - Curva <i>CBEMA</i> adaptada de Kyei et al (2002) .....	9
Figura 2 - Curva <i>ITIC</i> adaptada de Kyei et al (2002) .....	10
Figura 3 - Modelo matemático de um neurônio .....	16
Figura 4 - Comportamento da função de ativação do tipo linear por partes .....	17
Figura 5 - Comportamento da função de ativação hiperbólica .....	18
Figura 6 - Rede neural de camada única .....	19
Figura 7 – Rede neural de múltiplas camadas .....	21
Figura 8 - Representação da função booleana OU exclusivo (XOR).....	22
Figura 9 – Procedimento para monitorar remotamente um ponto (carga) de interesse dentro de um SD.....	26
Figura 10 – Fluxo das informações relacionadas ao procedimento de aplicação da metodologia de monitoramento remoto inteligente.....	28
Figura 11 – Aspecto da modelagem computacional do SD sob análise utilizando o <i>software ATP</i> .....	31
Figura 12 - Aspecto geral do SD modelado com a localização dos pontos de monitoramento remoto (MR <sub>n</sub> ), da subestação (SE) e dos pontos de aplicação de faltas elétricas (numerados de 1 a 20).....	36
Figura 13 - Detalhe da chave que simula o curto-circuito monofásico via interface gráfica <i>ATPDraw</i> .....	37
Figura 14 – Dados de entrada da tensão referente à Fase A apresentados à RNA antes da permutação aleatória .....	39
Figura 15 – Dados de entrada da corrente referente à Fase A apresentados à RNA antes da permutação aleatória .....	39
Figura 16 - Dados de entrada da tensão referente à Fase A apresentados à RNA após a permutação aleatória .....	40
Figura 17 - Dados de entrada da corrente referente à Fase A apresentados à RNA após a permutação aleatória .....	40
Figura 18 - Histograma de erros para o ponto de monitoramento remoto MR1 .....	44
Figura 19 - Histograma de erros para o ponto de monitoramento remoto MR2.....	45
Figura 20 - Histograma de erros para o ponto de monitoramento remoto MR3.....	45
Figura 21 - Histograma de erros para o ponto de monitoramento remoto MR4.....	46
Figura 22 - Histograma de erros para o ponto de monitoramento remoto MR5.....	47
Figura 23 - Histograma de erros para o ponto de monitoramento remoto MR6.....	47

Figura 24 - Comparação entre os valores das tensões eficazes estimadas e seus respectivos valores esperados para o ponto MR1.....	51
Figura 25 - Comparação entre os valores das tensões eficazes estimadas e seus respectivos valores esperados para o ponto MR2.....	52
Figura 26 - Comparação entre os valores das tensões eficazes estimadas e seus respectivos valores esperados para o ponto MR3.....	53
Figura 27 - Comparação entre os valores das tensões eficazes estimadas e seus respectivos valores esperados para o ponto MR4.....	54
Figura 28 - Comparação entre os valores das tensões eficazes estimadas e seus respectivos valores esperados para o ponto MR5.....	55
Figura 29 - Comparação entre os valores das tensões eficazes estimadas e seus respectivos valores esperados para o ponto MR6.....	56

## Lista de Tabelas

Tabela 1 - Classificação das variações de tensão de curta e de longa duração.....	6
Tabela 2 - Parâmetros da fonte de tensão modelada.....	32
Tabela 3 - Características do modelo RL mutuamente acoplado, em série com a fonte de tensão.....	32
Tabela 4 - Principais parâmetros do transformador de potência do SD.....	33
Tabela 5 - Características dos bancos de capacitores do SD .....	33
Tabela 6 - Exemplos de dados das carga do SD .....	34
Tabela 7 - Parâmetros de dois trechos de condutores dos alimentadores para sequência zero.....	34
Tabela 8 - Parâmetros de dois trechos de condutores dos alimentadores para sequência positiva .....	34
Tabela 9 – Configuração dos curtos-circuitos simulados para obtenção da base de treinamento das RNA.....	38
Tabela 10 - Dados do desempenho da aplicação da metodologia proposta em MR1. ....	41
Tabela 11 - Dados do desempenho da aplicação da metodologia proposta em MR2. ....	41
Tabela 12 - Dados do desempenho da aplicação da metodologia proposta em MR3. ....	42
Tabela 13 - Dados do desempenho da aplicação da metodologia proposta em MR4. ....	42
Tabela 14 - Dados do desempenho da aplicação da metodologia proposta em MR5. ....	42
Tabela 15 - Dados do desempenho da aplicação da metodologia proposta em MR6. ....	42
Tabela 16 - Tempo de treinamento das RNA em MR1.....	48
Tabela 17 - Tempo de treinamento das RNA em MR2.....	49
Tabela 18 - Tempo de treinamento das RNA em MR3.....	49
Tabela 19 - Tempo de treinamento das RNA em MR4.....	49
Tabela 20 - Tempo de treinamento das RNA em MR5.....	49
Tabela 21 - Tempo de treinamento das RNA em MR6.....	50





## Resumo

CAMARGO, F. S. P. **Uma estimação alternativa, remota e continuada das variações de tensão em um sistema de distribuição utilizando redes neurais artificiais**, 2012. 84f. 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, 2012.

O processo de monitoramento da energia elétrica fornecida às cargas alocadas em um sistema de distribuição está diretamente ligado à manutenção da qualidade da energia elétrica. Entretanto, alguns entraves são observados na execução deste monitoramento, tais como a elevada complexidade em se obter um panorama representativo do sistema, e o respectivo investimento financeiro associado a tal procedimento. Neste sentido, este trabalho apresenta um método de monitoramento remoto da tensão eficaz em uma ou mais cargas de interesse do sistema elétrico por meio de redes neurais artificiais. Para o desenvolvimento da técnica, utilizou-se uma base de dados, compilada a partir de um sistema de distribuição real devidamente modelado no *software ATP (Alternative Transients Program)*, de maneira a treinar redes neurais artificiais específicas e capazes de estimar a tensão eficaz entregue às cargas analisadas. Ressalta-se que as redes neurais estimam os valores eficazes nas cargas monitoradas tomando-se apenas medidas das tensões e correntes trifásicas na subestação do sistema de distribuição. Os resultados relacionados ao desempenho das redes neurais indicam a eficácia e a possibilidade de se generalizar o método para todas as cargas no sistema, constituindo, portanto, uma alternativa complementar ao monitoramento convencional da qualidade da energia elétrica.

**Palavras Chaves:** Qualidade da energia elétrica, sistema de distribuição de energia elétrica, monitoramento remoto, variações de tensão de curta duração, variações de tensão de longa duração, redes neurais artificiais.



## Abstract

CAMARGO, F. S. P. An alternative, remote and continuous estimation of voltage variations in a distribution system using artificial neural networks, 2012. 84p. 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, 2012.

The process of monitoring the power supplied to loads placed in a distribution system is directly linked to maintaining the power quality. However, some barriers are observed in carrying out the monitoring such as the increased complexity in obtaining a representative picture of the system, and the respective financial investment associated with such a procedure. In this sense, this work presents a method for remote monitoring of the root mean square (RMS) voltage on one or more important loads of the power system through artificial neural networks. For the technique development, a database was built from a real distribution system which was properly modeled in the software ATP (Alternative Transients Program). This database was used to train artificial neural networks that are able to estimate the RMS voltage delivered to specific analyzed loads. It is noteworthy that artificial neural networks estimate the RMS values of loads monitored by taking only measures of the three phase voltages and currents at the power system substation. The results related to the performance of neural networks indicate the effectiveness and the possibility of extending the method to all loads in the system, thus constituting a complementary and alternative power quality monitoring process.

**Keywords:** Power quality, distribution system, power quality, remote monitoring, short-term voltage variations, long-term voltage variations and artificial neural networks.



## 1. Introdução

Pode-se definir a qualidade da energia elétrica (QEE) como sendo a disponibilidade de energia na forma de onda puramente senoidal sem que haja alterações em sua amplitude e frequência (Dugan et al, 2003). No entanto, esta condição desejada, frequentemente, não é observada na prática. Em um sistema elétrico de potência (SEP) há diversos problemas e diferentes condições de operações que podem ocorrer e, por consequência, depreciar a QEE fornecida. Dentre os problemas mencionados, podem-se destacar os tipos de cargas acopladas ao sistema, a inserção de elementos que fazem uso de eletrônica de potência, os quais, por exemplo, podem inserir distorção harmônica na rede. Cabe salientar que harmônicos são componentes de uma onda periódica cuja frequência é um valor múltiplo inteiro da frequência fundamental (60Hz no caso do sistema elétrico brasileiro). Já a distorção harmônica se caracteriza pela injeção de corrente elétrica não linear em frequências diferentes da fundamental por meio de equipamentos, em geral com eletrônica de potência envolvida, acoplados ao sistema. Também se pode citar como problema que deprecia a QEE em um SEP a ocorrência de faltas (curtos-circuitos) ao longo do sistema de distribuição, dentre outros (Dugan et al, 2003).

Como consequência da falta de QEE no SEP, é possível observar a ocorrência do mau funcionamento da carga alimentada e, dependendo de sua sensibilidade, pode ocorrer severa deterioração e inutilização da mesma. Além disso, em alguns casos, ocorrem perdas de processos industriais, cuja recuperação não será imediata, refletindo de imediato em prejuízos econômicos consideráveis, já que, elevadas quantidades de produtos são perdidos e fases de processos interrompidas (Dugan et al, 2003).

A tendência de uma exigência por uma melhor QEE fornecida, seja por parte dos consumidores ou das concessionárias de energia elétrica, é crescente na atualidade. Isto é, na década dos anos 2010. Assim como os consumidores industriais, os consumidores comerciais e residenciais têm se tornado mais cientes dos seus direitos, e demandam serem supridos por energia elétrica com qualidade. Isso se observa pelo surgimento e consolidação de normatizações que visam assegurar a QEE aos consumidores conforme descrito no módulo 1 do PRODIST (Procedimento de Distribuição de Energia Elétrica no Sistema Elétrico Nacional) (ANEEL, 2012a). Assim, fica evidente a preocupação com assuntos relacionados à QEE e suas possíveis implicações legais e econômicas.

Entre os fenômenos que comprometem a QEE, destaca-se, pela frequência (número) de ocorrência, o afundamento de tensão. Dados apontam que 87% de todas as ocorrências de fenômenos relacionados à QEE dizem respeito a este tipo de distúrbio (Goldstein e Speranza, 1982).

Entre as possíveis causas dos afundamentos de tensão, está a ocorrência de faltas (curtos-circuitos) ao longo do sistema elétrico de potência, dado que o afundamento de tensão no ponto da falta se propaga ao longo da linha (Bollen et al, 2006)

Neste contexto, tem-se que cargas sensíveis alocadas em diferentes pontos de um SEP podem vir a operar inadequadamente sob certas variações de tensão (afundamentos). Como fato, tem-se que distintas situações de faltas ocorridas sobre o sistema elétrico podem vir a caracterizar diferentes níveis de tensão abaixo do exigido, que, por sua vez, devem ser avaliados e, na medida em que as condições técnicas permitirem, mitigados.

Desta forma, garantir níveis aceitáveis de QEE é fundamental para que cargas sensíveis alocadas em diferentes pontos do sistema elétrico possam operar de forma adequada. Todavia, o processo de avaliação da QEE, no cenário atual, apresenta-se como um procedimento não trivial e de investimento financeiro relativamente considerável.

Portanto, o desenvolvimento de metodologias que possam ser técnica e financeiramente aplicadas ao monitoramento dos distúrbios recorrentes ao SEP é de fundamental importância. Um dos principais problemas para a consolidação das metodologias observadas até então é a falta de informação relevante sobre quais localidades fornecem a melhor representação da situação de operação enfrentada pelo sistema de energia elétrica sob o ponto de vista da QEE.. Ademais, o caráter estocástico inerente à ocorrência dos distúrbios de QEE em um SEP implica em se considerar a topologia do sistema, assim como manipular outros parâmetros menos controláveis para se obter uma estratégia de monitoramento eficaz (Bollen e Gu, 2006).

Sabendo das dificuldades de se realizar o monitoramento de distúrbios de QEE, o alto custo de implantação de medidores de QEE e a crescente demanda por parte de todos os tipos de consumidores de energia elétrica por um alto nível de QEE, propõe-se o desenvolvimento de uma metodologia que seja capaz de fornecer dados que demonstrem como o SEP reage, em cada um dos seus pontos, utilizando uma importante técnica de inteligência artificial, as redes neurais artificiais (RNA). O intuito é monitorar os níveis de tensão eficaz em um, ou mais, pontos de interesse dentro de um SD qualquer, para averiguar os níveis QEE, relacionados principalmente aos afundamentos de tensão. A metodologia visa, a partir das correntes e tensões eficazes medidas na subestação do SD, estimar os níveis de tensão em um ponto qualquer de interesse dentro deste sistema. Define-se ponto de interesse como sendo uma carga (consumidor) pertencente ao SD em estudo, na qual é necessário realizar uma medição de forma continuada e avaliação dos níveis de tensão.

## 1.1. Objetivos do trabalho

O principal objetivo do trabalho é aprimorar e generalizar uma metodologia que baseada nos valores eficazes das tensões e correntes trifásicas, medidos na subestação de um SD de energia, seja capaz de quantificar o valor eficaz da tensão em um ponto genérico, definido e de interesse do usuário (que neste é representado pela figura da concessionária de distribuição de energia), dentro do SD em questão. Desta maneira, pelo valor da tensão eficaz apontado para um ponto qualquer sobre o SD, poderá ser realizada uma análise remota e continuada de possíveis problemas relacionados à QEE.

Cabe colocar que a metodologia a ser aprimorada e generalizada fará uso de RNA. Estudos iniciais com relação a topologia, arquitetura e algoritmos de treinamentos das RNA já foram determinados e apresentados anteriormente em Bottura (2010) e serão tomados como base para a otimização e generalização do procedimento de monitoramento descrito sobre o SD.

Com base nos dados representativos do SD já utilizados em Bottura (2010), um novo banco de dados será formulado buscando atender a uma generalização a ser aplicada de forma independente a mais de um ponto de monitoramento sobre o SD em análise. Este novo banco de dados será compilado por meio de simulações de faltas no SD modelado via o *software ATP (Alternative Transients Program)* por meio de uma interface gráfica (*ATPDraw*) (Leuven EMTP Center, 1987). Pela reestruturação da forma como os dados serão apresentados às RNA, será possível alcançar o desejado aprimoramento e generalização de todo o processo de aplicação da metodologia. Cabe ressaltar que a generalização ocorrerá a partir da comprovação da eficácia da metodologia por meio de aplicação do monitoramento da tensão para diversos pontos de análise ao longo do SD em estudo, via RNA, a partir de medidas realizadas na subestação do mesmo.

## 1.2. Apresentação do documento

O presente documento apresenta, além deste capítulo introdutório, mais sete capítulos. O capítulo dois apresenta uma revisão bibliográfica acerca dos principais conceitos relacionados à QEE e as recentes pesquisas desenvolvidas nesta área. Na sequência, o capítulo três traz os principais aspectos teóricos sobre RNA. O capítulo quatro apresenta a metodologia de monitoramento da tensão eficaz dentro do SD em estudo. O capítulo cinco introduz o SD previamente modelado computacionalmente que será objeto de estudo. O capítulo seis apresenta a compilação dos conjuntos de treinamento e validação das RNA que são utilizadas ao longo deste trabalho. Além disso, são demonstrados os casos de curto-circuito utilizados, os pontos de monitoramento remoto e também todo o

trabalho de compilação e expansão do banco de dados das RNA para pontos genéricos sobre o sistema elétrico.

Para o capítulo sete, reservva-se uma análise do desempenho da metologologia proposta. Neste capítulo, o desempenho da metodologia é demonstrado por meio da apresentação de tabelas com os índices de acertos das RNA para três faixas de erros determinadas, bem como pelos respectivos histogramas de erros, e pela avaliação da acuracidade das mesmas por meio da escolha de um ponto de aplicação de um caso de falta elétrica específico. Neste cenário, são averiguados graficamente os resultados produzidos por cada uma das RNA em comparação com o resultado esperado. Ademais, são exibidos resultados relacionados ao maior erro atingido pelas RNA e também os tempos de treinamento das mesmas.

Finalmente, o capítulo oito traz as principais conclusões obtidas com a realização deste trabalho e também tópicos de interesse para o aprimoramento e continuidade da metodologia proposta nesta pesquisa.



## **2. Revisão Bibliográfica**

O presente capítulo traz os principais fundamentos teóricos relacionados à QEE, salientando-se os principais distúrbios que influenciam a mesma no âmbito da tensão fornecida. Além disso, também são exploradas outras pesquisas desenvolvidas na atualidade que fazem uso de ferramentas inteligentes, como as RNA, por exemplo, e que se apresentam de grande relevância para o desenvolvimento deste campo de pesquisa.

### **2.1. Qualidade da energia elétrica**

Na atualidade, a QEE caracteriza um fator determinante na competitividade em praticamente todos os setores industriais e de serviços. No entanto, ao longo das últimas décadas o setor de energia elétrica vem atravessando problemas oriundos, principalmente, da alteração da natureza de suas cargas consumidoras, desregulamentação do setor elétrico em curso a nível mundial, proliferação de autoprodutores, surgimento de novas tecnologias de geração e a crescente pressão por adoção de tais tecnologias em função dos fatores ambientais. Esses fatores têm causado alterações significantes no modo de operação do sistema elétrico, o que pode implicar em alterações consideráveis no fornecimento da QEE.

Nos SD, a energia elétrica é transportada por extensas malhas de linhas aéreas e / ou subterrâneas de distribuição até ser entregue ao consumidor final. Ao longo deste processo, a energia elétrica percorre grandes distâncias e, por razões operacionais, sua tensão pode ser reduzida e / ou elevada por transformadores alocados sobre o SEP. Neste processo, manter o nível de tensão dentro de limites operacionais aceitáveis é uma tarefa árdua que requer medidas de controle e acompanhamento de órgãos de fiscalização, bem como das concessionárias fornecedoras de energia elétrica (Kagan et al, 2005).

A fim de avaliar se um SEP está operando dentro das condições nominais, duas grandezas elétricas básicas são frequentemente monitoradas: a frequência e a tensão. No Brasil, é aceitável que a frequência situe-se em  $60,0\text{Hz} \pm 0,5\text{Hz}$  conforme se estabelece no módulo 8 do PRODIST (ANEEL, 2012b). Já quanto à tensão elétrica, três aspectos relevantes devem ser observados, sendo eles, a forma de onda, que deve ser a mais próxima de uma senóide pura, a simetria do sistema elétrico, isto é, iguais níveis de corrente e tensão em todas as fases em qualquer ponto de sua configuração, e as magnitudes das tensões, que devem permanecer dentro dos níveis aceitáveis, como será descrito detalhadamente mais adiante.

Todavia, nos SEP há diversos fenômenos aleatórios e / ou intrínsecos ao seu funcionamento, que provocam nas grandezas elétricas mencionadas certo desvio das condições nominais, caracterizando, portanto, um distúrbio na QEE.

Um dos principais distúrbios da QEE é a variação de tensão, caracterizado pela permanência do nível de tensão fora da faixa nominal por um determinado intervalo de tempo. Podem-se subdividir as variações de tensão em dois principais grupos, sendo eles: variações de tensão de longa duração (VTLD) e variações de tensão de curta duração (VTCD).

A classificação VTLD é designada a fenômenos de variação de tensão com duração superior a um minuto, cuja tensão monitorada se eleva entre 1.1 p.u e 1.2 p.u. Isto é, uma elevação da tensão entre 10% e 20% do valor nominal por mais de um minuto, tem-se o que se denomina sobretensão. Já quando o valor da tensão remanescente situa-se em um patamar abaixo de 0,9 p.u. por um intervalo de tempo superior a um minuto, caracteriza-se o fenômeno de subtensão (Dugan et al, 2003). A Tabela 1, traz os intervalos das definições das VTLD. As principais causas de VTLD são variações de carga no SEP, chaveamentos no mesmo e também faltas sustentadas no sistema que podem causar sobretensão, subtensão e /ou interrupção (Dugan et al, 2003).

**Tabela 1 - Classificação das variações de tensão de curta e de longa duração.**

<b>Fenômeno</b>	<b>Duração Típica</b>	<b>Amplitude de Tensão Típica</b>
<b><i>Variação de Tensão de Curta Duração</i></b>		
<b>Instantânea</b>		
Interrupção	0,5 – 30 ciclos	< 0,1 p.u.
Afundamento	0,5 – 30 ciclos	0,1 – 0,9 p.u
Elevação	0,5 – 30 ciclos	>1,1p.u.
<b>Momentânea</b>		
Interrupção	30 ciclos – 3s	< 0,1 p.u.
Afundamento	30 ciclos – 3s	0,1 – 0,9 p.u
Elevação	30 ciclos – 3s	>1,1p.u.
<b>Temporária</b>		
Interrupção	3s – 1 min	< 0,1 p.u.
Afundamento	3s – 1 min	0,1 – 0,9 p.u
Elevação	3s – 1 min	>1,1 p.u.
<b><i>Variação de Tensão de Longa Duração</i></b>		
Interrupção	> 1 min	0 p.u.
Subtensão	> 1 min	0,8 – 0,9 p.u.
Sobretensão	> 1 min	> 1,1 p.u.

A sobretensão, geralmente é causada a partir do processo de desligamento de grandes cargas do sistema ou da energização de bancos de capacitores ao longo do mesmo. Como dito, essa pode comprometer a vida útil de equipamentos. Já a subtensão, em geral, é originada a partir de, por exemplo, excesso de carregamento de circuitos alimentadores ou pela entrada de grandes cargas no sistema. Como efeito, estes distúrbios podem acarretar na retirada de operação de equipamentos eletrônicos sensíveis, elevação no tempo de partida de máquinas de indução, dentre outras consequências negativas às cargas sensíveis do sistema. Caso haja uma situação mais grave de VTLD, tem-se uma interrupção sustentada, na qual a tensão elétrica permanece nula por tempo superior a um minuto (Dugan et al, 2003).

Por outro lado, os fenômenos de VTCD estão relacionados a tempo de duração inferiores a um minuto. São subdivididos em três principais categorias: variações instantâneas (de 0,5 a 30 ciclos), momentâneas (de 30 ciclos a 3 segundos) e temporárias (de 3 segundos a 1 minuto) (Dugan et al, 2003). Com respeito à magnitude da tensão, pode-se classificar uma VTCD em interrupção, afundamento e elevação de tensão conforme se observa na Tabela 1.

Em geral, uma VTCD é causada por condições de falta ao longo do SEP, energização de grandes cargas que necessitam de elevadas correntes na partida, ou perda intermitentes de conexões nos cabos de um SEP. Ao se tratar de uma falta elétrica, dependendo do ponto de ocorrência e das condições do sistema, pode-se gerar um decréscimo de tensão (afundamento) ou aumento da tensão (elevação). Ou ainda, completa perda de tensão (interrupção). A condição faltosa pode se localizar perto ou distante do ponto de monitoramento de interesse. Desta forma, diferentes VTCD podem ocorrer até que o sistema de proteção atue. Com isso, as VTCD podem resultar em redução da vida útil de determinados equipamentos e também causar a completa inutilização ou parada dos mesmos.

A interrupção de tensão é uma VTCD que ocorre quando a tensão ou corrente de carga permanece em um valor inferior a 0,1 p.u. por um período de tempo inferior a um minuto. Essa é consequência principalmente da ausência de fornecimento de energia, falhas nos equipamentos e também mau funcionamento de sistemas de controle.

O aumento da tensão eficaz do sistema em cerca de 0,1 p.u. a 0,8 p.u., com duração de até 1 minuto, é chamado de elevação de tensão. Este fenômeno ocorre principalmente nas fases sãs de um circuito trifásico, quando há um curto-circuito em outra fase do sistema. Usualmente, elevações de tensão estão relacionadas à faltas elétricas, porém, não são tão comuns quanto os afundamentos de tensão. Sua duração está ligada diretamente

aos ajustes dos dispositivos de proteção, à natureza da falta (permanente ou temporária) e à sua localização no sistema. Ocorre principalmente em situações de saídas de grandes cargas, energização de grandes bancos de capacitores ou alterações nos *taps* de transformadores.


Em meio aos diferentes tipos de distúrbios de QEE, o afundamento de tensão é aquele que desperta maior interesse, principalmente pelo alto nível de incidência e os principais prejuízos que esse pode causar. Um afundamento de tensão é uma VTCD caracterizada por um decréscimo no valor da tensão remanescente para níveis entre 0,1 p.u. e 0,9 p.u., com duração inferior a 1 minuto, conforme ilustra a Tabela 1. Em geral, estão associados à faltas no sistema. Todavia, também podem estar relacionados a energização de grandes cargas, partidas de grandes motores ou pela corrente de magnetização de transformadores (Huang et al,1998; Dugan et al, 2003).

Cabe acrescentar que o módulo 8 do PRODIST (ANEEL, 2012b), responsável por estabelecer normas para a QEE do sistema elétrico brasileiro, define intervalos diferentes dos apresentados na Tabela 1 para as variações de tensão. Neste documento, o afundamento momentâneo de tensão compreende um intervalo de tempo superior ou igual a um ciclo, e inferior ou igual a três segundos. Já o temporário compreende em uma faixa de tempo superior a três segundos e inferior a três minutos. A definição destes intervalos apresenta-se como uma classificação menos rígida, quando comparada à literatura técnica correlata, no que diz respeito a garantir a qualidade da tensão elétrica entregue aos consumidores, já que afundamentos de tensão, mesmo quando inferiores a um ciclo, também podem ser danosos às cargas sensíveis alocadas no SD.

No sentido de prevenir que equipamentos sensíveis às variações de tensão tenham seus desempenhos comprometidos, curvas de sensibilidade foram desenvolvidas a fim de especificar zonas de tolerância de operações de equipamentos .

Um exemplo deste tipo de estudo de sensibilidade foi o que resultou na curva *CBEMA* (*Computer Business Manufacturers Association*) (Dugan et al, 2003). Esta curva, representada na Figura 1, desenvolvida por fabricantes de computadores eletrônicos, foi a primeira do tipo a atender aos propósitos mencionados, caracterizando-se como referência principal aos estudos de tolerância de equipamentos eletrônicos. A Figura 1 traz um exemplo da curva CBEMA. Nesta, são destacadas três principais regiões de operação representadas pelas letras A, B e C. A região A caracteriza a região normal de operação, isto é, zona aceitável para determinada atividade de operação. A região B indica uma zona de perigo de trabalho, na qual pode haver ruptura de isolamento de equipamentos. Por fim, a

região demarcada por C mostra uma zona também perigosa de trabalho, na qual há a possibilidade de paralisação do funcionamento de equipamentos.



**Figura 1 - Curva CBEMA adaptada de Kyei et al (2002).**

A popularização da curva CBEMA motivou a criação de um novo padrão para a avaliação dos efeitos das variações de tensão sobre os equipamentos eletrônicos, a chamada curva ITIC (*Information Technology Industry Council*). Essa curva, ilustrada na Figura 2, apresenta uma divisão mais criteriosa com respeito aos níveis da magnitude e duração das VTCD, conforme exposto por Dugan et al (2003).

A curva ITIC apresenta demarcações de regiões semelhantes às encontradas na curva CBEMA, conforme indicado anteriormente. Ou seja, na curva ITIC, a região denotada por A indica a zona de operação normal dos equipamentos, e as zonas B e C são chamadas zonas de perigo, cujas condições operacionais ocasionam mau funcionamento de cargas sensíveis.




Figura 2 - Curva ITIC adaptada de Kyei et al (2002).

## 2.2. Redes neurais artificiais e ferramentas matemáticas aplicadas na análise de QEE

A pesquisa de Devaraj et al. (2006) propõe um método de detecção e classificação de problemas relacionados à QEE utilizando, conjuntamente a análise do sinal por Transformada *Wavelet* (TW) e RNA. Isto é, esta abordagem se dá pela aplicação da TW sobre sinais de corrente e tensão, sendo possível detectar e extrair características relacionadas a vários tipos de distúrbios elétricos, já que esta ferramenta é sensível a irregularidades no sinal (com a presença de distúrbios de QEE), e insensível a comportamento regular do sinal (sem a presença de distúrbios de QEE). Em seguida, com os dados obtidos após a análise dos sinais de corrente e tensão elétrica pela aplicação da TW, os autores propõem que os mesmos sejam utilizados para treinar uma RNA específica, que possui como função realizar a classificação dos distúrbios de QEE entre: (i) afundamento de tensão, (ii) elevação de tensão, (iii) distorção harmônica e (iv) transitórios devidos a chaveamentos. Para tanto, afirmam os autores, que cada distúrbio de QEE, representado nos sinais de corrente e tensão, apresenta desvios únicos da forma de onda senoidal pura, que são detectados pela RNA. Dessa maneira, é possível prover a classificação de forma confiável dos distúrbios de QEE mencionados. A metodologia foi testada por meio da simulação de um SEP de quatro barras no qual foram estudados vários tipos de curtos-circuitos que permitam caracterizar os distúrbios de QEE. Além disso, foram

simuladas situações de injeção de harmônicos na rede, que representam anomalias de QEE vinculadas às cargas não lineares alocados no sistema. Cabe ressaltar que o índice de acerto das classificações realizadas pela RNA foi elevado, o que atendeu aos propósitos e objetivos iniciais do trabalho em questão, evidenciando a aptidão da técnica inteligente ao monitoramento da QEE no sistema elétrico considerado.

O uso de RNA aplicada à QEE também é explorado no trabalho de Srinivasan et al. (2006). Neste, os autores propõem um método de identificação de fontes geradoras de harmônicos, em que diferentes RNA são treinadas a fim de extrair a assinatura única dos dispositivos (cargas) que injetam harmônicos no sistema, observando-se unicamente a forma de onda da corrente elétrica dos mesmos. Uma base de dados foi construída por meio de experimentos conduzidos em laboratório, nos quais se dispunha de uma instalação elétrica contendo várias cargas lineares e não lineares alocadas paralelamente. Inúmeras combinações destas cargas proporcionaram a observação dos respectivos sinais de correntes, tomados no ponto de acoplamento comum. Sobre estes sinais de corrente, a transformada de Fourier foi aplicada a fim de preparar o banco de dados de teste e validação das RNA. A metodologia de classificação dos distúrbios de QEE desenvolvida foi testada e aponta para uma excelente identificação da assinatura de corrente dos dispositivos alocados na instalação elétrica. Cabe destacar que os melhores resultados foram obtidos pela aplicação de redes do tipo *Perceptron* de Múltiplas Camadas (PMC).

Na mesma linha de pesquisa, Talaat et al. (2008) também afirma que o processo de análise e avaliação da QEE é complexo de ser realizado, já que a modelagem de sistemas de energia é de elevada complexidade. Além disso, é necessário processar uma significativa quantidade de informações disponível. Diante deste cenário, os autores propõem uma metodologia que utiliza técnicas inteligentes capazes de classificar eventos relacionados à falta de QEE em um SEP. As técnicas mencionadas envolvem a aplicação da TW, algoritmo de agrupamento subtrativo (*cluster subtractive algorithm*) e RNA. A metodologia de classificação dos eventos de QEE é validada pela geração de sinais de tensão que simulam diferentes anomalias relacionadas à QEE, utilizados como entradas para um módulo de decomposição de sinal, em que se aplica a TW. A seguir, um módulo de extração de características é utilizado para caracterizar alguns coeficientes representativos dentro de todos os gerados da análise de multi-resolução do sinal efetuada no primeiro módulo. Este estágio de extração utiliza o algoritmo de agrupamento subtrativo para a decomposição de múltiplos sinais. O propósito desse agrupamento é identificar grupos naturais de informações dentro da base de dados gerada, com o intuito de produzir uma representação concisa dos tipos de distúrbios de QEE envolvidos no problema. Por fim, a saída do estágio de extração é utilizada para treinar as RNA. Cabe salientar que é utilizada

uma RNA específica para cada tipo de entrada (distúrbio), isto é, características de agrupamento identificadas pelo bloco de extração de característica. Dados conclusivos do estudo indicam que as RNAs treinadas atingiram níveis de acerto satisfatórios, cerca de 98%, apresentando-se, portanto, como uma adequada estratégia para a classificação de eventos relacionados à QEE.

A classificação de eventos envolvendo QEE também é investigada na pesquisa de Devaraj et al. (2008), em que os autores apresentam uma técnica que combina transformadas de Fourier e *Wavelet* com o uso de RNA, com o intuito de se desenvolver um sistema automático de reconhecimento de distúrbios de QEE. Analogamente às pesquisas já mencionadas, um banco de dados é gerado através de simulações computacionais do SEP. Sobre este banco de dados, aplicam-se as transformadas de Fourier e *Wavelet* nos sinais de corrente e tensão a fim de se extrair características úteis à classificação de distúrbios de QEE. Ao final de todo o processo essas características são utilizadas para treinar uma RNA que possui como função a classificação dos distúrbios de QEE propriamente ditos. Sobre os seis distúrbios considerados, o índice de acerto das RNA utilizadas na técnica de classificação proposta foi de 99,6.

O uso de rede neurais também é explorado no sentido de estimar a localização de faltas elétricas em uma linha de transmissão, como é proposto por Abdollahi et al. (2010). Neste trabalho os autores realizam um estudo comparativo de desempenho entre as transformadas discretas de Fourier e *Wavelet* a fim de estimar a localização do ponto onde ocorreu determinada falta elétrica em uma linha de transmissão.

A pesquisa de Bottura (2010) apresenta uma metodologia de monitoramento dos valores eficazes da tensão em um sistema de distribuição por meio do uso de RNA. O estudo engloba aspectos da modelagem computacional do SEP em estudo, a determinação da melhor topologia das RNA, algoritmo de treinamento, bem como o melhor posicionamento de faltas elétricas monofásicas ao longo do SEP, a fim de caracterizar um banco de dados que compreende diversas situações de operação sobre o mesmo. A técnica utilizada visa montar um banco de dados com as correntes e as tensões trifásicas registradas na subestação do SEP e também os valores eficazes das tensões em um determinado ponto de interesse. Este banco de dados é utilizado com a finalidade de treinar três redes neurais que estimam a tensão trifásica em um ponto de interesse. Para o SEP em estudo foi definida que a topologia 6-15-10-1 (seis neurônios na camada de entrada, 15 e 10 nas duas camadas intermediárias, e 1 neurônio na camada de saída) com algoritmo de treinamento de *Levenberg-Marquardt* apresentou melhor desempenho, com índice de



acerto médio de 95,57% quando há uma tolerância de 0,03 p.u. entre o valor esperado e o valor estimado da tensão eficaz nos pontos de interesse.

Pela revisão bibliográfica realizada neste trabalho, é possível afirmar que a utilização de ferramentas inteligentes, em especial as RNA, em assuntos relacionados à QEE, tais como classificação e monitoramento de distúrbios da mesma, são indícios que sustentam a oportunidade de se pesquisar nesta área a fim de garantir soluções complementares às existentes na atualidade. Assim, dá-se a motivação e a inspiração de continuar o estudo nesta grande área, já que a tendência de uso de ferramentas inteligentes tem mostrado resultados extremamente significativos. No sentido do monitoramento remoto da QEE em um ponto qualquer de interesse dentro de um SD, destaca-se o fato de que uma das principais consequências é a redução do valor econômico necessário quando implementados os novos métodos, uma vez que, de forma geral, podem ser utilizados complementarmente aos dispendiosos equipamentos de medição de QEE atuais.



### 3. Redes neurais artificiais

No presente capítulo, no item 3.1, é apresentada uma introdução sobre os principais conceitos de RNA. Nos itens 3.2 e 3.3 é abordada a evolução histórica das principais arquiteturas e o tipo de treinamento vinculado a estas arquiteturas, além da forma como estes conceitos são aplicados no presente trabalho.

#### 3.1. Introdução às redes neurais artificiais

As RNA constituem uma ferramenta inspirada na maneira como o cérebro humano realiza uma tarefa em particular, ou uma função de interesse. A RNA, na prática, é geralmente implementada por meio de componentes eletrônicos ou simulações computacionais em um computador digital. Seu funcionamento é baseado em um importante aspecto do processo de aprendizagem do cérebro humano, isto é, uma RNA é capaz de aprender, ou extrair conhecimento, por meio de exemplos, e, posteriormente, generalizar o conhecimento adquirido de tal forma a ser aproveitado em diversas aplicações (Haykin, 2008).

A capacidade de generalização das RNA está ligada ao fato de que estas são capazes de produzir respostas às saídas que não faziam parte do processo de aprendizagem da mesma. Estas qualidades, além da tolerância a falhas, aproximação de funções e previsões de resultados, conferem às RNA excelentes características que podem ser utilizadas em complexos problemas cuja solução analítica não é trivial.

O problema da estimação do valor eficaz da tensão elétrica em um determinado ponto de monitoramento de interesse dentro de um sistema elétrico, como se apresenta nesta pesquisa, por exemplo, é de difícil execução e, além disso, encontrar uma solução analítica, apresenta-se como procedimento pouco viável. Dessa forma, o uso de RNA como estratégia para a obtenção do monitoramento desejado, caracteriza-se como uma importante e eficaz alternativa para a solução do problema mencionado.

A fim de atingir altos níveis de desempenho, uma RNA emprega uma rede interconectada de unidades de processamento de dados chamadas de neurônios (Haykin, 2008), como pode ser visto na representação da Figura 3.

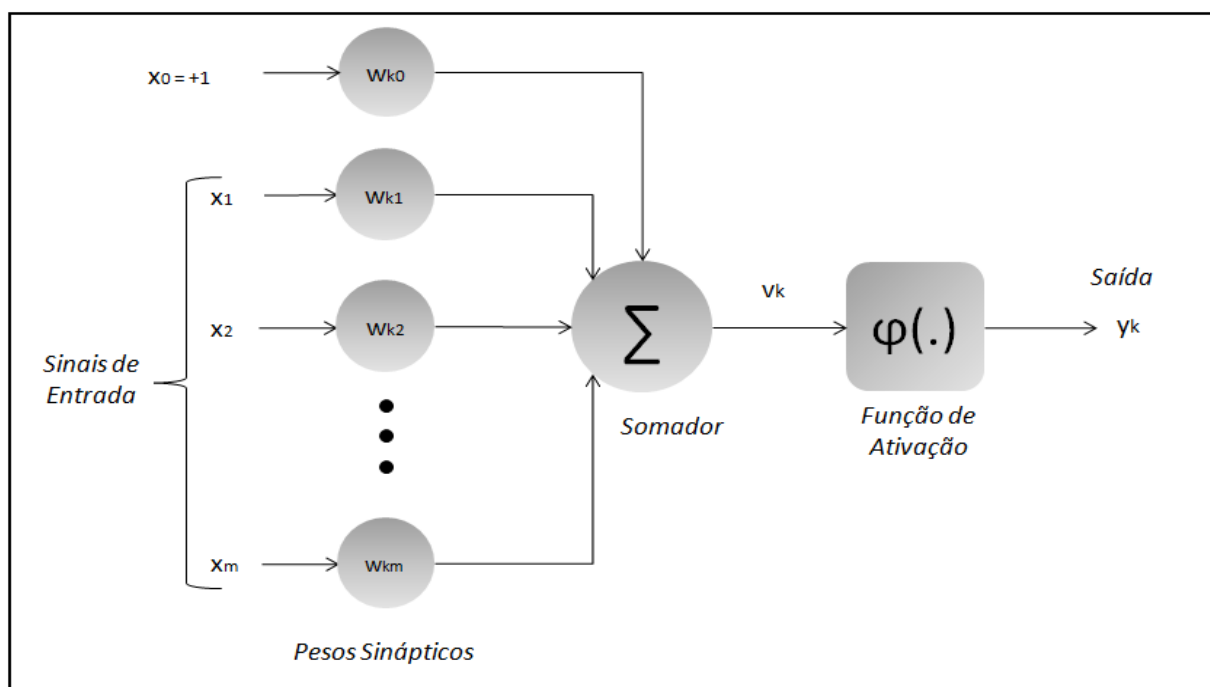
Com o intuito de se obter um modelo neural, três aspectos devem ser considerados, conforme ilustrado na Figura 3. O primeiro deles é a existência de um conjunto de sinapses, ou conexões, entre os neurônios. Cada entrada  $x_j$  do neurônio  $k$  está associada a um peso sináptico, cujo respectivo sinal de entrada será multiplicado pelo peso sináptico  $w_{kj}$

associado. O segundo aspecto a ser considerado é o somador. Este tem por função somar os sinais que foram devidamente ponderados pelos pesos sinápticos, constituindo-se, portanto, um combinador linear cuja saída é dada pelo campo local induzido denotado por  $v_k$ . O termo  $w_{k0}$  ilustrado na Figura 3 chamado *bias*, consiste em um valor fixo pré-determinado, cujo objetivo é inserir um limiar de ativação ao neurônio, conforme registrado na Equação (1), que traz a expressão para o campo local induzido.

$$v_k = \sum_{j=1}^m x_j w_{kj} - w_{k0} \quad (1)$$

Finalmente, o terceiro aspecto a ser destacado neste modelo é a função de ativação, cuja finalidade é limitar a amplitude da saída de um neurônio (Haykin, 2008). Por fim, uma função de ativação  $\phi(.)$  limita o valor da saída do neurônio  $k$  em um valor finito em termos do potencial de ativação Equação (2).

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




**Figura 3 - Modelo matemático de um neurônio.**

Os tipos mais comuns de funções de ativação são: a função de limiar, função linear por partes, função sigmoide, função sinal e, tangente hiperbólica.

Destaca-se o uso das funções de ativação linear por partes e da tangente hiperbólica, por serem os tipos de funções utilizadas nesta pesquisa, além de serem as mais recorrentes. A primeira delas se assemelha a uma função do tipo rampa com uma inclinação  $\alpha$  no intervalo em que  $|v_k| \leq V$ , em que  $V \in \mathbb{R}$ . Fora deste intervalo, assume valor unitário de  $v_k > V$  e valor nulo se  $v_k < -V$ . Assim, define-se a função de ativação linear por partes como sendo:

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

Para um valor suficientemente grande de  $\alpha$  tem-se uma função do tipo limiar citada anteriormente. A Figura 4 ilustra graficamente o comportamento da função de ativação linear por partes.




**Figura 4 - Comportamento da função de ativação do tipo linear por partes.**

A função de ativação hiperbólica é dada pela Equação (4). Esta função tem papel importante no treinamento de uma rede perceptron de múltiplas camadas com algoritmo de retropropagação, já que é capaz de acelerar a convergência do mesmo quanto ao número de iterações (Haykin, 2008).

$$\varphi(v) = \tanh(v) \quad (4)$$

Na Figura 5 há uma representação gráfica do comportamento da função de ativação hiperbólica.



**Figura 5 - Comportamento da função de ativação hiperbólica.**

Cabe salientar que a aprendizagem de determinado padrão de comportamento de um sistema em análise é consequência da devida alteração dos valores dos pesos sinápticos ao longo de um processo iterativo, que segue uma determinada regra de aprendizado, caracterizando o algoritmo de aprendizagem, conforme explicado em detalhes nos itens que seguem.

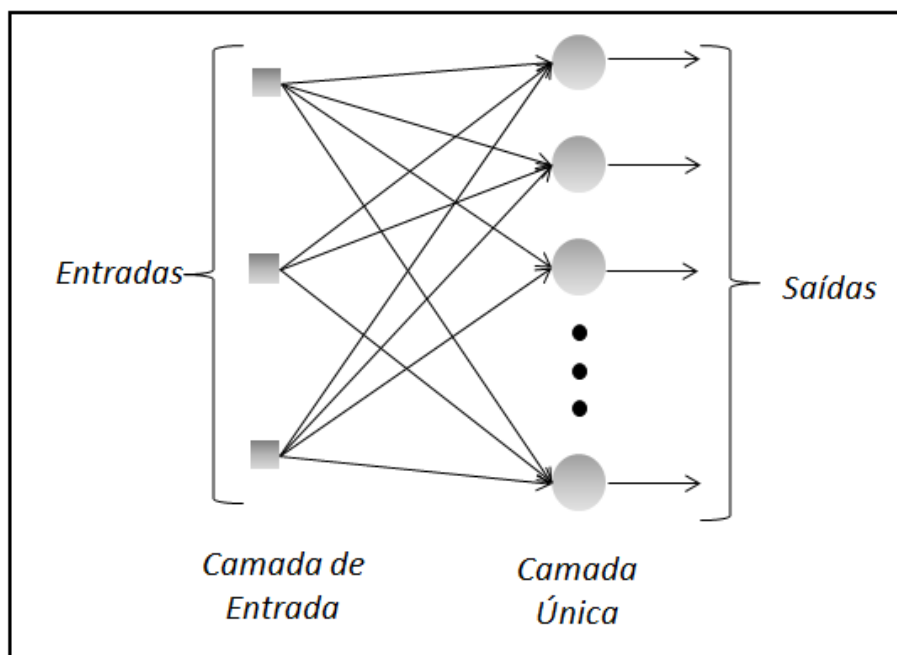
### **3.2 Principais arquiteturas de redes neurais artificiais supervisionadas**

A arquitetura de uma RNA diz respeito à forma como os neurônios estão distribuídos topologicamente, ou seja, a maneira como eles estão interconectados. As RNA podem ser divididas em duas principais categorias relacionadas às arquiteturas, sendo elas: arquiteturas de apenas uma camada, ou arquiteturas com múltiplas camadas.

Ademais, a arquitetura está diretamente relacionada com o tipo de treinamento, uma vez que o algoritmo de treinamento utilizado depende do modo conforme estão distribuídas as conexões entre os neurônios da rede.

### 3.2.1 Redes de camada única

A arquitetura de RNA de camada única apresenta uma camada de entrada e uma camada de saída apenas. Assim, a camada que contém os chamados nós computacionais já é a camada de saída da rede. Na Figura 6, tem-se ilustrada uma rede de camada única.



**Figura 6 - Rede neural de camada única.**

Os principais exemplos de redes de camada única são as redes *Perceptron* e *ADALINE*. Dentre as principais funções dessas redes, destaca-se a habilidade de fazer a separação de padrões que podem ser linearmente separáveis.

A rede *Perceptron* é concebida utilizando o modelo de neurônio não linear de McCulloch-Pitts, com função de ativação do tipo limiar ou sinal. Ou seja, limita-se abruptamente a saída do neurônio. Dessa forma, caracteriza-se uma regra para se discriminar estímulos de entradas em duas diferentes classes, tomando-se dois diferentes tipos de saídas produzidos pela *Perceptron* (Haykin, 2008). A Equação (5) representa a saída da rede neural:

$$y = \varphi(v) = \varphi \left( \sum_{j=1}^m w_j x_j - b \right) \quad (5)$$

De acordo com Silva et al (2010), a Equação (5) representa um hiperplano que divide o espaço euclidiano  $m$ -dimensional (fronteira de decisão), definido pelos  $(m)$  estímulos de entrada em duas regiões ( $A$  e  $B$ ). Para o caso bidimensional, ou seja,  $m = 2$ , obtém-se o hiperplano que se resume a uma reta como fronteira de separação.

A rede monocamada *Perceptron* é treinada segundo o princípio de aprendizado de Hebb, no qual a atualização dos seus pesos sinápticos é realizada por um incremento ( $\Delta w$ ) dado pela Equação (6):

$$\Delta w_j = \eta(d(n) - y)x_j(n), \text{ para } j = 1, 2, \dots, m \quad (6)$$

Na Equação (6), observa-se que a alteração dos pesos sinápticos depende do produto da entrada  $\underline{x}(n)$ , do sinal de erro vindo da diferença entre a saída desejada e a saída produzida pela rede ( $d(n)-y$ ), e também da taxa de aprendizagem dada por  $(\eta)$ .

De forma complementar ao *Perceptron*, desenvolveu-se a rede monocamada *ADALINE*, o que trouxe importante contribuição ao desenvolvimento dos estudos de RNA. A principal inovação se dá na introdução do princípio de aprendizado da regra Delta (Silva, 2010). O processo de aprendizado da regra delta consiste em um algoritmo supervisionado com a finalidade de minimizar o erro quadrático médio entre a saída do combinador linear  $v(n)$  e a saída desejada  $d(n)$ . A regra Delta é expressa na Equação (7):

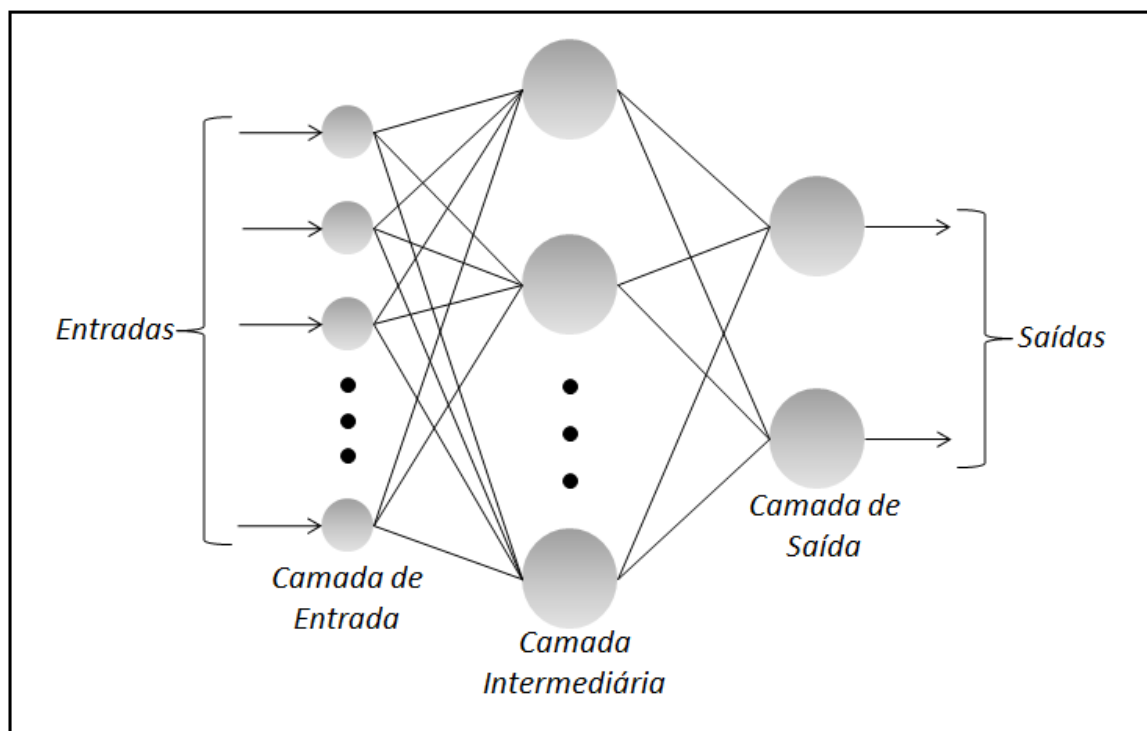
$$\Delta \underline{w} = \eta(d(n) - v(n))\underline{x}(n), \quad \text{para } n = 1, 2, \dots, N \quad (7)$$

Cabe salientar que a principal diferença entre a rede *Perceptron* e *ADALINE* está no fato de que a última faz a minimização das distâncias dos padrões classificados em relação a uma única fronteira de decisão. Já o *Perceptron*, a cada execução do algoritmo de aprendizagem, está sujeito a encontrar uma fronteira de decisão diferente que dependerá da inicialização dos pesos sinápticos (Haykin, 2008).

### 3.2.2 Redes de múltiplas camadas

Nas arquiteturas que envolvem múltiplas camadas, os neurônios estão arranjados em uma ou mais camadas intermediárias, situadas entre a camada de entrada e a camada de saída, conforme ilustra a Figura 7, em que se tem uma rede neural com duas camadas escondidas. Estas camadas são chamadas de camadas escondidas, ou camadas ocultas. Como principal exemplo de arquitetura com múltiplas camadas, pode-se citar a rede *Perceptron* Multicamadas (PMC).






**Figura 7 – Rede neural de múltiplas camadas.**

O surgimento das redes PMC está intimamente ligado à necessidade de se classificar padrões que não são linearmente separáveis. Neste contexto, tem-se o exemplo clássico relacionado ao problema da resolução da função booleana OU exclusivo (*XOR*) (Haykin, 2008). Neste caso, a rede *Perceptron*, ou então a rede *ADALINE*, de apenas uma camada deve ser capaz de traçar duas retas como fronteiras de decisão com o objetivo de resolver a função *XOR*, isto é, separando os padrões de saída desta função conforme é exibido na Figura 8.

É evidente que ambas as redes mencionadas, a rede *Perceptron* e a rede *ADALINE*, não são indicadas para a resolução deste problema, pois, apresentam limitações de funcionalidade, já que o problema em questão não é linearmente separável. Ou seja, não são capazes de fornecer uma única fronteira de separação que separe corretamente os diferentes padrões apresentados. Desta forma, faz-se necessário o uso de redes neurais de múltiplas camadas para a separação dos padrões não separáveis linearmente.

No presente trabalho, que visa à estimação do valor eficaz da tensão trifásica em um determinado ponto genérico de interesse, dentro de um SD, utiliza-se a arquitetura neural PMC, visto que, tem-se um problema de elevada complexidade, em que os padrões não são linearmente separáveis. Além disso, não se possui de antemão conhecimento acerca

da geometria da fronteira de separabilidade do mesmo, de maneira que a rede PMC utilizada possui duas camadas ocultas (Haykin, 2008). A rede PMC é organizada em camadas de neurônios interconectadas. Classificam-se as camadas em: (i) camada de entrada, em que padrões são apresentados à rede; (ii) camadas intermediárias ou ocultas, onde ocorrem os processamentos dos dados (nestas camadas é feita a extração das principais características presentes nos sinais de entrada) e (iii) camada de saída, na qual são disponibilizadas as respostas produzidas pela rede neural.



**Figura 8 - Representação da função booleana OU exclusivo (XOR).**

### 3.3. Treinamento de Levenberg-Marquardt

O algoritmo de treinamento utilizado ao longo deste trabalho é o Levenberg-Marquardt, que possui como base a técnica dos mínimos quadrados. A demonstração de Fernandes (2009) de ajuste dos pesos sinápticos do algoritmo de treinamento de Levenberg-Marquardt mostra que este é derivado do método de Newton, e objetiva minimizar o erro quadrático médio relativo a todas as  $N$  entradas de treinamento da rede neural pertencentes ao conjunto de treinamento.

Sejam os índices  $(i)$  e  $(j)$  correspondentes a neurônios que pertencem a camadas subsequentes, isto é, o neurônio  $(j)$  se encontra em uma camada à direita da camada da qual pertence o neurônio  $(i)$ . Assim, o sinal de erro, na apresentação do  $n$ -ésimo padrão de treinamento, quando o neurônio  $(j)$  é um nó de saída, é dado por:

$$e_j(n) = d_j(n) - y_j(n) \quad (8)$$

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

$$E(n) = \frac{1}{2} \sum_j (e_j(n))^2 \quad (9)$$

O objetivo do algoritmo é minimizar o erro quadrático médio  $\bar{E}$  relativo a todos os padrões de treinamento, normalizando-os em relação ao tamanho deste conjunto, obtém-se:

$$\bar{E} = \frac{1}{N} \sum_{n=1}^N E(n) \quad (10)$$

Na forma vetorial, a equação do erro quadrático médio, Equação (10), é dada por:

$$\bar{E} = \frac{1}{2N} \sum_{n=1}^N \sum_j (e_j(n))^2 = \frac{1}{2N} \sum_{n=1}^N \underline{e}(n)^T \cdot \underline{e}(n) \quad (11)$$

A partir da Equação (11) pode ser vista como um vetor de erros em função dos pesos sinápticos  $W$  da rede referentes aos  $N$  padrões de treinamento apresentados à RNA.

$$\bar{E} = \underline{e}(W) = e_1(W) + e_2(W) + \dots + e_N(W) \quad (12)$$

A equação iterativa obtida para o método de treinamento de *Levenberg-Marquadt* que ajusta os parâmetros da rede é dada pela Equação (13).

$$\Delta W = (J^T(W) \cdot J(W) + \mu I)^{-1} \cdot J^T(W) \cdot \underline{e}(W) \quad (13)$$

Sendo ( $J$ ) a matriz jacobiana derivada do desenvolvimento realizado via método de Newton;  $\mu$  é o parâmetro de ajuste da taxa de convergência do algoritmo e; ( $I$ ) é a matriz identidade.

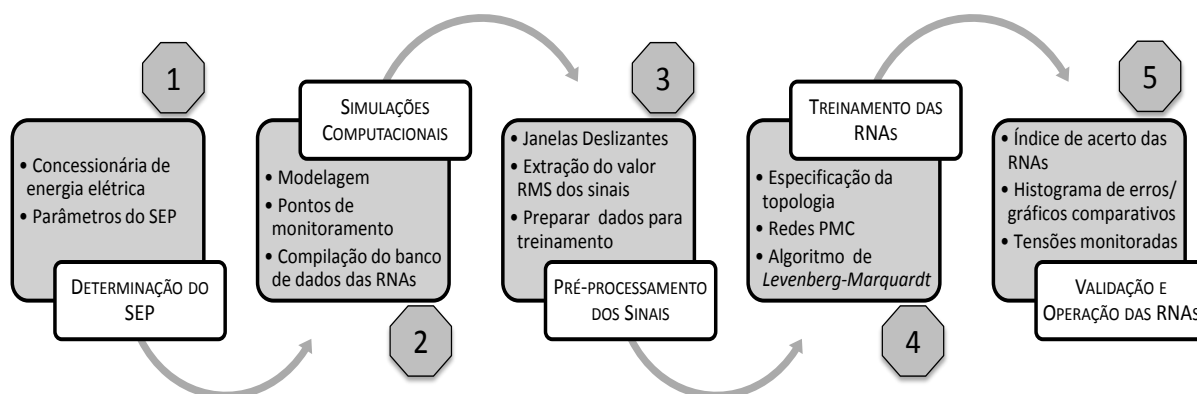


## **4. Estimação do valor eficaz da tensão de uma carga de um sistema de distribuição por meio de redes neurais artificiais**

Neste capítulo, conforme ilustra a Figura 9, serão apresentadas todas as informações referentes às etapas constituintes da metodologia de monitoramento remoto proposta, sendo as mesmas detalhadamente descritas no item 4.1 quando aplicadas a uma carga específica. Mais adiante, no item 4.2, estão ressaltadas as modificações que devem ser consideradas em cada uma das referidas etapas da metodologia de modo a se estender a aplicação da mesma para pontos de monitoramento adicionais, caracterizando, por conseguinte a generalização da metodologia no que se refere ao monitoramento de qualquer carga do SEP.

### **4.1. Estimação do valor eficaz da tensão em uma carga (ponto de interesse) do SD via RNA**

O valor eficaz da tensão fornecida a uma determinada carga do SD monitorado, denominada ponto de monitoramento remoto 1 (MR1) é estimado por três RNA distintas. Assim, cada uma das RNAs destina-se a estimar o valor eficaz da tensão em cada uma das três fases de MR1. Desta forma, uma RNA fornecerá o valor eficaz da tensão elétrica referente à fase *A*, outra será responsável por estimar o valor correspondente da fase *B*, e a terceira será da fase *C*. Portanto, as três RNA, operando simultaneamente em paralelo, são capazes de fornecer o valor da tensão eficaz trifásica no ponto MR1, tomando por entradas as tensões e correntes trifásicas disponibilizadas por um medidor presente na subestação do SD. Esta configuração está ilustrada na Figura 10, em que é possível observar o fluxo das informações, desde a aquisição dos sinais de entrada das RNA, referentes às tensões e correntes trifásicas medidas na SE, até a disponibilização dos valores eficazes das tensões em um ponto de monitoramento remoto específico para as três fases do sistema. Cabe ressaltar que as entradas mencionadas são submetidas a um pré-processamento antes de serem apresentadas às RNA, conforme explicado mais adiante neste capítulo.



**Figura 9 – Procedimento para monitorar remotamente um ponto (carga) de interesse dentro de um SD.**

Neste contexto, a etapa 1 (*Determinação do SEP*) da Figura 9 diz respeito ao sistema elétrico que será objeto de estudo e aplicação da metodologia de monitoramento proposta. Nesta primeira etapa, objetiva-se obter junto à concessionária de energia elétrica os parâmetros que representem o sistema elétrico real, pois o intuito é o de se estabelecer condições de desenvolvimento da metodologia que sejam as mais fiéis possíveis ao real funcionamento do sistema elétrico em análise. Cabe ressaltar que a boa qualidade dos parâmetros será capaz de fornecer melhores condições de modelagem do SD e, por consequência, melhor aplicabilidade da metodologia em um SD real.

Na etapa 2 (*Simulações Computacionais*) é realizada a modelagem computacional do sistema elétrico no *software ATP* (Leuven EMTP Center, 1987), além de todas as simulações pertinentes à compilação do banco de dados por meio da simulação do sistema frente a aplicação de diferentes situações de faltas (curtos-circuitos), conforme demonstrado no Capítulo 6 deste trabalho. O banco de dados construído é destinado ao treinamento e validação das RNAs utilizadas no processo de monitoramento da carga de interesse (MR1).

Os dados oriundos das simulações computacionais realizadas na etapa 2 são pré-processados ao longo da etapa 3 (*Pré-processamento dos Sinais*). Nesta etapa, os sinais são formatados como pares de entradas e saídas correspondentes, ou seja, para uma dada combinação de tensões e correntes medidas na subestação do SD (entrada), há um par correspondente de tensões eficazes no ponto de monitoramento de interesse MR1 (saída). Sendo assim, para cada situação de curto-circuito simulada, obtém-se um par de entradas e saídas correspondentes.

O conjunto de todos os pares de entradas e saídas forma um banco de dados que é utilizado nas etapas de treinamento e validação das RNA. As entradas são compostas por

nove ciclos dos sinais das três tensões e das três correntes elétricas amostradas na subestação do SD. Já as saídas são compostas pelos nove ciclos de tensão correspondentes amostrados no ponto de carga (MR1). Dos nove ciclos monitorados, os três primeiros são obtidos quando o SD se encontra em estado de regime permanente, e os seis seguintes reportam o comportamento do SD perante a aplicação de uma determinada falta (curto-circuito monofásico envolvendo a fase A do sistema). Os sinais de entrada, ou seja, as tensões e correntes trifásicas medidas na subestação do SD foram amostrados a uma taxa de 128 amostras por ciclo na frequência fundamental do sistema (60Hz). Sobre estes sinais foi aplicada uma janela deslizante de meio ciclo (64 amostras). Desta forma, a cada passo da janela deslizante são calculados os valores eficazes de cada sinal de interesse, isto é, das três tensões e das três correntes na entrada. Cabe salientar que para o cálculo dos valores eficazes das tensões e correntes elétricas tanto das entradas como das saídas, conforme mencionado, é utilizada a fórmula de cálculo do valor eficaz *RMS* (*root mean square*), dado por  $X_{RMS}$ , para uma coleção de  $N$  pontos amostrados ( $x_i$ ), conforme mostra a Equação (14).

$$X_{RMS} = \sqrt{\frac{1}{N} \sum_{i=1}^N x_i^2} \quad (14)$$

De forma análoga são extraídos os valores eficazes das tensões no ponto MR1. Os dados compilados são organizados em dois grupos. O primeiro deles, composto de 70% das amostras, é dedicado ao treinamento das RNA, e o segundo, com 30% dos dados, é utilizado para a validação das mesmas.

De posse do banco de dados pré-processado, segue-se à etapa 4 (*Treinamento das RNA*) na qual é determinada a topologia das RNA e o algoritmo de treinamento é executado.

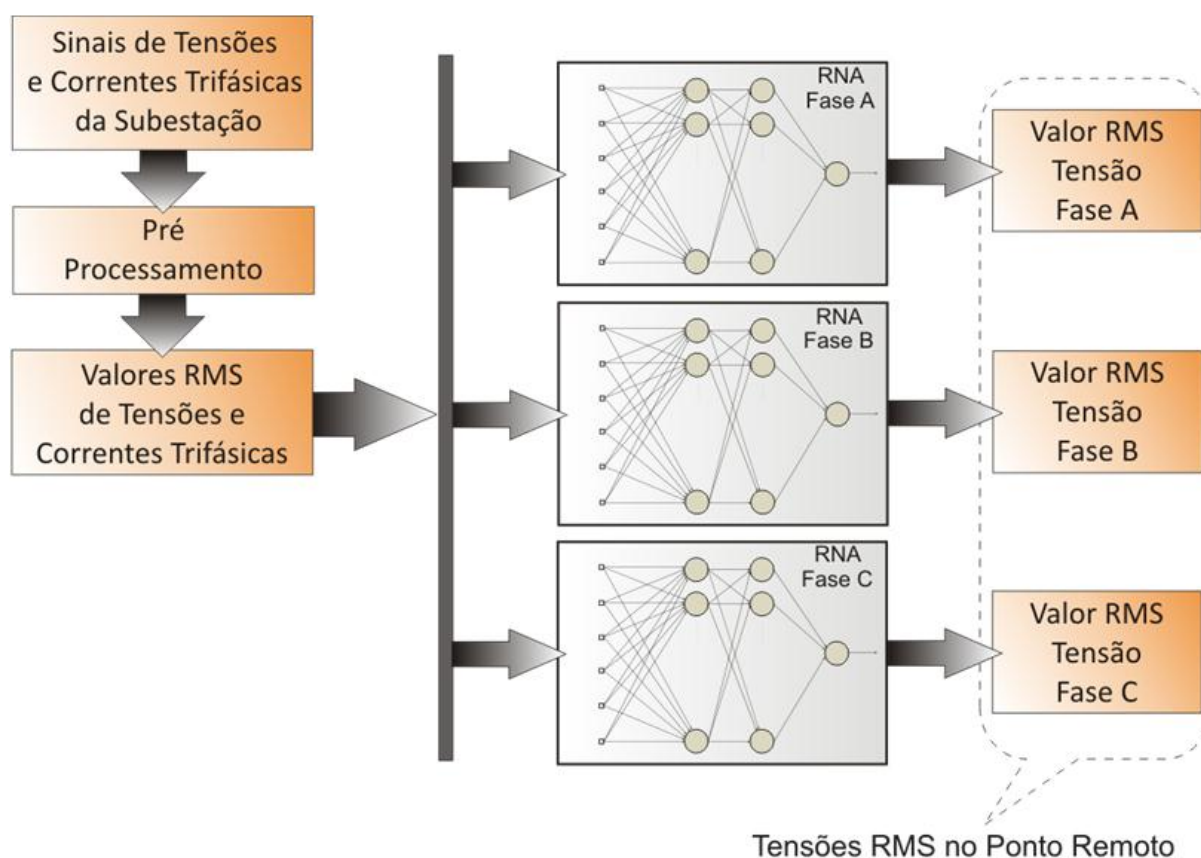
Durante a etapa 4 (*Treinamento das RNA*) é realizada a definição da topologia das redes e a execução do algoritmo de treinamento das mesmas. Cada rede recebe como entrada os valores eficazes das tensões e correntes das três fases medidas na subestação, totalizando seis entradas para cada rede neural. O valor eficaz de cada fase estimado no ponto de interesse MR1 é dado por cada uma das respectivas RNA.

Conforme descrito anteriormente, todas as RNA mencionadas são do tipo PMC (Haykin, 2008). A topologia utilizada foi obtida a partir da análise de desempenho da rede variando-se o número de neurônios das camadas intermediárias. A busca pela topologia

adequada foi feita inicialmente para a RNA que monitora a fase *A* e, posteriormente, a topologia encontrada foi replicada para as fases *B* e *C* (Bottura, 2010).

O algoritmo de treinamento utilizado foi o de Levenberg-Marquardt (Haykin, 2008) cujo critério de parada foi determinado ao se atingir erro quadrático médio menor ou igual a  $10^{-6}$ , ou então, até que se atingisse o número total de 800 épocas de treinamento. A função de ativação utilizada foi a tangente hiperbólica nas camadas intermediárias, e a função de ativação linear na camada de saída. O parâmetro de ajuste de convergência ( $\mu$ ) inicial do algoritmo foi fixado em 0,001.

Após uma ampla busca pela melhor topologia a ser adotada, conforme descrito anteriormente, definiu-se que a topologia deve ser composta por 6 neurônios na camada de entrada, 15 neurônios na primeira camada escondida, 10 neurônios na segunda camada escondida, e 1 neurônio na camada neural de saída. É importante frisar que esta topologia foi inicialmente definida para o ponto de monitoramento MR1, e posteriormente, estendida aos demais pontos de monitoramento alocados ao longo do SD em estudo, conforme procedimento demonstrado na seção 4.2 deste trabalho.



**Figura 10 – Fluxo das informações relacionadas ao procedimento de aplicação da metodologia de monitoramento remoto inteligente.**



Finalmente, logo após a etapa de treinamento, segue-se para a etapa 5 (*Validação e Operação das RNAs*), na qual é realizada a validação dos dados obtidos no treinamento por meio da comparação com as respostas simuladas no SD modelado. Isso se dá pela análise de histogramas de erros, análise de tabela e também por meio de gráficos comparativos entre a resposta desejada e a resposta obtida pelas RNA, conforme será apresentado no Capítulo 7 deste trabalho.

#### **4.2 Procedimento para estimar a tensão eficaz em demais pontos de carga alocados no sistema de distribuição**

Realizado o treinamento, a definição da topologia e a validação das RNA para a estimação da tensão eficaz no ponto de carga MR1 é possível estender a metodologia de estimação remota inteligente da tensão eficaz para as demais cargas de interesse alocadas no SD em estudo, caracterizando assim a obtenção da generalização da metodologia, principalmente no que diz respeito à topologia adotada para as RNA. Para tanto, são necessárias algumas mudanças em determinadas etapas descritas no item 4.1, conforme descrito no que segue.

Durante a etapa 1 (*Determinação do SEP*) não são requeridas quaisquer alterações, uma vez que o SD em estudo continua sendo o mesmo. Todavia, a etapa 2 (*Simulações Computacionais*) carece de mudanças significativas. Parte do banco de dados referentes ao treinamento e validação das RNA deve ser modificada em função do acréscimo do  $n$ -ésimo ponto de monitoramento a ser acrescentado (MR $n$ ). Assim, com a determinação do novo ponto de carga, as simulações computacionais devem suprir o banco de dados com os valores de tensões trifásicas observadas no local deste novo ponto de monitoramento. Ademais, é fundamental salientar que os dados referentes às entradas das RNAs não são modificados, uma vez que as situações de faltas simuladas, cujos efeitos são percebidos na subestação, são idênticas às realizadas inicialmente para MR1.

A partir da obtenção do novo banco de dados, a etapa 3 (*Pré-processamento dos Sinais*) segue de forma semelhante à descrita no item 4.1, cabendo apenas a preparação dos dados de interesse para o treinamento das RNA do ponto genérico MR $n$ , isto é, as entradas, as mesmas consideradas no ponto MR1, e as saídas, resultantes do pré-processamento do banco de dados atualizado, obtido na etapa 2 relativa ao ponto MR $n$ .

A etapa 4 (*Treinamento das RNAs*) sofrerá importantes simplificações, uma vez que para o treinamento dos dados referentes ao ponto MR $n$  não é preciso fazer uma análise para a busca da melhor topologia, algoritmo de treinamento, critérios de parada e outros

parâmetros que concernem a definição do melhor arranjo topológico das RNA. Todos estes aspectos já foram investigados e definidos para o ponto de monitoramento MR1, e são simplesmente replicados para o ponto genérico MR $n$ . Vale ressaltar que o algoritmo de aprendizado, que é o mesmo utilizado nos procedimentos descritos na seção anterior, ao final do treinamento e da validação (etapas 4 e 5), fornece novas matrizes de pesos sinápticos que mapeiam a relação entre os sinais medidos na subestação e o ponto de monitoramento de interesse adicional (MR $n$ ).

Desta forma, durante a etapa de operação das RNA, etapa 5, é possível monitorar remotamente a tensão eficaz em qualquer carga do sistema, sem a necessidade de empregar fisicamente medidores extras de QEE ao longo do SD, tornando a metodologia de monitoramento remoto inteligente uma ferramenta complementar a ser utilizada em conjunto com o método de monitoramento convencional praticado pelas companhias de distribuição de energia elétrica.



relevantes. A fonte de tensão utilizada nas simulações via *software ATP* é do tipo 14 (Leuven EMTP Center, 1987). Suas características para a fase A estão representadas na Tabela 2 abaixo. Cabe acrescentar que a sequência de fases é *ABC*.

**Tabela 2 - Parâmetros da fonte de tensão modelada.**

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

A fim de complementar o modelo utilizado do equivalente elétrico do sistema, adicionou-se uma impedância em série com a fonte de tensão de acordo com o modelo RL mutuamente acoplado (Leuven EMTP Center, 1987). Na Tabela 3 estão representados os principais parâmetros do modelo RL mutuamente acoplado.

**Tabela 3 - Características do modelo RL mutuamente acoplado, em série com a fonte de tensão.**

Parâmetro	Valor
Resistência de sequência zero	20,805 $\Omega$
Indutância se sequência zero	203,721 mH
Resistência de sequência positiva	4,062 $\Omega$
Indutância se sequência positiva	52,5397 mH

O transformador de potência na subestação do SD foi simulado seguindo o modelo de transformador trifásico saturável com dois enrolamentos (Leuven EMTP Center, 1987), com potência nominal de 15/20MVA e conexão Y- $\Delta$  entre o primário e o secundário do mesmo. Na Tabela 4 são apresentadas as principais características deste transformador de potência.

**Tabela 4 - Principais parâmetros do transformador de potência do SD**

<b>Parâmetro</b>	<b>Valor</b>
Potência nominal	15/20MVA
Relação de transformação	3,809524
Corrente nominal do primário	131,215970 A
Corrente nominal do secundário	499,870363 A
Ligação do primário	Estrela
Ligação do secundário	Delta
Deslocamento angular	30°
Resistência do primário	0,054695 $\Omega$
Resistência do secundário	0,79376 $\Omega$
Indutância do primário	1,628 mH
Indutância do secundário	23,6258 mH
Resistência de magnetização	1 M $\Omega$

No sistema de distribuição da concessionária de energia elétrica também consta a presença de dois bancos de capacitores utilizados com a finalidade de melhorar o perfil de tensão do SD. Esses bancos de capacitores foram modelados como um elemento capacitivo concentrado não acoplado, do tipo zero, conectado em estrela (Leuven EMTP Center, 1987). Os principais parâmetros dos bancos de capacitores são mostrados na Tabela 5.

**Tabela 5 - Características dos bancos de capacitores do SD**

<b>Parâmetro</b>	<b>Valor</b>
Capacitância da fase A	5,96521 $\mu\text{F}$
Capacitância da fase B	5,96521 $\mu\text{F}$
Capacitância da fase C	5,96521 $\mu\text{F}$

As cargas alocadas nos alimentadores foram modeladas por potências constantes, via um elemento RL concentrado, não acoplado, do tipo zero, conecta em delta (Leuven EMTP Center, 1987). Em virtude da grande quantidade de consumidores alocados nos alimentadores, serão apresentadas as características de apenas alguns dos consumidores. Dentre eles, as cargas referentes ao ponto de monitoramento de interesse deste trabalho. As informações seguem na Tabela 6.

**Tabela 6 - Exemplos de dados das carga do SD**

<b>Carga</b>	<b>Resistência (<math>\Omega</math>)</b>	<b>Indutância (mH)</b>
Ponto 1	8179,90	$9,243.10^{-3}$
Ponto 2	2944,76	$3,328.10^{-3}$
Ponto de Monitoramento	2453,97	$2,773.10^{-3}$

Finalmente, a fim de completar a modelagem do SD em estudo, têm-se os dados que são referentes aos condutores do mesmo. Cada um dos trechos dos alimentadores foi modelado por valores de resistências e indutâncias, por meio de um elemento RL mutuamente acoplado, dos tipos 51, 52 e 53 (Leuven EMTP Center, 1987). Os condutores do sistema elétrico simulado 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, dentre os vários existentes, possui característica própria representada a fim de se obter o correto funcionamento do modelo computacional modelado. Nas Tabelas 7 e 8 são mostrados os parâmetros de dois trechos dos alimentadores para a sequência zero e sequência positiva, respectivamente.

**Tabela 7 - Parâmetros de dois trechos de condutores dos alimentadores para sequência zero**

<b>Trecho</b>	<b>Distância (m)</b>	<b>Cabo</b>	<b><math>R_0</math> (<math>\Omega</math>)</b>	<b><math>L_0</math> (mH)</b>
I	124,2	336,4 MCM	0,045972	0,251375
II	573,4	1/0 AWG	0,449227	1,18634

**Tabela 8 - Parâmetros de dois trechos de condutores dos alimentadores para sequência positiva**

<b>Trecho</b>	<b>Distância (m)</b>	<b>Cabo</b>	<b><math>R_0</math> (<math>\Omega</math>)</b>	<b><math>L_0</math> (mH)</b>
I	124,2	336,4 MCM	0,023995	0,038526
II	573,4	1/0 AWG	0,347767	0,203670

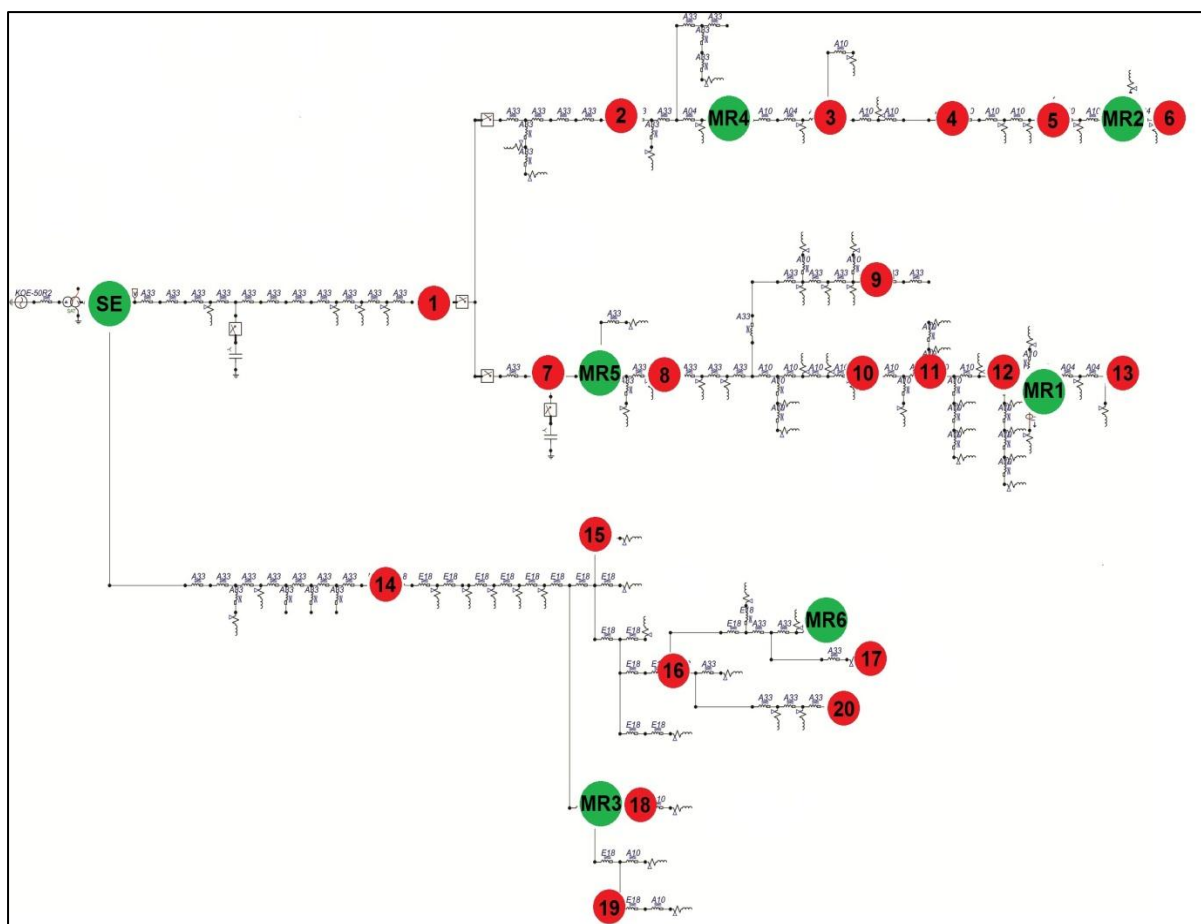
## 6. Compilação dos conjuntos de treinamento e validação das RNA

Este capítulo traz todas as informações referentes à compilação do banco de dados das RNA, tanto do conjunto de treinamento, como do conjunto de teste e de validação. Conforme descrito anteriormente, os dados do sistema elétrico em estudo foram fornecidos por uma concessionária de distribuição de energia elétrica regional. Sendo assim, a partir da determinação deste SD de interesse e sua posterior modelagem, foram realizadas as etapas de simulações computacionais e pré-processamento dos sinais, a fim de se obter o valor eficaz da tensão trifásica nos pontos de monitoramento de interesse.

A Figura 12 traz o SD modelado, a representação dos pontos no quais foram aplicadas as faltas elétricas, isto é, curtos-circuitos monofásicos envolvendo a fase A do SD (círculos vermelhos numerados de 1 a 20), a subestação do SD (representada por um círculo verde com a inscrição SE) e também os seis pontos de cargas ( $MR_n$ ) definidos como objetos de estudo para investigação acerca da generalização da metodologia de monitoramento remoto inteligente proposta (círculos verdes com a inscrição  $MR_n$ , em que  $n = 1, 2, 3, 4, 5$  e  $6$ ).

Os diversos casos possíveis de faltas elétricas representadas contemplam a variação da distância dos pontos de aplicação de curto-circuito e variação, tanto na impedância de falta, como no ângulo de incidência da mesma. A boa diversidade de casos contribui ativamente na alta capacidade de generalização das RNA, já que possibilitou uma correta representação do SD em estudo, uma vez que as RNA são capazes de estimar corretamente os níveis de tensão para os pontos de interesse escolhidos ao longo do sistema elétrico, conforme exposto mais adiante no Capítulo 7.


Cabe ainda acrescentar que em cada ponto de aplicação de falta a impedância de falta é variada de 0 até  $40\Omega$  em intervalos de  $10\Omega$  conforme exposto em Bottura, (2010). Além disso, o valor do ângulo de falta também é variado entre  $0^\circ$  e  $90^\circ$ . Assim, para cada ponto de aplicação é possível simular uma quantidade de 10 casos de curtos-circuitos diferentes, apenas variando os parâmetros impedância de falta e o ângulo de falta. Com isso, como há 20 pontos de aplicação de falta e 10 casos possíveis de curtos-circuitos por ponto, tem-se 200 casos de curtos-circuitos possíveis para alimentar o banco de dados, utilizado na etapa de treinamento das RNA. A Tabela 9 mostra as 200 combinações possíveis de casos faltosos.



**Figura 12 - Aspecto geral do SD modelado com a localização dos pontos de monitoramento remoto (MR $n$ ), da subestação (SE) e dos pontos de aplicação de faltas elétricas (numerados de 1 a 20).**

Cabe frisar que as faltas elétricas simuladas nos 20 pontos em destaque são curtos-circuitos monofásicos, e, nas simulações computacionais, são representadas por chaves elétricas conectadas em série com uma impedância cujo valor pode ser variado conforme descritos na Tabela 9. A Figura 13 ilustra como a representação computacional das faltas é efetuada no software *ATPDraw*. Ainda na Figura 13, nota-se que apenas uma das chaves é fechada, caracterizando, portanto, uma situação faltosa monofásica, conforme destacado por uma seta curvilínea vermelha, denotando qual chave elétrica será fechada a fim de provocar a falta.





**Figura 13 - Detalhe da chave que simula o curto-circuito monofásico via interface gráfica ATPDraw**

Por meio dos sinais de tensão e corrente das três fases, medidos na SE, foram selecionados três ciclos precedentes e seis ciclos subsequentes ao instante de início de cada defeito aplicado. Nestes sinais, que foram amostrados a uma taxa de 128 amostras por ciclo na frequência fundamental do sistema (60 Hz), foi utilizada 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. Assim, resulta-se em seis valores de entrada (três de tensão e três de corrente). Desta forma, tanto as situações em regime permanente, quanto os eventos associados e de interesse relacionados à QEE da forma como são percebidos na SE, foram apresentados como padrões de entrada às RNAs.

Da forma como foram simulados, entre o início de cada curto-circuito e o seu fim, há um total de 9 ciclos, obtendo-se, portanto, 17 padrões de entrada (valores eficazes resultantes da janela deslizante de meio ciclo) a serem apresentados às RNA oriundos de cada situação de defeito que foi simulada. Assim, com 200 casos de faltas simuladas, o banco de dados possui 3400 padrões de entrada.

A fim de se obter os padrões de saída, aplicou-se o mesmo procedimento utilizado nas entradas nos sinais de saída em cada um dos pontos de monitoramento de interesse. Portanto, obtêm-se os respectivos 3400 padrões de saída.

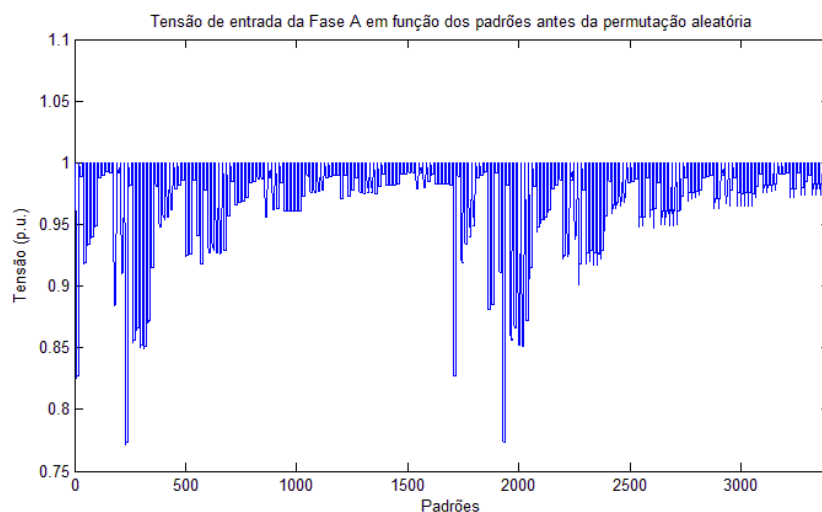
**Tabela 9 – Configuração dos curtos-circuitos simulados para obtenção da base de treinamento das RNA.**

Ponto de aplicação de falta	Impedância de falta ( $\Omega$ )	Ângulo de falta ( $^\circ$ )	Quantidade de casos
1	0; 10; 20; 30 e 40	0 e 90	10
2	0; 10; 20; 30 e 40	0 e 90	10
3	0; 10; 20; 30 e 40	0 e 90	10
4	0; 10; 20; 30 e 40	0 e 90	10
5	0; 10; 20; 30 e 40	0 e 90	10
6	0; 10; 20; 30 e 40	0 e 90	10
7	0; 10; 20; 30 e 40	0 e 90	10
8	0; 10; 20; 30 e 40	0 e 90	10
9	0; 10; 20; 30 e 40	0 e 90	10
10	0; 10; 20; 30 e 40	0 e 90	10
11	0; 10; 20; 30 e 40	0 e 90	10
12	0; 10; 20; 30 e 40	0 e 90	10
13	0; 10; 20; 30 e 40	0 e 90	10
14	0; 10; 20; 30 e 40	0 e 90	10
15	0; 10; 20; 30 e 40	0 e 90	10
16	0; 10; 20; 30 e 40	0 e 90	10
17	0; 10; 20; 30 e 40	0 e 90	10
18	0; 10; 20; 30 e 40	0 e 90	10
19	0; 10; 20; 30 e 40	0 e 90	10
20	0; 10; 20; 30 e 40	0 e 90	10
<b>Total</b>	-	-	200


Com o intuito de garantir a maior generalização possível do processo de monitoramento da tensão eficaz é necessário que os dados da Tabela 9 sejam apresentados de forma aleatória na etapa de treinamento e validação das RNA (Haykin, 2008). Neste sentido, o Anexo 1 deste trabalho traz o código *Matlab*<sup>®</sup> implementado que faz com que os pares de entrada e saída sejam permutados de forma totalmente aleatória. As Figuras de 14 a 17 são uma representação gráfica comparativa de como os dados de entrada da corrente e da tensão referentes à Fase A de alimentação do SD em estudo estão antes e após sua permutação. Nas Figuras 14 e 15 os dados de tensão e corrente, respectivamente, ainda não foram permutados, isto é, foram apresentados na ordem que segue na Tabela 9, ou seja, primeiro fixa-se o ângulo de falta em 0°, em seguida fixa-se a

impedância de falta em  $0\Omega$ , e variam-se todos os pontos de aplicação de falta. A seguir, incrementa-se a impedância de falta em  $10\Omega$  e percorrem-se todos os pontos de falta novamente. Assim, segue até que todos os casos com ângulo de falta de  $0^\circ$  sejam passados para a RNA. Então, repete-se o procedimento para ângulo de falta de  $90^\circ$ .

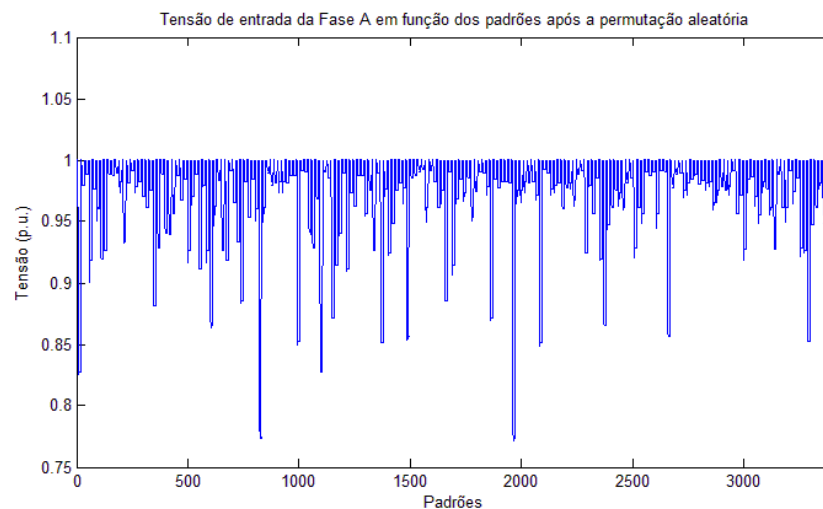
Já nas Figuras 16 e 17 o algoritmo de permutação desenvolvido realizou a permutação aleatória das amostras com a finalidade de garantir maior grau de generalização das RNAs, já que durante a fase de treinamento as amostras serão, por conseguinte, apresentadas de maneira aleatória às RNA (Haykin, 2008).




**Figura 14 – Dados de entrada da tensão referente à Fase A apresentados à RNA antes da permutação aleatória.**



**Figura 15 – Dados de entrada da corrente referente à Fase A apresentados à RNA antes da permutação aleatória.**



**Figura 16 - Dados de entrada da tensão referente à Fase A apresentados à RNA após a permutação aleatória.**



**Figura 17 - Dados de entrada da corrente referente à Fase A apresentados à RNA após a permutação aleatória.**

Dos 3400 padrões de entradas e saídas obtidos, 70% destes, ou seja, 2380 padrões foram utilizados na etapa de treinamento das RNA. Já os 30% restantes, isto é, 1020 diferentes padrões foram reservados para a etapa de validação das mesmas.

Como especificado anteriormente, para cada ponto de monitoramento são necessárias três RNA para estimar o valor *RMS* de cada uma das fases. Dessa forma, como o estudo envolve seis pontos de monitoramento, tem-se um total de 18 treinamentos necessários para a obtenção das respectivas matrizes sinápticas que mapeiam a relação entre os sinais de entrada (tensões e corrente trifásicas medidos na SE) e os sinais de saída (tensão eficaz estimada) em todos os seis pontos de monitoramento remoto.

## 7. Desempenho da metodologia e monitoramento remoto inteligente das variações de tensão

Realizada a definição da topologia das RNAs, destinadas a monitorar remotamente os níveis de tensão em pontos quaisquer de interesse dentro do SD, é realizada uma análise de desempenho minuciosa a fim de se confirmar os objetivos iniciais da pesquisa. Essa análise consiste na averiguação dos índices de acertos das RNAs por meio do arranjo dos resultados em tabelas comparativas, os respectivos histogramas de erros, análise do valor máximo do erro, bem como gráficos comparativos entre as respostas desejadas e aquelas fornecidas por meio da ferramenta inteligente utilizada. Também são exibidos os dados referentes à etapa de treinamento das RNA, tais quais tempo alocado para o treinamento de cada uma das RNA e também a descrição do *hardware* utilizado a fim de comparação e possível utilização do treinamento em tempo real.

As Tabelas de 10 a 15 mostram os erros menores ou iguais a 0,01 p.u., menores ou iguais a 0,03 p.u., e menores ou iguais a 0,05 p.u. entre as respostas fornecidas pelas RNA e as saídas para os pontos de monitoramento de MR1 a MR6, quantificados em porcentagem e também a topologia das RNA utilizada.

**Tabela 10 - Dados do desempenho da aplicação da metodologia proposta em MR1.**

Monitoramento remoto			Erros inferiores ou iguais a 0,01p.u.	Erros inferiores ou iguais a 0,03p.u.	Erros inferiores ou iguais a 0,05p.u.	Erro Máximo (p.u.)
MR1	6-15-10-1	Fase A	90,0%	94,9%	97,4%	0,1437
	6-15-10-1	Fase B	94,8%	99,3%	99,7%	0,1851
	6-15-10-1	Fase C	97,5%	99,1%	99,3%	0,3683

**Tabela 11 - Dados do desempenho da aplicação da metodologia proposta em MR2.**

Monitoramento remoto			Erros inferiores ou iguais a 0,01p.u.	Erros inferiores ou iguais a 0,03p.u.	Erros inferiores ou iguais a 0,05p.u.	Erro Máximo (p.u.)
MR2	6-15-10-1	Fase A	86,8%	93,5%	96,4%	0,1954
	6-15-10-1	Fase B	93,8%	96,1%	99,2%	0,1974
	6-15-10-1	Fase C	91,3%	94,4%	97,3%	0,2612

**Tabela 12 - Dados do desempenho da aplicação da metodologia proposta em MR3.**

Monitoramento remoto			Erros inferiores ou iguais a 0,01p.u.	Erros inferiores ou iguais a 0,03p.u.	Erros inferiores ou iguais a 0,05p.u.	Erro Máximo (p.u.)
MR3	6-15-10-1	Fase A	96,0%	99,4%	99,6%	0,7840
	6-15-10-1	Fase B	98,2%	99,4%	99,6%	0,1312
	6-15-10-1	Fase C	99,1%	99,7%	99,8%	0,1908

**Tabela 13 - Dados do desempenho da aplicação da metodologia proposta em MR4.**

Monitoramento remoto			Erros inferiores ou iguais a 0,01p.u.	Erros inferiores ou iguais a 0,03p.u.	Erros inferiores ou iguais a 0,05p.u.	Erro Máximo (p.u.)
MR4	6-15-10-1	Fase A	86,3%	96,6%	99,0%	0,7358
	6-15-10-1	Fase B	95,1%	99,5%	99,7%	0,0967
	6-15-10-1	Fase C	97,9%	99,3%	99,5%	0,1967

**Tabela 14 - Dados do desempenho da aplicação da metodologia proposta em MR5.**

Monitoramento remoto			Erros inferiores ou iguais a 0,01p.u.	Erros inferiores ou iguais a 0,03p.u.	Erros inferiores ou iguais a 0,05p.u.	Erro Máximo (p.u.)
MR5	6-15-10-1	Fase A	98,7%	99,7%	99,8%	0,2150
	6-15-10-1	Fase B	99,1%	99,6%	99,9%	0,0645
	6-15-10-1	Fase C	99,1%	99,6%	99,6%	0,0940

**Tabela 15 - Dados do desempenho da aplicação da metodologia proposta em MR6.**

Monitoramento remoto			Erros inferiores ou iguais a 0,01p.u.	Erros inferiores ou iguais a 0,03p.u.	Erros inferiores ou iguais a 0,05p.u.	Erro Máximo (p.u.)
MR6	6-15-10-1	Fase A	94,1%	98,8%	99,3%	0,3262
	6-15-10-1	Fase B	97,2%	99,2%	99,5%	0,1815
	6-15-10-1	Fase C	99,4%	99,7%	100%	0,0499

A análise da segunda coluna da Tabela 10 indica uma significativa quantidade em porcentagem de erros inferiores a 0,01 p.u. Como se pode observar, para o ponto MR1 constata-se que 90% a 97,5% dos casos estão nesta faixa de erro. Para MR2, vê-se na segunda coluna da Tabela 11 que os erros inferiores a 0,01 p.u. contemplam de 86,8% a 93,8% dos casos. Com relação a MR3, na Tabela 12, tem-se de 96% a 99,1%; para MR4 de 86,4% a 97,9%, conforme se observa na Tabela 13; para MR5 de 98,7% a 99,1%, Tabela 14 e, finalmente, em MR6 de 94,1% a 99,4% dos casos apresentam erros inferiores a 0,01 p.u. como pode ser observado na Tabela 15.

Em média, 95,24% dos casos apresentam erros inferiores a 1%, ou seja, 0,01 p.u. Isso implica em um índice médio de acerto consideravelmente elevado para a faixa de erro analisada, independentemente do ponto de monitoramento observado, indicando que é possível obter uma forma generalizada de aplicação do método de monitoramento da tensão eficaz em um determinado SD em estudo para quaisquer cargas nele alocadas.


Pela inspeção da terceira coluna das Tabelas de 10 a 15, que inclui uma maior faixa de tolerância para erros, isto é, 0,03 p.u., observa-se que poucas mudanças ocorrem em relação à faixa de análise anterior, sendo as mudanças mais significativas verificadas nos pontos de monitoramento MR2 e MR4. Com esta nova margem, a média de acerto das RNAs levando em conta erros inferiores a 3% sobe para 98,21%.

Quando se leva em conta os erros das RNAs para uma faixa de até 0,05 p.u., ou seja, até 5%, tem-se, em média, uma taxa de acerto das RNA em torno de 99,14%. Estes dados podem ser observados na quarta coluna das Tabelas de 10 a 15.

As últimas colunas das Tabelas de 10 a 15 trazem dados referentes ao erro máximo, em p.u., encontrado em cada um dos pontos monitorados. É importantes ressaltar que, por mais que em alguns casos este valor seja elevado, como na fase A de MR3 visto na Tabela 12, em que o erro máximo foi 0,7840 p.u., esses eventos são de caráter isolados e não comprometem os significativos resultados obtidos pela metodologia como um todo. Entretanto, cabe colocar que uma análise mais detalhada pode ser conduzida futuramente com o objetivo de melhorar o desempenho da técnica relação a tais casos de teste.

Como se observa, os pontos de monitoramento MR1, MR2, MR3, MR4, MR5 e MR6 apresentam elevados índices de acertos em relação às respostas desejadas para as três faixas de erro analisadas, demonstrando a eficiência da aplicação da metodologia proposta no monitoramento da tensão eficaz de um ponto genérico (MR $n$ ) dentro de um SD estudado.

As Figuras de 18 a 23 correspondem aos histogramas de erros relacionados aos pontos de monitoramento de MR1 a MR6, respectivamente, através do qual é possível se obter uma melhor perspectiva acerca da distribuição das magnitudes dos erros entre resposta alvo e resposta das RNA em função da quantidade de casos de teste utilizados.




**Figura 18 - Histograma de erros para o ponto de monitoramento remoto MR1.**

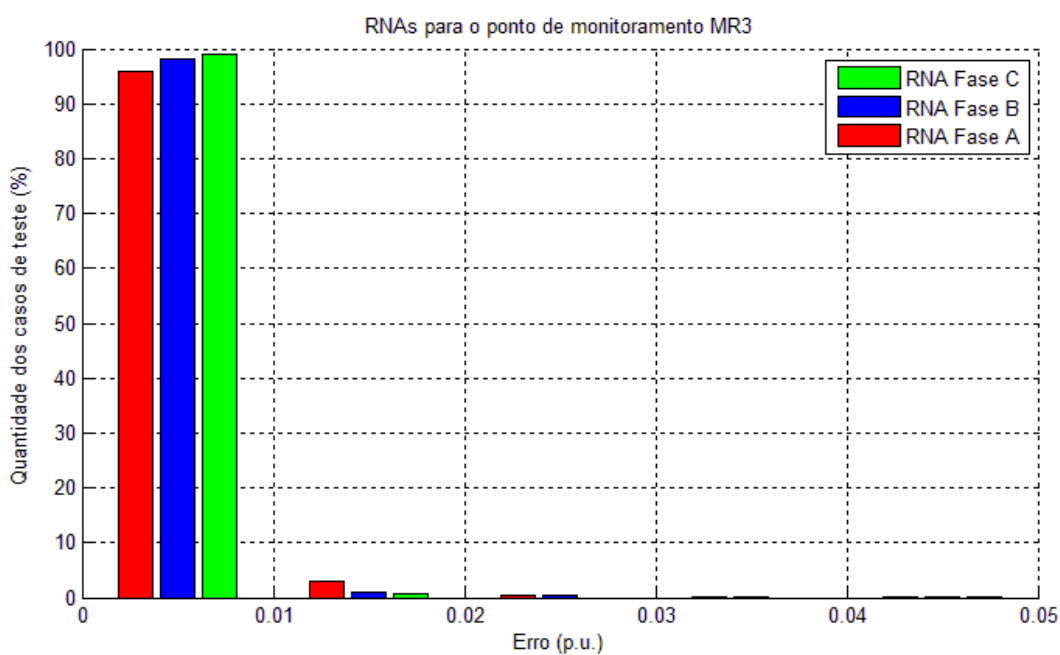
O histograma da Figura 18 ilustra como a grande maioria dos erros entre as respostas esperadas e as respostas das RNAs para o ponto de monitoramento MR1 estão abaixo de 0,01 p.u. para as três fases em estudo. Nota-se que a fase A, caracterizada por uma barra vermelha é a que apresenta o menor índice de acerto. Todavia, praticamente a totalidade de erros (97,4%) se concentra em até 0,05 p.u.

A mesma análise anterior pode ser feita para o histograma da Figura 19 relacionado com o ponto de carga MR2. Neste caso, destaca-se que, embora a porcentagem de acertos nos casos de teste esteja um pouco diminuída em relação à MR1, quando levados em conta um erro menor do que 0,01 p.u., os índices de acertos são significativos, e apresentam média de acerto superior a 85% nas três fases monitoradas. Novamente, cabe destacar que quando são analisados erros de até 0,05 p.u., isto é, somando-se os valores representados por cada uma das barras, a porcentagem de casos de testes dentro desta faixa permanece em valores acima de 97%.





**Figura 19 - Histograma de erros para o ponto de monitoramento remoto MR2.**




**Figura 20 - Histograma de erros para o ponto de monitoramento remoto MR3.**

A simples análise do histograma ilustrado pela Figura 20 indica que o ponto de monitoramento MR3 apresenta alto índice de acertos (entre 96% e 99,1%) quando se leva em conta a faixa de erro cujos níveis são de até 0,01 p.u.. Ademais, a média de acertos

para as três RNA, considerando-se erros de até 0,05 p.u., é superior a 99,6%, evidenciando o elevado índice de generalização das respostas fornecidas pelas redes neurais.

A Figura 21 traz o histograma de erros do ponto de carga MR4. Assim como nos outros casos já mencionados, constata-se um alto índice de acertos para os casos de teste considerando erro de 0,01 p.u. para as três fases em estudo, média de 93,6%. Além disso, praticamente a totalidade dos casos de teste (acima de 99%) apresentam erros inferiores a 0,05 p.u.

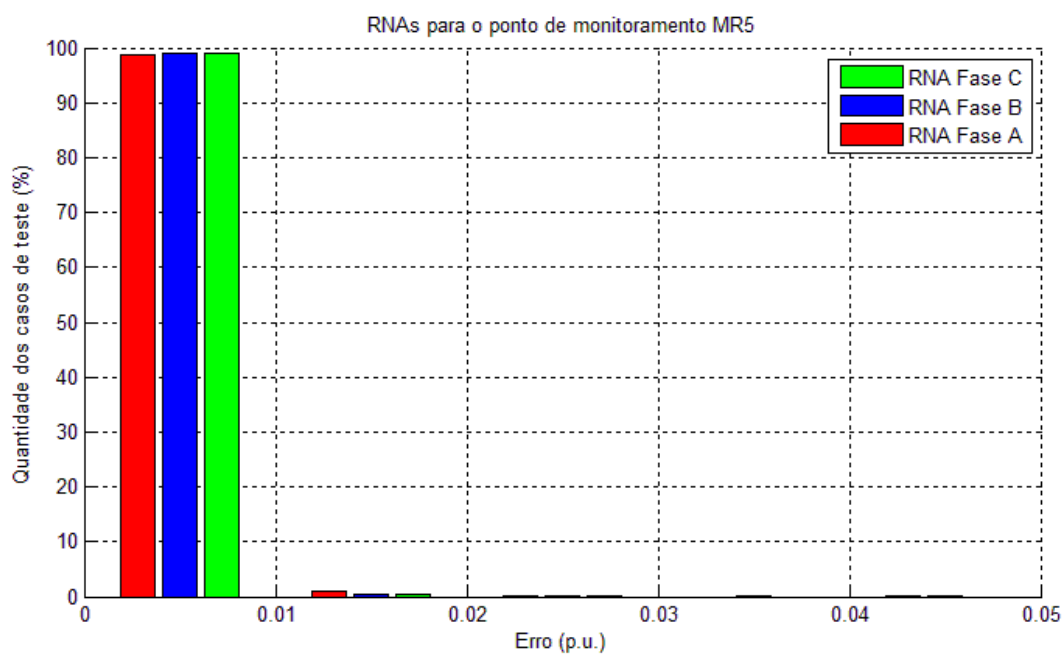


**Figura 21 - Histograma de erros para o ponto de monitoramento remoto MR4.**


O ponto de monitoramento MR5 também se destaca pelos altos níveis de acerto na estimação do valor eficaz das tensões elétricas pelas RNA para as três fases em estudo. O histograma relacionado ao ponto de carga MR5 é exibido na Figura 22 que ilustra grande taxa de acertos considerando a margem de erro de 0,01 p.u. Praticamente a totalidade dos casos está dentro desta margem (acima de 98,7%), o que caracteriza o alto grau de generalização das respostas fornecidas pelas RNA. Ao tomar como referência a quantidade de casos de teste com erros inferiores a 0,05 p.u., verifica-se que, em média, tem-se um índice de acerto de 99,7% dos casos.

O mesmo comportamento observado nos histogramas anteriores pode ser encontrado no histograma da Figura 23. Neste, observa-se que as RNA associadas ao ponto MR6 também exibem alto nível de acerto para as três fases do sistema. Cabe

acrescentar que para erros menores do que 0,05 p.u. tem-se um índice de acerto bastante expressivo, situando-se em níveis superiores a 99,5%.



**Figura 22 - Histograma de erros para o ponto de monitoramento remoto MR5.**



**Figura 23 - Histograma de erros para o ponto de monitoramento remoto MR6.**

Pelos resultados apresentados até então, fica evidente que, independentemente do ponto de monitoramento que se adote, a metodologia se mostrou eficaz e apresenta altos níveis de acertos ao estimar as tensões eficazes nos pontos de interesse ( $MR_n$ ). Pelo exposto, é possível constatar a alta capacidade de generalização do método de monitoramento remoto proposto no que se refere à aplicação do mesmo a quaisquer pontos de interesse alocados ao longo do SD em estudo. Ou seja, a partir de uma investigação inicial para a detecção da melhor topologia de rede a ser utilizada, relacionada a um ponto de monitoramento remoto específico, esta pode ser posteriormente replicada para as demais RNA que irão monitorar os pontos adicionais, salvo as devidas modificações necessárias já mencionadas no item 4.2., sem perda de qualidade das respostas fornecidas pelas RNA.

Na Tabela de 16 a 21, têm-se informações referentes ao tempo total gasto (em segundos) na etapa de treinamento para cada uma das três fases dos seis pontos de monitoramento da tensão eficaz. Os tempos de treinamento apresentados são referentes à utilização de um processador *Intel® Core™ 2 Duo* com processador de 2,26GHz.

Cada um dos treinamentos foi realizado cinco vezes, a fim de se obter os melhores resultados possíveis, em virtude da aleatoriedade dos pesos sinápticos iniciais. Os tempos descritos nas Tabelas de 16 a 21 são referentes aos treinamentos que apresentaram os maiores índices de acertos dentre os cinco treinamentos efetuados. Cabe ainda ressaltar que, dependendo da complexidade do sistema em análise, este tempo de treinamento pode variar, assim como se espera que o mesmo varie caso haja mudança na topologia das RNA, como, por exemplo, acrescentando mais neurônios nas camadas escondidas. Além disso, o critério de parada do treinamento das RNA também é responsável pela discrepância nos tempos de treinamento. Por exemplo, quando o treinamento para, porque atingiu um o número de 800 épocas, o tempo é maior do que quando o critério de parada está relacionado ao desempenho, isto é, atingiu um valor de erro quadrático médio menor de que  $10^{-6}$ .

**Tabela 16 - Tempo de treinamento das RNA em MR1.**

Monitoramento remoto			Tempo de treinamento
MR1	6-15-10-1	Fase A	82 s
	6-15-10-1	Fase B	81 s
	6-15-10-1	Fase C	81 s

Tabela 17 - Tempo de treinamento das RNA em MR2.

Monitoramento remoto			Tempo de treinamento
MR2	6-15-10-1	Fase A	94 s
	6-15-10-1	Fase B	90 s
	6-15-10-1	Fase C	82 s

Tabela 18 - Tempo de treinamento das RNA em MR3.

Monitoramento remoto			Tempo de treinamento
MR3	6-15-10-1	Fase A	82 s
	6-15-10-1	Fase B	8 s
	6-15-10-1	Fase C	35 s

Tabela 19 - Tempo de treinamento das RNA em MR4.

Monitoramento remoto			Tempo de treinamento
MR4	6-15-10-1	Fase A	85 s
	6-15-10-1	Fase B	37 s
	6-15-10-1	Fase C	75 s

Tabela 20 - Tempo de treinamento das RNA em MR5.

Monitoramento remoto			Tempo de treinamento
MR5	6-15-10-1	Fase A	78 s
	6-15-10-1	Fase B	17 s
	6-15-10-1	Fase C	20 s

**Tabela 21 - Tempo de treinamento das RNA em MR6.**


Monitoramento remoto			Tempo de treinamento
MR6	6-15-10-1	Fase A	83 s
	6-15-10-1	Fase B	84 s
	6-15-10-1	Fase C	79 s

### 7.1. Tensão eficaz medida no ponto MR1

Com o intuito de ilustrar e exemplificar os resultados obtidos pela metodologia e realizar uma análise comparativa de desempenho das RNAs no que se refere à estimação do valor eficaz da tensão trifásica nos pontos de carga de interesse dentro do SD em estudo, foi escolhido o ponto de aplicação de falta número 5 no sistema da Figura 12. Este possui ângulo de inserção de  $0^\circ$  e  $30\Omega$  de resistência de falta. Ademais, este ponto de aplicação de falta dista em torno de 21 km da SE do SD em estudo, conforme dados repassados pela concessionária de energia elétrica regional.

Na Figura 24 é possível verificar o comportamento da tensão fornecida pelas RNA das fases A, B e C no ponto de monitoramento MR1 mediante ao caso de falta escolhido. A partir deste exemplo, observa-se que a fase C mantém-se em níveis de tensão próximos ao nominal (entre 0,9 p.u. e 1,1 p.u.). A fase B sofre pequena queda nos níveis de tensão, porém, não está caracterizado um afundamento de tensão, uma vez que este nível não é inferior a 0,9 p.u.. A fase A sofre a maior queda de tensão. Contudo, também não caracteriza um afundamento de tensão, já que permanece sempre acima do nível de 0.9 p.u. durante todos os ciclos considerados.

De maneira geral, constata-se que as respostas das RNA das três fases são significativamente condizentes com os valores de tensão eficazes esperados representados pelos marcadores circulares. Cabe acrescentar que nos três primeiros ciclos o sistema está em regime permanente, isto é, os níveis de tensão assumem valores nominais do sistema, sendo, neste caso, o valor eficaz da tensão próximo a 0,95 p.u..



**Figura 24 - Comparação entre os valores das tensões eficazes estimadas e seus respectivos valores esperados para o ponto MR1.**

## 7.2. Tensão eficaz medida no ponto MR2

No ponto de monitoramento MR2, constatou-se que o caso de falta selecionado é capaz de provocar significativas variações de tensões em duas das fases monitoradas, conforme se observa na Figura 25.

A fase A apresenta leve variação da tensão, porém, com níveis insuficientes para configurar afundamento de tensão (menor do que 0,9 p.u.). Assim como na fase A, os valores das tensões nas fases B e C não caracterizam afundamento ou elevação de tensão, isto é, permanecem dentro da faixa de valores nominais (0,9 p.u. a 1,1 p.u.). Cabe acrescentar que as respostas das RNA para as três fases apresentam altos níveis de acertos para os casos em que a tensão eficaz fica dentro dos níveis nominais.

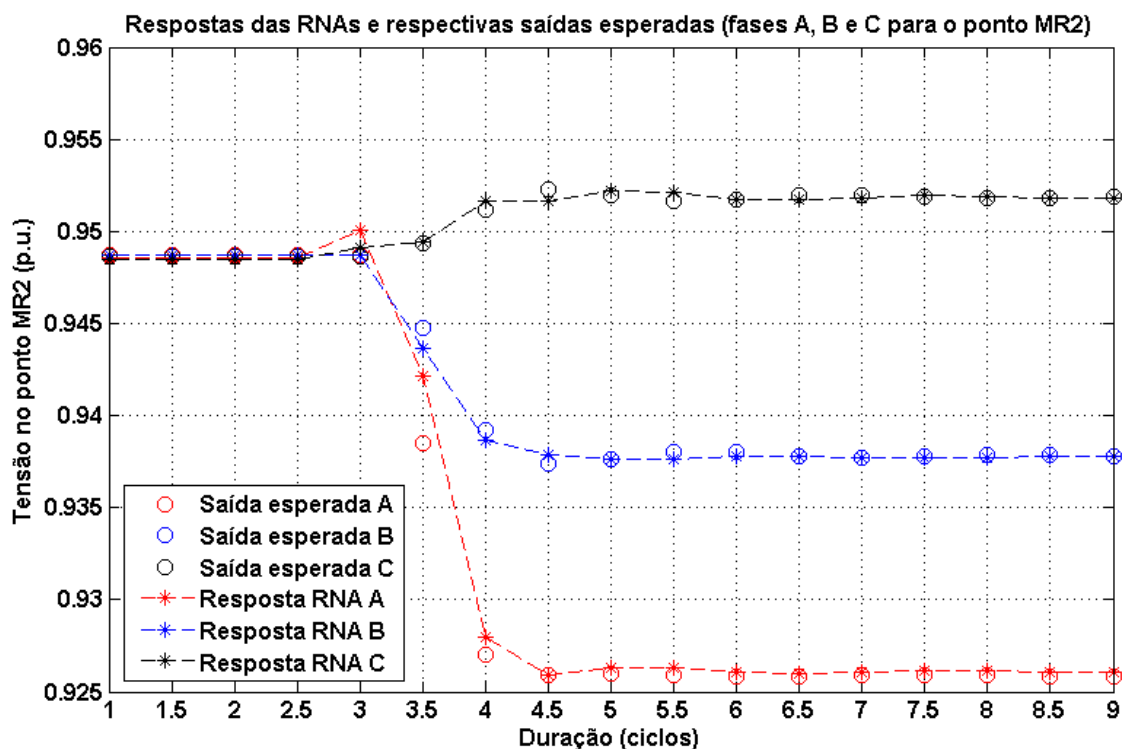
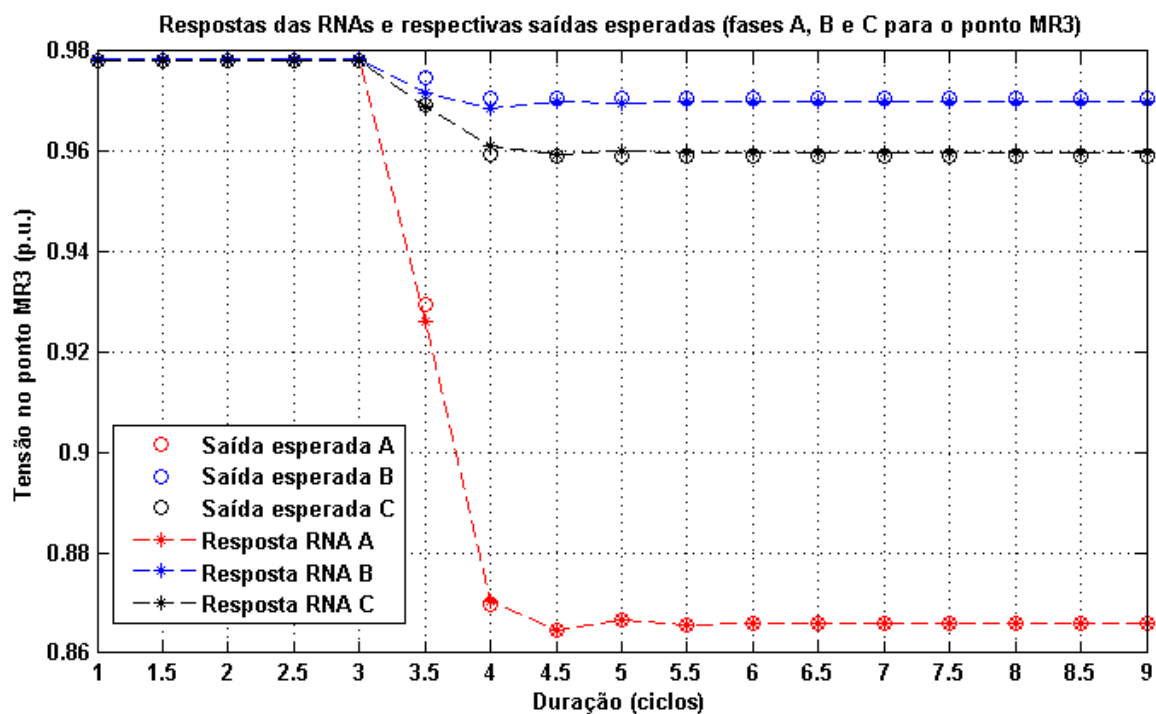


Figura 25 - Comparação entre os valores das tensões eficazes estimadas e seus respectivos valores esperados para o ponto MR2.

### 7.3. Tensão eficaz medida no ponto MR3

O caso de falta escolhido reflete um afundamento de tensão da fase A no ponto de monitoramento da tensão eficaz no ponto MR3 conforme ilustrado na Figura 26. Os níveis de tensão para a fase A ficam em torno de 0,87 p.u. (abaixo de 0,9 p.u.). Já para as fases B e C constata-se que os níveis de tensão ficam próximos aos valores nominais, cerca de 0,97 p.u. e 0,96 p.u., respectivamente.






**Figura 26 - Comparação entre os valores das tensões eficazes estimadas e seus respectivos valores esperados para o ponto MR3.**

#### **7.4. Tensão eficaz medida no ponto MR4**


No ponto de monitoramento remoto MR4 observa-se que o caso de falta selecionado não é capaz de provocar variações significativas de tensão, conforme ilustrado na Figura 27. Os valores eficazes das tensões nas três fases, estimados pelas respectivas RNAs, permanecem próximos do valor nominal (entre 0,9 p.u. e 1,1 p.u), sendo registradas tensões remanescentes em torno de 0,945 p.u. para a fase A, 0,955 p.u. para a fase B e 0,97 p.u. para a fase C.



**Figura 27 - Comparação entre os valores das tensões eficazes estimadas e seus respectivos valores esperados para o ponto MR4.**

### 7.5. Tensão eficaz medida no ponto MR5


Comportamento semelhante ao verificado no monitoramento do ponto MR4 é observado no ponto MR5, ao se considerar o caso de falta escolhido conforme se observa na Figura 28. Ou seja, não são registradas variações relevantes nos níveis de tensão eficaz no ponto de monitoramento remoto. Os valores de tensão permanecem dentro dos limites nominais (entre 0.9 p.u. e 1.1 p.u.). Pela análise da Figura 28 também é possível afirmar que os valores das tensões estimadas remotamente pelas RNA das três fases, aproximam-se dos valores esperados, revelando a elevada capacidade de generalização das respostas fornecidas pelas redes treinadas.



**Figura 28 - Comparação entre os valores das tensões eficazes estimadas e seus respectivos valores esperados para o ponto MR5.**

## 7.6. Tensão eficaz medida no ponto MR6

Por fim, completando a ilustração do caso de curto-circuito selecionado, tem-se que de acordo com os resultados apresentados na Figura 29 fica evidente que o caso de falta escolhido foi responsável por provocar um afundamento de tensão na fase A no ponto de monitoramento MR6. A tensão observada na fase A apresenta níveis de tensão remanescentes em torno de 0,87 p.u. Já as tensões registradas nas fases B e C permanecem dentro da faixa de valores nominais (entre 0,9 p.u. e 1,1 p.u.) com cerca de 0,87 p.u. e 0,86 p.u, respectivamente.



**Figura 29 - Comparação entre os valores das tensões eficazes estimadas e seus respectivos valores esperados para o ponto MR6.**

Pelo exposto, fica evidente a capacidade de generalização das respostas RNA frente ao caso de falta selecionado. Sendo assim, é possível afirmar que as três RNA estimam corretamente os níveis de tensão eficaz para as três fases com excelente nível de acerto, fornecendo fortes indícios de que, caso haja interesse, por exemplo, pode-se definir um novo ponto de carga adicional MR7 em qualquer localização ao longo do SD em questão, e, a partir das adaptações apontadas no item 4.2 do Capítulo 4, podem-se obter os respectivos valores de tensão eficaz estimados pela metodologia neste novo ponto de monitoramento remoto.

## Conclusão

A metodologia utilizada no trabalho é fundamentada no uso de ferramenta inteligente, em específico, de RNA. Sua aplicação se mostrou satisfatória na tarefa de se monitorar remotamente os valores eficazes das tensões em pontos distantes da subestação, local este em que as redes neurais estão localizadas e sendo supridas com as medidas dos níveis de tensão e corrente provenientes de um medidor de QEE da subestação. Fica evidente, através do apresentado que a metodologia pode complementar o processo de monitoramento convencional do SD em estudo, realizado com a utilização de medidores físicos de custo considerável.

O conjunto de treinamento das RNA é bem diversificado, contando com distintos casos possíveis de faltas elétricas uma vez que há a variação da distância dos pontos de aplicação de curto-circuito e variação tanto na impedância de falta como no ângulo de incidência da mesma. A boa diversidade de casos contribui ativamente na alta capacidade de generalização das RNA, de forma que estas são capazes de estimar corretamente os níveis de tensão em qualquer ponto de interesse ao longo do SD em estudo, desde que respeitando o domínio de operação para o qual as RNA foram projetadas.

O procedimento para a obtenção do monitoramento remoto de uma carga genérica dentro do SD se mostrou eficaz, uma vez que após a realização de uma investigação inicial da melhor topologia de RNA e sua aplicação no ponto de carga MR1 foi possível, com as devidas alterações e precauções indicadas, aplicar o método de monitoramento proposto para os pontos MR2, MR3, MR4, MR5 e MR6, alocados ao longo do SD em estudo, e obter resultados satisfatórios em todas estas cargas monitoradas. A quantidade de casos de teste, quando analisados os seis pontos de carga escolhidos, com erros inferiores a 0,03 p.u entre a reposta deseja e a resposta estimada pelas RNA permaneceu entre 93,5% e 99,7%. A mesma análise, considerando-se casos de teste com erros inferiores a 0,01 p.u., revela que de 85,3% a 99,4% dos casos de teste permaneceram nesta faixa de erro.

De fato, o elevado índice de acerto das RNA dos respectivos pontos monitorados, obtido ao se adotar topologias idênticas para as mesmas, fornece fortes evidências de que o grau de complexidade das do mapeamento tensões eficazes de cada uma das cargas presentes no SD é similar e aproximadamente constante em relação ao ponto de monitoramento escolhido ( $MR_n$ ), conferindo à metodologia proposta excelentes perspectivas referentes a sua implementação prática, tendo em vista que uma vez adequadamente executada a investigação inicial sobre a melhor topologia das redes, esta

pode ser estendida a quaisquer cargas de interesse no SD, conforme os objetivos propostos inicialmente neste trabalho.

Cabe ressaltar que o modelo exposto, da maneira como foi elaborado, é válido para uma topologia específica de operação do SD e um perfil de carregamento estático. Sendo assim, em trabalhos futuros será possível ampliar a metodologia proposta incluindo perfis de carregamento do SD no treinamento das RNA. Além disso, não se descarta a necessidade de um cuidado extra na escolha dos melhores pontos de aplicação das faltas, considerando aspectos como a taxa de falhas dos alimentadores, potência de curto-circuito das barras e os demais tipos de falta, já que neste trabalho são abordadas apenas as faltas monofásicas entre a fase *A* e o terra do sistema. Tais aspectos serão fundamentais para aprimorar a representatividade do SD, obtendo-se um banco de dados para treinamento mais abrangente e consistente, elevando ainda mais a capacidade de generalização das RNA diante de outras condições de operação do SD não levadas em conta neste trabalho.

## Referências Bibliográficas

ABDOLLAHI, A.; SEYEDTABAI, S. Real. **Transmission Line Fault Location Estimation by Fourier and Wavelet Transforms and ANN**. In: The 4th International Power Engineering

AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA – ANEEL. **Procedimento de Distribuição de Energia Elétrica no Sistema Elétrico Nacional – PRODIST: Módulo 1: Introdução**, 2012a

AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA – ANEEL. **Procedimento de Distribuição de Energia Elétrica no Sistema Elétrico Nacional – PRODIST: Módulo 8: Qualidade da Energia Elétrica**, 2012b,

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

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**. Trabalho de Conclusão de Curso (Engenharia Elétrica) – Escola de Engenharia de São Carlos (EESC), Universidade de São Paulo (USP). São Carlos – SP, 2010.

CARDENAS, A.; GUZMAN, C.; AGBOSSOU, K. **Real-Time Evaluation of Power Quality Using FPGA Based Measurement System**. In: IEEE International Symposium on Industrial Electronics, 2010.

DEVARAJ, D.; RADHIKA, P. **Discrimination of power quality disturbances using combined mathematical transforms and artificial neural network**. In: IEEE International Conference on Sustainable Energy Technologies, 2008.

DEVARAJ, D.; SUBASRI, V.; RADHIKA, P.; KANAGAVALLI, R. **Power Quality Monitoring Using Wavelet Transform and Artificial Neural Networks**. In: India International Conference on Power Electronics, 2006.

DUGAN, R. C., MCGRANAGHAN, M. F., SANTOSO, S., BEATY, H. W. **Electrical Power Systems Quality**, 2.ed, New York: McGraw-Hill, 2003.

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

HAYKIN, S. **Neural Networks and Learning Machines**: Prentice Hall, 2008.

HUANG, S. J.; HSIEH, C. T.; HIANG, C. L. **Application of wavelet to classify power system disturbances**. Electric Power Systems Research, No 47, pp. 87-93, 1998.

KAGAN N.; ROBBA, E. J.; OLIVEIRA, C. B. D. **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, 2002.

Leuven EMTP Center. **Alternative Transients Program Rule Book**, 1987.

SILVA, I. N da.; SPATTI, D. H.; FLAUZINO, R. A., **Redes Neurais Artificiais: para engenharia e ciências aplicadas**, São Paulo, Artliber, 2010.

SRINIVASAN, D.; NG, W.; LIEW, A. **Neural-Network-Based Signature Recognition for Harmonic Source Identification**. IEEE Transactions on Power Delivery, Vol. 21 NO.1, 2006.

TALAAT, N.; IBRAHIM, W.; KUSIC, G. **New technique for categorization of power quality disturbances**. In: Power Quality and Supply Reliability Conference, 2008.

VEGA, V.; KAGAN, N.; ORDOÑEZ, G.; DUARTE, C. **Automatic Power Quality Disturbance Classification Using Wavelet, Support Vector Machine and Artificial Neural Network**. International Conference on Electricity Distribution, 2009.



## Anexo

### Anexo 1 - Código de permuta aleatória das matrizes

```
% saida1_RNA = ones(200,17);
% saida2_RNA = 2*ones(200,17);
% saida3_RNA = 3*ones(200,17);
% entrada_RNA = 4*ones(6,3400);

%% Redimensionamento das saídas
%=====
%Redimensiona saida1 de 200x17 para 1x3400
matriz = saida1_RNA;
sizemat2 = size(matriz);
k=1;
vet1 = 0;
    for i=1:sizemat2(1,1)
        for j=1:sizemat2(1,2)
            vet1(k) = matriz(i,j);
            k = k+1;
        end
    end
vet1; %Vetor 1x3400 com as saidas referentes a fase A

%Redimensiona saida2 de 200x17 para 1x3400
matriz = saida2_RNA;
sizemat2 = size(matriz);
k=1;
vet2 = 0;
    for i=1:sizemat2(1,1)
        for j=1:sizemat2(1,2)
            vet2(k) = matriz(i,j);
            k = k+1;
        end
    end
vet2; %Vetor 1x3400 com as saidas referentes a fase B

%Redimensiona saida3 de 200x17 para 1x3400
matriz = saida3_RNA;
sizemat2 = size(matriz);
k=1;
vet3 = 0;
    for i=1:sizemat2(1,1)
        for j=1:sizemat2(1,2)
            vet3(k) = matriz(i,j);
            k = k+1;
        end
    end
vet3; %Vetor 1x3400 com as saidas referentes a fase C

%% =====

%Concatena as matrizes de entrada e as de saída
mat = [entrada_RNA;vet1;vet2;vet3];
```

```

%Faz a permuta aleatória dos elementos da matriz concatenada

matsize = size(mat);                                %Tamanho da matriz
nemb = 1000;                                         %Numero de embaralhamentos
auxemb = 0;                                          %Auxiliar
colunas = 17;                                       %Determina de quantas colunas
serão embaralhadas

%vetor de controle

for h=1:200
    controle(h)=h;
end

%Troca de posições dos elementos da matriz
for n=1:nemb
    %Define os índices que serão trocados
    indice = round(matsize(1,2)*rand(1,1));
    indice2 = round(matsize(1,2)*rand(1,1));

    % Garante que os índices são múltiplos do número de colunas que
nao    % serão embaralhados

    while ~mod(indice,colunas)==0
        indice = indice+1;
    end

    while ~mod(indice2,colunas)==0
        indice2 = indice2+1;
    end

    %Índice recebe uma unidade a mais
    indice = indice+1;
    indice2 = indice2+1;

    %Verifica se os índices não são zero
    if indice ==0
        indice = 1;
    end

    if indice2 == 0
        indice2 = 1;
    end

    %Considera o caso em que o índice é maior que a matriz que será
    %permutada

    if indice >= matsize(1,2)
        indice = indice-colunas;
    end

    if indice2 >= matsize(1,2)
        indice2 = indice2-colunas;
    end
end

```

```

%Ajusta os valores do vetor de controle conforme são trocados na
%permuta
    if (indice==1 && indice2 ~=1)
        auxcont = controle(1);
        controle(1)=controle((indice2-1)/17);
        controle((indice2-1)/17) = auxcont;
        elseif (indice==1 && indice2 ~=1)
            auxcont = controle((indice-1)/17);
            controle((indice-1)/17)=controle(1);
            controle(1) = auxcont;
        elseif (indice==1 && indice2 ~=1)
            auxcont = controle(1);
            controle(1)=controle(1);
            controle(1) = auxcont;
        elseif (indice~=1 && indice2 ~=1)
            auxcont = controle((indice-1)/17);
            controle((indice-1)/17)=controle((indice2-1)/17);
            controle((indice2-1)/17) = auxcont;
    end

    %Faz a troca de posições em todas as linhas da matriz
    for j=1:matsize(1,1)
        for i=0:colunas-1
            auxemb(i+1) = mat(j,indice+i);
            mat(j,indice+i) = mat(j,indice2+i);
            mat(j,indice2+i) = auxemb(i+1);
        end
    end
end
mat;

%Saídas já permutadas aleatoriamente
vet1 = mat(7,:);
vet2 = mat(8,:);
vet3 = mat(9,:);
entrada_RNA = mat(1:6,:);

%% =====
%Redimensiona as saídas para o formato original

%Redimensiona saida1 para 200x17
k=1;
for i=1:sizemat2(1,1)
    for j=1:sizemat2(1,2)
        matriz(i,j) = vet1(k);
        k = k+1;
    end
end

saida1_RNA = matriz;
%matriz

%Redimensiona saida2 para 200x17
k=1;
for i=1:sizemat2(1,1)
    for j=1:sizemat2(1,2)
        matriz(i,j) = vet2(k);

```

```
        k = k+1;
    end
end

saida2_RNA = matriz;
%matriz

%Redimensiona saida3 para 200x17
k=1;
for i=1:sizemat2(1,1)
    for j=1:sizemat2(1,2)
        matriz(i,j) = vet3(k);
        k = k+1;
    end
end

saida3_RNA = matriz;
%matriz
```