



UNIVERSIDADE  
ESTADUAL DE LONDRINA

---

ELTON JESER DINIZ DOS SANTOS

**APLICAÇÃO DE REDES NEURAIS ARTIFICIAIS NA  
ANÁLISE DO ENCAPSULAMENTO DE BOBINAS DE  
TRANSFORMADORES**

---

Londrina  
2013

ELTON JESER DINIZ DOS SANTOS

**APLICAÇÃO DE REDES NEURAIS ARTIFICIAIS NA  
ANÁLISE DO ENCAPSULAMENTO DE BOBINAS DE  
TRANSFORMADORES**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Elétrica da Universidade Estadual de Londrina como parte dos Requisitos para obtenção do Título de Mestre em Engenharia Elétrica.

Área de concentração: Sistemas Elétricos de Potência.

Especialidade: Máquinas Elétricas e Dispositivos de Potência.

Orientador: Prof. Dr. Márcio Roberto Covacic.

Londrina  
2013

### Dados Internacionais de Catalogação-na-Publicação (CIP)

S237a Santos, Elton Jeser Diniz dos.  
Aplicação de Redes Neurais Artificiais na Análise do  
Encapsulamento de Bobinas de Transformadores / Elton Jeser Diniz dos Santos  
– Londrina, 2013.  
202 f. : il.

Orientador: Márcio Roberto Covacic  
Dissertação (Mestrado em Engenharia Elétrica) – Universidade Estadual de  
Londrina, Centro de Tecnologia e Urbanismo, Programa de Pós-Graduação em  
Engenharia Elétrica, 2013.  
Inclui bibliografia.

1. Transformadores secos – Teses. 2. Análise do encapsulamento de bobinas –  
Teses. 3. Descargas parciais – Teses. 4. Redes neurais artificiais – Teses. I. Covacic,  
Márcio Roberto. II. Universidade Estadual de Londrina. Centro de Tecnologia e  
Urbanismo. Programa de Pós-Graduação em Engenharia Elétrica. III. Título.

CDU 621.314

ELTON JESER DINIZ DOS SANTOS

**APLICAÇÃO DE REDES NEURAIS ARTIFICIAIS NA ANÁLISE DO  
ENCAPSULAMENTO DE BOBINAS DE TRANSFORMADORES**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Elétrica da Universidade Estadual de Londrina como parte dos Requisitos para obtenção do Título de Mestre em Engenharia Elétrica.

**BANCA EXAMINADORA**

---

Prof. Dr. Márcio Roberto Covacic  
Universidade Estadual de Londrina - UEL

---

Prof<sup>a</sup>. Dr<sup>a</sup>. Silvia Galvão de Souza Cervantes  
Universidade Estadual de Londrina - UEL

---

Prof. Dr. Luiz Henrique Geromel  
Instituto Federal de São Paulo - IFSP

Londrina, 25 de janeiro de 2013.

Dedico esta dissertação ao meu filho Victorio, à minha esposa Yolanda, aos meus pais e a toda a minha família e amigos, pelo apoio, força e incentivo.

# Agradecimentos

A Deus e ao Senhor Jesus Cristo pois Têm sido o meu Pastor e nada tem me faltado. Se Deus é por nós quem será contra?

Ao meu orientador Prof. Dr. Márcio Roberto Covacic por estar sempre pronto a me atender e orientar.

Aos professores, Prof. Dr. Luiz Henrique Geromel e Prof. Dr. Márcio Mendonça pois foram de fundamental importância na condução das pesquisas.

À Prof<sup>a</sup>. Dr<sup>a</sup>. Silvia Galvão de Souza Cervantes pois foi imenso o seu apoio durante a realização do mestrado.

Aos meus amigos Márcio Tardivo, Cláudio Torres, Emerson Martins, Fabio Gentilin, Flávio Rossini e Adriano Siqueira pelo incentivo e apoio.

Aos amigos da Romagnole que auxiliaram nos levantamentos de dados e na realização dos ensaios.

SANTOS, Elton Jeser Diniz dos. **Aplicação de Redes Neurais Artificiais na Análise do Encapsulamento de Bobinas de Transformadores**. 2013. 93p. Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Elétrica – Universidade Estadual de Londrina, Londrina, 2013.

## RESUMO

As bobinas de média tensão dos transformadores secos são encapsuladas com resina epóxi. Apesar do rigoroso processo de qualidade no encapsulamento sob vácuo, existem pequenas bolhas ou vazios que permanecem internamente ao encapsulamento das bobinas. Estas bolhas ou vazios, são fontes geradoras de descargas parciais que são medidas através do ensaio de tensão induzida nos transformadores. No entanto, este ensaio é realizado somente após a montagem final do transformador, de forma que, caso haja alguma reprovação neste, por descargas parciais elevadas, será necessário a desmontagem do transformador, a fabricação de novas bobinas, uma nova montagem e a repetição de todos os ensaios de rotina. Esta reprovação e retrabalhos oneram os custos de produção e impactam diretamente no prazo de entrega do transformador. Para minimização deste problema, esta pesquisa propõe uma metodologia de ensaio de descargas parciais por tensão aplicada em bobinas de média tensão, que seja realizada antes da montagem no transformador. A metodologia possibilita analisar se o encapsulamento está ou não adequado, bem como estimar os valores das medições de descargas parciais por tensão induzida no transformador montado. As Redes Neurais Artificiais são utilizadas para relacionar as medições por tensão aplicada realizadas nas bobinas e as medições de descargas parciais por tensão induzida realizadas nos transformadores montados. A escolha das Redes Neurais Artificiais é em função da capacidade que as mesmas possuem de assimilar conhecimento a partir de sua própria experiência e generalizar soluções. Os resultados obtidos com os ensaios de tensão aplicada apresentam erros relativos médios menores que 0,5%, quando comparados com os resultados dos ensaios de tensão induzida, comprovando sua validação como alternativa para avaliação da qualidade do encapsulamento das bobinas de média tensão dos transformadores secos.

**Palavras-chave:** Transformadores secos. Análise do encapsulamento de bobinas. Descargas parciais. Redes neurais artificiais.

SANTOS, Elton Jeser Diniz dos. **Artificial Neural Network Application for Analysis of Encapsulated Transformers Coils**. 2013. 93 p. Dissertation presented to Electrical Engineering Post Graduated Program – Universidade Estadual de Londrina, Londrina, 2013.

## **ABSTRACT**

The medium voltage coils of dry-type transformers are encapsulated with epoxy resin. Although there is strict quality process in vacuum encapsulation, there are small bubbles or voids that remain inside the coil encapsulation. These bubbles or voids are sources of partial discharges that are measured by the induced voltage test. However, this test is performed only after the transformer is fully assembled. So, if there is any failure by high partial discharges, it is necessary to disassemble the transformer, manufacture new coils, re-assemble it and repeat the routine test. This failure and rework costs directly impact the production and delivery of the transformer. To minimize this problem, this research proposes a methodology for partial discharge voltage applied test on medium voltage coils, which is performed before assembling the transformer. The methodology allows to analyze whether the quality of the encapsulation is appropriate and to estimate the values of partial discharge measurements for induced voltage test. Artificial Neural Networks are used to link the partial discharge by voltage applied test and induced voltage test. The choice of Artificial Neural Networks is based on the capacity that they have to assimilate knowledge from their own experience and generalize solutions. The results obtained from the testing of applied voltage test have mean relative errors less than 0.5% when compared to results of the induced voltage test. It confirms this validation as an alternative to evaluate the quality of the encapsulation of medium voltage coils of dry-type transformers.

**Keywords:** Dry-type transformers. Coil encapsulating analysis. Partial discharges. Artificial neural network.

# Lista de Figuras

Figura 1 - Modelagem 3D de um transformador seco (Fonte: Romagnole).....	22
Figura 2 - Transformador seco sem bobinas em uma fase (Fonte: Romagnole).....	24
Figura 3 - Molde de aço carbono para bobinas de média tensão (Fonte: Vacuum Technology Co.).....	26
Figura 4 - Autoclave para encapsulamento de bobinas (Fonte: Hübers).....	27
Figura 5 - Bobinas de média e baixa tensão previamente montadas (Fonte: Romagnole).....	28
Figura 6 - Neurônio biológico.....	40
Figura 7 - Sinapses entre neurônios.....	41
Figura 8 - Neurônio artificial.....	43
Figura 9 - Função de ativação linear .....	45
Figura 10 - Função de ativação degrau .....	46
Figura 11 - Função de ativação sinal.....	47
Figura 12 - Função de ativação rampa simétrica.....	47
Figura 13 - Função de ativação sigmoide.....	48
Figura 14 - Influência do parâmetro $\beta$ na função sigmoide.....	48
Figura 15 - Função de ativação tangente hiperbólica .....	49
Figura 16 - Influência do parâmetro $\beta$ na função tangente hiperbólica .....	49
Figura 17 - Rede <i>feedforward</i> de camada simples .....	51
Figura 18 - Rede <i>feedforward</i> de camadas múltiplas .....	52
Figura 19 - Rede recorrente .....	53
Figura 20 - Bobina didática de média tensão encapsulada (Fonte: 2010 IEEE PES T&D Conference and Exposition).....	61
Figura 21 - Ensaio de medição de descargas parciais por tensão aplicada em bobinas de média tensão encapsuladas (Fonte: Acervo próprio).....	62
Figura 22 - Transformador trifásico seco: bobinas e núcleo (Fonte: Romagnole).....	64
Figura 23 - Rede neural artificial.....	66
Figura 24 - Treinamento da RNA com 5 neurônios - Agrupamento #1 .....	70

Figura 25 - Treinamento da RNA com 10 neurônios - Agrupamento #1.....	71
Figura 26 - Treinamento da RNA com 15 neurônios - Agrupamento #1.....	72
Figura 27 - Treinamento da RNA com 20 neurônios - Agrupamento #1.....	73
Figura 28 - Treinamento da RNA com 5 neurônios - Agrupamento #2 .....	75
Figura 29 - Treinamento da RNA com 10 neurônios - Agrupamento #2.....	76
Figura 30 - Treinamento da RNA com 15 neurônios - Agrupamento #2.....	77
Figura 31 - Treinamento da RNA com 20 neurônios - Agrupamento #2.....	78
Figura 32 - Treinamento da RNA com 5 neurônios - Agrupamento #3 .....	80
Figura 33 - Treinamento da RNA com 10 neurônios - Agrupamento #3 .....	81
Figura 34 - Treinamento da RNA com 15 neurônios - Agrupamento #3.....	83
Figura 35 - Treinamento da RNA com 20 neurônios - Agrupamento #3.....	84
Figura 36 - Avaliação da taxa de acerto média para os 3 agrupamentos de conjuntos de dados e 4 valores de neurônios na camada escondida da rede.....	85
Figura 37 - Avaliação da quantidade de épocas para os 3 agrupamentos de conjuntos de dados e 4 valores de neurônios na camada escondida da rede.....	87
Figura 38 - Avaliação do erro relativo médio para os 3 agrupamentos de conjuntos de dados e 4 valores de neurônios na camada escondida da rede.....	88

# Lista de Tabelas

Tabela 1 -	Características magnéticas do aço elétrico de grão orientado (Fonte: Aperam).....	23
Tabela 2 -	Níveis de ruído para transformador seco (AN ou ANAN) (NBR10295,2011).....	23
Tabela 3 -	Classe de temperatura de materiais isolantes (NBR/IEC60085, 2012).....	29
Tabela 4 -	Símbolos literais para os métodos de resfriamento (NBR10295, 2011).....	29
Tabela 5 -	Valores de referência de descargas parciais para equipamentos (Fonte: CEPEL).....	37
Tabela 6 -	Exemplo do banco de dados das medições de DP por tensão aplicada.....	63
Tabela 7 -	Exemplo do banco de dados das medições de DP por tensão induzida.....	65
Tabela 8 -	Distribuição dos agrupamentos de conjuntos dos dados de entrada.....	67
Tabela 9 -	Valores de DP obtidos pela RNA 5 neurônios - Agrupamento #1.....	70
Tabela 10 -	Valores de DP obtidos pela RNA 10 neurônios - Agrupamento #1.....	71
Tabela 11 -	Valores de DP obtidos pela RNA 15 neurônios - Agrupamento #1.....	72
Tabela 12 -	Valores de DP obtidos pela RNA 20 neurônios - Agrupamento #1.....	73
Tabela 13 -	Valores de DP obtidos pela RNA 5 neurônios - Agrupamento #2.....	74
Tabela 14 -	Valores de DP obtidos pela RNA 10 neurônios - Agrupamento #2.....	76
Tabela 15 -	Valores de DP obtidos pela RNA 15 neurônios - Agrupamento #2.....	77
Tabela 16 -	Valores de DP obtidos pela RNA 20 neurônios - Agrupamento #2.....	78
Tabela 17 -	Valores de DP obtidos pela RNA 5 neurônios - Agrupamento #3.....	79
Tabela 18 -	Valores de DP obtidos pela RNA 10 neurônios - Agrupamento #3.....	81
Tabela 19 -	Valores de DP obtidos pela RNA 15 neurônios - Agrupamento #3.....	82
Tabela 20 -	Valores de DP obtidos pela RNA 20 neurônios - Agrupamento #3.....	84

# Lista de Abreviaturas e Siglas

ABNT	Associação Brasileira de Normas Técnicas
AN	Ar Natural
ANAN	Ar Natural / Ar Natural
CLP	Controlador Lógico Programável
DP	Descarga(s) Parcial (ais)
IEC	<i>International Electrotechnical Commission</i> (Comissão Eletrotécnica Internacional)
MLP	<i>Multilayer Perceptron</i> (Perceptron Multicamadas)
NBR	Norma Brasileira
pC	Picocoulombs
RBF	<i>Radial Basis Function</i> (Função Base Radial)
RNA	Rede Neural Artificial
RNA's	Redes Neurais Artificiais
$V_N$	Tensão Nominal por Fase
UL	<i>Underwriters Laboratories</i> (Laboratórios Underwriters)

# Sumário

<b>1 INTRODUÇÃO</b>	12
1.1 REVISÃO BIBLIOGRÁFICA	14
1.2 OBJETIVO	16
1.2.1 Principal	16
1.2.2 Secundário	17
1.2.3 Justificativa	17
1.2.4 Metodologia	18
1.2.5 Organização da Dissertação	18
<b>2 TRANSFORMADORES SECOS ENCAPSULADOS</b>	21
2.1 TRANSFORMADOR	21
2.1.1 Núcleo e Ferragens	22
2.1.2 Enrolamentos de Baixa Tensão	24
2.1.3 Enrolamentos de Média Tensão	25
2.1.4 Classe de Térmica dos Materiais Isolantes	28
2.1.5 Classificação dos Métodos de Resfriamento	29
2.1.6 Ensaios	30
2.1.6.1 Ensaios de Rotina	30
2.1.6.2 Ensaios de Tipo	31
2.1.6.3 Ensaios Especiais	31
2.2 RESINA EPÓXI	32
2.3 DESCARGAS	34
<b>3 REDES NEURAIS ARTIFICIAIS</b>	38
3.1 TOPOLOGIA DAS REDES NEURAIS	39
3.1.1 Neurônio biológico	39
3.1.2 Neurônio artificial	41
3.1.3 Funções de ativação	44
3.1.3.1 Função linear	45
3.1.3.2 Função degrau	45
3.1.3.3 Função sinal	46
3.1.3.4 Função rampa simétrica	47
3.1.3.5 Função sigmoide	47
3.1.3.6 Função tangente hiperbólica	48
3.2 ARQUITETURA DAS REDES NEURAIS ARTIFICIAIS	49
3.2.1 Arquitetura de rede <i>feedforward</i> de camada simples	50

3.2.2	Arquitetura de rede <i>feedforward</i> de camadas múltiplas.....	51
3.2.3	Arquitetura de rede recorrente.....	52
3.3	TREINAMENTO DAS REDES NEURAIS ARTIFICIAIS .....	53
3.3.1	Aprendizado supervisionado .....	54
3.3.2	Aprendizado não-supervisionado .....	55
3.4	REDES PERCEPTRON MULTICAMADAS .....	56
3.4.1	Algoritmo <i>backpropagation</i> .....	57
3.4.2	Método de Levenberg-Marquardt .....	58
3.5	PROCESSO DE DESENVOLVIMENTO DE REDES NEURAIS ARTIFICIAIS .....	59
<b>4</b>	<b>APLICAÇÃO DE REDES NEURAIS PARA ANÁLISE DO ENCAPSULAMENTO .....</b>	<b>61</b>
4.1	LEVANTAMENTO DE DADOS .....	61
4.2	CONSTRUÇÃO DO SISTEMA NEURAL .....	65
4.3	ESTRATÉGIA DE TREINAMENTO .....	67
<b>5</b>	<b>VALIDAÇÃO DA FERRAMENTA DE ANÁLISE DO ENCAPSULAMENTO .....</b>	<b>69</b>
5.1	TREINAMENTOS E TESTES DAS RNA'S .....	69
5.1.1	Agrupamentos de conjuntos #1 .....	69
5.1.1.1	Camada intermediária com 5 neurônios .....	69
5.1.1.2	Camada intermediária com 10 neurônios .....	70
5.1.1.3	Camada intermediária com 15 neurônios .....	71
5.1.1.4	Camada intermediária com 20 neurônios .....	73
5.1.2	Agrupamentos de conjuntos #2 .....	74
5.1.2.1	Camada intermediária com 5 neurônios .....	74
5.1.2.2	Camada intermediária com 10 neurônios .....	75
5.1.2.3	Camada intermediária com 15 neurônios .....	76
5.1.2.4	Camada intermediária com 20 neurônios .....	78
5.1.3	Agrupamentos de conjuntos #3 .....	79
5.1.3.1	Camada intermediária com 5 neurônios .....	79
5.1.3.2	Camada intermediária com 10 neurônios .....	80
5.1.3.3	Camada intermediária com 15 neurônios .....	82
5.1.3.4	Camada intermediária com 20 neurônios .....	83
5.2	DISCUSSÃO DOS RESULTADOS .....	85
<b>6</b>	<b>CONCLUSÃO .....</b>	<b>89</b>
	<b>REFERÊNCIAS BIBLIOGRÁFICAS .....</b>	<b>91</b>

## 1 INTRODUÇÃO

Os transformadores são máquinas elétricas estáticas que têm a função de transmitir, mediante um campo eletromagnético alternado, a energia elétrica de um sistema, com determinada tensão, para outro sistema, com a tensão desejada, porém com capacidade e frequência inalteradas (Fitzgerald, et al., 2006).

Com a larga utilização de energia elétrica em edifícios comerciais, *shopping centers*, praças poliesportivas, estações de metrô e trem, necessita-se que os transformadores sejam instalados o mais próximo possível das cargas, permitindo também uma redução de custos com cabos de alimentação, melhor regulação de tensão e proteções contra explosão e fogo (Stigant & Franklin, 1983). Para instalações internas, como é o caso da maioria dos exemplos acima, é recomendada a utilização de transformadores de tecnologia seca, que não utilizam óleo, pois apresentam dimensões reduzidas, baixa necessidade de manutenção, simplicidade de instalação e ausência do risco de explosão e incêndio.

Os transformadores secos são compostos por um núcleo magnético e enrolamentos primários e secundários (Stigant & Franklin, 1983) cuja parte ativa não está imersa em óleo (NBR10295, 2011). A isolamento elétrica é obtida através dos papéis, filmes e resinas utilizados na fabricação com propriedades dielétricas e térmicas específicas para este tipo de transformador.

As bobinas de média tensão são fabricadas com isolamento sólida, ou seja, encapsuladas. Para tal processo, os enrolamentos de média tensão são submetidos ao processo de aplicação de resina epóxi sob vácuo (Feldman & Barbalata, 1996) (Silva, 2005). Neste processo de aplicação da resina não devem existir bolhas de ar ou falhas no encapsulamento, pois comprometem a rigidez dielétrica do encapsulamento, a confiabilidade e a vida útil dos transformadores.

As falhas do processo de encapsulamento podem ser detectadas nos ensaios de tensão aplicada, tensão induzida e descargas parciais aos quais se submetem os transformadores após a fabricação (NBR10295, 2011).

No entanto, os ensaios de tensão aplicada e induzida detectam somente as falhas maiores deixando a detecção de pequenas bolhas de ar para o ensaio de descargas (Kreuger, 1989) (Mason, 1995). O ensaio de medição de descargas parciais é realizado após a conclusão da montagem do transformador para verificar a qualidade do seu encapsulamento.

Caso seja detectada alguma anomalia ou reprovação neste ensaio tendo como referência os valores dispostos na (NBR10295, 2011) e (NBR5356, 2007), o transformador é reprovado e suas bobinas de média tensão são descartadas, sendo necessária a fabricação de um novo conjunto composto por três bobinas para nova montagem e reensaio do transformador. Trata-se de um processo que demanda tempo para o retrabalho, fabricação das novas bobinas e montagem, utilização de matéria-prima e recursos para fabricação, além do atraso na entrega do transformador e geração de resíduos sólidos.

Desta forma, propõe-se o desenvolvimento de uma metodologia para análise do encapsulamento das bobinas de média tensão com a medição de descargas parciais por tensão aplicada individualmente às bobinas antes da realização da montagem no transformador com o uso de Redes Neurais Artificiais (RNA's) (Haykin, 2001) (Geromel & Souza, 2002) (Chang, et al., 2004).

Para validação da rede neural desenvolvida, foram analisados os resultados de ensaios de medição de descargas parciais por tensão aplicada realizados em bobinas de média tensão, comparativamente ao resultado do ensaio de medição de descargas parciais por tensão induzida realizados nos

transformadores montados.

## 1.1 REVISÃO BIBLIOGRÁFICA

Diversos artigos e trabalhos relacionados com o tema desta dissertação foram consultados e os relacionados abaixo em muito contribuíram para o desenvolvimento desta pesquisa.

GEROMEL (2002) aplicou RNA na aplicação de sistemas inteligentes em projetos de transformadores de potência. Foram utilizadas arquiteturas de redes integradas entre si, com as funções de escolha dos parâmetros iniciais de projeto, cálculo das perdas específicas no núcleo, cálculo das perdas complementares nos enrolamentos, cálculo do fator  $K_r$  e cálculo das temperaturas internas. O erro obtido nas redes utilizadas foi mínimo.

FINOCCHIO (2010) aplicou RNA na determinação da temperatura de enrolamentos de transformadores a seco e suas perdas totais baseado em redes neurais artificiais. Utilizando redes neurais para avaliação da temperatura a partir dos parâmetros geométricos do transformador, avaliação das perdas a vazio e a curto-circuito, foram obtidos resultados com erros menores que 1%.

TARDIVO (2012) aplicou RNA para estimação da elevação de temperatura de transformadores monofásicos de distribuição em líquido isolante, uma vez que ensaios de elevação de temperatura tem duração aproximada de doze horas. A RNA estima, a partir dos parâmetros geométricos e das perdas totais dos transformadores, a temperatura em transformadores para otimização do ensaio de elevação de temperatura, diminuindo o tempo necessário para execução. Os resultados obtidos apresentam erros menores que 1% em comparação ao sistema convencional

Assuntos relacionados a especificação, construção, condições de operação, aplicação e ensaios de transformadores secos são tratados pelas normas técnicas IEC60076-11 (2004) – *Power transformers – Part 11: Dry-type transformers*, NBR10295 (2011): Transformadores de Potência Secos, NBR14039 (2005): Instalações Elétricas de Média Tensão de 1,0 kV a 36,2 kV e NBR5356 (2007): Transformadores de potência.

Assuntos relacionados a teoria, construção e ensaios de transformadores secos também são citados por DOOLEY (1998), NUNN (2000), STIGANT; FRANKLIN (1983) e FITZGERALD et. al. (2006).

Assuntos relacionados a teoria, medições e aplicações de descargas parciais são citados por ALEXANDER; SADIKU (2003), IEC60270 (2000): *High-voltage test techniques – Partial Discharge Measurements*, CHANG et al. (2004), GOLUBEV; PAOLETTI (1999), KREUGER (1989), MASON (1995) e MUNDLEIN et al. (2003).

Assuntos relacionados a materiais isolantes elétricos e resina epóxi são citados por NBR/IEC60085 (2012): *Isolação elétrica — Avaliação térmica e designação*, FELDMAN; BARBALATA (1996), SILVA (2005) e ALMEIDA; MONTEIRO (1996).

Assuntos relacionados a teoria de redes neurais artificiais também são citados por HAGAN; MENHAJ (1994), HAYKIN (2001), MAREN; JONES; FRANKLIN (1999), MATLAB (1994), MCCULLOCH; PITTS (1943), SILVA (2010), RUMELHART; HINTON; WILLIAMS (1986), SANTOS; SILVA; ARRUDA (2011) e SILVA; SPATTI; FLAUZINO (2010).

## 1.2 OBJETIVO

### 1.2.1 Principal

O ensaio de medição de descargas parciais por tensão induzida é um ensaio realizado em transformadores secos para verificar a qualidade e condições do encapsulamento das bobinas de média tensão e da montagem. A metodologia para realização do ensaio deve ser de acordo com a norma (NBR5356, 2007) e será apresentada no capítulo 4. O transformador é submetido a este ensaio após a etapa final de montagem e deve apresentar valores em conformidade com as normas nacionais (NBR5356, 2007) ou internacionais (IEC60076-11, 2004).

Caso o transformador esteja com o nível de descargas parciais dentro dos limites estabelecidos por norma, será considerado aprovado e liberado para entrega ao cliente e instalação.

Se os valores medidos no ensaio excederem os limites especificados é necessário retrabalhar o transformador, uma vez que um valor elevado de descargas parciais representa que a montagem, o encapsulamento das bobinas de média tensão ou ambos estão com qualidade inaceitável.

Neste caso, o retrabalho pode envolver apenas uma correção no posicionamento das bobinas melhorando a sua montagem ou até mesmo a necessidade de substituição das bobinas em função de uma possível falha no processo de encapsulamento.

O objetivo principal desta pesquisa é desenvolver uma metodologia que permita analisar a qualidade do encapsulamento das bobinas de média tensão embasado na medição das descargas parciais em cada uma das bobinas, utilizando RNA's, antes da montagem das mesmas no transformador.

### 1.2.2 Secundário

O objetivo secundário é reduzir o número de reprovações no ensaio de descargas parciais dos transformadores montados, evitando que muitos deles sejam montados com encapsulamento deficiente.

### 1.2.3 Justificativa

Nas bobinas com isolamento sólida ou encapsuladas submetidas ao processo de aplicação de resina epóxi sob vácuo, não devem existir bolhas de ar ou falhas no encapsulamento que comprometam a rigidez dielétrica da bobina e também a sua vida útil. As falhas podem ser observadas somente após a realização dos ensaios de rotina, tipo e especiais aplicados aos transformadores, causando a reprovação de transformadores, atrasos na entrega, retrabalhos de montagem e, por conseguinte, aumento nos custos de produção.

Para detectar as possíveis falhas de encapsulamento, pode-se utilizar uma ferramenta que se trata da medição de descargas parciais das bobinas (IEC60270, 2000). Contudo, não existe uma metodologia de medição de descargas parciais com tensão aplicada para as bobinas encapsuladas individualmente, com a capacidade de relacionar seus resultados de maneira direta com a medição de descargas parciais em tensão induzida do transformador completamente montado, pois se tratam de variáveis de processo não lineares ou pouco definidas.

Dessa forma, faz-se necessária a pesquisa e desenvolvimento de um método que possibilite relacionar o ensaio de medição de descargas parciais por tensão aplicada nas bobinas de média tensão com o ensaio de medição de descargas parciais por tensão induzida no transformador.

#### 1.2.4 Metodologia

A metodologia desta pesquisa consiste em realizar ensaio de medição de descargas parciais por tensão aplicada em todas as bobinas de média tensão encapsuladas logo após a sua fabricação. Os valores obtidos nestes ensaios são inseridos em um banco de dados e as bobinas são liberadas para montagem ao núcleo e bobinas de baixa tensão, dando continuidade do processo de fabricação do transformador.

Após a fabricação do transformador, este é submetido ao ensaio de medição de descargas parciais por tensão induzida e os valores obtidos também são inseridos no banco de dados relacionado com as bobinas de média tensão que compuseram o transformador.

Desta forma, embasado nos valores de descargas parciais das bobinas individuais e do transformador, relacionam-se tais valores através de uma rede neural artificial possibilitando identificar qual o padrão de resposta de uma bobina após montada no transformador e testada através de tensão induzida com o resultado obtido antes da montagem e testada por tensão aplicada.

Uma vez identificado este padrão de resposta, possibilita-se que por meio da análise dos valores de ensaios de medição de descargas parciais por tensão aplicada nas bobinas encapsuladas de média tensão seja possível detectar eventuais falhas de encapsulamento nestas que possam causar reprovação do transformador no ensaio de medição de descargas parciais por tensão induzida.

#### 1.2.5 Organização da Dissertação

Esta dissertação está dividida em seis capítulos organizados

conforme descrito a seguir.

O capítulo 1 apresenta a revisão bibliográfica, a justificativa, a metodologia e os objetivos desta pesquisa.

O capítulo 2 apresenta as principais características dos transformadores secos encapsulados. Fornece informações sobre condições de operação, núcleo, nível de ruído, classe térmica, enrolamento de média e baixa tensão, materiais isolantes, métodos de resfriamento, ensaios, encapsulamento, resina epóxi e descargas parciais. Também procura apresentar a importância da medição de descargas parciais em transformadores secos para análise do encapsulamento de bobinas.

O capítulo 3 apresenta uma introdução às Redes Neurais Artificiais (RNA's) apresentando os conceitos necessários a sua aplicação. Aborda a topologia, arquitetura, técnicas de treinamento, métodos de otimização e o processo de desenvolvimento. Trata-se de uma abordagem de RNA's necessária para a compreensão da sua aplicação no desenvolvimento desta pesquisa.

O capítulo 4 apresenta a metodologia desenvolvida para análise do encapsulamento de bobinas. Demonstra as etapas de levantamento dos dados, ou seja, a medição de descargas parciais nos ensaios de tensão aplicada nas bobinas e de tensão induzida nos transformadores. Apresenta a construção do sistema neural e sua topologia. Também é demonstrada a estratégia de treinamento adotada com diferentes números de neurônios e agrupamento de conjuntos de dados de entrada.

O capítulo 5 apresenta os treinamentos, testes e resultados para cada uma das 12 RNA's implementadas, através das 4 variações do número de neurônios na camada intermediária combinadas com os 3 agrupamentos de

conjuntos de dados de entrada. Este capítulo, através dos valores de desempenho obtidos nas RNA's e da discussão dos resultados, apresenta a validação da ferramenta de análise do encapsulamento de bobinas de transformadores secos.

O capítulo 6 traz as conclusões da pesquisa, comentando os resultados obtidos e as sugestões de continuidade.

## 2 TRANSFORMADORES SECOS ENCAPSULADOS

### 2.1 TRANSFORMADOR SECO

O transformador seco é uma máquina elétrica cuja parte ativa não está imersa em líquido isolante. Pode ser do tipo encapsulado, que possui um ou mais enrolamentos encapsulados com isolamento sólido ou não encapsulado, no qual nenhum dos enrolamentos possui isolamento sólido (NBR10295, 2011).

As condições normais de operação de um transformador seco, conforme Figura 1, são especificadas abaixo:

- Altitude inferior a 1000m;
- Temperatura ambiente máxima de 40°C;
- Temperatura média em qualquer período de 24 horas não superior a 30°C;
- Tensão de alimentação senoidal e equilibrada;
- Corrente de carga senoidal com fator harmônico não superior a 0,05 pu;
- Instalação interior.

Para condições de operação distintas das especificadas acima, o projeto e instalação dos transformadores devem seguir as características específicas de cada caso (NBR10295, 2011).

Em situações nas quais a subestação de transformação faz parte integrante da edificação industrial, residencial e/ou comercial, somente é permitido o emprego de transformadores secos, mesmo que haja paredes de alvenaria e portas corta-fogo (NBR14039, 2005).




Figura 1 - Modelagem 3D de um transformador seco (Fonte: Romagnole)

O sistema de proteção térmica do transformador seco deve ser composto por sensores térmicos com contatos independentes para controle e proteção e, quando solicitado pelo cliente, deve ser fornecido com indicador de temperatura.

### 2.1.1 Núcleo e Ferragens

O núcleo é do tipo envolvido e construído com chapas de silício de grão orientado, laminadas a frio, de baixas perdas e isoladas com material inorgânico. O aço elétrico (aço silício) utilizado deve possuir qualidade no mínimo igual a do tipo E004-7 conforme a Tabela 1, onde é possível observar os valores da perda magnética em W/kg para densidades de fluxo de 1,5 e 1,7T para as frequências de 50 e 60Hz.

A temperatura do núcleo não deve ultrapassar o limite da classe térmica dos enrolamentos e o nível de ruído deve estar de acordo com a Tabela 2 (NBR10295, 2011).

Tabela 1 - Características magnéticas do aço elétrico de grão orientado (Fonte: Aperam)

<b>Características Magnéticas Típicas</b>									
Produto		Espessura (mm)	Perda Magnética (W/kg)				Indução Magnética (T)		
Referência	Aperam		1,5T		1,7T		800	2500	10000
			50Hz	60Hz	50Hz	60Hz	A/m	A/m	A/m
M108-23	E003-9	0,224	0,70	0,91	1,01	1,31	1,87	1,93	1,98
M117-23	E003-9	0,224	0,72	0,94	1,07	1,38	1,85	1,93	1,97
M112-27	E004-7	0,263	0,77	1,01	1,09	1,42	1,86	1,93	1,97
M125-27	E004-7	0,263	0,79	1,04	1,14	1,47	1,85	1,93	1,97
M130-30	E005-4	0,293	0,83	1,10	1,17	1,54	1,86	1,93	1,97
M140-30	E005-7	0,293	0,86	1,14	1,23	1,61	1,84	1,93	1,97
M150-35	E006-2	0,342	0,94	1,25	1,30	1,73	1,85	1,93	1,97

Tabela 2 - Níveis de ruído para transformador seco (AN ou ANAN) (NBR10295, 2011)

Potência nominal (kVA)	Nível médio de ruído (dB)	
	AN	ANAN
0-300	58	57
301-500	60	59
501-700	62	61
701-1000	64	63
1001-1500	65	64
1501-2000	66	65
2001-3000	68	66
3001-4000	70	69
4001-5000	71	69
5001-6000	72	70
6001-7000	73	71

Na Figura 2 - Transformador seco sem bobinas em uma fase (Fonte: Romagnole) Figura 2, para ilustrar melhor o núcleo, foram retiradas as bobinas primária e secundária de uma fase. As culatras superior e inferior do núcleo e as colunas do mesmo, conforme mostrado na Figura 2, são prensadas por meio de

perfis de aço carbono e cintas de material isolantes. Após a prensagem, o núcleo montado é pintado com tinta dielétrica (60kV/mm) de classe F (155°C), formulada a partir de resina alquídica. Além das proteções dielétricas e contra corrosão, o tratamento contribui reduzindo ainda mais o baixo nível de ruído acústico do transformador.




Figura 2 - Transformador seco sem bobinas em uma fase (Fonte: Romagnole)

### 2.1.2 Enrolamentos de Baixa Tensão

Os enrolamentos de baixa tensão podem ser construídos utilizando fio ou chapa dos materiais condutores cobre ou alumínio.

Os enrolamentos em fio, para garantir a suportabilidade a curto-circuito requerida, são encapsulados. Neste caso, o processo utilizado deverá ser equivalente ao do enrolamento de média tensão. Uma vez encapsuladas, as bobinas adquirem excelente resistência a esforços térmicos e dinâmicos de curto-circuito,

bem como completa imunidade ao ambiente atmosférico (Nunn, 2000).

Para enrolamentos em chapa, os condutores devem ter a altura da bobina e ser isolados por um filme impregnado com resina epoxídica autoextinguível em estágio B de polimerização (pré-curado).

Após enrolada, a bobina é submetida a um tratamento térmico, obtendo-se a completa polimerização do isolamento que une as camadas do enrolamento, tornando-o um bloco compacto. Visando maior resistência a umidade, as cabeceiras da bobina são preenchidas com resina epoxídica.

Em função do formato do condutor, esforços de curto-circuito nas bobinas fabricadas em chapa são mínimos, garantindo ao transformador incomparável desempenho neste quesito.

A isolação utilizada nas bobinas deve ser sempre de classe térmica igual ou superior à do enrolamento sendo mais comum a classe térmica F (155°C).

É importante a especificação correta do material dos barramentos empregado na conexão do transformador, pois o contato entre cobre e alumínio deve ser evitado em função da corrosão galvânica inerente, podendo implicar, posteriormente em falhas nas conexões. Para o acoplamento cobre-alumínio são utilizadas chapas cladeadas, estanhagem dos barramentos ou, como paliativo, pastas anti-corrosivas próprias para conexões elétricas. As barras de cobre prateadas são evitadas.

### 2.1.3 Enrolamentos de Média Tensão

Os enrolamentos de média tensão podem ser construídos utilizando fio ou fita dos materiais condutores cobre ou alumínio (NBR10295, 2011).

A isolação utilizada nas bobinas deve ser sempre de classe térmica

igual ou superior à do enrolamento, sendo mais comum a classe térmica F (155°C).

São adicionados, interna e externamente à bobina, reforços mecânicos (isolantes pré-curados), os quais, após submetidos a tratamento térmico, conferem à bobina a ser encapsulada, elevada resistência a esforços de curto-circuito.

Após a cura dos isolamentos, os moldes de impregnação mostrados na Figura 3 são montados sobre as bobinas a serem encapsuladas. As bobinas em conjunto com os moldes são postas sob vácuo e alta temperatura na autoclave, passando por um processo de secagem para retirada da umidade.



Figura 3 - Molde de aço carbono para bobinas de média tensão (Fonte: Vacuum Technology Co.)

Antes da impregnação, os componentes da resina são misturados e completamente desgaseificados em equipamentos com tecnologia adequada.

As resinas epoxídicas utilizadas possuem classificação anti-chama (autoextinguíveis e não explosivas) e certificado UL para 200°C, combinada com altíssima resistência à formação de fissuras (trincas em temperaturas até 100°C) e ao choque térmico.

Após a secagem das bobinas e degaseificação da resina, os moldes são preenchidos e permanecem na autoclave, conforme Figura 4, para a pré-cura. Todo este processo é executado com níveis de vácuo, garantidos por um sistema de alta tecnologia.



Figura 4 - Autoclave para encapsulamento de bobinas (Fonte: Hübers)

Após pré-curadas, as bobinas são transferidas para um estufa onde a cura é concluída em uma seqüência de temperaturas controladas por Controlador Lógico Programável (CLP) para garantir a eliminação dos esforços internos no enrolamento. Terminada esta etapa, as bobinas são finalmente desmoldadas e testadas uma a uma para posterior liberação para linha de montagem.

As bobinas de média e baixa tensão, conforme mostrado na Figura 5, são projetadas e cuidadosamente controladas no processo de fabricação, para conferir ao transformador seco uma excepcional resistência ao curto-circuito e isenção de descargas parciais, traduzidas por uma excelente *performance* ao longo de sua vida útil, independente das variações de carga e temperatura.




Figura 5 - Bobinas de média e baixa tensão previamente montadas (Fonte: Romagnole)

#### 2.1.4 Classe de Térmica dos Materiais Isolantes

Os materiais isolantes elétricos são classificados em classes de temperatura, as quais definem a temperatura máxima suportável de cada material isolante para aplicações distintas e que combinadas com o método de resfriamento do transformador determinam o comportamento térmico e a vida útil do transformador com relação à degradação do isolante (Finocchio, 2010) (Tardivo, 2012).

As classes de temperatura dos materiais isolantes são apresentadas na Tabela 3 (NBR/IEC60085, 2012).

Tabela 3 - Classe de temperatura de materiais isolantes (NBR/IEC60085, 2012)

<b>Classe</b>	<b>Tipo de isolante</b>	<b>Temperatura máxima (°C)</b>
Y	Materiais fibrosos a base de celulose ou seda, não imersos em líquidos isolantes.	90
A	Materiais fibrosos a base de celulose ou seda impregnados com líquidos isolantes.	105
E	Fibras orgânicas sintéticas e outros.	120
B	Materiais a base de poliéster e polimídicos aglutinados com materiais orgânicos ou impregnados com estes.	130
F	Materiais à base de mica, amianto e fibra de vidro aglutinado com materiais sintéticos, usualmente silicones, poliésteres ou epóxi.	155
H	Materiais à base de mica, asbesto ou fibra de vidro aglutinada tipicamente com silicones de alta estabilidade térmica.	180
C	Mica, vidro, cerâmica e quartzo sem aglutinante.	220

#### 2.1.5 Classificação dos Métodos de Resfriamento

Os transformadores devem ser designados de acordo com o método de resfriamento utilizado. Para transformadores secos, esta designação é realizada por meio de símbolos literais correspondentes apresentados na Tabela 4 (NBR10295, 2011).

Tabela 4 - Símbolos literais para os métodos de resfriamento (NBR10295, 2011)

	<b>Descrição</b>	<b>Símbolo</b>
<b>Natureza do tipo de resfriamento</b>	Gás	G
	Água	W
	Ar	A
<b>Natureza da circulação</b>	Natural	N
	Forçada	F

O método de resfriamento é indicado por duas letras se o transformador seco não possui invólucro protetor ou quatro letras caso possua invólucro protetor. Assim, a primeira e a segunda letra indicam o tipo e circulação deste resfriamento que esteja em contato com as bobinas e a terceira e quarta letra indicam o tipo e circulação do resfriamento que está em contato com o invólucro.

A designação mais comum do método de resfriamento para transformadores secos sem invólucro protetor é AN e para transformadores com gabinetes é ANAN que se referem a métodos de resfriamento com circulação de ar natural.

#### 2.1.6 Ensaaios

Os ensaios são procedimentos de testes definidos em norma aos quais devem ser submetidos os transformadores secos. Os ensaios podem ser classificados em ensaios de rotina, tipo e especiais (NBR10295, 2011).

##### 2.1.6.1 Ensaaios de Rotina

Os ensaios de rotina são aqueles realizados em todas as unidades de transformadores produzidas (NBR5356, 2007) e relacionados abaixo:

- Resistência elétrica dos enrolamentos;
- Relação de tensão;
- Resistência do isolamento;
- Polaridade;
- Deslocamento angular e sequência de fases;

- Perdas (em vazio e em carga);
- Corrente de excitação;
- Impedância de curto-circuito;
- Ensaio dielétricos:
  - Tensão suportável nominal à frequência industrial (tensão aplicada);
  - Tensão induzida.
- Verificação do funcionamento dos acessórios.

#### 2.1.6.2 Ensaio de Tipo

Os ensaios de tipo são realizados em apenas um transformador que represente os demais transformadores<sup>1</sup> e objetiva demonstrar que todos estes cumprem com as condições especificadas não verificadas nos ensaios de rotina (NBR5356, 2007). Os ensaios de tipo são apresentados a seguir:

- Fator de potência do isolamento;
- Elevação de temperatura;
- Tensão suportável nominal de impulso atmosférico;
- Nível de ruído;
- Nível de tensão de radiointerferência.

#### 2.1.6.3 Ensaio Especial

Os ensaios especiais são realizados mediante acordo entre

---

<sup>1</sup> Um transformador é considerado representante de outros transformadores se for completamente idêntico em relação aos valores nominais e a construção. Ensaio de tipo podem ser considerados igualmente válidos, se efetuados em um transformador que apresente ligeiros desvios de valores nominais ou outras características. Estes desvios devem ser objeto de acordo entre fabricante e comprador.

fabricantes e compradores nas unidades solicitadas. São ensaios não relacionados como rotina ou de tipo, porém pode ser solicitados ou realizados dependendo de cada caso. Os ensaios especiais são apresentados a seguir:

- Tensão induzida com medição de descargas parciais;
- Ensaio de curto-circuito;
- Medição da potência absorvida pelos motores de ventiladores;
- Medição da impedância de sequência zero nos transformadores trifásicos;
- Medição de harmônicos na corrente de excitação.

## 2.2 RESINA EPÓXI

O isolante deve ser um material com alta oposição à passagem da corrente elétrica e que confine esta corrente elétrica em um determinado circuito. Os melhores materiais isolantes disponíveis são: ar, vidro, mica, porcelana, fluidos isolantes de origem mineral e vegetal, silicone e os polímeros.

Os materiais isolantes sólidos são empregados para efetuar a isolamento de diversos equipamentos elétricos tais como transformadores secos. Dentre estes materiais, pode-se destacar a resina epóxi (Nunn, 2000).

O comportamento do transformador seco encapsulado com resina epóxi se deve às características deste material isolante (Dooley, 1998). A resina epóxi possui excelentes características de encapsulamento e isolamento, propriedades termoelétricas e termomecânicas retardantes de chamas.

A resina epóxi é um material polimérico sintético na forma de fluido viscoso que, através do processo de cura, é transformada em um material sólido

termofixo que uma vez produzido não retorna à condição de fluido (Silva, 2005).

A cura é realizada com a adição de um composto endurecedor que contém múltiplos grupos reativos capazes de reagir com os grupos epóxi. Os agentes endurecedores utilizados incluem aminas, poliamidas e anidridos.

As aminas e as poliamidas, pela sua alta reatividade com os grupos epóxi, são mais utilizadas em formulações onde a reação de cura é realizada em temperatura ambiente. As poliamidas são utilizadas para obter compostos mais flexíveis, enquanto as aminas fornecem materiais mais rígidos.

Nas formulações onde o agente endurecedor é o anidrido, a reação de cura deve ser submetida a elevadas temperaturas e com a adição de agentes aceleradores (Almeida & Monteiro, 1996).

De forma geral, a resina epóxi após a cura, apresenta como propriedades excelente resistência química, alta resistência mecânica, estabilidade dimensional e propriedades elétricas isolantes excepcionais.

Em função disto, a resina epóxi é utilizada como sistema de isolamento em transformadores secos, impregnação de bobinas de motores e geradores bem como na moldagem de componentes elétricos como buchas e isoladores.

As falhas dielétricas são os maiores problemas em materiais dielétricos com alta permissividade e em geral são causadas por descargas parciais (Mundlein, et al., 2003).

As descargas parciais em equipamentos encapsulados podem ser causadas por diversas condições sendo as mais usuais o vácuo, a flutuação de componentes e ar ou outros gases internos ao dielétrico (Mundlein, et al., 2003).

Embora a resina epóxi seja muito utilizada na isolamento de transformadores secos em função de sua elevada rigidez dielétrica, mesmo que seja

realizado um rigoroso controle de qualidade durante o processo de encapsulamento das bobinas, é praticamente impossível evitar a presença de falhas (vazios) nas mesmas. Estes vazios são as fontes geradoras de descargas parciais internas.

A ocorrência contínua de descargas elétricas, em momentos de excitação, causam deterioração progressiva das propriedades físicas dos materiais isolantes, podendo ocasionar a falha do transformador por ruptura dielétrica.

A medição de descargas parciais é o método mais usual para detecção destes vazios presentes na isolação elétrica e tem sido vastamente utilizada nos ensaios de transformadores secos para avaliação da qualidade do encapsulamento.

### 2.3 DESCARGAS PARCIAIS

A carga elétrica é uma propriedade das partículas atômicas das quais a matéria é composta, medida em *coulombs* (C) e pode ser obtida através das equações (2.1) e (2.2) abaixo (Alexander & Sadiku, 2003):

$$q = \int_{t_0}^t i \cdot dt \tag{2.1}$$

$$q = C \cdot v \tag{2.2}$$

onde:

$C$  – capacitância [F]

$i$  – corrente elétrica [A]

$q$  – carga elétrica [C]

$t_0$  e  $t$  – tempo inicial e atual, respectivamente [s]

$v$  – tensão [V]

As descargas parciais (DP) são descargas elétricas que rompem apenas parcialmente o isolamento elétrico entre condutores, ou ainda, são descargas elétricas localizadas que curto-circuitam parcialmente um material isolante separando dois condutores e que pode estar adjacente ou não a um dos condutores (IEC60270, 2000).

As descargas parciais são descargas elétricas localizadas, ou seja, que não chegam a percorrer todo o caminho dentro de um material isolante colocado entre dois condutores submetidos a uma diferença de potencial (Golubev & Paoletti, 1999).

São pulsos de corrente de alta frequência que ocorrem, de maneira repetitiva, no interior dos sistemas isolantes dos equipamentos de média ou alta tensão. Para efeito de compreensão pode-se dizer que DP são “descargas disruptivas” ocorrendo em pequena parte de um material isolante.

Em muitos casos, o efeito Corona na superfície de materiais condutores e dielétricos também é medido como sendo descargas parciais.

Em dielétricos sólidos, as DP são produzidas pela ionização de pequenas cavidades de ar no interior do dielétrico.

A isolação elétrica em equipamentos de média tensão tem como função primária minimizar o fluxo de corrente entre condutores submetidos a diferencial de potencial elétrico, suportando o campo elétrico resultante. Deve, ainda, apresentar propriedades mecânicas, térmicas e químicas apropriadas ao cumprimento de sua função.

Os isolamentos elétricos sofrem redução de sua capacidade ao longo do tempo, mesmo quando submetidos às condições normais de projeto.

Quando submetido a condições mais severas, a vida útil estimada é

reduzida. Na medida em que ocorre uma redução de sua capacidade, vários processos podem ocorrer no sentido de acelerar esta redução, levando a uma incapacidade de realizar sua função, ou seja, à falha do isolamento.

A recuperação de um isolamento nestas condições nem sempre é possível e os custos envolvidos são geralmente elevados.

As descargas parciais não apresentam nenhuma característica visível a olho nu, ou seja, quando da abertura de um equipamento no qual foi detectada a presença de descargas parciais anormais, pode não ser possível confirmar a presença das mesmas, a menos que a falha possua proporções muito críticas.

Os métodos de avaliação da degradação podem medir diretamente características intrínsecas do isolamento, produtos de sua degradação, ou ainda seus efeitos em parâmetros físicos ou químicos. Os principais métodos utilizados nos isolamentos sólidos são medição de descargas parciais e medição de fator de dissipação.

A medição de descargas parciais, descargas elétricas onde não ocorre a ruptura total do isolamento, tem por objetivo determinar sua ocorrência no isolamento, caracterizando assim este processo de falha.

Na Tabela 5 são apresentados valores de referência para alguns equipamentos e componentes dos sistemas elétricos de potência.

Sua medição pode ser realizada pelo sinal elétrico gerado pela descarga ou acusticamente pelo sinal gerado pela onda de choque da descarga. A medição do sinal elétrico gerado permite uma associação com a intensidade da descarga e uma caracterização da configuração dos eletrodos envolvidos. A medição dos sinais acústicos não permite uma caracterização confiável da

intensidade da descarga, mas permite a localização da fonte espacialmente.

Tabela 5 - Valores de referência de descargas parciais para equipamentos (Fonte: CEPEL)

Tipos de equipamentos	Descargas parciais (em pC)	
Equipamentos de média e alta tensão em geral	< 10	
Cabos blindados de média e alta tensão	< 1 ou 2 (ruído de fundo)	
Motores e geradores	2000 a 5000	
Transformadores a óleo (médio e grande porte)	< 300	
Transformadores secos	< 10 (IEC)	< 20 (NBR)

A medição de descargas parciais em isolamentos sólidos tem a motivação principal de identificar falhas ou tendência de deterioração destes isolamentos, no entanto pode ser utilizada para os propósitos a seguir:

- Controle de qualidade do sistema isolante;
- Controle dos processos construtivos e dos materiais utilizados na fabricação de equipamentos;
- Verificação das condições dielétricas após manutenção de equipamentos;
- Identificação de possíveis montagens irregulares, complementações de outras avaliações e identificação do início de descargas internas;
- Verificação do estado dielétrico antes e após outros ensaios de solicitação dos equipamentos;
- Previsão para manutenção preventiva.

O método para medição de descargas parciais de transformadores é padronizado conforme a norma ABNT NBR 5356-3:2007, onde os valores da medição devem ser apresentados em *picocoulombs* (pC).

### 3 REDES NEURAIIS ARTIFICIAIS

As Redes Neurais Artificiais (RNA's) são modelos computacionais embasados no comportamento do sistema nervoso de seres vivos. Elas possuem condições de adquirir e manter conhecimento através de métodos de treinamento e conjunto de dados. As RNA's têm capacidade para solucionar problemas por intermédio de circuitos simples que simulam o funcionamento e o comportamento do cérebro humano.

As principais características das RNA's são (Silva, et al., 2010):

- a) Capacidade de aprendizado: através de um processo de treinamento, a partir de um banco de dados existente, a rede consegue extrair uma relação entre as diversas variáveis que compõe a aplicação;
- b) Habilidade de generalização: uma vez que a rede tenha realizado o treinamento, ela consegue generalizar o conhecimento dando a oportunidade de estimar soluções para mesma aplicação formada por dados externos ao banco de dados de treinamento;
- c) Possibilidade de prototipagem: após o processo de treinamento e generalização da rede, é possível implementá-la em *hardware* ou *software*.

As RNA's são empregadas em diversas aplicações para solução de problemas nas áreas de engenharia e ciências. As principais aplicações e funções das RNA's são:

- a) Sistemas de previsão: nestes sistemas o objetivo da rede é estimar valores futuros em determinado processo levando em

- conta valores observados e adquiridos previamente e podem ser utilizados, entre outros, no mercado financeiro e clima;
- b) Reconhecimento e classificação de padrões: a rede tem por meta associar padrões de entrada (valores amostrais) a classe de resposta ou classificação e são típicos destas aplicações o reconhecimento de voz e imagens;
  - c) Otimização de sistemas: a meta da rede nestas aplicações é maximizar ou minimizar resultados atendendo às restrições impostas para a solução;
  - d) Controle de processos: consiste na identificação de ações que atendam aos requisitos de qualidade, eficiência e segurança do processo tendo aplicações, dentre outras, em robótica, aeronaves, elevadores e satélites.


### 3.1 TOPOLOGIA DAS REDES NEURAIS ARTIFICIAIS

#### 3.1.1 Neurônio biológico

Os neurônios biológicos são células especializadas na transmissão de informações através processos que conduzem impulsos nervosos. Os impulsos nervosos são reações físico-químicas que se verificam nas superfícies dos neurônios e seus processos. São células características elementares do sistema nervoso cerebral que fornecem ao cérebro humano funcionalidades tais como memorização, pensamento, aprendizado e decisão (Silva, et al., 2010).

Os neurônios biológicos, conforme Figura 6, são constituídos pelas seguintes partes principais:

- a) **Corpo celular:** composto pelo citoplasma, membrana e núcleo celular e demais organelas, é responsável pelo processamento das informações recebidas pelos dendritos e também da produção de um potencial de ativação que indicará se o neurônio deve disparar um impulso elétrico através do axônio;
- b) **Dendritos:** são finos prolongamentos cuja função é receber os sinais elétricos enviados por outros neurônios através das relações sinápticas;
- c) **Axônio :** é um prolongamento responsável pela condução dos impulsos elétricos até suas terminações sinápticas, possibilitando que os impulsos nervosos gerados pelo neurônio sejam transmitidos aos outros neurônios ou aos músculos.




Fonte: Site <http://laips.sel.eesc.usp.br/livrorna>

Figura 6 - Neurônio biológico

As sinapses nervosas são os pontos onde as extremidades de neurônios vizinhos se encontram e o estímulo passa de um neurônio para o seguinte

por meio dos neurotransmissores. Estas conexões possibilitam a transferência de impulsos elétricos do axônio de um neurônio para os dendritos de outros e são formadas por: membrana pré-sináptica, fenda sináptica e membrana pós sináptica.

Embora inexista contato físico entre os neurônios em função do espaço denominado fenda sináptica, os axônios liberam substâncias neurotransmissoras que atravessam a fenda permitindo o "contato" das terminações nervosas chamadas axônios com os dendritos de outro neurônio conforme Figura 7.



Fonte: Site <http://laips.sel.eesc.usp.br/livrorna>

Figura 7 - Sinapses entre neurônios

### 3.1.2 Neurônio artificial

O neurônio artificial é um modelo simplificado (McCulloch & Pitts, 1943) inspirado na estrutura de neurônios biológicos do sistema nervoso cerebral que possuem capacidade de adquirir conhecimento através da experiência. O neurônio artificial é a unidade básica de processamento das RNA's sendo que seu funcionamento pode ser descrito conforme apresentado a seguir:


- Um conjunto de valores é apresentado como variável de entrada;
- As variáveis de entrada são multiplicadas por pesos sinápticos respectivos conforme a influência de cada valor;

- O potencial de ativação neural é obtido através da soma ponderada dos sinais de entrada, subtraindo-se o limiar de ativação;
- A saída do neurônio é limitada utilizando uma função de ativação apropriada;
- O sinal de saída é produzido relacionado a cada um dos conjuntos de variáveis de entrada.

As RNA's podem ser formadas por diversas unidades de processamento, denominadas neurônios artificiais, simulando os neurônios biológicos que compõem o sistema nervoso.

Estes módulos de processamento são elementos não-lineares que fornecem saídas contínuas resultantes da coleta de valores de entrada, dos respectivos pesos sinápticos e da função de ativação correspondente.

A Figura 8 ilustra o modelo de um neurônio artificial. Os sinais de entrada são representados pelos valores  $X_1, X_2, X_3, \dots, X_n$ , que representam impulsos elétricos externos em um neurônio biológico. Os pesos sinápticos ponderando a relevância de cada entrada são representados pelo conjunto de valores  $W_1, W_2, W_3, \dots, W_n$ , que serão os índices de multiplicação dos valores de entrada. Desta forma, através de um limiar de ativação  $\theta$ , a soma ponderada das entradas  $u$  é limitada pela função de ativação apresentado o resultado em  $y$ .



Fonte: Site <http://laips.sel.eesc.usp.br/livrorna>

Figura 8 - Neurônio artificial

Com base na Figura 8, percebe-se que o neurônio artificial é composto por 7 elementos básicos os quais são apresentados a seguir:

- a) Sinais de entrada ( $x_1, x_2, x_3, \dots, x_n$ ): são os sinais, medidas ou valores oriundos do meio externo e representam os valores das variáveis de determinada aplicação. Estes sinais são geralmente normalizados para aumentar a eficiência dos algoritmos do aprendizado;
- b) Pesos sinápticos ( $w_1, w_2, w_3, \dots, w_n$ ): são os valores que farão a ponderação dos sinais de entrada, possibilitando dar relevâncias distintas a cada entrada de acordo com a funcionalidade do neurônio;
- c) Combinador linear ( $\Sigma$ ): elemento cuja função é agregar os sinais de entrada ponderados através dos pesos sinápticos e então produzir um potencial de ativação;
- d) Potencial de ativação ( $u$ ): é a diferença do valor produzido pelo combinador linear e o limiar de ativação. Caso o valor seja positivo, o neurônio produz um potencial excitatório.

Caso contrário, o potencial produzido será inibitório;

- e) Limiar de ativação ( $\theta$ ): trata-se de uma variável específica que será o patamar apropriado para que o combinador linear gere um disparo em direção à saída do neurônio;
- f) Função de ativação ( $g$ ): tem como função limitar os valores de saída do neurônio dentro de um intervalo de valores razoáveis;
- g) Sinal de saída ( $y$ ): é o valor final gerado pelo neurônio associado a um conjunto de variáveis ditos sinais de entrada. Também pode ser utilizado por outros neurônios que estejam ligados na sequência.

Dessa forma, o resultado produzido pelos neurônios artificiais pode ser sintetizado conforme as equações (3.1) e (3.2) (McCulloch & Pitts, 1943) sendo  $n$  o número de sinais de entrada e  $g(u)$  a função de ativação.

$$u = \sum_{i=1}^n w_i \cdot x_i - \theta \tag{3.1}$$

$$y = g(u), \tag{3.2}$$

### 3.1.3 Funções de ativação

A equação (3.1) mostra que a função de ativação processa o conjunto de entradas recebidas ponderadas e o transforma em estado de ativação limitado em intervalos de valores. O estado de ativação dos neurônios pode assumir os seguintes valores (Haykin, 2001):

- valores binários (0 e 1);
- valores bipolares (-1 e 1);
- valores reais.

As funções de ativação são escolhidas em função da necessidade de cada aplicação em que a rede esteja operando. As principais funções de ativação são apresentadas a seguir.


### 3.1.3.1 Função linear

A função linear produz resultados de saída iguais aos valores do potencial de ativação  $u$  e tem sua expressão matemática definida conforme equação (3.3).

$$g(u) = u$$

(3.3)

A representação gráfica é mostrada na Figura 9.



Fonte: Site <http://laips.sel.eesc.usp.br/livrorna>

Figura 9 - Função de ativação linear


### 3.1.3.2 Função degrau

Os resultados da função degrau serão valores unitários positivos

para potenciais de ativação iguais ou maiores que zero e valores nulos para potencial de ativação menor que zero conforme equação (3.4).

$$g(u) = \begin{cases} 1, & \text{se } u \geq 0 \\ 0, & \text{se } u < 0 \end{cases} \quad (3.4)$$

A representação gráfica é mostrada na Figura 10.




Fonte: Site <http://laips.sel.eesc.usp.br/livrorna>

Figura 10 - Função de ativação degrau

### 3.1.3.3 Função sinal

A função de ativação sinal apresentada na Figura 11 e representada pela equação (3.5) assumirá valor unitário positivo para potencial de ativação maior que zero, valor nulo para potencial nulo e valor unitário negativo para valor de potencial menor que zero.

$$g(u) = \begin{cases} 1, & \text{se } u > 0 \\ 0, & \text{se } u = 0 \\ -1, & \text{se } u < 0 \end{cases} \quad (3.5)$$



Fonte: Site <http://laips.sel.eesc.usp.br/livrorna>


Figura 11 - Função de ativação sinal

### 3.1.3.4 Função rampa simétrica

Na função rampa simétrica apresentada na Figura 12 e representada pela equação (3.6), o resultado produzido pela função assume o próprio valor do potencial de ativação  $u$  para contidos no intervalo  $[-a, a]$  e os valores limites  $-a$  e  $a$ , caso contrário.

$$g(u) = \begin{cases} a, & \text{se } u > a \\ u, & \text{se } -a \leq u \leq a \\ -a, & \text{se } u < -a \end{cases}$$

(3.6)



Fonte: Site <http://laips.sel.eesc.usp.br/livrorna>


Figura 12 - Função de ativação rampa simétrica

### 3.1.3.5 Função sigmóide

Os resultados de função sigmóide assumirão valores reais entre


zero e um e sua expressão matemática é dada pela equação (3.7), cuja representação gráfica está ilustrada na Figura 13. O parâmetro  $\beta$  é uma constante real associada com o nível de inclinação da função sigmóide, conforme mostrado na Figura 14.

$$g(u) = \frac{1}{1 + e^{-\beta \cdot u}} \quad (3.7)$$



Fonte: Site <http://laips.sel.eesc.usp.br/livrorna>

Figura 13 - Função de ativação sigmóide



Fonte: Site <http://laips.sel.eesc.usp.br/livrorna>


Figura 14 - Influência do parâmetro  $\beta$  na função sigmóide

### 3.1.3.6 Função tangente hiperbólica

Os resultados de função tangente hiperbólica assumirão valores reais entre -1 e 1 e sua expressão matemática é dada pela equação (3.8) cuja representação gráfica está ilustrada na Figura 15. O parâmetro  $\beta$  também é uma


constante real associada com o nível de inclinação da função tangente hiperbólica conforme mostrado na Figura 16.

$$g(u) = \frac{1 - e^{-\beta \cdot u}}{1 + e^{-\beta \cdot u}} \quad (3.8)$$



Fonte: Site <http://laips.sel.eesc.usp.br/livrorna>

Figura 15 - Função de ativação tangente hiperbólica



Fonte: Site <http://laips.sel.eesc.usp.br/livrorna>

Figura 16 - Influência do parâmetro  $\beta$  na função tangente hiperbólica

### 3.2 ARQUITETURA DAS REDES NEURAIS ARTIFICIAIS

A arquitetura das RNA's diz respeito à forma como os diversos neurônios que compõem a rede estão dispostos uns relação aos outros, ou seja,

como as conexões sinápticas estão estruturadas (Silva, et al., 2010).


As RNA's são divididas em camadas nomeadas e definidas conforme abaixo:

- a) Camada de entrada: é a camada por onde os sinais externos (dados) são introduzidos à rede, sendo que estas entradas devem ser normalizadas, o que implica em uma melhor precisão nas operações matemáticas realizadas pela rede;
- b) Camadas intermediárias ou escondidas: são as camadas responsáveis pela maior parte do processamento interno da rede que através de conexões ponderadas extraem as características associadas ao processo;
- c) Camada de saída: é a camada na qual são apresentados os resultados finais advindos do processamento realizado pelos neurônios das camadas anteriores.

As principais arquiteturas das RNA's, considerando a disposição dos neurônios, formas de interligação e constituição de camadas, são as redes *feedforward* de camada simples ou camadas múltiplas e as redes recorrentes.

### 3.2.1 Arquitetura de rede *feedforward* de camada simples

São RNA's que contém apenas uma camada de entrada e a camada de saída é a própria camada de neurônios conforme Figura 17 que demonstra uma rede com  $n$  entradas e  $m$  saídas. Observa-se que a quantidade de saídas será igual ao número de neurônios da rede. Estas redes são empregados em aplicações de filtragem linear, memória associativa e classificação de padrões.



Fonte: Site <http://laips.sel.eesc.usp.br/livrorna>


Figura 17 - Rede *feedforward* de camada simples

São exemplos desta arquitetura as redes *Perceptron* e *Adaline*.

### 3.2.2 Arquitetura de rede *feedforward* de camadas múltiplas

As redes de camadas múltiplas possuem uma ou mais camadas de neurônios escondidas e são aplicadas em diversos problemas tais como aproximação de funções, classificação de padrões, otimização, controle de processos, etc. A Figura 18 mostra uma rede *feedforward* de camadas múltiplas formada por uma camada de  $n$  entradas, duas camadas intermediárias com  $n_1$  e  $n_2$  neurônios respectivamente e uma camada de saída com  $m$  neurônios.

São exemplos desta rede o *Perceptron* multicamadas MLP (*multilayer Perceptron*) e as redes de base radial RBF (*radial basis function*). Nestas redes, o número de neurônios das camadas intermediárias é independente e, conforme a complexidade da aplicação, o número de neurônios da camada de saídas é sempre igual ao número de saídas.




Fonte: Site <http://laips.sel.eesc.usp.br/livrorna>

Figura 18 - Rede *feedforward* de camadas múltiplas

### 3.2.3 Arquitetura de rede recorrente

Este tipo de rede possui realimentação entre diferentes camadas de neurônios na qual as saídas dos neurônios são realimentadas como sinais de entradas em outros neurônios. Os principais tipos destas redes são o modelo de *Hopfield* e o *Perceptron* multicamadas com realimentação, onde tais redes possuem processamento dinâmico de informações e são utilizadas em sistemas variantes no tempo, tais como otimização, identificação de sistemas, controle de processos, previsão de séries temporais, etc.



Fonte: Site <http://laips.sel.eesc.usp.br/livrorna>

Figura 19 - Rede recorrente

A Figura 19 contém um exemplo de rede *Perceptron* multicamadas com realimentação na qual um dos sinais da camada de saída realimenta a camada intermediária.

### 3.3 TREINAMENTO DAS REDES NEURAIS ARTIFICIAIS

Uma das principais características associadas às RNA's é a capacidade de aprendizado a partir de amostras conhecidas que contêm o comportamento do sistema, sendo que, a partir do aprendizado que a rede obtém através destas amostras, ela adquire a capacidade de generalização de soluções a partir de quaisquer sinais inseridos nas suas entradas (Silva, et al., 2010).

O processo de treinamento é a adequação iterativa dos pesos sinápticos e limiares de ativação de todos os neurônios da rede e encerra-se quando a RNA consegue generalizar soluções para uma classe de problemas cujas respostas são representativas na aplicação que está sendo processada.

Todo o conhecimento da RNA está armazenado nos pesos

sinápticos e no limiar de ativação de cada neurônio.

Cada apresentação completa do conjunto de valores de entradas e saídas para treinamento à rede com a finalidade de ajustes dos pesos e limiar de ativação, é denominada época de treinamento.

O conjunto de valores reais conhecidos (amostras) normalmente é dividido em subconjuntos de treinamento e teste da RNA (Silva, 2010). Cerca de 60 a 90% das amostras é separada para efetuar o aprendizado da RNA, a fim de que esta aprenda as regras do processo e ajuste os pesos sinápticos e o limiar de ativação. Os demais dados ou amostras são apresentados à RNA após a fase de treinamento com o objetivo de verificar e testar se a generalização produzida pela rede resulta em saídas adequadas para os dados não apresentados durante o treinamento. Caso as saídas dos dados de testes sejam adequados, a rede obteve um grau de generalização aceitável e, assim, obtém-se a validação da topologia empregada.

Os algoritmos de aprendizado são compostos por um conjunto de regras bem definidas para buscar a solução de um problema de aprendizado. Existem diversos tipos de algoritmos de aprendizado para as RNAs, que divergem entre si na forma como os pesos e limiares são alterados durante o processo. As principais formas de ajustes de pesos e aprendizado são: aprendizado supervisionado e aprendizado não-supervisionado.

### 3.3.1 Aprendizado supervisionado

O aprendizado supervisionado é aquele no qual é apresentada para a rede uma tabela de dados com entradas e saídas conhecidas caracterizando qual é o valor adequado ou inadequado para cada entrada apresentada. Assim, a RNA é

treinada para fornecer a saída desejada em relação a uma entrada específica (Haykin, 2001).

Quando um vetor de entrada é aplicado, a saída da rede é calculada e comparada com o padrão de saída da tabela de dados e os pesos sinápticos e limiares são ajustados continuamente mediante ações comparativas executadas pelo algoritmo de aprendizado, supervisionando o erro em relação ao padrão de saída. Esta operação é repetida em diversas épocas até que o erro esteja dentro dos valores aceitáveis.

### 3.3.2 Aprendizado não-supervisionado

O aprendizado não-supervisionado não possui os valores de saídas conhecidos para um conjunto de valores de entrada. Neste processo, a rede considera que subconjuntos de valores com determinado comportamento respondam de maneira similar. Assim a rede se autoorganiza em relação a estes subconjuntos de entrada (*clusters*) com características similares. Os pesos sinápticos e limiares dos neurônios são ajustados pelo algoritmo de treinamento de maneira a representar internamente estas similaridades dentro da própria rede (Haykin, 2001).

Ao contrário da aprendizagem supervisionada, não existe um conjunto de categorias dentro do qual os padrões serão classificados, cabendo à própria rede desenvolver esta identificação. No entanto, o projetista da rede, embasado no seu conhecimento do problema a ser tratado, pode especificar a quantidade máxima dos *clusters*.

### 3.4 REDES PERCEPTRON MULTICAMADAS

As redes *Perceptron* de múltiplas camadas (MLP) são caracterizadas pela existência de pelo menos uma camada de neurônios intermediária ou escondida situada entre a camada de entrada e a camada neural de saída. As redes MLP são aplicáveis a diversas áreas, em função da sua versatilidade de aplicações (Silva, et al., 2010). Dentre estas áreas destacam-se:

- Aproximador universal de funções;
- Reconhecimento de padrões;
- Previsão de séries temporais;
- Otimização de sistemas;
- Identificação e controle de processos.

Nas redes MLP, cada camada tem uma função específica. A camada neural de saída recebe os estímulos da camada intermediária e produz o padrão que será a resposta. As camadas neurais intermediárias funcionam como extratoras de características ajustando os pesos sinápticos e limiares de ativação que representam a codificação das características dos padrões de entrada. Dessa forma, a RNA cria sua própria representação do problema.

São necessárias, no máximo, duas camadas neurais intermediárias com um número suficiente de neurônios por camada para produzir quaisquer mapeamentos de funções, bem como apenas um camada intermediária para aproximar funções contínuas (Silva, et al., 2010).

A rede MLP pertence à arquitetura *feedforward* de camadas múltiplas cujo treinamento é realizado de forma supervisionada. O fluxo de informações se inicia na camada de entrada, percorre as camadas neurais intermediárias e finaliza-se na camada de saída. Em um rede MLP convencional, não existe qualquer tipo de

realimentação dos valores das camadas intermediárias ou de saída.

### 3.4.1 Algoritmo *backpropagation*

O algoritmo *backpropagation* (Rumelhart, et al., 1986) permitiu a implementação do treinamento em redes MLP, sendo responsável pela popularidade e aplicabilidade destas redes.

A estratégia de treinamento da rede através do algoritmo *backpropagation*, conhecido também como regra Delta generalizada, pode ser descrita através das ações apresentadas a seguir (Haykin, 2001):

- Um padrão de entrada é apresentado à camada de entrada da rede;
- A atividade resultante é propagada pela rede, camada por camada, até que a camada de saída produza uma resposta;
- A saída obtida é comparada com a saída real desejada;
- O erro da saída é calculado e propagado a partir da camada de saída até a camada de entrada;
- Os pesos sinápticos e os limiares de ativação são alterados gradativamente a cada iteração, conforme o erro é retropropagado.
- Este processo é repetido para todos os vetores de entrada da rede até que o erro quadrático médio das saídas da rede esteja dentro de um valor admissível.

A função representativa do erro quadrático médio, cujo objetivo é medir o desvio entre as respostas produzidas pelos neurônios em relação aos valores desejados, é apresentada nas equações (3.9) e (3.10).

$$E(k) = \frac{1}{2} \sum_{j=1}^{n_3} \left( d_j(k) - Y_j^{(3)}(k) \right)^2$$
(3.9)

$$E_M = \frac{1}{p} \sum_{k=1}^p E(k)$$
(3.10)

### 3.4.2 Método de Levenberg-Marquardt

O algoritmo *backpropagation* ajusta os pesos sinápticos em função do erro quadrático médio, no entanto, na prática este algoritmo converge de uma forma muito lenta o que exige um esforço de processamento intenso. Para evitar este problemas, algumas técnicas de otimização têm sido incorporadas ao *backpropagation* para reduzir o tempo de convergência e consequentemente o esforço computacional exigido. Dentre as técnicas de otimização, a mais destacada é o algoritmo de Levenberg-Marquardt (Hagan & Menhaj, 1994).

O algoritmo de Levenberg-Marquardt é uma técnica que pode ser incorporada ao algoritmo *backpropagation* para aumentar a eficiência do treinamento. A função do erro quadrático e erro quadrático médio deste algoritmo são expressas conjuntamente conforme equação (3.11).

$$V = \frac{1}{2p} \cdot \sum_{k=1}^p E^T(k) \cdot E(k)$$
(3.11)

Através do método Levenberg-Marquardt, consegue-se conduzir o processo de treinamento de redes MLP na ordem de 10 a 100 vezes mais rápido que o algoritmo *backpropagation* convencional (Hagan & Menhaj, 1994).

### 3.5 PROCESSO DE DESENVOLVIMENTO DE REDES NEURAIS ARTIFICIAIS

Com o objetivo da utilização adequada da técnica, prevenindo e evitando a ocorrência de problemas durante o treinamento, o processo de desenvolvimento de uma RNA pode ser sistematizado e sintetizado. Portanto, no desenvolvimento de RNA's, devem ser observadas as etapas apresentadas a seguir:

- a) Coleta de dados: esta primeira ação do desenvolvimento de RNA's é uma tarefa que requer uma cuidadosa análise do problema para minimizar ambiguidades e erros nos dados obtidos. Os dados coletados devem ser significativos e conter um domínio amplo do problema, e não apenas operações normais ou rotineiras, mas também exceções e demais condições pertencentes aos limites do problema.
- b) Separação em conjuntos: os dados coletados devem ser separados em subconjuntos classificados como dados de treinamento e dados de testes. Os dados de treinamento são utilizados pelo algoritmo de aprendizado para generalização da rede. Os dados de testes são utilizados para verificação do desempenho da rede, sendo possível reproduzir, através da generalização da rede, o resultado de saída conhecido para uma determinada entrada, dentro de um erro admissível. Tais dados geralmente possuem a necessidade de pré-processamento através de normalizações e conversões para torná-los apropriados à sua utilização da RNA.
- c) Configuração da rede: a configuração da rede pode ser elaborada em três etapas.

- Seleção do paradigma neural apropriado à aplicação;
- Determinação da topologia da rede tais como número de camadas, de neurônios em cada camada, etc;
- Determinação dos parâmetros de treinamento e da função de ativação dos neurônios.

A escolha destes parâmetros para configuração da rede é feita normalmente de forma empírica através de experiência do projetista e testes.

- d) Treinamento: neste etapa, é determinado o algoritmo de treinamento a ser utilizado e considerados aspectos relativos à inicialização da rede, modo e tempo de treinamento. São definidos os critérios de parada do treinamento tais como número máximo de épocas e erro. Deve-se evitar a ocorrência de *over-training*, que é caracterizado pela especialização da rede em um determinado conjunto de valores causando a perda da capacidade de generalização. O treinamento é encerrado quando a rede apresenta uma boa generalização e quando a taxa de erro menor que o nível previamente estabelecido.
- e) Teste e integração: nesta fase, o conjunto de dados para teste é apresentado como entrada da rede e é observada qual a saída para estes valores conhecidos, comparando com os valores reais das saídas. Com a rede treinada e avaliada, ela pode ser integrada no ambiente da aplicação.

## 4 APLICAÇÃO DE REDES NEURAIS PARA ANÁLISE DO ENCAPSULAMENTO

### 4.1 LEVANTAMENTO DE DADOS

A metodologia com aplicação de RNA's é uma ferramenta para análise da qualidade do encapsulamento das bobinas de média tensão mostrada na Figura 20. Nesta bobinas, são realizadas as medições de descargas parciais por tensão aplicada individualmente, conforme Figura 21.

Todas as amostras de bobinas fabricadas foram ensaiadas segundo esta metodologia, na qual foi realizada a medição das descargas com aplicação de 100, 105 e 110% da tensão nominal por fase ( $V_N$ ).



Figura 20 - Bobina didática de média tensão encapsulada (Fonte: 2010 IEEE PES T&D Conference and Exposition)

A etapa de coleta e levantamento de dados teve uma duração de aproximadamente dois anos e seis meses, sendo realizada no período de janeiro de 2009 a julho de 2011.

A coleta de dados foi realizada nas instalações da Romagnole Produtos Elétricos S.A, fabricante nacional de transformadores secos. A coleta de dados consiste na realização do ensaio de medição de descargas parciais em cada

bobina fabricada aplicando 100, 105 e 110% da tensão nominal por fase ( $V_N$ ).



Figura 21 - Ensaio de medição de descargas parciais por tensão aplicada em bobinas de média tensão encapsuladas (Fonte: Acervo próprio)

As bobinas ensaiadas possuem tensão nominal por fase 13800V ou 23100V, conforme a classe de tensão do transformador seco de que fazem parte.

O tempo médio para realização do ensaio em cada bobina é de aproximadamente 15 minutos, entre preparação, montagem no laboratório, aplicações da tensão e medições necessárias.

Uma vez realizadas as medições, os dados foram catalogados de acordo com o número de identificação da bobina e também da fase correspondente (fase H1, fase H2 e fase H3) e inseridos em um banco de dados para posterior utilização pelo sistema neural.

A Tabela 6, a seguir, apresenta um exemplo parcial do banco de dados formado com os valores individuais das medições de DP, conforme metodologia proposta, e que serão utilizados como variáveis de entrada do sistema neural desenvolvido para relacionar as medições de DP das bobinas com as medições no transformador.

Tabela 6 - Exemplo do banco de dados das medições de DP por tensão aplicada

<b>Medições de DP por tensão aplicada em cada bobina (em pC)</b>								
Tensão aplicada ( $V_N$ )			Tensão aplicada ( $1,05 \times V_N$ )			Tensão aplicada ( $1,1 \times V_N$ )		
H1	H2	H3	H1	H2	H3	H1	H2	H3
3,94	3,94	3,94	4,24	5,3	4,09	10,61	9,24	4,07
10,19	7,69	7,31	17,31	18,85	12,88	20,19	18,46	15,58
13,84	13,86	13,82	14,57	14,45	14,6	15,49	15,24	15,16
13,72	13,84	13,84	14,57	14,6	14,49	15,3	15,25	15,18
13,93	13,86	13,84	14,46	14,41	14,63	15,24	15,14	15,14
13,91	13,74	13,85	14,39	14,5	14,44	15,08	15,09	15,27
13,89	13,88	13,81	14,54	14,44	14,48	15,17	15,14	15,19
13,77	13,79	13,81	14,54	14,49	14,48	15,27	15,22	15,23
13,74	13,85	14,03	14,46	14,68	14,45	15,21	15,14	15,1

Após o ensaio da metodologia, as bobinas de média tensão encapsuladas foram montadas no núcleo magnético formando os transformadores trifásicos secos, conforme Figura 22, nos quais é possível realizar o ensaio de tensão induzida de longa duração com medição de descargas parciais conforme as normas (NBR10295, 2011) e (IEC60076-11, 2004).

A realização do ensaio de tensão induzida com medição de DP em cada fase tem a seguinte sequência:

- Aplicação de  $1,5 \times V_N$  durante 30 segundos para excitação;
- Aplicação de  $1,1 \times V_N$  durante 3 minutos para leituras dos valores das medição de DP.

O tempo médio envolvido para preparação do transformador, montagem do ensaio, aplicação da tensão induzida e leituras dos valores é de aproximadamente 60 minutos por transformador.



Figura 22 - Transformador trifásico seco: bobinas e núcleo (Fonte: Romagnole)

Uma vez obtidos os valores das medições de descargas parciais por tensão induzida nos transformadores secos, tais valores também foram inseridos no banco de dados relacionando-os com as bobinas que compõem o transformador.

A Tabela 7 a seguir, apresenta um exemplo parcial do banco de dados incluindo os valores das medições de DP dos transformadores conforme metodologia da norma (NBR10295, 2011). Estes valores são os resultados da saída que o sistema neural utilizará como referência ao relacionamento com as entradas durante a etapa de treinamento e os valores a serem comparados com a resposta da rede neural durante os testes e validação da RNA.

De posse do banco de dados completos, ou seja, com valores de descargas parciais (DP) das bobinas encapsuladas e também do transformador montado, há a necessidade da utilização de um sistema inteligente para relacionar as grandezas em função da inexistência de uma relação linear e bem definida dos dados de DP.

Tabela 7 - Exemplo do banco de dados das medições de DP por tensão induzida

<b>Medições de DP por tensão induzida no transformador (em pC)</b>		
Tensão induzida conforme NBR-5356		
Fase H1	Fase H2	Fase H3
4,48	3,36	4,48
7,73	5,61	9,55
15,12	15,04	15,14
15,09	15,17	15,15
15,05	15,13	15,01
15,16	15,17	15,21
15,19	15,01	15,15
15,08	15,23	15,21
15,15	15,13	15,16

As redes neurais artificiais foram utilizadas para relacionar as medições de descargas parciais feitas nos transformadores montados e as medições feitas individualmente nas bobinas que compõem o transformador.

Estas medições de descargas parciais por tensão aplicada (nas bobinas encapsuladas) e por tensão induzida (nos transformadores secos montados) formaram um banco de dados amplo com os resultados dos ensaios, possibilitando a implementação de uma rede neural artificial com dados de treinamento e validação para relacionar as duas metodologias de ensaios.

#### 4.2 CONSTRUÇÃO DO SISTEMA NEURAL

No desenvolvimento da rede neural artificial, foi utilizada a ferramenta computacional MATLAB (MATLAB, 1994). Implementou-se a arquitetura da rede *feedforward* tipo *Perceptron* de múltiplas camadas, conforme Figura 23, com a utilização de uma camada neural intermediária entre a camada de entrada e a camada de saída (Silva, et al., 2010).




Figura 23 - Rede neural artificial

Os neurônios na camada escondida tem função de ativação logística (função sigmóide) e os neurônios de saída são do tipo linear na qual a saída do neurônio assume valores reais entre 0 e 1. O algoritmo de treinamento utilizado foi o de *backpropagation* com a técnica de otimização do Método de Levenberg-Marquardt.

A definição do número de camadas escondidas foi embasada no estudo de (Maren, et al., 1999) onde se define que um problema de classificação deve utilizar apenas uma camada escondida na rede neural.

Para efetuar o treinamento e validação da rede utilizaram-se os 207 ensaios realizados nas bobinas de média tensão agrupados por conjunto de fases H1, H2 e H3 do transformador trifásico combinados com o resultado final dos ensaios no transformador montado realizado de acordo com (NBR10295, 2011) e (IEC60076-11, 2004).

### 4.3 ESTRATÉGIA DE TREINAMENTO

Os 207 ensaios de descargas parciais por tensão aplicada realizados formaram 23 conjuntos de dados, que por sua vez, representam os valores medidos de descargas parciais nas fases H1, H2 e H3 para tensão aplicada de 100, 105 e 110% da tensão nominal por fase e têm sua correspondência no resultado final do ensaio de descargas parciais por tensão induzida realizado no transformador montado de acordo com (NBR10295, 2011) e (IEC60076-11, 2004).

Estes 23 conjuntos de dados foram distribuídos em 3 agrupamentos de conjuntos para treinamento e testes. Esta distribuição, conforme mostrada na Tabela 8, permite uma melhor análise e avaliação de desempenho da rede neural, como mostrado a seguir (Santos, et al., 2011).

Tabela 8 - Distribuição dos agrupamentos de conjuntos dos dados de entrada

Agrupamento de conjunto	% Dados de entrada	
	Treinamento	Testes
#1	91	9
#2	87	13
#3	83	17

A divisão dos dados de entrada para cada agrupamento de conjunto foi realizada de forma aleatória e valores foram normalizados para maximizar a eficiência do treinamento da RNA.

O conjunto de dados de treinamento de uma rede neural artificial tem por finalidade permitir o ajuste dos pesos das conexões sinápticas bem como do limiar de ativação, através do algoritmo de treinamento.

O conjunto de dados de testes foi utilizado logo após o fim do treinamento da rede para avaliar a capacidade de generalização da rede treinada.

Os valores gerados em cada ensaio de tensão aplicada são

convertidos em um vetor de entrada composto pelos valores de descargas parciais por tensão aplicada para 100, 105 e 110% da tensão nominal por fase.

Realizado isto para cada agrupamento de conjuntos de dados, obtêm-se os vetores de entrada que serão relacionados com os resultados de saída, ou seja, os valores de descargas parciais por tensão induzida nas três fases do transformador.

Desta forma, como pode ser observado na Figura 23, a rede neural foi configurada para 9 neurônios na camada de entrada e 3 neurônios na camada de saída.

A entrada de dados na rede foi projetada para que seja de forma aleatória, possibilitando um equilíbrio na adequação dos pesos sinápticos no decorrer do treinamento.

O número de neurônios da camada escondida foi alterado de forma a analisar qual agrupamento de conjuntos, juntamente com o número de neurônios na camada escondida, apresenta o melhor resultado (Santos, et al., 2011).

Definiu-se a utilização de quatro quantidades de neurônios: 5, 10, 15 e 20 neurônios. A motivação deste método de alteração neste intervalo de neurônios é evitar o sobre-treinamento, no qual a rede treina em demasia e ocorrem erros nos pesos sinápticos tornando a RNA incapaz de obter uma generalização (Santos, et al., 2011).

O treinamento da rede foi elaborado utilizando como parâmetros um erro limite de 0,0001% e um total de 5000 épocas.

## 5 VALIDAÇÃO DA FERRAMENTA DE ANÁLISE DO ENCAPSULAMENTO

### 5.1 TREINAMENTOS E TESTES DAS RNA'S

Para todos os agrupamentos de conjuntos de dados, foram testadas as quatro configurações de números de neurônios na camada escondida, onde para cada combinação de agrupamento de conjunto-neurônios na camada escondida, a rede foi processada dez vezes para diminuir a incerteza aleatória no processo de treinamento.

#### 5.1.1 Agrupamentos de conjuntos #1

O agrupamento de conjunto #1 foi aplicado à RNA com quatro configurações de neurônios distintas na camada intermediária conforme simulações e resultados a seguir.

##### 5.1.1.1 Camada intermediária com 5 neurônios

O treinamento da RNA com 5 neurônios na camada intermediária pode ser observado na Figura 24. Para esta RNA, a parada do treinamento ocorreu em 1021 épocas, quando foi alcançado o erro desejado.

A Tabela 9 apresenta os resultados obtidos através da generalização da rede por ocasião do treinamento realizado. O erro relativo médio percentual obtido nestes testes foi de 0,1252% e a taxa de acerto média foi de 99,7488%.

Tabela 9 - Valores de DP obtidos pela RNA 5 neurônios - Agrupamento #1

Medições de DP (pC)		Erro absoluto (pC)	Erro relativo (%)
Ensaio	RNA		
17,94	17,9322	0,0078	0,04348
17,89	17,8547	0,0353	0,19732
17,92	17,9664	-0,0464	-0,25893
17,89	17,9564	-0,0664	-0,37116
17,87	17,9592	-0,0892	-0,49916
17,94	17,9154	0,0246	0,13712

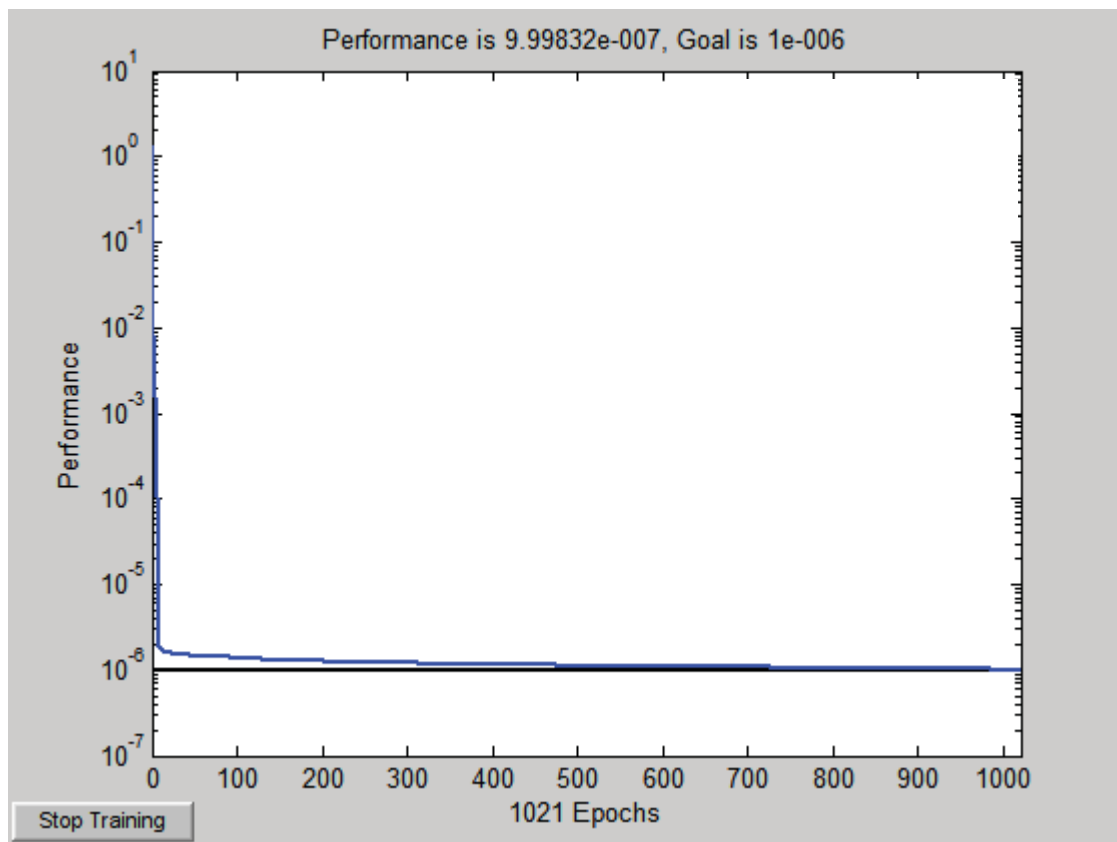


Figura 24 - Treinamento da RNA com 5 neurônios - Agrupamento #1

#### 5.1.1.2 Camada intermediária com 10 neurônios

O treinamento da RNA com 10 neurônios na camada intermediária pode ser observado na Figura 25. Para esta RNA, a parada do treinamento ocorreu em 601 épocas, quando foi alcançado o erro desejado.

A Tabela 10 apresenta os resultados obtidos através da

generalização da rede por ocasião do treinamento realizado. O erro relativo médio percentual obtido nestes testes foi de 0,4372% e a taxa de acerto média foi de 99,4758%.

Tabela 10 - Valores de DP obtidos pela RNA 10 neurônios - Agrupamento #1

Medições de DP (pC)		Erro absoluto (pC)	Erro relativo (%)
Ensaio	RNA		
17,94	18,0286	-0,0886	-0,49387
17,89	18,0844	-0,1944	-1,08664
17,92	18,0537	-0,1337	-0,74609
17,89	17,9461	-0,0561	-0,31358
17,87	17,9136	-0,0436	-0,24398
17,94	17,8932	0,0468	0,26087




Figura 25 - Treinamento da RNA com 10 neurônios - Agrupamento #1

### 5.1.1.3 Camada intermediária com 15 neurônios

O treinamento da RNA com 15 neurônios na camada intermediária

pode ser observado na Figura 26. Para esta RNA, a parada do treinamento ocorreu em 349 épocas, quando foi alcançado o erro desejado.

A Tabela 11 apresenta os resultados obtidos através da generalização da rede por ocasião do treinamento realizado. O erro relativo médio percentual obtido nestes testes foi de 0,4305% e a taxa de acerto média foi de 99,5214%.

Tabela 11 - Valores de DP obtidos pela RNA 15 neurônios - Agrupamento #1

Medições de DP (pC)		Erro absoluto (pC)	Erro relativo (%)
Ensaio	RNA		
17,94	17,9881	-0,0481	-0,26812
17,89	18,0743	-0,1843	-1,03018
17,92	18,0309	-0,1109	-0,61886
17,89	17,9674	-0,0774	-0,43264
17,87	17,9375	-0,0675	-0,37773
17,94	17,9141	0,0259	0,14437




Figura 26 - Treinamento da RNA com 15 neurônios - Agrupamento #1

#### 5.1.1.4 Camada intermediária com 20 neurônios

O treinamento da RNA com 20 neurônios na camada intermediária pode ser observado na Figura 27. Para esta RNA, a parada do treinamento ocorreu em 37 épocas, quando foi alcançado o erro desejado.

A Tabela 12 apresenta os resultados obtidos através da generalização da rede por ocasião do treinamento realizado. O erro relativo médio percentual obtido nestes testes foi de 0,4122% e a taxa de acerto média foi de 99,5643%.

Tabela 12 - Valores de DP obtidos pela RNA 20 neurônios - Agrupamento #1

Medições de DP (pC)		Erro absoluto (pC)	Erro relativo (%)
Ensaio	RNA		
17,94	17,9754	-0,0354	-0,19732
17,89	18,0887	-0,1987	-1,11068
17,92	18,0234	-0,1034	-0,57701
17,89	17,957	-0,0670	-0,37451
17,87	17,9207	-0,0507	-0,28372
17,94	17,9274	0,0126	0,07023




Figura 27 - Treinamento da RNA com 20 neurônios - Agrupamento #1

### 5.1.2 Agrupamentos de conjuntos #2

O agrupamento de conjunto #2 foi aplicado à RNA com quatro configurações de neurônios distintas na camada intermediária conforme simulações e resultados a seguir.

#### 5.1.2.1 Camada intermediária com 5 neurônios

O treinamento da RNA com 5 neurônios na camada intermediária pode ser observado na Figura 28 Para esta RNA, a parada do treinamento ocorreu em 421 épocas, quando foi alcançado o erro desejado.

A Tabela 13 apresenta os resultados obtidos através da generalização da rede por ocasião do treinamento realizado. O erro relativo médio percentual obtido nestes testes foi de 0,0718% e a taxa de acerto média foi de 99,5782%.

Tabela 13 - Valores de DP obtidos pela RNA 5 neurônios - Agrupamento #2

Medições de DP (pC)		Erro absoluto (pC)	Erro relativo (%)
Ensaio	RNA		
17,95	17,9394	0,0106	0,05905
17,98	17,9575	0,0225	0,12514
18,18	17,8699	0,3101	1,70572
17,94	17,9949	-0,0549	-0,30602
17,89	17,9996	-0,1096	-0,61263
17,92	17,9254	-0,0054	-0,03013
17,89	17,9504	-0,0604	-0,33762
17,87	17,9216	-0,0516	-0,28875
17,94	17,8806	0,0594	0,33110




Figura 28 - Treinamento da RNA com 5 neurônios - Agrupamento #2

#### 5.1.2.2 Camada intermediária com 10 neurônios

O treinamento da RNA com 10 neurônios na camada intermediária pode ser observado na Figura 29. Para esta RNA, a parada do treinamento ocorreu em 327 épocas, quando foi alcançado o erro desejado.

A Tabela 14 apresenta os resultados obtidos através da generalização da rede por ocasião do treinamento realizado. O erro relativo médio percentual obtido nestes testes foi de 0,0666% e a taxa de acerto média foi de 99,6005%.

Tabela 14 - Valores de DP obtidos pela RNA 10 neurônios - Agrupamento #2

Medições de DP (pC)		Erro absoluto (pC)	Erro relativo (%)
Ensaio	RNA		
17,95	17,9581	-0,0081	-0,04513
17,98	17,9629	0,0171	0,09511
18,18	17,8922	0,2878	1,58306
17,94	17,9365	0,0035	0,01951
17,89	18,0166	-0,1266	-0,70766
17,92	17,8823	0,0377	0,21038
17,89	17,9569	-0,0669	-0,37395
17,87	17,9364	-0,0664	-0,37157
17,94	17,906	0,0340	0,18952




Figura 29 - Treinamento da RNA com 10 neurônios - Agrupamento #2

### 5.1.2.3 Camada intermediária com 15 neurônios

O treinamento da RNA com 15 neurônios na camada intermediária pode ser observado na Figura 30. Para esta RNA, a parada do treinamento ocorreu

em 37 épocas, quando foi alcançado o erro desejado.

A Tabela 15 apresenta os resultados obtidos através da generalização da rede por ocasião do treinamento realizado. O erro relativo médio percentual obtido nestes testes foi de 0,1310% e a taxa de acerto média foi de 99,5781%.

Tabela 15 - Valores de DP obtidos pela RNA 15 neurônios - Agrupamento #2

Medições de DP (pC)		Erro absoluto (pC)	Erro relativo (%)
Ensaio	RNA		
17,95	17,9256	0,0244	0,13593
17,98	17,9391	0,0409	0,22747
18,18	17,8598	0,3202	1,76128
17,94	17,9627	-0,0227	-0,12653
17,89	17,9915	-0,1015	-0,56736
17,92	17,9094	0,0106	0,05915
17,89	17,9496	-0,0596	-0,33315
17,87	17,9204	-0,0504	-0,28204
17,94	17,9060	0,0340	0,18952

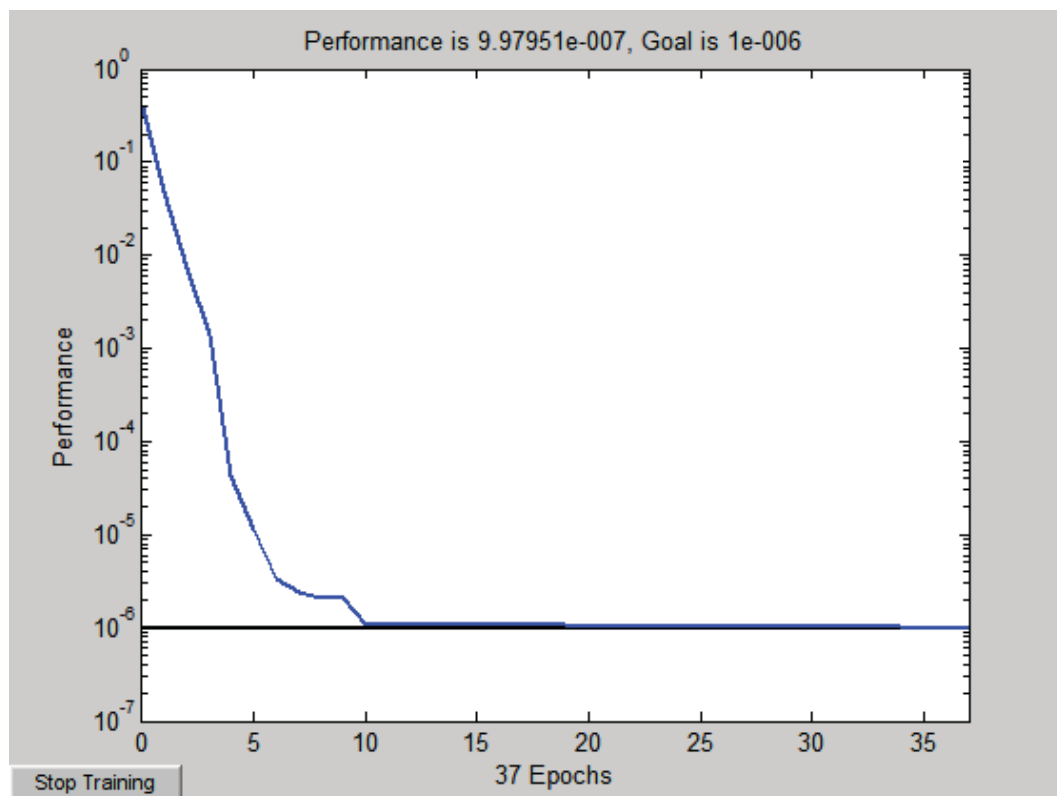


Figura 30 - Treinamento da RNA com 15 neurônios - Agrupamento #2

#### 5.1.2.4 Camada intermediária com 20 neurônios

O treinamento da RNA com 20 neurônios na camada intermediária pode ser observado na Figura 31. Para esta RNA, a parada do treinamento ocorreu em 15 épocas, quando foi alcançado o erro desejado.

A Tabela 16 apresenta os resultados obtidos através da generalização da rede por ocasião do treinamento realizado. O erro relativo médio percentual obtido nestes testes foi de 0,0719% e a taxa de acerto média foi de 99,5293%.

Tabela 16 - Valores de DP obtidos pela RNA 20 neurônios - Agrupamento #2

Medições de DP (pC)		Erro absoluto (pC)	Erro relativo (%)
Ensaio	RNA		
17,95	17,9173	0,0327	0,18217
17,98	17,9143	0,0657	0,36541
18,18	17,8722	0,3078	1,69307
17,94	17,9613	-0,0213	-0,11873
17,89	18,0076	-0,1176	-0,65735
17,92	17,884	0,036	0,20089
17,89	17,9493	-0,0593	-0,33147
17,87	17,9209	-0,0509	-0,28483
17,94	17,8678	-0,0722	-0,40245

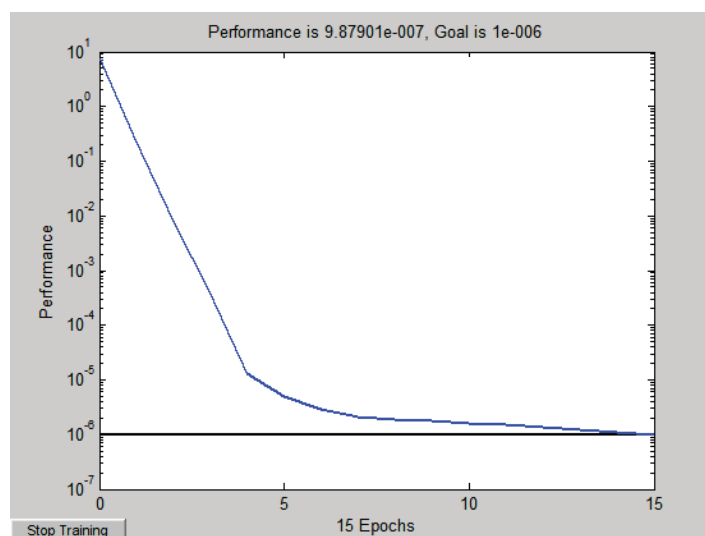


Figura 31 - Treinamento da RNA com 20 neurônios - Agrupamento #2

### 5.1.3 Agrupamentos de conjuntos #3

O agrupamento de conjunto #3 foi aplicado à RNA com quatro configurações de neurônios distintas na camada intermediária conforme simulações e resultados a seguir.

#### 5.1.3.1 Camada intermediária com 5 neurônios

O treinamento da RNA com 5 neurônios na camada intermediária pode ser observado na Figura 32. Para esta RNA, a parada do treinamento ocorreu em 150 épocas, quando foi alcançado o erro desejado.

A Tabela 17 apresenta os resultados obtidos através da generalização da rede por ocasião do treinamento realizado. O erro relativo médio percentual obtido nestes testes foi de 0,1764% e a taxa de acerto média foi de 99,5358%.

Tabela 17 - Valores de DP obtidos pela RNA 5 neurônios - Agrupamento #3

Medições de DP (pC)		Erro absoluto (pC)	Erro relativo (%)
Ensaio	RNA		
17,93	17,7607	0,1693	0,94423
17,90	17,8944	0,0056	0,03128
18,01	17,8771	0,1329	0,73792
17,95	17,9057	0,0443	0,24680
17,98	17,9544	0,0256	0,14238
18,18	17,8758	0,3042	1,67327
17,94	17,9362	0,0038	0,02118
17,89	18,0884	-0,1984	-1,10900
17,92	17,9124	0,0076	0,04241
17,89	17,9855	-0,0955	-0,53382
17,87	17,9249	-0,0549	-0,30722
17,94	17,8992	0,0408	0,22742




Figura 32 - Treinamento da RNA com 5 neurônios - Agrupamento #3

#### 5.1.3.2 Camada intermediária com 10 neurônios

O treinamento da RNA com 10 neurônios na camada intermediária pode ser observado na Figura 33. Para esta RNA, a parada do treinamento ocorreu em 113 épocas, quando foi alcançado o erro desejado.

A Tabela 18 apresenta os resultados obtidos através da generalização da rede por ocasião do treinamento realizado. O erro relativo médio percentual obtido nestes testes foi de 0,2341% e a taxa de acerto média foi de 99,4579%.

Tabela 18 - Valores de DP obtidos pela RNA 10 neurônios - Agrupamento #3

Medições de DP (pC)		Erro absoluto (pC)	Erro relativo (%)
Ensaio	RNA		
17,93	17,6939	0,2361	1,31679
17,90	17,9956	-0,0956	-0,53408
18,01	17,8356	0,1744	0,96835
17,95	17,9181	0,0319	0,17772
17,98	17,9381	0,0419	0,23304
18,18	17,8722	0,3078	1,69307
17,94	17,9215	0,0185	0,10312
17,89	18,0108	-0,1208	-0,67524
17,92	17,8904	0,0296	0,16518
17,89	18,0011	-0,1111	-0,62102
17,87	17,8712	-0,0012	-0,00672
17,94	17,942	-0,002	-0,01115




Figura 33 - Treinamento da RNA com 10 neurônios - Agrupamento #3

### 5.1.3.3 Camada intermediária com 15 neurônios

O treinamento da RNA com 15 neurônios na camada intermediária pode ser observado na Figura 34. Para esta RNA, a parada do treinamento ocorreu em 18 épocas, quando foi alcançado o erro desejado.

A Tabela 19 apresenta os resultados obtidos através da generalização da rede por ocasião do treinamento realizado. O erro relativo médio percentual obtido nestes testes foi de 0,1325% e a taxa de acerto média foi de 99,5057%.

Tabela 19 - Valores de DP obtidos pela RNA 15 neurônios - Agrupamento #3

Medições de DP (pC)		Erro absoluto (pC)	Erro relativo (%)
Ensaio	RNA		
17,93	17,8108	0,1192	0,66481
17,90	18,0198	-0,1198	-0,66927
18,01	17,8891	0,1209	0,67129
17,95	17,9579	-0,0079	-0,04401
17,98	17,9187	0,0613	0,34093
18,18	17,8694	0,3106	1,70847
17,94	17,9866	-0,0466	-0,25975
17,89	18,014	-0,1240	-0,69312
17,92	17,9029	0,0171	0,09542
17,89	17,9803	-0,0903	-0,50475
17,87	17,8642	0,0058	0,03246
17,94	17,8957	0,0443	0,24693




Figura 34 - Treinamento da RNA com 15 neurônios - Agrupamento #3

#### 5.1.3.4 Camada intermediária com 20 neurônios

O treinamento da RNA com 20 neurônios na camada intermediária pode ser observado na Figura 35. Para esta RNA, a parada do treinamento ocorreu em 11 épocas, quando foi alcançado o erro desejado.

A Tabela 20 apresenta os resultados obtidos através da generalização da rede por ocasião do treinamento realizado. O erro relativo médio percentual obtido nestes testes foi de 0,1878% e a taxa de acerto média foi de 99,4294%.

Tabela 20 - Valores de DP obtidos pela RNA 20 neurônios - Agrupamento #3

Medições de DP (pC)		Erro absoluto (pC)	Erro relativo (%)
Ensaio	RNA		
17,93	17,6878	0,2422	1,35081
17,90	18,0505	-0,1505	-0,84078
18,01	17,8798	0,1302	0,72293
17,95	17,9298	0,0202	0,11253
17,98	17,9590	0,0210	0,11680
18,18	17,8545	0,3255	1,79043
17,94	17,9355	0,0045	0,02508
17,89	18,0695	-0,1795	-1,00335
17,92	17,8836	-0,0364	-0,20313
17,89	17,9673	0,0773	0,43208
17,87	17,8674	-0,0026	-0,01455
17,94	17,8978	-0,0422	-0,23523

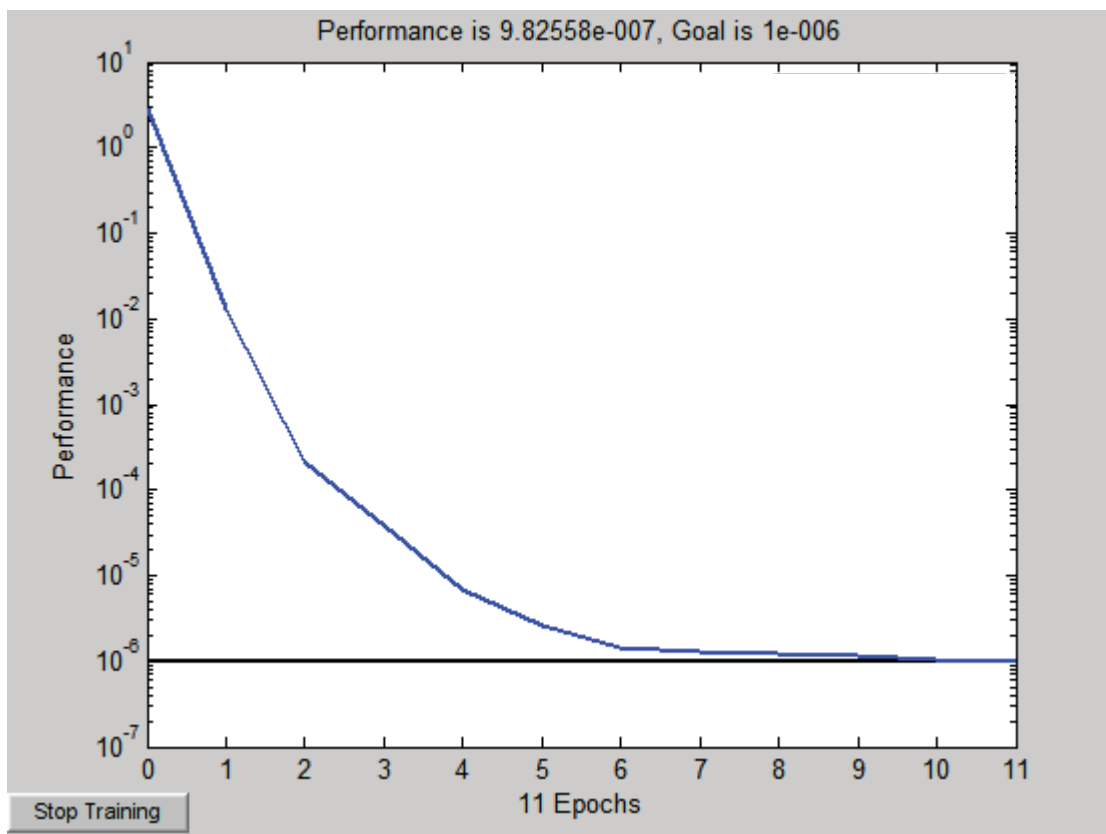


Figura 35 - Treinamento da RNA com 20 neurônios - Agrupamento #3

## 5.2 DISCUSSÃO DOS RESULTADOS

Para cada configuração de agrupamento de conjunto de dados relacionado com as quantidades de neurônios variável na camada intermediária, através dos valores individuais dos resultados apresentados, percebe-se que nenhuma das RNA's apresentou erro absoluto com variação superior a 1pC.

Este fato já garante a validação da metodologia, visto que se trata de um valor satisfatório de variação, considerando as incertezas de medição, bem como as dificuldades inerentes às medições de descargas parciais em transformadores.

No entanto, além deste quesito, foram analisados também os itens taxa de acerto média, quantidade de épocas para treinamento e erro relativo médio para detectar qual RNA apresentou o melhor desempenho para ser utilizada em aplicações no processo de fabricação das bobinas encapsuladas.




Figura 36 - Avaliação da taxa de acerto média para os 3 agrupamentos de conjuntos de dados e 4 valores de neurônios na camada escondida da rede

A Figura 36 apresenta a taxa de acerto média para todos os testes realizados em cada combinação de agrupamento de conjunto-neurônios.

Ao analisar a Figura 36, o agrupamento de conjunto #1 se destaca por apresentar a maior taxa de acerto média global, porém vale ressaltar que o número de amostras para testes nesta configuração foi de apenas de 9% do total de amostras.

Considerando assim, um compromisso entre o tamanho dos agrupamentos de conjuntos de treinamento e testes e a taxa de acerto média, percebe-se que o agrupamento de conjunto #2 obteve bons resultados em todas as configurações de neurônios.

Para este agrupamento de conjuntos #2, a rede com 10 neurônios na camada escondida teve uma taxa de acerto média de 99,6005% para os 13% de valores que compõem o agrupamento de conjunto de dados para teste.

Esta taxa de acerto média também foi a segunda maior taxa global entre todos os agrupamentos e quantidade de neurônios na camada oculta da rede.

A Figura 37 apresenta a quantidade de épocas de treinamento das redes utilizadas para cada combinação de agrupamento de conjunto-neurônios.

Através da Figura 37 percebe-se que o número de épocas que a rede de 10 neurônios no agrupamento de conjunto #2 utilizou para alcançar a generalização com a melhor taxa de acerto média é de apenas 327 épocas. Esta quantidade de épocas é relativamente baixa ao valor limite de 5000 e portanto pode ser considerado um valor satisfatório para tempo de treinamento.

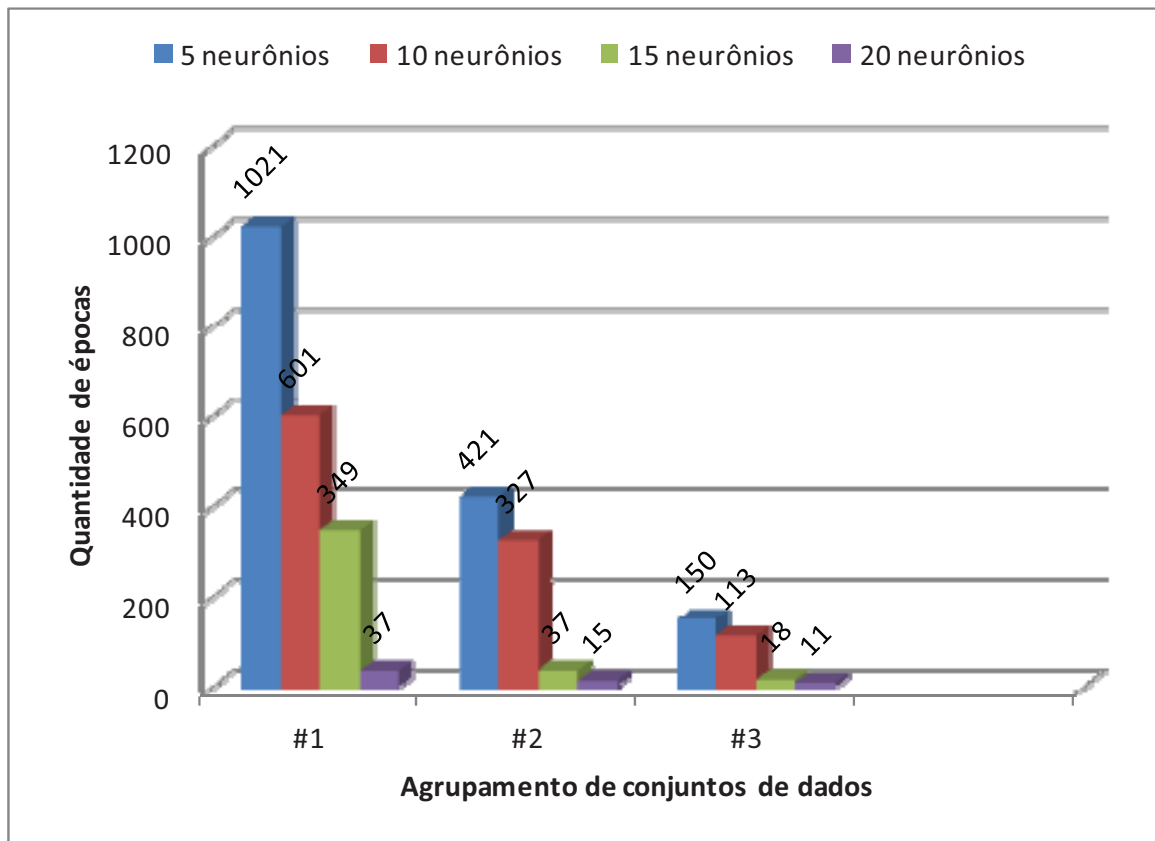


Figura 37 - Avaliação da quantidade de épocas para os 3 agrupamentos de conjuntos de dados e 4 valores de neurônios na camada escondida da rede

A Figura 38 apresenta o erro relativo médio para todos os testes realizados em cada combinação de agrupamento de conjunto-neurônios.

É possível verificar na Figura 38 que o agrupamento de conjunto #2 apresenta os menores erros relativos médios para todas as configurações de neurônios na camada intermediária sendo que o menor valor deste erro é 0,0666%.

O menor erro relativo global foi verificado no agrupamento de conjunto #2 com a configuração de 10 neurônios na camada oculta.

Desta forma, percebe-se que, para todos os quesitos analisados, a saber, taxa de acerto média, quantidade de épocas para treinamento e erro relativo médio, a RNA que apresentou o melhor desempenho é a rede com 10 neurônios para o agrupamento de conjuntos #2.

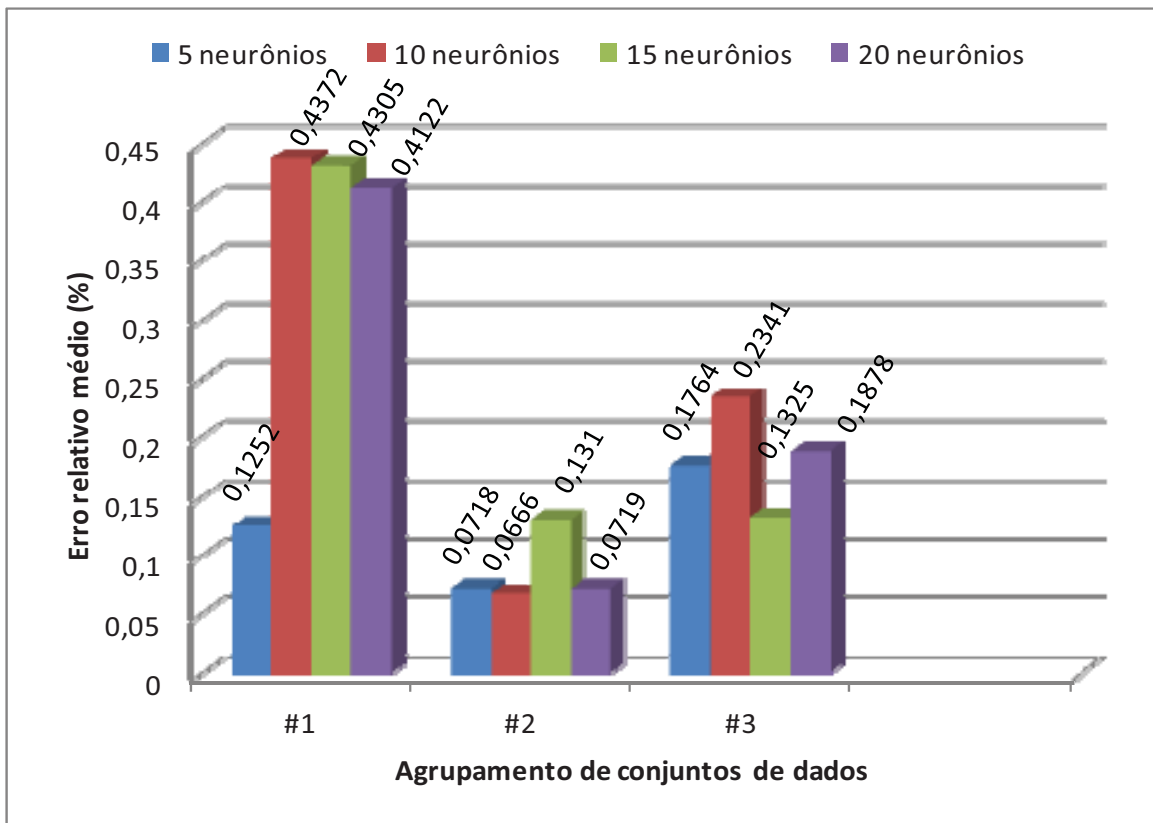


Figura 38 - Avaliação do erro relativo médio para os 3 agrupamentos de conjuntos de dados e 4 valores de neurônios na camada escondida da rede

Assim, esta é a RNA que, através de seus resultados, valida a metodologia proposta e deve ser utilizada para aplicação desta metodologia nos processos fabris de encapsulamento de bobinas de transformadores.

## 6 CONCLUSÃO

Esta pesquisa tem como contribuição principal a proposta e validação de um modelo baseado em redes neurais, de modo a para estabelecer uma relação entre as medições de descargas parciais através da metodologia por tensão aplicada com as medições de descargas parciais por tensão induzida, tornando-se uma ferramenta referencial para análise da qualidade do encapsulamento de bobinas de média tensão em plantas industriais de fabricação de transformadores secos com classe de tensão 15 e 24,2kV.

Percebe-se, através das redes neurais apresentadas, que há relação entre os resultados dos métodos de ensaios propostos nesta pesquisa e os ensaios determinados pelas normas de referência (NBR10295, 2011) e (IEC60076-11, 2004).

No entanto, somente através das RNA's foi possível encontrar um relacionamento entre tais resultados e medições, estabelecendo uma generalização que possibilita prever o comportamento das bobinas no resultado do ensaio do transformador.

Assim, foi implementado o sistema inteligente com RNA's, que possibilitou, através dos valores obtidos na medição de descargas parciais por tensão aplicada nas bobinas individualmente, prever o comportamento final destas bobinas no ensaio de descargas parciais por tensão induzida do transformador completamente montado e decidir pela aprovação ou rejeição desta bobina, no processo de fabricação.

Esta RNA atua como uma ferramenta de auxílio à inspeção de qualidade, permitindo que sejam colocadas no transformador somente as bobinas aprovadas. Esta medida evita a rejeição do transformador no ensaio de descargas

parciais por tensão induzida em consequência de falha no encapsulamento das bobinas.

Isto permite a redução de retrabalhos na linha de montagem e consequentemente, a diminuição dos custos de produção do transformador, bem como a avaliação da necessidade de implantação de melhorias e otimização no processo de encapsulamento.

Esta RNA também pode auxiliar no desenvolvimento de processos de encapsulamento para classes de tensões maiores, tais como 36,2kV, onde o processo de encapsulamento deve ser mais rigoroso e com menos possibilidade de falhas.

As propostas de continuidade desta pesquisa são:

- Ampliação do banco de dados de amostras para melhorar o comportamento da rede e aumentar a robustez da mesma;
- Implementação deste sistema em *hardware* para aplicação direta no ambiente de manufatura e também em laboratório de ensaios de transformadores secos;
- Simulação dos ensaios de medição de descargas parciais por tensão induzida para eliminar a necessidade de sua realização;
- Desenvolvimento de melhorias no processo de encapsulamento com base nesta pesquisa.

## REFERÊNCIAS BIBLIOGRÁFICAS

- Alexander, C. K. e Sadiku, M. N. *Fundamentos de circuitos elétricos*. Porto Alegre: Bookman, 2003
- Almeida, J. R. M. e Monteiro, S. N. Efeito da Variação da Razão Resina/Endurecedor sobre a Resistência ao Impacto de uma Resina Epóxi. *Polímeros: Ciência e Tecnologia*, 1996: pp. 44-49.
- Chang, H., Kuo, Y., Lee, C. e Lin, H. *A Partial Discharge Based Defect-Diagnosis System for Cast-Resin Current Transformers*. IN: 39th UPEC - Universities Power Engineering Conference, 2004: pp. 233-237.
- Dooley, P. K. A Comparison of Liquid-filled and Dry-Type Transformers for Industrial Applications. *IEEE Transactions on Industry Applications*, vol. 34, 1998: pp. 222-226.
- Feldman, D. e Barbalata, A. *Synthetic Polymers - Technology, Properties and Applications*. London: Chapman&Hall, 1996.
- Finocchio, M. A. F. *Determinação da Temperatura de Enrolamentos de Transformadores a Seco e de Suas Perdas Totais Baseado em Redes Neurais Artificiais*. UEL: Dissertação de Mestrado, 2010.
- Fitzgerald, A. E., Junior, C. K. e Umans, S. D. *Máquinas Elétricas*. Porto Alegre: Bookman, 2006.
- Geromel, L. H. e Souza, C. R. *The application of intelligent systems in power transformer design*. IN: Canada Conference Electrical and a Computer Engineering 1, 2002: pp. 285-290.
- Golubev, A. e Paoletti, G. *Partial Discharge Theory and Applications to Electrical Systems*. IN: IEEE IAS Pulp and Paper Industry Conference. Seattle: IEEE, 1999.

- Hagan, M. T. e Menhaj, M. B. Training feedforward networks with the Marquardt algorithm. *IEEE Transactions on Neural Networks*, vol. 5, nº 6, 1994: pp. 989-993.
- Haykin, S. *Redes Neurais Princípios e Prática*. Porto Alegre: Bookman, 2001.
- IEC60076-11. *Power transformers - Part 11: Dry-type transformers*. Switzerland: IEC, 2004.
- IEC60270. *High-voltage test techniques – Partial Discharge Measurements*. Switzerland: IEC, 2000.
- Kreuger, F. H. *Partial Discharge Detection in High-Voltage Equipament*. London: Butterworths, 1989.
- Maren, A. J., Jones, D. e Franklin, F. *Configuring and Optimizing the Back-Propagation Network*. Academic Press, Inc., 1999.
- Mason, H. M. Enhancing the significance of PD measurements. *IEEE TDEI* 2, 1995: pp. 876-888.
- MATLAB. *The MathWorks, Inc.* 1994. <http://www.mathworks.com> (Acesso em 19 de Janeiro de 2012).
- McCulloch, W. S. e Pitts, W. A logical calculus of the ideas immanent in nervous activity. *Bulletin of Mathematical Biophysics*, vol. 5, 1943: pp. 115-133.
- Mundlein, M., Hauser, H., Nicolis, J. e Chabicovsky, R. *Partial Discharge Current Measurement in High Permittivity Dielectrics and their Meaning for Quality Control*. IN: 26th International Spring Seminar on Electronics Technology. Stará Lesná, Slovak Republic, 2003: pp. 438-443.
- NBR/IEC60085. *Isolação elétrica — Avaliação térmica e designação*. Brasil: ABNT, 2012.
- NBR10295. *NBR 10295: Transformadores de Potência Secos*. Brasil: ABNT, 2011.

- NBR14039. *NBR14039: Instalações Elétricas de Média Tensão de 1,0 kV a 36,2 kV*.  
Brasil: ABNT, 2005.
- NBR5356. *NBR 5356: Transformadores de potência*. Brasil: ABNT, 2007.
- Nunn, T. A Comparison of Liquid-Filled and Dry-Type Transformer Technologies. IN:  
*IEEE-IAS Cement Industry Committee*, 2000: pp. 105-112.
- Rumelhart, D. E., Hinton, G. E. e Williams, R. J. *Learning internal representations by error propagation*. Parallel Distributed Processing, vol. 1, chapter 8,  
Cambridge, Massachusetts: MIT Press, 1986.
- Santos, E. N., Silva, M. J. e Arruda, L. V. R. *Reconhecimento de padrões e classificação de imagens de escoamentos bifásicos utilizando redes neurais*.  
IN: X SBAI - Simpósio Brasileiro de Automação Inteligente. Juiz de Fora,  
2011: pp. 427-431, volume X.
- Silva, G. C. *Descargas Parciais Estimuladas por Raio-X Contínuo e Pulsado em Materiais Dielétricos*. UFPR: Tese de Doutorado, 2005.
- Silva, I. N. *Avanços em tecnologias de sistemas inteligentes e aplicações*. IN:  
Tutoriais do XVIII Congresso Brasileiro de Automática. Bonito, MS: Cultura Acadêmica, 2010.
- Silva, I. N., Spatti, D. H. e Flauzino, R. A. *Redes Neurais Artificiais: para engenharia e ciências aplicadas*. São Paulo: Artliber, 2010.
- Stigant, A. S. e Franklin, J. S. C. *The J&P transformer book*. Oxford: Butterworth-Heinemann, 1983.
- Tardivo, M. A. *Uma Aplicação de Redes Neurais Artificiais para Estimação da Elevação de Temperatura de Transformadores Monofásicos de Distribuição Imersos em Líquido Isolante*. UEL: Dissertação de Mestrado, 2012.