



UNIVERSIDADE ESTADUAL PAULISTA
Faculdade de Engenharia
Campus de Bauru



Aplicação de Redes Neurais Artificiais para Melhorar a Avaliação de Perdas Elétricas em Transformadores na Fase de Manufatura

Cláudia Fiuza Lima Naves de Souza

Dissertação apresentada à Faculdade de Engenharia da UNESP - Campus de Bauru, para obtenção do título de Mestre em Engenharia Industrial.

BAURU
2003





UNIVERSIDADE ESTADUAL PAULISTA

FACULDADE DE ENGENHARIA
CAMPUS DE BAURU



**APLICAÇÃO DE REDES NEURAIS ARTIFICIAIS PARA
MELHORAR A AVALIAÇÃO DE PERDAS ELÉTRICAS EM
TRANSFORMADORES NA FASE DE MANUFATURA**

CLÁUDIA FIUZA LIMA NAVES DE SOUZA

**Dissertação apresentada à Faculdade
de Engenharia da UNESP - Campus
de Bauru, para obtenção do Título de
Mestre em Engenharia Industrial.**

**BAURU - SP
Fevereiro - 2003**



Cod. Lapes - 3.04.04.02-9 - Transmissão da
Energia elétrica, distribuição da
Energia elétrica
Transformadores de distribuição
Redes neurais artificiais
Perdas elétricas

Número de chamada
Clas. 7/UNESP
PHA 5714a
Tombo n.º 1095



UNIVERSIDADE ESTADUAL PAULISTA
FACULDADE DE ENGENHARIA
CAMPUS DE BAURU



**APLICAÇÃO DE REDES NEURAIS ARTIFICIAIS PARA
MELHORAR A AVALIAÇÃO DE PERDAS ELÉTRICAS EM
TRANSFORMADORES NA FASE DE MANUFATURA**

CLÁUDIA FIUZA LIMA NAVES DE SOUZA

Orientador: Prof. Dr. André Nunes de Souza

Co-orientador: Prof. Dr. Ivan Nunes da Silva



**Dissertação apresentada à Faculdade
de Engenharia da UNESP - Campus
de Bauru, para obtenção do Título de
Mestre em Engenharia Industrial.**

**BAURU - SP
Fevereiro - 2003**



Ficha catalográfica elaborada por
DIVISÃO TÉCNICA DE BIBLIOTECA E DOCUMENTAÇÃO
UNESP - Bauru

Souza, Cláudia Fiuza Lima Naves de
Aplicação de redes neurais artificiais para melhorar a
avaliação de perdas elétricas em transformadores na fase de
manufatura / Cláudia Lima Naves de Souza - - Bauru :
[s.n.], 2003.
121 f.

Dissertação (Mestrado) – Universidade Estadual
Paulista. Faculdade de Engenharia.

Orientador: Prof. Dr. André Nunes de Souza

1. Transformadores de distribuição. 2. Redes neurais
artificiais. 3. Perdas elétricas. I – Título. II – Universidade
Estadual Paulista. Faculdade de Engenharia.



PÓS-GRADUAÇÃO
ENGENHARIA INDUSTRIAL

ATA Nº 035/2003.

ATA DA DEFESA PÚBLICA DA DISSERTAÇÃO DE MESTRADO DE *CLÁUDIA FIUZA LIMA NAVES DE SOUZA*, ALUNA DO PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA INDUSTRIAL, DA FACULDADE DE ENGENHARIA DA UNESP – CAMPUS DE BAURU.

No dia vinte e sete de fevereiro de dois mil e três, às quatorze horas, no anfiteatro do prédio da Pós-graduação da Faculdade de Engenharia da UNESP, Campus de Bauru, reuniu-se a Comissão Examinadora da Defesa Pública, composta pelos Professores Doutores: André Nunes de Souza do Departamento de Engenharia Elétrica da Faculdade de Engenharia - UNESP – Campus de Bauru, Presidente da Banca, Geraldo Francisco Burani do Departamento de Engenharia de Energia e Automação Elétrica da Escola Politécnica – USP – São Paulo e Fernando Selles Ribeiro do Departamento de Engenharia de Energia e Automação Elétrica da Escola Politécnica – USP – São Paulo, a fim de proceder a arguição pública da Dissertação de Mestrado da candidata *Cláudia Fiuza Lima Naves de Souza*, intitulada “APLICAÇÃO DE REDES NEURAIS ARTIFICIAIS PARA MELHORAR A AVALIAÇÃO DE PERDAS ELÉTRICAS EM TRANSFORMADORES NA FASE DE MANUFATURA”. O Professor Doutor André Nunes de Souza, Presidente da Banca, apresentou a candidata, que dissertou sobre seu trabalho, em quarenta minutos, após, a candidata foi argüida oralmente pelos membros componentes da Comissão Examinadora no tempo regulamentar exigido. Logo após, reuniu-se a Comissão Examinadora, tendo apresentado o conceito final: **APROVADO**. Nada mais havendo, foi lavrada a presente ata, que após, lida e aprovada, será assinada pelos Senhores Membros da Comissão Examinadora. Bauru, vinte e sete de fevereiro de dois mil e três. / . / . / . / . / . /

Prof. Dr. André Nunes de Souza - Presidente

Prof. Dr. Geraldo Francisco Burani - Membro

Prof. Dr. Fernando Selles Ribeiro - Membro

unesp 

UNIVERSIDADE ESTADUAL PAULISTA
Faculdade de Engenharia - Bauru

Av. Engº Luiz Edmundo Carrijo Coube s/nº • Caixa Postal 473 • CEP 17 033-360 • Bauru • SP • Fone: 14 221 6000 e 14 221 6108 • Fax: 14 221 6104
E-mail: spg@feb.unesp.br • home page: www.feb.unesp.br/pos/fe.htm

unesp 

Amigos e Sabedoria

O isolamento é um método, e bom;
Mas o homem superior rejubila-se quando os
amigos aparecem,
Porque o homem se aperfeiçoa pela associação
com outros.
Quem deseja adquirir sabedoria deve polir-se
dessa maneira.
Mas se o homem isola-se de tudo e de todos,
Torna-se culpado de violar o grande caminho...
O Caminho dos Sábios não se mostra isento de
matérias prosaicas...

Muro Kyuso, filósofo japonês (1657)

À minha mãe Alba e ao meu marido Celso,
com carinho e estima, por suas presenças
amigas, solidariedade e companheirismo. E
ao meu pai, pela presença espiritual.

AGRADECIMENTOS

Este trabalho não poderia ser realizado sem a ajuda de diversas pessoas, às quais expresso o meu sincero agradecimento:

ao meu orientador Prof. Dr. André Nunes de Souza, pela atenção, incentivo e apoio;

à Engenheira Maria Goretti Zago, diretora da empresa Incotraz Indústria e Comércio de Transformadores Zago Ltda, pelo apoio técnico e sugestões;

aos colegas engenheiros Alessandro Goedel, Antônio Vanderlei Ortega e Rogério Andrade Flauzino, que ajudaram de forma direta e indireta na conclusão deste trabalho;

a todos os professores e colegas do departamento, pelas horas de amizade e companheirismo;

aos meus companheiros de viagem e de estudo.

ao CEFET-Pr/unidade de Cornélio Procopio, pela liberação parcial de meus horários.

à Profa. Marilú Martens de Oliveira, pela amizade.



SUMÁRIO

LISTA DE FIGURAS.....	09
LISTA DE TABELAS.....	11
Resumo.....	12
Abstract.....	13
 CAPÍTULO 1. Introdução.....	 14
1.1 Relevância e Motivação da Pesquisa.....	14
1.2 Proposta da Dissertação.....	15
1.3 Organização da Dissertação.....	17
 CAPÍTULO 2. Estado da Arte.....	 19
 CAPÍTULO 3. Características Construtivas, Funcionais e Operacionais dos Transformadores.....	 22
3.1 Topologia do Núcleo.....	22
3.1.1 Parte Ativa.....	22
3.1.2 Tipos dos Enrolamentos.....	26
3.2 Características Elétricas dos Transformadores.....	28
3.3 Ensaios em Transformadores.....	29
3.3.1 Ensaios de Rotina.....	29
3.3.2 Ensaios de Tipo.....	30
3.3.3 Ensaios Especiais.....	31
3.4 Perdas Elétricas em Transformadores.....	31
3.4.1 Perdas no Cobre.....	32
3.4.2 Perdas no Ferro do Núcleo Magnético (Perdas em Vazio).....	34

3.4.3 Perdas Totais.....	40
3.4.4 Rendimento.....	40
CAPÍTULO 4. Fundamentos de Redes Neurais.....	42
4.1 Introdução.....	42
4.2 O Neurônio Biológico.....	44
4.3 O Neurônio Artificial.....	46
4.4 Arquitetura de Redes Neurais Artificiais.....	49
4.4.1 Redes em camadas “feedforward”.....	49
4.4.2 Redes recorrentes “feedback”.....	51
4.5 Processo de Aprendizagem.....	52
4.6 Algoritmos de Treinamento da Rede Perceptron.....	53
4.6.1 Derivação do algoritmo “backpropagation”.....	54
4.6.2 Algoritmo de Levenberg – Marquardt.....	59
4.6.3. Algoritmo de Levenberg Marquardt com Regularização Bayesiana.....	63
CAPÍTULO 5. Desenvolvimento da Arquitetura Neural.....	66
5.1 Obtenção dos Dados de Treinamento.....	66
5.2 Geração dos Dados Para o Treinamento.....	67
5.2.1 Ensaio em Vazio.....	67
5.2.2 Ensaio de Curto Circuito.....	68
5.2.3 Ensaio de Resistência dos Enrolamentos.....	70
5.3 Descrição das Arquiteturas Neurais.....	71
5.3.1 Estimação das Perdas em Vazio.....	72
5.3.2 Estimação das Perdas no Cobre.....	74
5.3.3 Estimação das Perdas Totais.....	75
5.4 Quantificação das Perdas a Partir dos Ensaios Laboratoriais.....	77

CAPÍTULO 6. Resultados e Análises.....	82
6.1 Estimação das Perdas Elétricas.....	82
6.1.1 Estimação das Perdas em Vazio.....	83
6.1.2 Estimação das Perdas no Cobre.....	86
6.1.3 Identificação das Perdas Totais.....	93
 CAPÍTULO 7. Conclusões.....	 101
7.1. Futuras Linhas de Pesquisa.....	102
REFERÊNCIAS BIBLIOGRÁFICAS.....	103
APÊNDICE A.....	106
APÊNDICE B.....	119

LISTA DE FIGURAS

Figura 3.1 - Transformador trifásico do tipo de núcleo envolvente.....	23
Figura 3.2 - Transformador trifásico do tipo núcleo envolvido.....	24
Figura 3.3 (a) - Enrolamento de A.T. dividido em bobinas sobrepostas.....	27
Figura 3.3 (b) - Enrolamento de B. T. dividida em dois solenóides concên- trícos.....	27
Figura 3.4 - Enrolamento com bobinas alternadas.....	28
Figura 3.5 - Corte transversal de um núcleo.....	35
Figura 3.6 - Curva de magnetização $B = f(H)$	37
Figura 3.7 - Ciclo de histerese.....	38
Figura 4.1 - Estrutura do neurônio biológico.....	45
Figura 4.2 - Modelo do neurônio artificial.....	46
Figura 4.3 - Funções de ativação típicas.....	48
Figura 4.4 - A arquitetura feedforward.....	50
Figura 4.5 - Rede recorrente típica.....	51
Figura 4.6 - Diagrama esquemático da rede Perceptron.....	54
Figura 5.1 - Esquema do ensaio em vazio.....	68
Figura 5.2 - Esquema do ensaio em curto circuito.....	69
Figura 5.3 - Arquitetura da rede Perceptron para perda em vazio.....	73
Figura 5.4 - Arquitetura da rede Perceptron para perdas no cobre.....	74
Figura 5.5 - Arquitetura da rede Perceptron para perdas totais.....	76
Figura 5.6 - Generalização da rede para perdas em vazio.....	78
Figura 5.7 - Generalização da rede para perdas no cobre.....	79
Figura 5.8 - Generalização da rede para perdas totais.....	80
Figura 6.1 - Variação das perdas em vazio x resistência da bobina de alta tensão.....	84
Figura 6.2 - Variação das perdas em vazio x corrente de excitação.....	85



Figura 6.3 - Variação das perdas em vazio x generalização da rede.....	86
Figura 6.4 - Variação das perdas no cobre x tensão de curto circuito.....	88
Figura 6.5 - Variação das perdas no cobre x média das 3 resistências das bobinas de alta tensão.....	89
Figura 6.6 - Variação das perdas no cobre x média das 3 resistências das bobinas de baixa tensão.....	90
Figura 6.7 - Variação das perdas no cobre x corrente de excitação.....	91
Figura 6.8 - Variação da perda no cobre x temperatura.....	92
Figura 6.9 - Variação da perda no cobre x generalização da rede.....	93
Figura 6.10 - Variação das perdas totais x média das 3 resistências das bobinas de baixa tensão.....	95
Figura 6.11 - Variação das perdas totais x média das 3 resistências das bobinas de alta tensão.....	96
Figura 6.12 - Variação das perdas totais x corrente de excitação.....	97
Figura 6.13 - Variação das perdas totais x temperatura.....	98
Figura 6.14 - Variação da perdas totais x generalização da rede.....	99



LISTA DE TABELAS

Tabela 3.1 – Padrões de aços de silício.....	25
Tabela 5.1 - Valores Normalizados pela Norma NBR-5440.....	69
Tabela 5.2 -Temperatura de Referência.....	70
Tabela 5.3 - Valores mínimos e máximos dos dados de treinamento.....	77
Tabela 6.1 - Faixa de valores de teste utilizados na rede neural.....	83
Tabela 6.2 - Faixa de valores de teste utilizados na rede neural.....	87
Tabela 6.3 - Faixa de valores de teste utilizados na rede neural.....	94
Tabela 6.4 - Valores mínimos e máximos dos dados de teste.....	99



SOUZA, C. F. L. N.; *Aplicação de Redes Neurais Artificiais para Melhorar a Avaliação de Perdas Elétricas em Transformadores na Fase de Manufatura*. Bauru, 2002. 121 p. Dissertação (Mestrado em Engenharia Industrial) – Faculdade de Engenharia, Campus de Bauru. Universidade Estadual Paulista “Júlio de Mesquita Filho”.

RESUMO

Neste trabalho, apresenta-se o desenvolvimento de uma metodologia utilizando redes neurais artificiais, para melhorar a avaliação e quantificação de perdas elétricas em transformadores de distribuição. A rede neural atuou como um identificador de características estruturais que influenciam de maneira direta no processo de perdas elétricas. Desta forma, os parâmetros relacionados às perdas puderam ser estimados e generalizados. O modelo foi treinado e validado por dados experimentais. Os resultados das simulações mostraram que a técnica desenvolvida pode ser usada como uma ferramenta de apoio à decisão, a qual propiciará uma avaliação mais qualitativa dos processos de perdas elétricas em transformadores de distribuição.

Palavras-Chave: Transformadores de Distribuição; Redes Neurais Artificiais; Perdas Elétricas.



SOUZA, C. F. L. N.; *Application of Artificial Neural Network to Improve the Assessment Electrical Losses in Transformers During the Manufacturing Process*. Bauru, 2002. 121 p. Master Degree Dissertation – Faculty of Engineering. State University of São Paulo, UNESP “Júlio de Mesquita Filho” .

ABSTRACT

In this work is presented the development of a novel methodology using artificial neural networks to improve the assessment and quantification of electrical losses regarding distribution transformers. The neural network acted as a structural characteristic identifier that directly influences on the processes of electrical losses. On this way, the standards related to losses could be estimated and generalized. That neural network was trained and validated using experimental data. The results of the simulations have showed that the developed technique can be used as a tool to support for decision making which will allow a better qualitative assessment on electrical losses regarding distribution transformers.

Keywords: Transformers; Artificial Neural Network; Electrical Losses.



CAPÍTULO 1

INTRODUÇÃO

1.1 Relevância e Motivação da Pesquisa

No Brasil, com o surgimento da crise energética provocada por problemas técnicos e ambientais aliados à globalização da economia, diversos programas têm sido elaborados com a missão prioritária de estabelecer índices de desempenho mais adequados, que conduzam a um melhor relacionamento entre a concessionária de energia elétrica e seus clientes.

A taxa de perdas elétricas em transformadores, nos sistemas de distribuição de energia elétrica brasileiro, tem alcançado níveis muito elevados quando comparados com os padrões internacionais. Existem diversos fatores que

contribuem para este cenário, como por exemplo: a dificuldade na avaliação de perdas elétricas na fase de manufatura, a falta de precisão no modelamento da carga, a atualização desses valores de perdas, prescritos em normas técnicas considerando-se o atual perfil do setor elétrico, a inexistência de uma política de manutenção eficaz, o aumento de áreas metropolitanas e a redução da capacidade financeira do setor (McConnell, 1998).

O transformador assume um papel fundamental em um sistema elétrico, não somente pelo volume de investimentos que exige, como também pela sua elevada responsabilidade na qualidade do serviço prestado ao consumidor. Assim, a identificação precisa das perdas de energia, torna-se imprescindível ao sistema elétrico como um todo.

Considerando-se este aspecto, as Redes Neurais Artificiais (RNA) estão sendo utilizadas para quantificar e estimar as perdas elétricas nos transformadores de distribuição. Tal abordagem tem sido realizada em função da habilidade das RNA em mapear relacionamentos complexos e não lineares em diversos processos de difícil modelagem matemática.

Neste sentido, quantificar as perdas de energia na fase de fabricação dos transformadores possibilitará uma adequação dos projetos, bem como da qualidade do produto, levando-se também em conta uma diminuição dos custos de fabricação dos mesmos. Soma-se também o fato de que a otimização de alguns ensaios poderá aumentar a produtividade da empresa.

Portanto, o presente trabalho terá como motivação principal a quantificação de perdas no processo de fabricação dos transformadores, utilizando-se Redes Neurais.

1.2 Proposta da Dissertação

A proposta desta pesquisa será possibilitar de uma maneira integrada uma melhora na avaliação das perdas totais em transformadores de distribuição, verificando-se a possibilidade de diminuir essas perdas na fase de



construção dos transformadores. Este tipo de abordagem promoverá o desenvolvimento de novas ferramentas computacionais para melhorar a avaliação dos processos relacionados às perdas nos transformadores de distribuição.

A estimativa das perdas de energia nos transformadores de distribuição será realizada através de um modelo neural desenvolvido especificamente para este tipo de problema. A partir de dados advindos dos ensaios laboratoriais, a rede neural será capaz de determinar as características estruturais presentes no processo, as quais seriam muito difíceis de serem identificadas ou calculadas por intermédio de ferramentas matemáticas convencionais ou através de ensaios experimentais. Após o treinamento da rede, será estabelecido o relacionamento entre as diversas variáveis envolvidas no processo.

A abordagem proposta neste trabalho utilizará redes neurais do tipo Perceptron com várias camadas. Após o treinamento da rede, a mesma é capaz de generalizar processos relacionados às perdas elétricas em transformadores. As principais vantagens em utilizar esta metodologia são:

- i) desenvolvimento de um sistema de apoio à tomada de decisão para estimar as perdas elétricas em transformadores de distribuição;
- ii) facilidade de integração com outras metodologias;
- iii) possibilidade de diminuição de ensaios de rotina e conseqüentemente; diminuição no custo do produto;
- iv) possibilidade de aumento da produtividade da empresa.

Essas vantagens justificam a utilização de redes neurais na avaliação das perdas em transformadores de distribuição, de maneira que as diversas variáveis que influenciam nos processos possam ser avaliadas de forma integrada, pois a maioria dos estudos referentes à redução das perdas de energia considera os fenômenos magnéticos e térmicos de maneira distinta, ou seja, no núcleo ou no cobre.



1.3 Organização da Dissertação

Esta dissertação estará dividida em 7 capítulos, distribuídos da seguinte maneira:

Capítulo 1

- Introdução.

Capítulo 2

- Apresentar-se-á o estado da arte: principais trabalhos envolvendo processos de perdas elétricas em transformadores.

Capítulo 3

- Os aspectos construtivos e de operação dos transformadores serão detalhados.

Capítulo 4

- Os fundamentos básicos de redes neurais artificiais serão descritos.

Capítulo 5

- Executar-se-á o desenvolvimento da arquitetura neural, incluindo-se todos os dados do treinamento.

Capítulo 6

- Serão vistos os resultados das simulações e discussões sobre a abordagem neural.

Capítulo 7

- Dele constarão as conclusões gerais e as futuras linhas de pesquisa.

Os estudos relacionados a esta dissertação já foram apresentados ou estão em processo de julgamento para publicações em fóruns nacionais e internacionais. Algumas dessas publicações são listadas a seguir:

1. SOUZA, C. F. L. N.; SOUZA, A. N.; GOEDTL, A.; ZAGO, M. G. Applied artificial neural networks in the identification of electric losses during the process of production of the transformers. IEEE Induscon, Salvador – BA, Julho 2002, CD.
2. SOUZA, C. F. L. N.; SOUZA, A. N.; GOEDTL, A.; ZAGO, M. G. Redes neurais artificiais aplicadas na identificação de perdas elétricas em transformadores visando uma adequação no fornecimento de energia elétrica. SAE BRASIL, São Paulo, Novembro 2002.CD.
3. SOUZA, André Nunes de; SILVA, Ivan Nunes da; SOUZA, Cláudia Fiuza Lima Naves de. Using Artificial Neural Networks for Identification of Electrical Losses in Transformers During the Manufacturing Phase. In IEEE international Joint Conference on Neural Networks, Honolulu. Proceedings of the IEEE IJCNN, 2002. p. 1346-1350.
4. SOUZA, André Nunes de, SILVA, Ivan Nunes da; ULSON, José Alfredo C., SOUZA, Cláudia Fiuza Lima Naves de. Application of Artificial Neural Networks in Evaluation and Identification of Electrical Loss in Transformers According to the Energy Consumption. In: PRESS, Wses. (Org.). Recent Advances in Simulation, Computational Methods and Soft Computing. USA, 2002, v. 1, p. 168-172.

Um outro tipo de contribuição, também muito importante, é que parte deste trabalho estará sendo utilizado no desenvolvimento de novas pesquisas, conforme as publicações citadas anteriormente.



CAPÍTULO 2

ESTADO DA ARTE

No Brasil, técnicas usadas para determinar as perdas elétricas nos transformadores estão contempladas nas normas da Associação Brasileira de Normas Técnicas (ABNT).

Atualmente existem diversos estudos envolvendo a redução de perdas elétricas em transformadores, entretanto, na maioria desses estudos, a tônica observada refere-se à redução de perdas elétricas de maneira separada, ou seja, no núcleo ou no cobre e nunca de forma integrada.

Outro tipo de estudo proposto para diminuir as perdas elétricas é a verificação do comportamento da capacidade de transformadores para altas temperaturas, com o emprego de novos materiais, os quais diminuem os efeitos das perdas. Nestes estudos são analisadas as vantagens de um transformador com bobinas de HTS (High Temperature Superconductors – HTS), sendo ainda discutidas as equações fundamentais para o projeto de transformadores. As perdas são calculadas para categorias de diferentes potências de transformadores (50, 150, 30 MVA), considerando a tensão e o preço para a construção das bobinas

com HTS. As regras de produção resultantes são discutidas e analisadas sistematicamente (Sissimatos, 2001).

Em diversos fóruns de debate é abordada a utilização do Método de Elementos Finitos para calcular as perdas elétricas no núcleo do transformador, com um enfoque direcionado principalmente ao processo magnético (histerese). Neste tipo de pesquisa, é feita uma formulação matemática bem detalhada, pautada em analisar o comportamento do campo magnético durante o processo de manufatura dos transformadores, permitindo a realização do mapeamento dos vetores magnéticos para diferentes projetos de núcleos magnéticos (Enokizono, 1999).

Existem, também, diversas constatações através de estudos teóricos e experimentais de que as perdas por histerese em um material magnético, sujeito à aplicação de um campo girante, diminuem consideravelmente com a amplitude do campo de magnetização conduzindo a uma saturação. Neste tipo de abordagem, o núcleo magnético é representado com precisão, e suas propriedades são simuladas usando um modelo de vetor de Preisach. Os resultados obtidos são usados como guia para determinar suas condições ótimas de operação (Adly, 1995).

De uma maneira também muito intensa, estão as pesquisas relacionadas às perdas elétricas através do cálculo matemático das perdas em vazio e em materiais ferromagnéticos, baseado na equação modificada de Steinmetz. São discutidas as influências das formas de onda de fluxo não senoidal nas perdas de remagnetização do ferro e materiais ferromagnéticos de indutores, transformadores e máquinas elétricas (Reinert, 2001).

A inserção de sistemas inteligentes em estudos de desempenho de transformador de potência tem sido uma constante. O projeto de transformadores de potência torna-se uma tarefa demorada devido ao número grande de variáveis a ser considerado e as múltiplas inter-relações, que não são completamente conhecidas. Esta nova metodologia é uma importante e moderna ferramenta



computacional, não somente por aperfeiçoar os projetos, mas também por minimizar substancialmente o tempo necessário para a sua execução, simplificando, assim, o procedimento de projeto. Um banco de dados, que contém vários resultados de teste atuais de um transformador de potência, é usado para a validação do método (Geromel, 2001).

Resultados de pesquisas têm sido publicados e analisados em diversos comitês científicos, discutindo os principais fundamentos e modelos que descrevem o comportamento das perdas elétricas em transformadores. Destacam-se a predição e a classificação de perdas específicas no ferro, através de redes neurais artificiais (RNA), que consideram as perdas por unidade de peso. Neste estudo, a RNA é treinada com dados para aprender a relacionar os vários parâmetros que afetam as perdas no ferro. Esses dados incluem características elétricas do aço, parâmetros do núcleo, controle da qualidade de construção das medidas do núcleo na linha de produção e a reunião de várias medidas de transformadores. Os resultados apontam para um erro absoluto comum de 2,32% na predição das perdas no ferro e um erro de 2,2% para as perdas específicas no transformador (Georgilakis, 1998).

Diante deste cenário, fica evidente que embora algumas literaturas internacionais apresentem soluções tradicionais, há avanços científicos e tecnológicos que não constituem tarefas triviais. Então, quando se trata a precisão da identificação e estimação de perdas elétricas como uma possibilidade de melhorar projetos de transformadores, justifica-se todo o empenho dedicado a esse tema.



CAPÍTULO 3

CARACTERÍSTICAS CONSTRUTIVAS, FUNCIONAIS E OPERACIONAIS DOS TRANSFORMADORES

3.1 Topologia do Núcleo

3.1.1 Parte Ativa

Denomina-se de parte ativa do transformador ao conjunto formado pelos enrolamentos, primário e secundário, e núcleo. A parte ativa deve constituir um conjunto mecanicamente rígido, capaz de suportar condições adversas de funcionamento.

Os transformadores são projetados para funcionar em frequências baixas (transformadores de força) e têm suas bobinas conhecidas como enrolamentos, as quais são enroladas em núcleos de ferro. Como esse oferece pouca resistência às linhas magnéticas, quase todo o campo magnético do primário se estabelece no núcleo de ferro.

O núcleo é formado de chapas de aço-silício, laminadas a frio e cobertas por uma película isolante. A laminação a frio, seguida de tratamento térmico, orienta os domínios magnéticos no sentido de laminação, permitindo, assim, que sejam alcançadas altas densidades de fluxo magnético com perdas reduzidas. Essas chapas são sustentadas por uma estrutura constituída por tirantes e por faixas de fibra de vidro impregnadas com resina.

Existem, na prática, dois tipos de circuitos magnéticos para transformadores, isto é, os de núcleo envolvente e os de núcleo envolvido. O núcleo envolvente possui a forma indicada na Figura 3.1 para um transformador trifásico.




Figura 3.1 - Transformador trifásico do tipo de núcleo envolvente.

O núcleo envolvido pode ser observado na Figura 3.2 para um transformador trifásico.

Neste tipo de núcleo, os enrolamentos colocados sobre as colunas envolvem o respectivo circuito magnético sem serem envolvidos por este.




Figura 3.2 – Transformador trifásico do tipo núcleo envolvido

As chapas utilizadas para construção do núcleo são constituídas de uma liga de ferro e carbono contendo o silício como principal elemento de liga. Os aços de silício da empresa Acesita S.A contêm teores desse elemento que variam entre 1,8 % e 3,5 %. É importante lembrar que a presença de silício aumenta a resistividade elétrica do aço e diminui as perdas magnéticas, porém aumenta sua dureza, tornando-o mais quebradiço.

Existem dois tipos de aços elétricos: os semiprocessados e os totalmente processados. Os primeiros são produzidos sem tratamento térmico para desenvolvimento das propriedades magnéticas finais. Essas propriedades são obtidas após um tratamento térmico a ser realizado pelo usuário final. Nos aços elétricos totalmente processados, as propriedades magnéticas são inteiramente desenvolvidas pela usina siderúrgica. Esses aços apresentam algum tipo de revestimento isolante, sendo fornecidos prontos para serem utilizados pelos usuários, sem a necessidade da realização de qualquer tratamento térmico adicional.

As chapas de aços de silício podem ser formadas de grão orientado (GO) ou de grão não orientado (GNO). A principal diferença entre os aços GO e GNO está na estrutura cristalográfica de ambos. O aço silício GO apresenta uma textura pronunciada, chamada textura de Goss, cujos cristais apresentam a direção

de mais fácil magnetização. Essa característica confere-lhe excelentes propriedades magnéticas na direção de laminação da chapa e torna-o adequado para uso em núcleos estáticos, onde o fluxo magnético coincide com a direção de laminação, como no caso dos transformadores.

Os aços de silício GO e GNO devem ser especificados pela sua principal característica, que é a perda magnética, expressa em Watts por quilograma (W/kg), medida a uma determinada frequência e densidade de fluxo. Ao escolher o aço silício, o usuário deve especificar a perda magnética máxima, a indução magnética (B) e a frequência (f).

A Tabela 3.1 apresenta as condições de testes padronizadas para os aços de silício:

Tabela 3.1 – Padrões de aços de silício

	GNO	GO
Indução magnética (B)	1,0 ou 1,5 Tesla	1,5 ou 1,7 Tesla
Frequência (f)	50 ou 60 Hz	50 ou 60 Hz

Os enrolamentos primários e secundários de transformadores de distribuição são constituídos de fios de cobre, isolados com esmalte ou papel, de seção retangular ou circular. Geralmente, para os transformadores de distribuição os condutores (fios) dos enrolamentos primários são de cobre redondo e esmaltado, e os dos enrolamentos secundários são de seção retangular.

Depois da confecção dos enrolamentos concluída, inicia-se a montagem destes enrolamentos sobre o núcleo de ferro, completando-se com a ligação dos comutadores. Após esta montagem, o núcleo recebe um jato de ar quente e posteriormente segue para a estufa, onde se processará a secagem da parte ativa com o objetivo de retirar toda a água contida na isolação.

3.1.2 Tipos dos Enrolamentos

Em geral, qualquer que seja o tipo de construção do transformador, os dois enrolamentos de alta tensão (A.T.) e baixa tensão (B.T.) da mesma fase são colocados sobre a mesma coluna.

Nos transformadores monofásicos é possível dispor o enrolamento de A.T. sobre uma coluna e o enrolamento B.T. sobre outra. Este critério, porém, não é aplicado pelo fato de dar origem a dispersões magnéticas notáveis, pois uma grande parte do fluxo gerado pelo enrolamento primário se fecha no ar sem concatenar-se com o secundário.

Nos transformadores industriais existem várias maneiras de se disporem as bobinas, a fim de se diminuir a dispersão magnética. Conforme a posição relativa em que são dispostas as bobinas A.T e B.T., obtêm-se os dois tipos de enrolamentos que são de bobinas concêntricas ou tubulares e de bobinas alternadas ou de discos (Martignoni, 1991).

a) Enrolamentos Concêntricos ou Tubulares

Esta construção realiza-se dispondo sobre cada coluna os dois enrolamentos de alta e baixa tensão, concêntricos e separados entre si por meio de material isolante. Para maior segurança, perto da coluna coloca-se sempre o enrolamento B.T. separado da mesma por meio de um tubo de material isolante.

As Figuras 3.3(a) e 3.3(b) adaptadas de (Martignoni, 1991) ilustram com detalhe este tipo de enrolamento.






Figura 3.3 (a) - Enrolamento de A.T. dividido em bobinas sobrepostas




Figura 3.3 (b) - Enrolamento de B. T dividida em dois solenóides concêntricos

Os enrolamentos de A.T. são divididos em várias bobinas sobrepostas e devidamente distanciados, enquanto que o enrolamento de B.T. é constituído em forma de solenóide contínuo.

b) Enrolamento com bobinas alternadas ou discos

Esta construção é realizada executando-se ambos os enrolamentos de A.T. e de B.T. com várias bobinas de comprimento axial pequeno (discos) e sobrepondo-se as bobinas A.T. e B.T. alternadamente.

A Figura 3.4 adaptada de (Martignoni, 1991) apresenta o enrolamento de discos.




Figura 3.4 - Enrolamento com bobinas alternadas

3.2 Características Elétricas dos Transformadores

Os transformadores possuem características elétricas que devem ser cuidadosamente consideradas na etapa do projeto. São elas:

- a) potência nominal;
- b) tensões primárias e derivações;
- c) tensão secundária;
- d) frequência nominal;
- e) normas aplicáveis;
- f) acessórios;
- g) valores de impedância, corrente de excitação e perdas.

De posse desses dados é possível processarem os seguintes cálculos:

- a) correntes primárias e secundárias;

- b) seção dos condutores;
- c) seção geométrica do núcleo;
- d) seção magnética do núcleo;
- e) escolha do núcleo;
- f) cálculo do número de espiras;
- g) seção do cobre enrolado;
- h) peso do ferro e do cobre.

3.3 Ensaios em Transformadores

Para verificar se realmente o transformador funciona adequadamente, são realizados ensaios pelos fabricantes, conforme prescrições contidas no documento de aquisição do comprador, sendo que esses ensaios devem ser executados de acordo com a Norma NBR 5380/1993, que prescreve os métodos a serem seguidos para ensaios em transformadores.

3.3.1 Ensaios de Rotina

Esses ensaios são realizados pelo fabricante em sua fábrica, executados em todas as unidades de produção. Os ensaios desta categoria são:

- a) resistência elétrica dos enrolamentos;
- b) relação de tensões;
- c) resistência do isolamento;
- d) polaridade;
- e) deslocamento angular e sequência de fases;
- f) perdas (em vazio e em carga);
- g) corrente de excitação;



h) ensaios dielétricos:

- Tensão suportável à frequência industrial, aplicada a fiação e acessórios;
- Tensão suportável nominal à frequência industrial (tensão aplicada);
- Tensão induzida, para transformadores com tensão máxima do equipamento $< 242 \text{ kV}$;
- Tensão suportável nominal de impulso de manobra, para transformadores com tensão máxima do equipamento $\geq 362 \text{ kV}$;
- Tensão suportável nominal de impulso atmosférico, para transformadores com tensão máxima do equipamento $\geq 362 \text{ kV}$;
- Tensão induzida de longa duração, com medição de descargas parciais, para transformadores com tensão máxima do equipamento $\geq 362 \text{ kV}$;

i) tensão de curto-circuito;

j) estanqueidade e resistência à pressão, à quente, em transformadores subterrâneos de qualquer potência nominal, e à temperatura ambiente nos demais transformadores com potência nominal $\geq 750 \text{ kVA}$.

l) verificação do funcionamento dos acessórios;

3.3.2 Ensaios de Tipo

O comprador deve especificar, na ordem de compra, os ensaios desejados e o número de unidades da encomenda sobre as quais devem ser executados. No caso de existirem resultados de ensaios anteriores executados sobre transformadores do mesmo projeto, o comprador pode dispensar a execução desses ensaios.

Os principais ensaios de tipo são:

a) elevação de temperatura;



- b) tensão suportável nominal de impulso atmosférico, para transformadores com tensão máxima do equipamento ≤ 242 kV;
- c) nível de ruído;
- d) ensaios no óleo isolante, após contato com equipamento, em transformadores com o equipamento, em transformadores com $U_m \leq 36,2$ kV;
- e) medição da potência absorvida pelos motores de bombas de óleo e ventiladores;

3.3.3 Ensaios Especiais

Os ensaios especiais são os seguintes:

- a) ensaio de curto circuito;
- b) medição da impedância de seqüências zero em transformadores trifásicos;
- c) medição dos harmônicos na corrente de excitação;
- d) vácuo interno;
- e) análise cromatográfica dos gases dissolvidos no óleo isolante
- f) nível de tensão de radiointerferência;
- h) ensaios para verificação do esquema de pintura das partes interna e externa do transformador, conforme a NBR 11388.

3.4 Perdas Elétricas em Transformadores

Nesta seção serão abordados todos os aspectos relacionados às perdas elétricas em transformadores. A descrição destas perdas é importante para o entendimento da arquitetura neural, que será apresentada no próximo capítulo.

As perdas elétricas em um transformador representam toda a potência absorvida e dissipada nos enrolamentos primário e secundário, e também pelo núcleo de ferro. As perdas de um transformador podem ser analisadas sob duas diferentes formas de operação, são denominadas de Perdas em Vazio e de Perdas no Cobre.

As expressões utilizadas no subitem 3.4.1 foram de (Martignoni, 1991).

3.4.1 Perdas no Cobre

São as perdas elétricas que ocorrem no material dos enrolamentos e que podem ocorrer devido à:

a) Resistência Ôhmica dos Enrolamentos:

Essas perdas surgem pela passagem de uma corrente (I) por um condutor de determinada resistência (R), e que pode ser calculada com o auxílio da expressão (3.1):

$$R_t = \frac{\rho_t \cdot l}{S} \quad (3.1)$$

Onde:

R_t é a resistência elétrica do fio numa determinada temperatura (Ω);

ρ_t é a resistividade do material utilizado para construir o enrolamento na mesma temperatura “t” em que se deseja determinar a resistência ($\Omega \cdot m$);

l é o comprimento do fio (m); e

S é a área da seção transversal do fio (m^2).

Como pode-se verificar, os valores de resistência utilizados nas equações acima são dependentes da temperatura. A resistência de todo condutor aumenta com a elevação deste parâmetro, conforme indicado na expressão (3.2):



$$R_t = R_0(1 + \alpha_0.t) \quad (3.2)$$

Onde:

R_t é a resistência a “t” graus Celsius;

R_0 é a resistência a 0 °C; e

α_0 é o coeficiente de temperatura da resistência a 0°C.

As perdas Ôhmicas podem ser representadas pela expressão (3.3):

$$P_{\text{cobre}} = R_{\text{cobre}} \cdot I_{\text{ef}}^2 \quad (3.3)$$

Essa expressão representa a perda no cobre crescendo quadraticamente quando a corrente no enrolamento aumenta.

Nos transformadores trifásicos com carga equilibrada, geralmente, indica-se com R_1 e R_2 as resistências de cada fase primária e secundária e com I_1 e I_2 as respectivas correntes. As perdas no cobre são dadas pela expressão:

$$P_{\text{cobre}} = 3.(R_1.I_1^2 + R_2.I_2^2) = 3.R_e.I_2^2 \quad (3.4)$$

O equacionamento das perdas no cobre fica simplificado quando se levam em conta o peso do cobre e a perda específica, isto é, a perda em Watt por cada Kg de material (Martignoni, 1991).

As perdas por efeito Joule, em um condutor de comprimento l_m e seção transversal S , são expressas por:

$$P_{\text{cobre}} = I^2 \cdot R = I^2 \cdot \rho \frac{l_m}{S} \quad (3.5)$$

O peso de um condutor é dado:

$$W_{\text{cu}} = 8,9.l_m.S.10^{-3} \quad (3.6)$$

onde 8,9 representa o peso específico do cobre. A perda específica no cobre resulta, então:

$$P_{cu} = \frac{P_{cu}}{W_{cu}} = \frac{I^2}{S^2} \cdot \rho \cdot \frac{10^3}{8,9} \quad (3.7)$$

Re-arranjando a equação acima e multiplicando pelo peso do cobre, encontra-se a perda total no cobre de um enrolamento:

$$P_{cu} = 2,43 \cdot J^2 \cdot W_{cu} \quad (3.8)$$

sendo J a densidade de corrente no condutor (em A/m^2) e substituindo-se o valor de ρ para cobre recozido a $75^\circ C$ ($0,0216 \Omega \cdot mm^2/m$).

b) Correntes Parasitas no Condutor dos Enrolamentos

São as perdas produzidas pelas correntes parasitas induzidas nos condutores das bobinas pelo fluxo de dispersão. Essas perdas dependem da corrente, do carregamento e da geometria dos condutores das bobinas.

3.4.2 Perdas no Ferro do Núcleo Magnético (Perdas em Vazio)

Os transformadores são desenvolvidos a partir de um núcleo magnético formado por chapas de aço-silício, onde são produzidas as perdas no ferro. Essas perdas ocorrem devido às correntes parasitas e à histerese magnética. A seguir, descrição dessas perdas:

a) Perdas por Correntes Parasitas ou de Foucault

As referidas perdas são correntes que se induzem na massa condutora do núcleo, em virtude da variação do fluxo magnético dentro do mesmo.

Para reduzir-se as perdas por correntes Parasitas ou de Foucault, o núcleo deve ser constituído de lâminas, ou finas chapas com uma finíssima

camada de isolante entre as mesmas. As lâminas são orientadas paralelamente à direção do fluxo, conforme comentado anteriormente na subseção 3.1.1.

A Figura 3.5 adaptada de (Falcone, 1992) apresenta um esquema detalhado de um corte transversal de um núcleo laminado, submetido a um campo magnético na direção da laminação.




Figura 3.5 - Corte transversal de um núcleo

Nos casos de excitação senoidal permanente, a densidade do fluxo no núcleo é dada por:

$$B(t) = B_{\max} \sin(\omega t) \quad (3.9)$$

O valor médio da potência dissipada por correntes parasitas em um núcleo laminado submetido a uma magnetização na direção da laminação, é dado por:

$$P_f = K_f \forall (f \cdot B_{\max} e)^2 \quad (3.10)$$

onde:

P_f são as perdas por correntes de Foucault (W);

K_f : é a constante que depende do material do núcleo;

$\forall$: é o volume ativo do núcleo (m^3);

f é a frequência das variações da indução (Hz);

e é a espessura das chapas do núcleo (m); e

$B_{m\acute{a}x}$ é a indução magnética máxima (T).

O volume ativo é dado por:

$$\forall = K_e \forall_G \quad (3.11)$$

Onde:

K_e : é o fator de empilhamento:

$\forall_G$: volume geométrico do núcleo:

Para a Figura 3.5 $\forall_G$ é:

$$\forall_G = a.b.h \quad (3.12)$$

O fator K_e de empilhamento, nos casos de chapas de 0,35 a 0,5 mm, é da ordem de 0,92 a 0,95.

b) Perdas por Histerese

Os materiais ferromagnéticos são passíveis de magnetização através do realinhamento dos domínios, o que ocorre ao se aplicar um campo (como o gerado por um indutor ou o primário do transformador). Esse processo consome energia por meio de aquecimento, devido ao fato do material tentar acompanhar o campo variável. Ao se interromper o campo, geralmente, o material mantém uma magnetização, denominada de *campo remanente*.

Sabe-se que a energia por unidade de volume, armazenada numa região de campo magnético de intensidade H e fluxo B , é dada pela integral:

$$W = \int_{B_1}^{B_2} H dB \quad (3.13)$$

Essa energia é absorvida da fonte elétrica de excitação, fonte essa que fornece uma corrente de magnetização e, portanto, a força magnetomotriz (*fmm*) necessária ao estabelecimento da intensidade de campo H .

Dada uma curva de magnetização de um material ferromagnético, nunca anteriormente magnetizado, como o caso da Figura 3.6, sua energia será representada pela área hachurada na figura. O acréscimo de intensidade de campo, $H_2 - H_1$ é o valor correspondente necessário para provocar o acréscimo de fluxo magnético, $B_2 - B_1$ (Falcone, 1992).




Figura 3.6 - Curva de magnetização $B = f(H)$

A relação entre a densidade de fluxo magnético e a força magnetizante para certos materiais, expressas pelas suas curvas de magnetização, dependem não só da força magnetomotriz utilizada como também do histórico magnético desses materiais. Isto significa que essas substâncias não voltam a sua situação magnética primitiva, após serem submetidas a um processo de magnetização.

Se uma amostra de um material ferromagnético sem qualquer imantação inicial fosse submetida a uma força magnetizante crescente, sua curva de magnetização seria semelhante à Figura 3.7 (de “O” para “A”):




Figura 3.7 – Ciclo de histerese

A redução da força magnetizante a zero deveria fazer cair também a zero o valor da densidade de fluxo. Entretanto, isto não ocorre, e o material permanece com alguma imantação (OB, Figura 3.7); este resíduo é chamado densidade de fluxo remanente (remanescente ou residual). O maior valor da densidade de fluxo remanente, que é conseguido com a imantação da amostra até a saturação, é conhecido como remanência do material.

Para fazer desaparecer o magnetismo residual é necessário imantar o material em sentido contrário. A força magnetizante necessária para anular a densidade de fluxo remanente é chamada força coerciva, e o maior valor desta força, justamente o correspondente de fluxo remanente, é chamado coercividade do material.

O aumento progressivo da força magnetizante, sua redução posterior, e novo aumento no sentido inicial da experiência provocam a variação da densidade de fluxo do modo observado na Figura 3.7 (traçado CDEFA).

O retardamento observado na variação da densidade de fluxo dá-se o nome de histerese, pois esta palavra significa atraso, retardamento.

A curva completa (ABCDEFA) obtida é denominada ciclo de histerese (P.J Mendes, 1987).

Se o material ferromagnético é submetido a um campo alternado, como é o núcleo de um transformador, é necessário que o circuito elétrico primário do transformador ceda energia ao campo magnético, e essa é devolvida em forma de calor. A esta energia dá-se o nome de perdas por histerese.

O cálculo das perdas por histerese é feito com a fórmula empírica de Steinmetz:

$$P_h = kVf\beta_{\max}^x \quad (3.14)$$

Onde:

P_h é a potência perdida por histerese (W);

V é o volume da massa magnetizada em (m^3);

f é a frequência, em (Hz);

$\beta_{\max}$ é a densidade de fluxo máxima, em (T);

k é o coeficiente de histerese, que depende da composição química do material, do seu tratamento térmico e mecânico e, até certo ponto, da densidade de fluxo magnético; e

x é o expoente que depende do material e da densidade de fluxo. Normalmente é considera-se a 1,6, entretanto, seu valor pode ser maior.

c) Perdas por Magnetostricção

A magnetostricção caracteriza-se como uma variação das dimensões do núcleo magnético quando este é submetido a um fluxo magnético. Essa variação, produzida por forças internas do material ferromagnético, ocorre nos núcleos.

Diante das elevadas forças internas oriundas do fenômeno denominado magnetostricção, o volume do material ferromagnético se expande e se contrai. Essa deformação é transferida para os elementos que suportam o núcleo, tais como as culatras, os parafusos e os meios de amarração do mesmo, causando deformações plásticas e elásticas. Com o passar do tempo, as deformações plásticas dão origem às folgas, surgindo ruídos na estrutura magnética da unidade. Por sua vez, a atuação dessas forças mecânicas de origem magnetostritivas resulta em um trabalho não útil e na conversão de energia da forma elétrica para forma mecânica.

3.4.3 Perdas Totais

As perdas totais de um transformador podem ser determinadas pela somatória das perdas em vazio e perdas no cobre em carga (NBR 5356/1993).

3.4.4 Rendimento

O rendimento é a relação entre a potência elétrica, fornecida pelo secundário do transformador, e a potência elétrica absorvida pelo primário, que pode ser expressa pela equação (3.16) (Martignoni, 1991):

$$\eta = \frac{P_s}{P_p} \quad (3.16)$$

Onde:

η é o rendimento do transformador;

P_s é a potência absorvida pelo secundário;

P_p é a potência absorvida pelo primário.

Considerando o fator de potência, o fator de carga e as perdas do equipamento, obtém-se o rendimento do transformador, o qual pode ser expresso em % pela equação (3.17) (Martignoni, 1991):

$$\eta = 100 - \frac{(P_{fe} + F_c \cdot P_{cu})}{F_c \cdot P_{nt} \cdot \cos\varphi + P_{fe} + F_c \cdot P_{cu}} \cdot 100 \quad (3.17)$$

Onde:

P_{fe} são as perdas no ferro, em kW;

P_{cu} são as perdas no cobre com carga normal, em kW;

F_c é o fator de carga;

$\cos\varphi$ é o fator de potência da carga;

P_{nt} é a potência nominal do transformador, em kVA.

Segundo a ABNT, o rendimento fornecido pelo fabricante deve-se referir às condições nominais e ao fator de potência da carga de valor unitário (Oliveira, 1998).

Na fase de projeto do transformador, deve-se estabelecer o valor de F_c como aproximadamente 1/2 para os transformadores de distribuição (Oliveira, 1998).

É importante comentar que todos esses aspectos construtivos, físicos e magnéticos, apresentados neste capítulo, foram muito importantes para a elaboração da arquitetura neural que será apresentada no Capítulo 5. Essas informações são pertinentes, pois servirão também como subsídios técnicos para fomentar discussões que serão apresentadas posteriormente no Capítulo 6.

CAPÍTULO 4

FUNDAMENTOS DE REDES NEURAIS

4.1 Introdução

O interesse crescente em Redes Neurais Artificiais (RNA) pode ser visto como um fenômeno notável dos anos 80 (Tagliarini, 1991) e ocorreu por suas características de grande capacidade de processamento e sua flexibilidade de integração com outras ferramentas matemáticas. As RNA têm atraído um grande número de pesquisadores de diversas áreas; entre elas destacam-se: matemáticos, físicos, psicólogos, neuro-fisiologistas, biólogos e engenheiros.

Os pesquisadores de RNA acreditam que o cérebro, constituído de neurônios, constrói suas próprias estratégias de processamento de informações, através do que é usualmente chamado de “experiência”. Assim, o foco deste novo desafio é baseado no reconhecimento, por essa comunidade, de que o cérebro processa informações de uma forma diferente do computador convencional em

que as informações são processadas sequencialmente por estruturas simbólicas (Silva, 1995).

A principal motivação para utilizar RNA na solução de problemas complexos e variados é inspirada no próprio cérebro humano, por sua capacidade de resolver, de forma rápida e satisfatória, problemas mal definidos e que exigem um grande esforço computacional.

As RNA têm sido utilizadas em várias aplicações, tais como: Reconhecimento de Padrões (Widrow, 1998), Processamento de Sinais (Haykin, 1992), Processamento de Fala (Waibel, 1989), Robótica (Van, 1991), Identificação e Controle (Narendra, 1990), Otimização de Sistemas (Tagliarini, 1991 e Silva, 1997) e muitas outras.

As características que tornam a metodologia de redes neurais interessante do ponto de vista da solução de problemas são:

- i) capacidade de “aprender” através da experiência; diz-se que tal “aprendizado” ocorre quando a rede atinge uma solução generalizada para uma classe de problemas;
- ii) desempenho eficiente em processos onde há ausência de conhecimento explícito sobre como identificar uma solução factível;
- iii) não necessidade de identificação de eventuais modelos matemáticos que descrevem o comportamento do sistema analisado; e
- iv) elevada imunidade ao ruído, isto é, o desempenho da rede não entra em colapso em presença de eventuais informações incorretas ou ausentes.

As redes neurais artificiais têm sido desenvolvidas tentando simular certos processos de aprendizagem e aquisição de conhecimento que são executados pelo cérebro humano. Elas consistem de um grupo de elementos chamados de neurônios artificiais, que são interligados com outros grupos de neurônios através de conexões, chamadas de sinapses artificiais, as quais

permitem que informações possam fluir entre os vários grupos ou camadas de neurônios.

Esses processos comportam-se de maneira similar aos grupos de neurônios do cérebro humano que recebem e transmitem informações através dos dendritos e axônios, respectivamente. Assim como se sabe dos correspondentes biológicos, as redes podem ser submetidas a processos matemáticos, ou, como dizem os especialistas, ser treinadas para cumprir ou aprender várias tarefas, tais como: modelagem de relacionamentos de entradas e saídas.

Quando a rede é alimentada por um conjunto de entradas e suas respectivas saídas, as quais estão representando o comportamento de um processo específico, a mesma (através do treinamento) é capaz de se auto-ajustar com o objetivo de mapear o relacionamento funcional entre as entradas e saídas. Por conseguinte, após a execução desse algoritmo de treinamento, a rede é capaz de generalizar o comportamento do processo quando outras entradas, diferentes daquelas utilizadas no treinamento, são apresentadas.

Tal característica é particularmente útil quando o relacionamento entre as entradas e saídas do processo analisado é não-linear, ou então, quando o relacionamento não é claramente definido de forma que a sua modelagem, por técnicas de identificação convencionais, torna-se muito difícil (Silva, 1997).

As redes neurais artificiais são ideais para a realização de computação paralela em computadores digitais, permitindo também a sua implementação em hardware (Hush, 1993).

4.2 O Neurônio Biológico

A estrutura básica de um neurônio biológico descrita pelos especialistas, e suas principais reações bioquímicas são por eles identificadas. A Figura 4.1 tenta ilustrar a representação de um neurônio biológico. Trata-se de um modelo bastante simplificado que somente serve para ilustrar a explicação seguinte do processo matemático.




Figura 4.1 - Estrutura do neurônio biológico

As arquiteturas das redes neurais artificiais são inspiradas no modelo das próprias células cerebrais e nervosas. Entretanto, o conhecimento sobre as mesmas ainda é considerado limitado.

Entende-se que a propagação de informações (pulsos elétricos) no neurônio biológico é realizada a partir dos dendritos, parte da célula encarregada de receber as informações em direção aos axônios, os quais por sua vez são responsáveis por levar as informações para os outros neurônios. A comunicação entre os dendritos de um neurônio com o axônio de outro é realizado através das sinapses que têm o objetivo de ponderar cada informação transferida.

Estima-se que o cérebro humano seja composto por cerca de 10^{11} neurônios, os quais são interligados por aproximadamente 10^{14} sinapses. Em função disto, o processamento de informações pelo cérebro humano torna-se o que pode ser chamado de altamente paralelo, não linear e adaptativo.

4.3 O Neurônio Artificial

Os modelos de neurônios artificiais normalmente utilizados nas implementações das redes neurais artificiais são baseados no modelo inicialmente proposto por McCulloch (McCulloch, 1943), e são uma versão bastante simplificada do neurônio biológico.

O modelo geral do neurônio artificial está ilustrado na Figura 4.2.




Figura 4.2 - Modelo do neurônio artificial

Onde:

$x_1, x_2 \dots x_N$ são os sinais de entrada.

$w_1, w_2 \dots w_N$ são os pesos ou conexões sinápticas.

θ é a polarização associada ao neurônio.

u é a saída do combinador linear.

$g(.)$ é a função de ativação do neurônio.

y é o sinal de saída do neurônio ou estado de ativação do neurônio.

Neste modelo, os sinais de entradas x_i são ponderados (multiplicados) pelos respectivos pesos w_i (sinapses); e se o valor de w_i for positivo a sinapse será excitatória, caso contrário a sinapse será inibitória. Em

seguida, o valor de polarização (θ) e os sinais de entrada (x_i), ponderadas pelas respectivas sinapses (w_i) do neurônio, são somados e o valor resultante (u) constitui a saída deste combinador linear. Finalmente, o valor de u é aplicado à função de ativação $g(\cdot)$ com o objetivo de limitar o valor do sinal de saída (y) do neurônio.

Em termos matemáticos, tem-se:

$$u = \sum_{i=1}^N w_i x_i + \theta \quad (4.1)$$

$$y = g(u) \quad (4.2)$$

A partir das equações (4.1) e (4.2), verifica-se que a função de ativação $g(\cdot)$ simplesmente processa o conjunto de entradas recebidas e o transforma em estado de ativação. Normalmente, a faixa de variação do neurônio pertence ao intervalo $[0,1]$ ou $[-1,1]$.

As funções de ativação mais típicas são:

a) Função degrau

Neste tipo de função de ativação (Figura 4.3 (a)), tem-se:

$$g(u) = \begin{cases} 1, & \text{se } u \geq 0 \\ u, & \text{se } u < 0 \end{cases} \quad (4.3)$$

Então, a saída do neurônio assumirá o valor 1 se o nível de atividade interna total do neurônio for não-negativo, caso contrário a saída do neurônio assumirá o valor 0.

b) Função sigmóide

Para a função sigmóide, ilustrada na Figura 4.3 (b), tem-se:

$$g(u) = \frac{1}{1 + e^{-\beta u}} \quad (4.4)$$

onde β é o parâmetro que define a inclinação (ganho) da função sigmóide. Neste tipo de função, a saída do neurônio assumirá valores reais entre 0 e 1.

c) Função tangente hiperbólica

Na função de ativação do tipo tangente hiperbólica (Figura 4.3 (c)), tem-se:

$$g(u) = \frac{1 - e^{-u}}{1 + e^{-u}} \quad (4.5)$$

Para esta função de ativação, a saída do neurônio pode assumir valores reais negativos e positivos no domínio de -1 a 1.

A especificação do tipo de função de ativação a ser adotada na RNA está intrinsecamente relacionada com o tipo da aplicação.




Figura 4.3 - Funções de ativação típicas

4.4 Arquitetura de Redes Neurais Artificiais

A arquitetura da rede neural artificial especifica a forma pela qual os neurônios estão arranjados na rede e sua definição está fortemente relacionada com o tipo de algoritmo utilizado para treinar a rede.

As duas principais arquiteturas, classificadas segundo o tipo de conexão, são definidas por:

4.4.1 Redes em camadas “feedforward”

A rede em camada é aquela em que os neurônios são organizados em camadas. A característica principal das redes em camadas é a presença de uma ou mais camadas escondidas que são responsáveis pela extração e armazenamento de conhecimentos associados a alguma aplicação específica.

Neste tipo de rede, o fluxo de dados (informações) das entradas para as saídas segue estritamente em uma única direção, isto é, existem apenas ligações entre as saídas dos nós de um nível inferior para as entradas dos nós de um nível superior, não existindo conexões entre os elementos de um mesmo nível. Redes em camadas são utilizadas em várias aplicações, tais como: aproximação de funções, reconhecimento de padrões, simulação de funções lógicas, otimização de sistemas, controle de processos, entre outras (Haykin, 1994).

A ilustração de uma rede feedforward com duas camadas escondidas é apresentada na Figura 4.4.




Figura 4.4 - A arquitetura feedforward

A partir da Figura 4.4, observa-se que os nós da camada de entrada da rede fornecem as informações (vetores de entrada) as quais constituem os sinais de entrada que serão aplicados aos neurônios da segunda camada (1ª camada neural). Os sinais de saída da segunda camada são utilizados como entradas para a terceira camada (2ª-camada neural). Finalmente, o conjunto de sinais de saída apresentados pelos neurônios da camada de saída reflete a resposta final da rede em relação ao vetor de entrada fornecido pelos nós fontes da primeira camada.

Entre as principais redes que utilizam a arquitetura em camadas destacam-se as redes perceptron (Hush, 1993 e Haykin, 1994), as redes funções de base radial (Radial Basis Function – RBF) (Haykin, 1994) e a rede Counter-Propagation (Hecht, 1990).

Neste trabalho utiliza-se uma rede do tipo Perceptron com uma e duas camadas escondidas. Os detalhes de implementação da rede Perceptron usada nas simulações são descritas no Capítulo 5.

4.4.2 Redes recorrentes “feedback”

Este tipo de rede tem a mesma estrutura que a rede em camadas, no entanto, são permitidas conexões entre as saídas de nós de um nível superior e as entradas de nós (realimentação) de um nível inferior. Redes com realimentação são apropriadas para aplicações de identificação de sistemas (modelagem), controle, filtragem, predição não linear, etc.

As respostas de tais redes são dinâmicas, isto é, depois de aplicar um conjunto de novas entradas, as saídas são calculadas e retro-alimentadas com a finalidade de modificar as entradas do instante anterior. A saída é então recalculada e o processo é repetido iterativamente. Para uma rede estável, estas iterações sucessivas produzem mudanças nas saídas cada vez menores até que todas as saídas tornam-se constantes. Para alguns tipos de redes, este processo pode se repetir indefinidamente, e tais redes são ditas serem instáveis (Kohonen, 1986). Redes instáveis possuem características particulares e têm sido estudadas como exemplo de sistemas caóticos. A Figura 4.5 apresenta o esquema de uma rede recorrente.




Figura 4.5 - Rede recorrente típica

A rede de Hopfield é provavelmente o melhor exemplo conhecido de rede recorrente (Hush, 1993). Esta rede apresenta geralmente uma única

camada com conexões retroalimentadas entre os nós. Na maioria dos casos os nós (neurônios) são completamente interconectados, isto é, todos os nós da rede são conectados a todos os outros e a si próprio, ou seja, todas as saídas da rede alimentam todas as suas entradas. Portanto, alguns ou todos os nós de saídas podem ser vistos também como entradas da rede. Além disso, alguns ou todos os nós da rede podem receber entradas externas.

4.5 Processo de Aprendizagem

O treinamento ou processo de aprendizagem de uma rede neural artificial consiste em ajustar os pesos sinápticos (matriz de pesos W) de forma que a aplicação de um conjunto de entradas produza um conjunto de saídas desejadas.

As situações de aprendizagem podem ser categorizadas em duas naturezas distintas:

- i) Supervisionado, associativo ou auto-supervisionado: a rede é treinada pelo fornecimento de padrões de saídas associados às suas respectivas entradas. Estes pares entradas-saídas podem ser fornecidos por um meio externo, ou pelo sistema que contiver a rede. Quando um vetor de entrada é aplicado, a saída da rede é calculada e comparada com o respectivo padrão de saída, a diferença (erro) é então propagada em sentido inverso ao fluxo de informações da rede (das saídas para as entradas) e os pesos são alterados de acordo com algum algoritmo que tende a minimizar o erro. Os vetores de entrada e de saída do conjunto de treinamento são aplicados sequencialmente, e os erros são calculados e os pesos ajustados para cada vetor, até que o erro para o conjunto de treinamento seja aceitável.
- ii) Não supervisionado autônomo ou auto organizado: neste processo de treinamento, uma unidade (de saída) é treinada a fim de reconhecer grupos de padrões dentre as entradas. Os vetores do conjunto de treinamento consistem unicamente de vetores de entrada. O algoritmo de treinamento modifica os pesos da rede para produzir vetores de saída que são consistentes, isto é, vetores do

conjunto de treinamento que são similares entre si produzirão o mesmo padrão de saída. Neste tipo de aprendizagem espera-se que o sistema deva estatisticamente descobrir características e particularidades marcantes da população de entrada. Ao contrário do aprendizado supervisionado, onde não existe um conjunto à priori de categorias dentro do qual os padrões irão ser classificados, o sistema é quem deve desenvolver sua própria representação do estímulo de entrada.

Entre as redes que utilizam o aprendizado supervisionado para ajustar os seus pesos destacam-se as redes Perceptron (Haykin, 1994), as redes de Função de Base Radial (RBF) (Hecht, 1990), e as redes Learning Vector Quantization (LVQ) (Kohonen, 1986). As principais redes que utilizam aprendizado não supervisionado são as redes Counter-Propagation [Hecht, 1990], e as redes de Kohonen (Kohonen, 1982).

Na próxima seção, descreve-se o algoritmo de treinamento referente ao processo de aprendizagem supervisionado das redes Perceptrons utilizada nas simulações referidas neste trabalho.

4.6 Algoritmos de Treinamento da Rede Perceptron

O treinamento supervisionado das redes neurais artificiais do tipo Perceptron utilizadas neste trabalho é baseado no algoritmo de aprendizagem “backpropagation” proposto por (Rumelhart, 1986).

Apresenta-se à rede um vetor de entrada (exemplo) que é propagado camada a camada. A saída produzida pela rede é então comparada com a saída desejada para o respectivo vetor de entrada, e a diferença entre ambas as saídas é calculada e o erro de saída da rede é então produzido. Este sinal de erro é retropropagado com o objetivo de ajustar os pesos sinápticos de forma que a saída produzida pela rede esteja próxima da saída desejada. Este processo é repetido para todos os vetores de entrada da rede até que o erro quadrático médio das saídas da rede esteja num valor aceitável.

4.6.1 Derivação do algoritmo “backpropagation”

A derivação do algoritmo “backpropagation”, para redes Perceptron com uma única camada escondida é realizada conforme a notação apresentada na Figura 4.6.




Figura 4.6 - Diagrama esquemático da rede Perceptron

A partir da Figura 4.6, adota-se a seguinte convenção:

- i-) O parâmetro N especifica o número de variáveis que constitui cada vetor de entrada.
- ii-) O parâmetro $N1$ especifica a quantidade de neurônios utilizados na camada neural escondida.
- iii-) O parâmetro $N2$ especifica o número de variáveis que constitui cada vetor de saída, e também indica a quantidade de neurônios utilizados na camada neural de saída.
- iv-) O vetor $\mathbf{x} = [x_1, x_2, \dots, x_N]^T$ denota o vetor de entrada da rede.

v-) O vetor $y = [y_1, y_2, \dots, y_N]^T$ denota o vetor de saída da rede.

vi-) O símbolo wl_{ji} fornece o valor do peso sináptico conectando o j -ésimo neurônio da camada (1) ao i -ésimo neurônio da camada (1-1).

vii-) O símbolo $I1_j$ fornece o valor correspondente à entrada ponderada do j -ésimo neurônio da camada (1), ou seja:

$$I1_j = \sum_{i=0}^N w1_{ji} \cdot x_i ; j = 1..N1 \quad (4.6)$$

$$I2_j = \sum_{i=0}^N w2_{ji} \cdot y1_i ; j = 1..N2 \quad (4.7)$$

viii-) O símbolo $y1_j$ fornece o valor correspondente à saída do j -ésimo neurônio da camada (1), ou seja:

$$y1_j = g(I1_j) ; j = 1..N1 \quad (4.8)$$

$$y2_j = g(I2_j) ; j = 1..N2 \quad (4.9)$$

As funções erro quadrático $\{E(k)\}$ e erro quadrático médio $\{E_M\}$, as quais são utilizadas como critérios de desempenho e de parada do processo de treinamento, são definidas por:

i-) erro quadrático

Esta função fornece o valor instantâneo da soma dos erros quadráticos (em relação ao k -ésimo padrão de treinamento) de todos os neurônios da camada de saída da rede, ou seja:

$$E(k) = \frac{1}{2} \sum_{j=1}^{N2} (d_j(k) - y2_j(k))^2 \quad (4.10)$$

onde $d_j(k)$ é o valor da saída desejada do neurônio j em relação ao k -ésimo padrão de entrada.

ii-) erro quadrático médio

O erro quadrático médio é obtido a partir da soma dos erros quadráticos relativos a todos os padrões de entrada utilizados no conjunto de treinamento da rede, ou seja:

$$E_M = \frac{1}{p} \sum_{k=1}^p E(k) \quad (4.11)$$

onde o parâmetro p especifica o número de padrões de treinamento ou a quantidade de vetores de entrada.

Assim, o objetivo do processo de aprendizagem, utilizando o algoritmo “backpropagation”, consiste em ajustar as matrizes de pesos $W1$ e $W2$ da rede a fim de minimizar a função E_M .

O processo de ajuste dos pesos pode ser dividido em duas fases como descrito a seguir:

Fase 1 - Ajuste dos pesos dos neurônios da camada de saída

O ajuste dos pesos dos neurônios da camada de saída (2ª camada neural) é feito a partir da minimização da função erro quadrático em relação aos pesos $w2_{ji}$. Utilizando a regra da diferenciação em cadeia, tem-se:

$$\nabla E_{(w2_{ji})} = \frac{\partial E}{\partial w2_{ji}} = \frac{\partial E}{\partial y2_j} \cdot \frac{\partial y2_j}{\partial I2_j} \cdot \frac{\partial I2_j}{\partial w2_{ji}} \quad (4.12)$$

onde:

$$\frac{\partial I2_j}{\partial w2_{ji}} = y1_i \quad (4.13)$$

$$\frac{\partial y2_j}{\partial I2_j} = g'(I2_j) \quad (4.14)$$

$$\frac{\partial E}{\partial y2_j} = -(d_j - y2_j) \quad (4.15)$$

Substituindo (4.13), (4.14) e (4.15) em (4.12), obtém-se:

$$\frac{\partial E}{\partial w_{ji}} = -(d_j - y_{2j}) \cdot g'(I_{2j}) \cdot y_{1i} \quad (4.16)$$

Logo, o ajuste deverá ser feito na direção oposta ao gradiente a fim de minimizar a função erro quadrático, ou seja:

$$\Delta w_{ji} = -\eta \cdot \frac{\partial E}{\partial w_{ji}} \quad (4.17)$$

$$\Delta w_{ji} = -\eta \cdot \delta 2_j \cdot y_{1i}$$

ou ainda:

$$w_{ji}(t+1) = w_{ji}(t) + \eta \cdot \delta 2_j \cdot y_{1i} \quad (4.18)$$

onde η é uma constante que determina a taxa de aprendizagem do algoritmo “backpropagation”, e $\delta 2_j$ denota o gradiente local sendo auto-definido por:

$$\delta 2_j = (d_j - y_{2j}) \cdot g'(I_{2j}) \quad (4.19)$$

Fase 2 - Ajuste dos pesos dos neurônios da camada intermediária

O ajuste dos pesos dos neurônios da camada intermediária (1ª camada neural) é feito normalmente a partir da função erro quadrático em relação aos pesos w_{1ji} . Utilizando a regra de diferenciação em cadeia, tem-se:

$$\nabla E_{(w_{1ji})} = \frac{\partial E}{\partial w_{1ji}} = \frac{\partial E}{\partial y_{1j}} \cdot \frac{\partial y_{1j}}{\partial I_{1j}} \cdot \frac{\partial I_{1j}}{\partial w_{1ji}} \quad (4.20)$$

onde:

$$\frac{\partial I_{1j}}{\partial w_{1ji}} = x_i \quad (4.21)$$

$$\frac{\partial y_{1j}}{\partial I_{1j}} = g'(I_{1j}) \quad (4.22)$$

$$\frac{\partial E}{\partial y_{1j}} = \sum_{k=1}^{N_2} \frac{\partial E}{\partial I_{2k}} \cdot \frac{\partial I_{2k}}{\partial y_{1j}} = \sum_{k=1}^{N_2} \frac{\partial E}{\partial I_{2k}} \cdot \frac{\partial (\sum_{k=1}^{N_2} w_{2kj} \cdot y_{1j})}{\partial y_{1j}}$$

$$= \sum_{k=1}^{N2} \frac{\partial E}{\partial I2_k} \cdot \frac{\partial (\sum_{k=1}^{N2} w2_{kj} \cdot y1_j)}{\partial y1_j} \quad (4.23)$$

Inserindo o resultado da multiplicação de (4.14) por (4.15) em (4.23), tem-se:

$$\frac{\partial E}{\partial y1_j} = - \sum_{k=1}^{N2} \delta 2_k \cdot w2_{kj} \quad (4.24)$$

Substituindo (4.21), (4.22) e (4.23) em (4.20), tem-se:

$$\frac{\partial E}{\partial w1_j} = (- \sum_{k=1}^{N2} \delta 2_k \cdot w2_{kj}) \cdot g'(I1_j) \cdot x_i \quad (4.25)$$

O ajuste deve ser feito na direção oposta ao gradiente. Então, a equação (4.25) torna-se:

$$\Delta w1_{ji} = -\eta \cdot \frac{\partial E}{\partial w1_{ji}} \quad (4.26)$$

$$\Delta w1_{ji} = -\eta \cdot \delta 1_j \cdot x_i$$

ou ainda:

$$w1_{ji}(t+1) = w1_{ji}(t) + \eta \cdot \delta 1_j \cdot x_i \quad (4.27)$$

onde $\delta 1_j$ denota o gradiente local e é auto-definido por:

$$\delta 1_j = g'(I1_j) \cdot (\sum_{k=1}^{N2} \delta 2_k \cdot w2_{kj}) \quad (4.28)$$

Assim, aplicam-se a Fase 1 e Fase 2 sequencialmente até que o erro quadrático médio da rede atinja um valor aceitável que é estipulado em função de cada aplicação específica.

4.6.2 Algoritmo de Levenberg - Marquardt

Como descrito na Subseção 4.6.2, o algoritmo “backpropagation” ajusta os valores das matrizes de pesos $W1$ e $W2$ em relação à direção oposta do gradiente da função erro quadrático. Entretanto, a utilização desse algoritmo na prática tende a convergir muito lentamente, exigindo assim um elevado esforço computacional. Para contornar este problema várias técnicas de otimização têm sido incorporadas ao algoritmo “backpropagation” a fim de reduzir o seu tempo de convergência e diminuir o esforço computacional exigido pelo mesmo. Dentre as técnicas de otimização mais utilizadas para este propósito destaca-se o algoritmo de Levenberg – Marquardt (Hagan, 1994).

O algoritmo de Levenberg – Marquardt é uma técnica baseada no método dos mínimos quadrados para modelos não-lineares que pode ser incorporada ao algoritmo “backpropagation” a fim de aumentar a eficiência do processo de treinamento. Neste algoritmo as funções erro quadrático e erro quadrático médio fornecidas respectivamente nas equações (4.10) e (4.11) podem ser expressas conjuntamente por:

$$V = \frac{1}{2p} \sum_{k=1}^p \sum_{j=1}^{N_2} [d_j(k) - y_{2j}(k)]^2$$

$$V = \frac{1}{2p} \sum_{k=1}^p (d(k) - y_2(k))^T \cdot (d(k) - y_2(k))$$

$$V = \frac{1}{2p} \sum_{k=1}^p e^T(k) \cdot e(k) \quad (4.29)$$

onde o termo $\{ e(k) = d(k) - y_2(k) \}$ denota o vetor erro em relação ao k -ésimo padrão de treinamento. Para um padrão k específico o erro é dado por:

$$V = \frac{1}{2} e^T(k) \cdot e(k) \quad (4.30)$$

Enquanto que o algoritmo “backpropagation” é um método de descida no gradiente da função erro quadrático, o algoritmo de Levenberg – Marquardt é uma aproximação do Método de Newton (Battiti, 1992 e Fioresse, 1997). Nesse método a minimização de uma função $V(\mathbf{z})$ em relação a um vetor paramétrico $\mathbf{z}$ é dada por:

$$\Delta \mathbf{z} = -[\nabla^2 V(\mathbf{z})]^{-1} \cdot \nabla V(\mathbf{z}) \quad (4.31)$$

onde $\nabla^2 V(\mathbf{z})$ denota a matriz Hessiana e $\nabla V(\mathbf{z})$ é a matriz Jacobiana de $V(\mathbf{z})$. Assumindo-se que $V(\mathbf{z})$ é uma função que executa soma de funções quadráticas da forma:

$$V(\mathbf{z}) = \sum_{i=1}^N e_i^2(\mathbf{z}) \quad (4.32)$$

Então a partir da equação anterior, pode ser mostrado que:

$$\nabla V(\mathbf{z}) = \mathbf{J}^T(\mathbf{z}) \cdot \mathbf{e}(\mathbf{z}) \quad (4.33)$$

$$\nabla^2 V(\mathbf{z}) = \mathbf{J}^T(\mathbf{z}) \cdot \mathbf{J}(\mathbf{z}) + \mathbf{S}(\mathbf{z}) \quad (4.34)$$

onde $\mathbf{J}(\mathbf{z})$ é a matriz Jacobiana definida por:

$$\mathbf{J}(\mathbf{z}) = \begin{bmatrix} \frac{\partial e_1(\mathbf{z})}{\partial z_1} & \frac{\partial e_1(\mathbf{z})}{\partial z_2} & \dots & \frac{\partial e_1(\mathbf{z})}{\partial z_N} \\ \frac{\partial e_2(\mathbf{z})}{\partial z_1} & \frac{\partial e_2(\mathbf{z})}{\partial z_2} & \dots & \frac{\partial e_2(\mathbf{z})}{\partial z_N} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial e_N(\mathbf{z})}{\partial z_1} & \frac{\partial e_N(\mathbf{z})}{\partial z_2} & \dots & \frac{\partial e_N(\mathbf{z})}{\partial z_N} \end{bmatrix} \quad (4.35)$$

e $\mathbf{S}(\mathbf{z})$ é uma função dada por:

$$\mathbf{S}(\mathbf{z}) = \sum_{i=1}^N e_i(\mathbf{z}) \nabla^2 e_i(\mathbf{z}) \quad (4.36)$$

Inserindo-se os resultados de (4.33) e (4.34) em (4.31), obtém-se a equação iterativa do método de Newton, ou seja:

$$\Delta z = [J^T(z).J(z) + S(z)]^{-1}.J^T(z).e(z) \quad (4.37)$$

No algoritmo de Levenberg – Marquardt a equação (4.37) é modificada da seguinte forma:

$$\Delta z = [J^T(z).J(z) + \mu I]^{-1}.J^T(z).e(z) \quad (4.38)$$

onde I é a matriz identidade e μ é um parâmetro que ajusta a taxa de convergência do algoritmo de Levenberg – Marquardt.

Portanto, a característica principal deste algoritmo é a computação da matriz Jacobiana. Para o processo de treinamento das redes neurais do tipo Perceptron utilizadas neste trabalho, e ilustrada na Figura 4.6, a matriz Jacobiana (4.35) passa então a ser re-escrita em função dos pesos sinápticos da rede, ou seja:

$$J(w) = [J(w1) | J(w2)]_{(p) \times (N.N1 + N1.N2)} \quad (4.39)$$

onde:

$$\begin{aligned} w &= [w1 | w2] \\ &= [w1_{1,1} \dots w1_{1,N} \quad w1_{2,1} \dots w1_{2,N} \quad \dots \quad w1_{N1,1} \dots w1_{N1,N} | \\ &\quad w2_{1,1} \dots w2_{1,N1} \quad w2_{2,1} \dots w2_{2,N1} \quad \dots \quad w2_{N2,1} \dots w2_{N2,N1}]_{(N.N1 + N1.N2) \times (1)}^T \end{aligned} \quad (4.40)$$

$$J(w1) = \begin{bmatrix} \frac{\partial e(1)}{\partial w_{1,1}} & \dots & \frac{\partial e(1)}{\partial w_{1,N}} & \frac{\partial e(1)}{\partial w_{2,1}} & \dots & \frac{\partial e(1)}{\partial w_{2,N}} & \dots & \frac{\partial e(1)}{\partial w_{N1,1}} & \dots & \frac{\partial e(1)}{\partial w_{N1,N}} \\ \frac{\partial e(2)}{\partial w_{1,1}} & \dots & \frac{\partial e(2)}{\partial w_{1,N}} & \frac{\partial e(2)}{\partial w_{2,1}} & \dots & \frac{\partial e(2)}{\partial w_{2,N}} & \dots & \frac{\partial e(2)}{\partial w_{N1,1}} & \dots & \frac{\partial e(2)}{\partial w_{N1,N}} \\ \vdots & & \vdots & \vdots & & \vdots & & \vdots & & \vdots \\ \frac{\partial e(p)}{\partial w_{1,1}} & \dots & \frac{\partial e(p)}{\partial w_{1,N}} & \frac{\partial e(p)}{\partial w_{2,1}} & \dots & \frac{\partial e(p)}{\partial w_{2,N}} & \dots & \frac{\partial e(p)}{\partial w_{N1,1}} & \dots & \frac{\partial e(p)}{\partial w_{N1,N}} \end{bmatrix}_{(p) \times (N \cdot N1)} \quad (4.41)$$

$$J(w2) = \begin{bmatrix} \frac{\partial e(1)}{\partial w_{1,1}} & \dots & \frac{\partial e(1)}{\partial w_{1,N1}} & \frac{\partial e(1)}{\partial w_{2,1}} & \dots & \frac{\partial e(1)}{\partial w_{2,N1}} & \dots & \frac{\partial e(1)}{\partial w_{N2,1}} & \dots & \frac{\partial e(1)}{\partial w_{N2,N1}} \\ \frac{\partial e(2)}{\partial w_{1,1}} & \dots & \frac{\partial e(2)}{\partial w_{1,N1}} & \frac{\partial e(2)}{\partial w_{2,1}} & \dots & \frac{\partial e(2)}{\partial w_{2,N1}} & \dots & \frac{\partial e(2)}{\partial w_{N2,1}} & \dots & \frac{\partial e(2)}{\partial w_{N2,N1}} \\ \vdots & & \vdots & \vdots & & \vdots & & \vdots & & \vdots \\ \frac{\partial e(p)}{\partial w_{1,1}} & \dots & \frac{\partial e(p)}{\partial w_{1,N1}} & \frac{\partial e(p)}{\partial w_{2,1}} & \dots & \frac{\partial e(p)}{\partial w_{2,N1}} & \dots & \frac{\partial e(p)}{\partial w_{N2,1}} & \dots & \frac{\partial e(p)}{\partial w_{N2,N1}} \end{bmatrix}_{(p) \times (N1 \cdot N2)} \quad (4.42)$$

A partir de (3438), a equação iterativa do método de Levenberg – Marquardt para o ajuste dos pesos da rede passa a ser definida por:

$$\Delta z = [J^T(W) \cdot J(W) + \mu I]^{-1} \cdot J^T(W) \cdot e(W) \quad (4.43)$$

onde $e(W) = [e_1(W), e_2(W), \dots, e_p(W)]^T_{(p) \times (1)}$ é o vetor erro (em relação à matriz W) referente aos p – padrões de treinamento.

Finalmente, os elementos das matrizes $J(W1)$ e $J(W2)$ são obtidos seqüencialmente a partir das Fases 1 e 2 do algoritmo “backpropagation” apresentado na Seção 4.6.1. Com estas modificações comprova-se que o algoritmo de Levenberg – Marquardt torna-se de 10 a 100 vezes mais rápido que o algoritmo “backpropagation” convencional.

4.6.3. Algoritmo de Levenberg Marquardt com Regularização Bayesiana.

Um dos problemas que ocorrem durante o treinamento de redes neurais do tipo Perceptron é denominado de “overfitting”. Quando acontece “overfitting”, o erro quadrático médio dos padrões de treinamento é muito pequeno, mas quando novos padrões (que não pertenciam ao conjunto de treinamento) são apresentados à rede, o erro torna-se muito grande. Este fato ocorre porque a rede memorizou apenas os padrões de treinamento, mas não conseguiu generalizar novas situações.

O problema do “overfitting” normalmente acontece quando a disponibilidade de dados usados no treinamento da rede é pequena. Um dos métodos para melhorar a generalização é o método de Levenberg regularizado, e que consiste em modificar a função erro quadrático médio da rede.

Tipicamente o treinamento da RNA objetiva a redução da soma do erro quadrático.

$$F = E_D \quad (4.44)$$

onde:

F é a soma dos erros quadráticos e

$$E_D = \sum_{i=1}^{i=n} (t_i - a_i)^2 \quad (4.45)$$

Onde:

t_i representa o valor desejado na saída;

a_i representa a resposta da rede.

Entretanto, na regularização adiciona-se termos adicionais; quais sejam: a função objetiva torna-se a soma dos erros quadráticos dos pesos da rede e os termos α e β são os parâmetros da função objetiva.

$$F = \beta E_D + \alpha E_w \quad (4.46)$$

onde:

E_w é a soma do quadrado dos pesos da rede.

O tamanho relativo entre a os parâmetros da função objetiva determinam a ênfase no treinamento. Se $\alpha \ll \beta$ o algoritmo de treinamento terá erros pequenos. Se $\alpha \gg \beta$ o algoritmo reduz o tamanho dos pesos, aumentando o erro da rede e produzindo uma resposta plana na saída.

O principal problema de implementar a regularização é determinar os valores de α e β . A otimização Bayesiana da regularização dos parâmetros exige o cálculo da matriz Hessiana de $F(w)$ para o ponto mínimo de w^{MP} . A variável w é o vetor dos pesos da rede e o índice MP representa o ponto de mínimo do vetor de pesos. A proposta de (Forsee & Hagan, 1997) o uso da aproximação de Gauss-Newton para a matriz Hessiana, a qual já está implementada no algoritmo de otimização de Levenberg-Marquadt, para determinação dos pontos de mínimo. O esforço computacional exigido para otimização da função de regularização é mínimo, conforme descrito por (Forsee & Hagan, 1997) no algoritmo abaixo:

- i) Inicializar α , β e os pesos. Escolhe-se inicialmente $\alpha = 0$ e $\beta = 1$ e usa-se o método de Nguyen-Widrow para inicializar os pesos. Após o primeiro passo de treinamento os parâmetros da função objetiva retornam aos valores originais.
- ii) Usa-se o algoritmo de Levenber-Marquadt para minimizar a função $F = \beta E_D + \alpha E_w$.
- iii) Computa-se o número efetivo de parâmetros usando a aproximação de Gauss-Newton na matriz Hessiana do algoritmo de Levenberg-Marquadt.
- iv) Calcula-se o valor de α e β .
- v) Retorna o algoritmo ao passo 2 até 4 enquanto não convergir os valor de α e β .

Neste trabalho foi utilizado o algoritmo de Levenberg Marquardt com Regularização Bayesiana (Hagan, 1994) em todas as simulações da rede neural, pois o mesmo se adequou melhor em função do tipo de dados utilizados no treinamento da rede.

Todos os aspectos relacionados com redes neurais artificiais apresentados neste capítulo foram utilizados para a composição do próximo capítulo, o qual refere-se ao desenvolvimento da arquitetura neural.



CAPÍTULO 5

DESENVOLVIMENTO DA ARQUITETURA NEURAL

5.1 Obtenção dos Dados de Treinamento

A determinação das perdas elétricas totais, ou seja, perdas no cobre e perdas no núcleo, nos transformadores são obtidas através de ensaios laboratoriais do próprio fabricante, os quais são executados em todas as unidades de produção, de acordo com a norma da ABNT NBR 5380/1993, que prescreve os métodos de ensaio a serem seguidos, abrangidos pela NBR 5356/1993, que fixa as condições exigíveis aos transformadores.

Neste capítulo, a partir de uma metodologia neural, realiza-se a quantificação das perdas elétricas totais em transformadores de distribuição, levando-se em conta os resultados advindos dos ensaios de laboratório.

Para se verificar o relacionamento das grandezas envolvidas nos ensaios, foi utilizada uma rede neural, capaz de relacionar diversos processos

referentes às perdas elétricas. Esses processos seriam muito difíceis de serem constatados através de equacionamentos matemáticos. Esta particularidade pode ser considerada como uma das principais contribuições deste trabalho, uma vez que esta ferramenta neural agregará mais elementos para melhorar a avaliação das perdas.

No desenvolvimento da arquitetura neural foram utilizados os dados dos ensaios de 200 transformadores trifásicos de 75 kVA. A rede neural utilizada neste mapeamento foi do tipo Perceptron multicamadas. A escolha por este tipo de rede foi estabelecida em função de uma ampla investigação bibliográfica, onde se constatou a adequação desta rede para alcançar os objetivos propostos anteriormente.

Para o treinamento da rede neural, foram utilizados os dados dos ensaios de perdas no cobre, de perdas em vazio e de resistência dos enrolamentos, e, posteriormente, 30 valores dos ensaios que não fizeram parte do treinamento foram usados para a validação da proposta neural desenvolvida.

5.2 Geração dos Dados Para o Treinamento:

5.2.1 Ensaio em Vazio

O ensaio em vazio de transformadores tem por finalidade a determinação das seguintes grandezas: perdas no núcleo, correntes em vazio, relação de transformação e parâmetros relacionados ao ramo magnetizante. Além dessas grandezas, esse ensaio permite analisar o formato não-senoidal da corrente em vazio e da corrente transitória de magnetização.

A Figura 5.1 representa o esquema simplificado do ensaio em vazio que foi utilizado no laboratório em um transformador trifásico.






Figura 5.1 - Esquema do ensaio em vazio

AT são os enrolamentos de alta tensão (AT);

BT são os enrolamentos de baixa tensão (BT);

W_1 e W_2 são os wattímetros que indicam as perdas (W);

V é o voltímetro;

A_1 , A_2 e A_3 são os amperímetros;

F é o frequencímetro.

5.2.2 Ensaio de Curto Circuito

O ensaio de curto circuito tem por objetivo estabelecer as seguintes grandezas: perdas no cobre, queda de tensão interna, impedância, resistência, e reatância percentuais.

A Figura. 5.2 representa o ensaio em curto circuito que foi realizado no laboratório para um transformador trifásico. É pertinente mencionar que a principal diferença verificada neste ensaio em relação ao ensaio em vazio é que os terminais de baixa tensão (BT) ficam curto-circuitados.




Figura 5.2 - Esquema do ensaio em curto circuito

A Tabela 5.1 apresenta os valores máximos de perdas totais prescritos na norma (NBR-5440, 1987).

Tabela 5.1 - Valores Normalizados pela Norma NBR-5440.

Potência (kVA)	Perdas em Vazio (W)	Perdas Totais (W)
15	120	460
30	200	770
45	260	1.040
75	390	1.530
112,5	520	2.070
150	640	2.550

Os valores apresentados na Tabela 5.1 podem variar de 10% para as perdas em vazio e 6% para as perdas totais, considerando-se um único transformador, conforme norma NBR 5356/1993 –TABELA 21 – Tolerâncias.

5.2.3 Ensaio de Resistência dos Enrolamentos

Os enrolamentos primário e secundário do transformador apresentam, como todo condutor, uma determinada resistência elétrica. Essas resistências são chamadas de resistência primária e secundária do transformador e são normalmente indicadas por R_1 e R_2 em cada fase. Elas exercem sobre o funcionamento do transformador um duplo efeito: i) determinando uma queda ôhmica denominada queda ôhmica primária e secundária, e ii) produzindo uma perda de energia por *Efeito Joule*, cuja potência constitui toda parte da perda no cobre do primário e secundário do transformador.

Para diminuir essas perdas em limites prescritos em normas técnicas, é necessário tornar pequenas as resistências primárias e secundárias, escolhendo-se adequadamente a seção dos condutores do enrolamento (Martignoni, 1991).

Na realização deste ensaio, devem ser registrados os valores das resistências elétricas de cada enrolamento, os terminais onde foram medidas, bem como suas respectivas temperaturas.

A resistência elétrica dos enrolamentos deve ser medida na derivação correspondente à tensão mais elevada e corrigida para a temperatura de referência, de acordo com a Tabela 5.2.

Tabela 5.2 - Temperatura de Referência dos enrolamentos

Limites de Elevação de Temperatura (°C)	Temperatura de Referência (°C)
55	75
65	85
80	115
105	
130	

No caso de transformadores polifásicos, este valor deve ser por fase. O comprador deve indicar as derivações adicionais para as quais o fabricante deve medir a resistência dos enrolamentos (NBR 5356, 1993).

É importante ressaltar que, depois da obtenção dos dados experimentais foram utilizados os mesmos para modelagem neural e posteriormente para a validação da rede neural.

5.3 Descrição das Arquiteturas Neurais

As arquiteturas neurais utilizadas neste trabalho são do tipo Perceptron Multicamadas, compostas por uma e duas camadas escondidas, com treinamento supervisionado pelo algoritmo Levenberg-Marquardt com Regularização Bayesiana (Hagan, 1994), como foi apresentado detalhadamente no Capítulo 4.

A metodologia empregada consiste em utilizar uma rede neural para cada tipo de perda a ser quantificada, ou seja, utilizou-se ao todo 3 redes neurais referentes às perdas no cobre, perda em vazio e perdas totais. O treinamento das redes foi realizado com os dados obtidos através de ensaios experimentais, considerando valores máximos, médios e mínimos das grandezas pré-determinadas para cada tipo de simulação.

A implementação do sistema iniciou-se com a obtenção dos dados de treinamento e todas as amostras foram obtidas a partir dos ensaios realizados na Empresa Incotraz - Indústria de transformadores Zago Ltda. As variáveis que compõem os vetores de entrada da rede neural foram definidas por grandezas que fazem parte do processo de perdas elétricas.

Inicialmente, utilizaram várias configurações (topologias) para o processo de treinamento de cada uma das redes neurais, as quais representam as perdas elétricas. As subseções seguintes apresentam os dados obtidos de simulações relativos às arquiteturas que apresentaram os melhores resultados.

A seguir são apresentados os dados dos transformadores estudados, que representam uma parcela significativa dos transformadores que são instalados no sistema de distribuição de energia brasileiro. Os dados são os seguintes:

transformador de Distribuição: 75 kVA;

classe de Tensão: 15 kV;

tipo de Refrigeração: Óleo;

tensão AT e BT: 13.8 kV/220V.

5.3.1 Estimação das Perdas em Vazio

Para quantificar e estimar as perdas em vazio utilizou-se como entrada da rede neural os seguintes dados (vetor de entrada):

R_1 é a resistência da bobina de alta tensão da fase 1 (Ω);

R_2 é a resistência da bobina de alta tensão da fase 2 (Ω);

R_3 é a resistência da bobina de alta tensão da fase 3 (Ω);

I_{ex} é a corrente de excitação (A).

O vetor de saída da rede neural foi composto por uma única variável, a qual representa a perda em vazio (P_{vazio}). A arquitetura da rede neural utilizada para identificação do processo é ilustrada na Figura 5.3.




Figura 5.3 - Arquitetura da rede Perceptron para perda em vazio.

A topologia da arquitetura neural elaborada neste trabalho foi a seguinte:

algoritmo de Treinamento: Trainbr;

função de Ativação: Tangente-Sigmoide;

Topologia da RNA:

arquitetura: Perceptron Multicamadas;

número de Camadas Escondidas: 1;

número de Neurônios das Camadas Escondidas: 5;

erro Médio: 1,7295;

variância: 1,5264;

desvio Padrão: 1,2355.

5.3.2 Estimação das Perdas no Cobre

Para quantificar e estimar as perdas no cobre dos transformadores foram definidas grandezas que fazem parte deste processo. Essas variáveis foram utilizadas como as entradas da rede:

R_{AT} representa a média das 3 resistências da bobina de alta tensão (Ω);

R_{BT} representa a média das 3 resistências da bobina de baixa tensão (Ω);

T_A é a temperatura ambiente ($^{\circ}\text{C}$);

I_{ex} é a corrente de excitação (A);

V_{cc} é a tensão de curto circuito (V).

O vetor de saída da rede neural foi composto por uma única variável, que representa as perdas no cobre (P_{cu}).

A arquitetura da rede neural utilizada para identificação do processo é mostrada na Figura 5.4.




Figura 5.4 - Arquitetura da rede Perceptron para perdas no cobre.

A topologia da arquitetura neural utilizada nesta etapa foi a seguinte:

algoritmo de Treinamento: Trainbr;

função de Ativação: Tangente-Sigmoide;

Topologia da RNA:

arquitetura: Perceptron Multicamadas;

número de Camadas Escondidas: 2;

número de Neurônios das Camadas Escondidas: 5 (primeira camada) e 1 (segunda camada);

erro Médio: 0,7763;

variância: 0,98159;

desvio Padrão: 0,99075.

5.3.3 Estimação das Perdas Totais

Para quantificar e estimar as perdas totais dos transformadores foram definidas as seguintes grandezas que representam as entradas da rede:

R_{AT} representa a média das 3 resistências da bobina de alta tensão (Ω);

R_{BT} representa a média das 3 resistências da bobina de baixa tensão (Ω);

T_A é a temperatura ambiente ($^{\circ}\text{C}$);

I_{ex} é a corrente de excitação (A);

O vetor de saída da rede neural foi composto de uma única variável, a qual representa as perdas totais (PT).

A arquitetura da rede neural utilizada para identificação do processo é apresentada na Figura 5.5




Figura 5.5 - Arquitetura da rede Perceptron para perdas totais.

A topologia da arquitetura neural, elaborada nesta etapa, foi a seguinte:

algoritmo de Treinamento: Trainbr;

função de Ativação: Tangente-Sigmoide;

Topologia da RNA:

arquitetura: Perceptron Multicamadas;

número de Camadas Escondidas: 1;

número de Neurônios das Camadas Escondidas: 2;

erro Médio: 0,5863;

variância: 0,1235;

desvio Padrão: 0,3515.

Para uma melhor visualização, são apresentados na Tabela 5.3 os valores de perdas máximos e mínimos utilizados no treinamento da rede neural.

Tabela 5.3 - Valores máximos e mínimos dos dados de treinamento.

Ensaio	Valores máximos (W)	Valores mínimos (W)
Perdas em Vazio	364	309
Perdas no Cobre	1130	1040
Perdas Totais	1485	1366

Conforme apresentado na Tabela 5.3, verifica-se que os valores dos ensaios apresentam uma faixa bastante interessante, pois abrangem grande parte das situações que podem ocorrer nos ensaios em laboratório, levando-se em conta o projeto de um transformador de 75 kVA.

5.4 Quantificação das Perdas a Partir dos Ensaio Laboratoriais

Para todas as análises que fazem parte desta seção, estão os valores experimentais (dados de ensaios que foram fornecidos à rede) e a resposta da rede referente a estes dados e o seu respectivo erro relativo. As generalizações obtidas para as perdas em vazio, perdas no cobre e perdas totais foram realizadas considerando-se 10 amostras, as quais não pertenceram ao conjunto de dados de treinamento.

O perfil dessas generalizações é apresentado para enfatizar o sucesso desta abordagem, bem como proporcionar uma comparação mais sistemática dos processos envolvidos. A Figura 5.6 apresenta a quantificação das perdas em vazio, identificando-se os valores experimentais, os valores advindos da rede neural e seu respectivo erro.




Figura 5.6 - Generalização da rede para perdas em vazio.

A partir da Figura 5.6, pode-se constatar que a resposta da rede em relação aos valores experimentais é bastante satisfatória, uma vez que os resultados são muito próximos daqueles obtidos nos ensaios em laboratório.

A Figura 5.7 apresenta a quantificação das perdas no cobre, identificando-se os valores experimentais, os valores fornecidos pela rede neural e seu respectivo erro.




Figura 5.7 - Generalização da rede para perdas no cobre.

Para as perdas no cobre, observa-se na Figura 5.7 que a generalização realizada pela rede neural é muito boa, tendo em vista que os erros relativos ficaram quase imperceptíveis.

A Figura 5.8 ilustra a quantificação das perdas totais, identificando-se os valores experimentais, os valores advindos da rede neural e seu respectivo erro.




Figura 5.8 - Generalização da rede para perdas totais.

A partir dos resultados apresentados, constata-se que a generalização realizada pela rede neural para quantificar e estimar as perdas totais, como pode ser observado na Figura 5.8, também foi muito boa, verificando que os valores computados pela rede neural são muito próximos àqueles valores obtidos nos ensaios experimentais, apresentando-se desta maneira um erro muito baixo.

Ressalta-se, também, que o desenvolvimento destas arquiteturas neurais teve como premissa estabelecer o relacionamento das grandezas presentes no processo das perdas totais, não somente para um simples cálculo, o qual pode ser realizado por ferramentas convencionais, mas sim para verificar a contribuição dessas grandezas de uma maneira integrada, ou seja, considerando aspectos construtivos, elétricos e magnéticos no processo de perdas.

Um outro detalhe também muito importante, que deve ser destacado é que este tipo de abordagem não é para substituir simplesmente os ensaios experimentais (perdas no cobre e perdas em vazio), e sim para adicionar subsídios a uma avaliação mais consistente das perdas totais.

No próximo capítulo serão apresentados, de maneira bem detalhada, todos os resultados e análises da aplicação da abordagem neural desenvolvida neste trabalho.

CAPÍTULO 6

RESULTADOS E ANÁLISES

6.1 Introdução e Generalização das Perdas Elétricas

Neste capítulo, serão apresentadas as simulações e discussões da metodologia proposta para a obtenção da arquitetura da abordagem neural proposta neste trabalho.

Para a obtenção dos resultados das perdas elétricas, foram realizados estudos de caso para diferentes valores de tensão, potência e comprimento de onda. Os resultados obtidos foram analisados e discutidos, mostrando a capacidade da abordagem proposta de generalizar os resultados para diferentes valores de tensão, potência e comprimento de onda.

Os resultados das simulações foram apresentados, a curva de perdas elétricas em função da tensão, potência e comprimento de onda. Os resultados mostram que a abordagem proposta é capaz de generalizar os resultados para diferentes valores de tensão, potência e comprimento de onda.

CAPÍTULO 6

RESULTADOS E ANÁLISES

6.1 Estimação e Generalização das Perdas Elétricas

Nesta seção, os resultados das simulações e discussões são apresentados para justificar a aplicação da abordagem neural proposta neste trabalho.

Os valores das simulações das perdas em vazio, perdas no cobre e perdas totais levaram em conta três tipos de situações distintas: valores mínimos, valores médios e valores máximos das grandezas que fazem parte do processo das perdas elétricas, as quais foram definidas no capítulo anterior.

Em todas as simulações que serão apresentadas, a curva 1 representará os valores mínimos, a curva 2 representará os valores médios e a curva 3 os valores máximos. É importante ressaltar também que as simulações

realizadas com os valores médios das grandezas são hipotéticas. Esta sistemática teve como objetivo identificar, num primeiro momento, possíveis problemas grosseiros de projeto.

6.1.1 Estimação das Perdas em Vazio

Para a estimação das perdas em vazio foi considerado o relacionamento da corrente de excitação (I_{ex}) e das resistências das bobinas de alta tensão (R_1 , R_2 e R_3).

A Tabela 6.1 destaca os valores mínimos, médios e máximos dessas grandezas utilizados nas simulações.

Tabela 6.1 - Faixa de valores de teste utilizados na rede neural.

	Valores Máximos	Valores Médios	Valores Mínimos
R_1	41,61 (Ω)	39,286 (Ω)	37,21 (Ω)
R_2	41,03 (Ω)	39,192 (Ω)	36,95 (Ω)
R_3	41,61 (Ω)	39,219 (Ω)	37,10 (Ω)
I_{ex}	6,65 (A)	5,993 (A)	5,55 (A)
P_{vazio}	335 (W)	324,3 (W)	314 (W)

A Figura 6.1 mostra o comportamento das perdas em vazio em relação à variação das três resistências da bobina de alta tensão (R_1 , R_2 e R_3). Nesta simulação foram utilizados valores mínimos, médios e máximos da corrente de excitação e das resistências das bobinas de alta tensão.




Figura 6.1 - Variação das perdas em vazio x resistência da bobina de alta tensão.

A partir da Figura 6.1, pode-se constatar uma tendência linear e crescente das perdas em vazio em relação às três situações simuladas, porém não totalmente paralelas (curva 2).

Ressalta-se que, neste tipo de situação, o fator mais importante é a variação dos patamares das perdas. Esse detalhe pode fornecer ao projetista um leque de alternativas na escolha do tipo de chapa utilizado no núcleo do transformador.

Uma outra observação bastante pertinente é que estes valores podem contribuir para o projeto do transformador não ficar subdimensionado (curva 3) ou sobredimensionado (curva 2). Esse tipo de identificação não seria possível de ser observado através de simples equacionamentos matemáticos, pois, como verificado na Figura 6.1, não existe uma linearidade entre as três curvas. Esse fato pode ser justificado em função do processo dinâmico, ou seja, as

variáveis possuem um peso diferente para cada simulação. Soma-se também a utilização de alguns valores hipotéticos, como apresentado na curva 2.

A Figura 6.2 apresenta o comportamento das perdas em vazio considerando a variação da corrente de excitação.




Figura 6.2 - Variação das perdas em vazio x corrente de excitação.

Observando a Figura 6.2, pode-se verificar que existe uma dependência direta entre o valor de corrente de excitação com as perdas em vazio. Esta dependência é crescente, porém não totalmente linear.

A partir da Figura 6.2, constata-se também que a maior influência desta corrente torna-se mais evidente a partir do valor pontual de 6,4 A, onde observa-se que existe uma concordância entre os valores máximos (curva 3), valores médios (curva 2) e valores mínimos (curva 1). Este tipo de detalhe seria impossível de ser calculado matematicamente devido à dinâmica do processo.

A Figura 6.3 confronta a generalização da rede neural com os dados de teste e também apresenta os erros relativos.




Figura 6.3 - Variação das perdas em vazio x generalização da rede.

Observando a Figura 6.3, pode-se comprovar que a rede neural desenvolvida para estimar as perdas em vazio pode ser validada, pois a rede generalizou valores de perdas que não foram utilizados no seu treinamento.

6.1.2 Estimação das Perdas no Cobre

Para a estimação das perdas no cobre, foi considerado o relacionamento da corrente de excitação, das resistências das bobinas de baixa tensão e de alta tensão, da temperatura ambiente e da tensão de curto circuito.

Nestas simulações foram utilizados valores mínimos, médios e máximos das grandezas acima mencionadas.

A Tabela 6.2 destaca os valores mínimos, médios e máximos dessas grandezas, empregado nas simulações para as perdas no cobre.

Tabela 6.2 - Faixa de valores de teste utilizados na rede neural.

	Valores Máximos	Valores Médios	Valores Mínimos
R_{AT}	40,83 (Ω)	39,295 (Ω)	38,45 (Ω)
R_{BT}	7,45 (m Ω)	7,247 (m Ω)	7,07 (m Ω)
I_{ex}	7,96 (A)	7,109 (A)	5,56 (A)
T_A	32,5 ($^{\circ}$ C)	26,98 ($^{\circ}$ C)	19,5 ($^{\circ}$ C)
V_{cc}	441,77 (V)	437,09 (V)	430,53 (V)
P_{cu}	1.110 (W)	1.084,5 (W)	1.045 (W)

A Figura 6.4 mostra o comportamento das perdas no cobre em relação à variação da tensão de curto circuito (V_{cc}). Nesta simulação foram usados valores mínimos, médios e máximos da média das 3 resistências da bobina de alta tensão (R_{AT}), média das 3 resistências da bobina de baixa tensão (R_{BT}), temperatura ambiente (T_A) e a corrente de excitação (I_{ex}).




Figura 6.4 - Variação das perdas no cobre x tensão de curto circuito.

Verificando a Figura 6.4, constata-se uma tendência quase constante, com um pequeno declínio para as 3 curvas, que pode ser relacionado à impedância do transformador. Este comportamento paralelo das 3 curvas já era esperado, vindo a comprovar a teoria existente.

Na Figura 6.5, observa-se o comportamento das perdas no cobre em relação à variação da média das 3 resistências da bobina de alta tensão (R_{AT}). Nesta etapa foram usados valores mínimos, médios e máximos da média das 3 resistências da bobina de baixa tensão (R_{BT}), da temperatura ambiente (T_A), da corrente de excitação (I_{ex}) e da tensão de curto circuito (V_{cc}).




Figura 6.5 - Variação das perdas no cobre x média das 3 resistências das bobinas de alta tensão.

Observa-se na Figura 6.5 uma tendência linear e crescente nas 3 curvas (efeito térmico). Constata-se também que as curvas 2 e 3 apresentam valores de perdas no cobre mais próximos, mesmo considerando valores médios e máximos das grandezas citadas. Esse tipo de análise mostra a sensibilidade da ferramenta neural desenvolvida. Para manter as perdas no cobre em limites convenientes, é necessário tornar pequenas as resistências, escolhendo-se de forma adequada à seção dos condutores do enrolamento.

Vale ressaltar que os valores simulados para as curvas 2 e 3 estão em desacordo com os valores recomendados por norma. Entretanto, esta condição é uma situação extrema de projeto, pois fornece subsídios importantes para o projetista de transformadores, uma vez que identifica qual a pior condição de projeto do transformador.

Na Figura 6.6, tem-se o comportamento das perdas no cobre em relação à variação da média das 3 resistências da bobina de baixa tensão (R_{BT}). Neste caso, foram usados valores mínimos, médios e máximos da média das 3 resistências da bobina de baixa tensão (R_{AT}), da temperatura ambiente (T_A), da corrente de excitação (I_{ex}) e da tensão de curto circuito (V_{cc}).




Figura 6.6 - Variação das perdas no cobre x média das 3 resistências das bobinas de baixa tensão.

A partir da Figura 6.6, observa-se um comportamento similar ao da Figura 6.5, e a principal diferença examinada é que as curvas são paralelas e constantes em relação às perdas no cobre. Essa simulação foi importante, pois evidenciou que o peso das variáveis que representam as resistências de baixa tensão não são tão significativas como as resistências de alta tensão (Figura 6.5).

Na Figura 6.7, ilustra-se o comportamento das perdas no cobre em relação à corrente de excitação (I_{ex}). Na simulação, foram usados valores mínimos, médios e máximos da média das 3 resistências da bobina de baixa

tensão (R_{AT}), da média das 3 resistências da bobina de baixa tensão (R_{BT}), da temperatura ambiente (T_A) e da tensão de curto circuito (V_{cc}).




Figura 6.7 - Variação das perdas no cobre x corrente de excitação.

A partir da Figura 6.7, constata-se que as perdas no cobre crescem linearmente com a corrente de excitação, igualmente para as 3 curvas e proporcionais aos valores máximos médios e mínimos. Este tipo de perfil seria muito difícil de ser observado através de ferramentas convencionais, devido à complexidade encontrada na modelagem matemática do fenômeno e tendo em vista que a ponderação da corrente de excitação fica restrita apenas às perdas em vazio (no núcleo). Esta é uma contribuição bastante significativa e original deste trabalho, pois tal fenômeno é muito difícil de ser quantificado.

Na Figura 6.8, verifica-se o comportamento das perdas no cobre em relação à temperatura ambiente (T_A). Nesta etapa foram usados valores mínimos, médios e máximos da média das 3 resistências da bobina de alta tensão (R_{AT}), da

média das 3 resistências da bobina de baixa tensão (R_{BT}), da corrente de excitação (I_{ex}), e da tensão de curto circuito (V_{cc}).




Figura 6.8 - Variação da perda no cobre x temperatura.

A partir da Figura 6.8, pode-se deduzir que existe uma dependência direta entre a temperatura e as perdas no cobre. Constata-se também o aumento crescente e uniforme das curvas: as curvas 1, 2 e 3 estão com distâncias proporcionais. Este tipo de comportamento já era esperado e está de acordo com a literatura, porém o mais importante a ser observado são os patamares das perdas.

Esta identificação é muito importante, para que o projetista possa definir o tipo de cobre mais adequado, sabendo dos limites máximos de temperatura (pureza do cobre).

A Figura 6.9 apresenta a generalização das perdas no cobre realizada pela rede desenvolvida, levando-se em conta os dados de teste e a estimativa da rede com seu respectivo erro relativo.




Figura 6.9 - Variação da perda no cobre x generalização da rede.

Observando a Figura 6.9, percebe-se que a generalização apresenta valores muito baixos de erro relativo, o que permite validar a abordagem neural para identificação de processos de perdas no cobre.

6.1.3 Identificação das Perdas Totais

Para a estimação das perdas totais, foi considerado o relacionamento da corrente de excitação, das resistências das bobinas de baixa tensão e de alta tensão e da temperatura ambiente. Foram utilizados valores mínimos, médios e máximos das grandezas acima mencionadas.

A Tabela 6.3 destaca os valores mínimos, médios e máximos dessas grandezas, empregados nas simulações para as perdas totais.

Tabela 6.3 - Faixa de valores de teste utilizados na rede neural.

	Valores Máximos	Valores Médios	Valores Mínimos
R_{AT}	40,43 (Ω)	39,131 (Ω)	38,11 (Ω)
R_{BT}	7,5 (m Ω)	7,156 (m Ω)	6,58 (m Ω)
I_{ex}	7,51 (A)	6,713 (A)	5,97 (A)
T_A	34 ($^{\circ}$ C)	27,96 ($^{\circ}$ C)	19 ($^{\circ}$ C)
PT	1.442 (W)	1.422,5 (W)	1.390 (W)

A Figura 6.10 mostra o comportamento das perdas totais em relação à variação da média das 3 resistências das bobinas de baixa tensão (R_{BT}). Na simulação, foram usados valores mínimos, médios e máximos da média das 3 resistências da bobina de alta tensão (R_{AT}), da corrente de excitação (I_{ex}) e da temperatura ambiente (T_A).




Figura 6.10 - Variação das perdas totais x média das 3 resistências das bobinas de baixa tensão.

Observa-se na Figura 6.10 uma tendência crescente nas curvas 1 e 2, constatando também que as curvas 2 e 3 apresentam valores de perdas totais próximos e comportamentos diferentes, mesmo considerando valores médios e máximos das grandezas citadas. A curva 1 fica distanciada e com comportamento um pouco diferente (quase constante). Este tipo de análise mostra a sensibilidade da rede neural desenvolvida. Para manter as perdas totais em limites convenientes, é necessário utilizar valores menores de resistências, o que pode ser constatado na curva 1 que empregou valores mínimos.

Vale ressaltar que os valores simulados para as curvas 2 e 3 são valores hipotéticos, em desacordo com os valores recomendados por norma. Entretanto, esta condição fornece subsídios importantes para o projeto dos transformadores, uma vez que identifica qual a pior e a melhor situação.

A Figura 6.11 ilustra o comportamento das perdas totais em relação à variação da média das 3 resistências das bobinas de alta tensão (R_{AT}). No caso, foram usados valores mínimos, médios e máximos da média das 3 resistências da bobina de alta tensão (R_{BT}), da corrente de excitação (I_{ex}), temperatura ambiente (T_A).




Figura 6.11 - Variação das perdas totais x média das 3 resistências das bobinas de alta tensão.

Constata-se, na Figura 6.11, um comportamento diferenciado para as 3 curvas: na curva 3 (valores máximos) obteve-se uma curva quase exponencial com valores de perdas totais altas; na curva 2 (valores médios), obteve-se uma curva quase linear com valores para perdas totais satisfatórios e, finalmente para curva 1 (valores mínimos), o comportamento foi totalmente linear e crescente, mas obedecendo aos valores descritos por norma.

A Figura 6.12 apresenta o comportamento das perdas totais em relação à variação da corrente de excitação (I_{ex}). Foram usados valores mínimos,

médios e máximos da média da média das 3 resistências das bobinas de alta tensão (R_{AT}), 3 resistências da bobina de alta tensão (R_{BT}) e temperatura ambiente (T_A).




Figura 6.12 - Variação das perdas totais x corrente de excitação.

A partir da Figura 6.12, verifica-se a influência da corrente de excitação no cálculo geral das perdas totais. Esse tipo de detalhe evidencia a sua contribuição, tanto para as perdas no cobre (Figura 6.9) como para as perdas totais, pois tiveram um comportamento praticamente igual.

A Figura 6.13 mostra o comportamento das perdas totais em relação à variação da temperatura ambiente (T_A). Na simulação foram usados valores mínimos, médios e máximos da média da média das 3 resistências das bobinas de alta tensão (R_{AT}), das 3 resistências da bobina de alta tensão (R_{BT}) e da corrente de excitação (I_{ex}).




Figura 6.13 - Variação das perdas totais x temperatura.

A partir da Figura 6.13, verifica-se um comportamento tradicional da temperatura, verificado em diversas literaturas, porém com uma forma não linear para as 3 situações.

Na Figura 6.14, apresenta-se o perfil das perdas totais realizada pela rede, levando-se em conta os dados de teste e a estimativa da rede com o respectivo erro relativo.




Figura 6.14 - Variação da perdas totais x generalização da rede.

Consta-se na Figura 6.14 que o valor de teste ficou muito próximo dos valores obtidos nos ensaios de laboratório, evidenciando desta maneira, o sucesso desta aplicação para este tipo de problema.

A Tabela 6.4 apresenta valores máximos e mínimos utilizados para o teste da rede neural.

Tabela 6.4 - Valores mínimos e máximos dos dados de teste.

Ensaio	Valores Mínimos (W)	Valores Máximos (W)
Perdas em Vazio	309	364
Perdas no Cobre	1.040	1.130
Perdas Totais	1.485	1.366

Conforme apresentado na Tabela 6.4, as variáveis que constituem as saídas das redes apresentam uma faixa bastante interessante, pois abrangem grande parte das situações que podem ocorrer em ensaios em laboratório, levando-se em conta as perdas em vazio, perdas no cobre e perdas totais.

As simulações apresentadas neste capítulo mostram que realmente existe uma relação entre as grandezas advindas dos ensaios laboratoriais com os dados que a rede generalizou, e a metodologia proposta prevê a possibilidade de estimar as perdas elétricas presentes em um transformador, diminuindo assim maneira, a realização de alguns tipos de ensaios laboratoriais.

Deve-se ressaltar que a aplicação da técnica proposta fornece subsídios para o projetista, quanto à escolha do melhor material a ser empregado tanto nos enrolamentos como também nas chapas que compõem o núcleo. Esses resultados podem ser utilizados como uma ferramenta computacional de apoio para quantificar e estimar as perdas elétricas em transformadores.

Uma das principais contribuições constatadas neste trabalho é que as simulações consideram valores máximos, médios e mínimos de cada grandeza que fazem parte do processo de perdas elétricas. Este tipo de comportamento seria muito difícil de ser estabelecido nos ensaios experimentais, pois utilizaram-se valores hipotéticos para detectar qual seria o perfil das perdas elétricas.

De uma maneira geral, verificou-se, através dos resultados apresentados, a possibilidade do desenvolvimento de uma abordagem neural para melhorar o conhecimento das perdas elétricas no transformador, bem como otimizar parte de alguns ensaios de rotina, o que vai, sem dúvida, inferir diretamente no custo final do transformador e impactar, de maneira positiva, em estudos correlatos.

CAPÍTULO 7

CONCLUSÕES

Neste trabalho a abordagem neural foi utilizada como um instrumento eficiente e alternativo na estimação e quantificação de processos de perdas elétricas em transformadores. Os valores utilizados na rede foram advindos de testes laboratoriais. Depois do treinamento, a rede foi capaz de estimar valores de perdas elétricas, e esta propriedade permite reduzir o tempo gasto com ensaios experimentais realizados em laboratórios, possibilitando, assim uma otimização dos custos de projetos.

A abordagem neural desenvolvida poderá ser utilizada para identificação de problemas técnicos que dificultam a fabricação de transformadores de distribuição.

Os resultados obtidos das simulações têm mostrado que a técnica pode ser utilizada como uma ferramenta computacional de apoio no diagnóstico de perdas em transformadores, vindo a contribuir decisivamente para uma melhor qualidade do sistema de energia como um todo.

Os resultados das simulações deste trabalho mostram que a técnica desenvolvida pode ser usada como uma ferramenta alternativa visando também adequar a qualidade dos projetos de transformadores.

7.1. Futuras Linhas de Pesquisa

A partir dos resultados apresentados, permite-se vislumbrar algumas linhas de pesquisa como uma continuidade do que foi apresentado. Entre as futuras linhas de pesquisa, destacam-se:

- i) estudos sobre a verificação do impacto das perdas elétricas frente aos índices de desempenho que indicam a qualidade dos sistemas de distribuição;
- ii) pesquisas sobre a identificação de problemas técnicos que dificultam a fabricação de transformadores de distribuição com perdas mínimas, considerando também a busca de uma relação custo/benefício em patamares aceitáveis;
- iii) desenvolvimento de sistemas de apoio à decisão que possibilitem a realização de análises que determinem os ganhos advindos da minimização de perdas de potência, quando se levam em consideração os custos envolvidos com a aquisição do transformador;
- iv) estudos para aumentar a vida útil dos transformadores, a partir da minimização das perdas elétricas, integrando os aspectos térmicos, os magnéticos e a inserção de novos materiais.

REFERÊNCIAS BIBLIOGRÁFICAS

- ADLY, A. A. Determination of Total transformer Losses Resulting From Semirotating Flux Excitation, *IEEE Transactions on Magnetics*, vol.31, No. 6, 1995.
- BATTITI, R. First and second order method for learning: between steepest descent and Newton's method. *Neural Computation*. v. 4, n.2, pp. 141-166, 1992.
- B. W. McConnell, "Increasing Distribution Transformer Efficiency: Potencial for Energy Savings". *IEEE Power Eng. Ver.*, Vol.18, pp. 8-10, 1998.
- CAVALCANTI, P. J. Fundamentos de eletrotécnica para técnicos em eletrotécnica. 17^a. ed. Ver. E mlh. Rio de Janeiro, Freitas Bastos, 1987.
- ENOKIZONO, M. and SODA, N., Core loss analysis of transformer by improved FEM, *Journal of Magnetism and Magnetic Materials* 196- 197, 1999, 910-912.
- FALCONE, A. G. Eletromecânica: transformadores e transdutores, conversão eletromecânica de energia, máquinas elétricas, 2^a reimpressão. São Paulo, Editora Edgard Blucher Ltda, 1992.
- FORESSE, F. D.; HAGAN, M. T. Gauss-Newton approximation to neural networks. *In: INTERNATIONAL JOINT CONFERENCE ON NEURAL NETWORKS*, pp. 1930-1935, 1997.
- GEROMEL, L. H.; The Application of Artificial Neural Networks in Power Transformer Design, *IEEE Induscon*, CD, 2002.
- GEORGILAKIS, P. S., Prediction of iron losses of wound core distribution transformers based on artificial neural networks, *Elsivier Science*, vol. 23, Issues 1-3, 1998.

- HAGAN, M. T.; MENHAJ, M. B. Training feedforward networks with the Marquardt algorithm. *IEEE Trans on Neural Networks*, v. 5, n. 6, pp. 989-993, 1994.
- HAYKIN, S.; LEUNG, H. Blind equalization formulated as a self-organized learning process. *ASILOMAR CONFERENCE ON SIGNALS, SYSTEMS, AND COMPUTERS*, 26, *Pacific Grove*: p.346-350, 1992.
- HAYKIN, S. *Neural Networks - A Comprehensive Foundation*. Englewood Cliffs: *Macmillan*, 1994.
- HECHT-NIELSEN, R. *Neurocomputing*. *Massachusetts: Addison-Wesley*, 1990.
- HUSH, D. R.; HORNE, B. G. Progress in Supervised Neural Networks. *IEEE Signal Processing Magazine*, Jan. p. 8-39, 1993.
- KOHONEN, T. Self- Organized formation of topologically correct feature maps. *Biological Cybernetics*, 43, p. 59-69, 1982.
- KOHONEN, T. Learning vector quantization for paltern recognition. Technical Report TKK- F-A601. Furland: *Helsinki University of Technology*, 1986.
- MARTIGNONI, A. *Transformadores*. 8. edição – São Paulo: Globo, 1991.
- MCCULLOCH, W. S. et al. A logical calculus of the ideas immanent in nervous activity. *Bulletin of Mathematical Biophysics*, v. 5, n.1, pp. 115-133, 1943.
- NARENDRA, K. S. et al. Identification and control of dynamical systems using neural networks. *IEEE Trans. On Neural Networks*, v.1. p. 4-27, 1990.
- MCCONNELL, B.W. Increasing Distribution on Transformer Efficiency. Potencial for Energy Savings. *IEEE Power Eng. Ver.*, vol. 18, pp. 8-10, 1998.
- NBR – 5356,” *Transformadores de Potência*” , *Associação Brasileira de Normas Técnicas - ABNT*, 1993.

- NBR – 5380,” Transformadores de Potência” , *Associação Brasileira de Normas Técnicas* - ABNT, 1993.
- NBR-5440, ”Transformadores de Distribuição de Energia Elétrica”, *Associação Brasileira de Normas Técnicas* - ABNT, 1987.
- OLIVEIRA, J. C. Transformadores: teoria e ensaios. 4ª reimpressão – São Paulo: Editora Edgard Blucher Ltda, 1998.
- SILVA, I. N. Estimção paramétrica robusta através de redes neurais artificiais. Campinas – SP, Janeiro de 1995. Dissertação de Mestrado. DCA/FEE/UNICAMP, Universidade de Campinas.
- SILVA, I. N. Uma abordagem neuro-nebulosa para otimização de sistemas e identificação robusta. Campinas – SP, Janeiro de 1997. Tese de Doutorado. DCA/FEE/UNICAMP, Universidade de Campinas.
- SISSIMATOS, E and Harms. G, Design rule for high-temperature superconducting power transformers, *Physica C* 354, 2001, 23- 26.
- REINERT, J. Calculation of Losses in Ferro- and Ferrimagnetic Materials Based on the Modified Steinmetz Equation, *IEEE Transactions on Industry Applications*. Vol. 37, NO. 4, 2001.
- TAGLIARINI, G. A.; CHRIST, J. F.; PAGE, E. W. Optimization using neural networks. *IEEE Trans. on Computers*, v. 40, n. 12, p 1347-1358, 1991.
- VAN DER SMAGT, P. P.; KROSE, J. A. A real-time learning neural robot controller. *INTERNATIONAL CONFERENCE ON ARTIFICIAL NEURAL NETWORK*, Finland: p. 351-356, 1991.
- WAIBEL, A. et al. Phoneme recognition using time delay neural networks. *IEEE Trans. on Acoustics*, ASSP-37, p. 328-339, 1989.
- WIDROW, B. et al. Layered neural nets for pattern recognition. *IEEE Trans. on Acoustics*, v. 36, p. 1109-1117, 1998.

APÊNDICE A

Este apêndice mostra a rede neural utilizada neste mapeamento, que foi do tipo Perceptron multicamadas, e o treinamento supervisionado pelo algoritmo Levenberg-Marquardt com regularização bayesiana.

ALGORITMO PARA TESTE DE RNA (Transformador:75 kVA)

clear all;

Matriz de dados

Ensaio de Curto Circuito

Transformador 75kVA

RAT	RBT	I _{ex}	Temp	V _{cc}	P _{cu}
M1=[	39.17	7.49	5.63	35.5	446.45
	38.98	7.32	6.30	30.0	435.22
	39.65	7.18	6.53	31.0	439.84
	39.23	7.03	6.39	27.5	438.40
	39.43	7.07	7.05	27.5	442.86
	39.40	7.42	6.31	35.0	443.96
	39.68	7.43	7.41	32.5	445.36
	39.70	7.22	6.39	31.5	437.55
	39.91	7.14	6.53	31.5	442.99
	37.25	6.88	5.74	20.5	433.78
	37.24	6.90	5.61	20.5	430.03
	37.40	6.92	5.51	20.5	432.19
	37.09	7.08	5.55	20.5	434.98
	38.72	7.17	5.40	28.5	434.28
	39.90	7.19	5.54	34.0	431.18
	37.43	7.00	5.55	20.0	438.07

					1079
					1088
					1102
					1070
					1082
					1088
					1097
					1089
					1090
					1052
					1052
					1058
					1052
					1085
					1105
					1048.....];
Mt1=[	38.68	7.14	7.53	29.0	432.81
	40.83	7.31	7.76	30.5	436.89
	38.52	7.28	7.44	24.3	434.26
	38.72	7.08	6.79	24.0	439.56
	40.07	7.41	7.50	32.5	441.77
	40.30	7.45	7.43	19.5	440.51
	39.08	7.42	7.96	25.5	440.28
	38.45	7.19	6.28	28.5	430.53
	38.94	7.07	5.56	28.0	436.57
	39.37	7.12	6.84	28.0	437.72

ALGORITMO PARA TREINAMENTO DA REDE NEURAL COM SAÍDA PARA PERDAS NO COBRE

DEFININDO OS PARÂMETROS DA REDE

X=[M1(:,1)'

M1(:,2)'

```

M1(:,3)'
M1(:,4)'
M1(:,5)']; % Matriz contendo as variáveis de entrada
d=[M1(:,6)']; % Vetor de saída
dominio = [min(X')
            max(X')]; % Obtendo o Domínio das entradas
camadas=[2,3,1] %0,10,1] % Especificando as camadas neurais
ativacoes={'tansig','tansig','purelin'}
Funções de Ativação das camadas neurais
treinamento='trainbr' % Algoritmo de treinamento utilizado

```

CRIANDO A REDE PERCEPTRON

```
net=newff(dominio,camadas,ativacoes,treinamento);
```

DEFININDO OS PARÂMETROS DO TREINAMENTO

```

net.trainParam.show=25; % Mostra a performance do treinamento a cada 25 épocas
net.trainParam.epochs=2000; % Finalizar o treinamento da rede após 1000 épocas
net.trainParam.goal=1e-3; % Finalizar o treinamento da rede quando atingir 0.5E-5
net.trainParam.mem_reduc = 2; % diminuição da memória usada

```

PRÉ-PROCESSANDO OS DADOS DE ENTRADAS E SAÍDAS (Dados de Treinamento)

```
[X,min_x,max_x,d,min_d,max_d] = premnmx(X,d);
```

TREINANDO A REDE

```
[net, erro] = train(net,X,d);
```

TESTANDO A REDE COM OS PADRÕES DE TESTE

MATRIZ M DE TESTE

```

X=[Mt1(:,1)'
   Mt1(:,2)'
   Mt1(:,3)'
   Mt1(:,4)'
   Mt1(:,5)']; % Matriz contendo as variáveis de entrada
d = [Mt1(:,6)']; % Vetor de saída

```

```

X=tramnmx(X,min_x,max_x); % Normaliza as Entradas da Matriz de Teste
resposta1=sim(net,X); % Simula a saída da rede (Resposta normalizada)

```

PÓS-PROCESSANDO OS DADOS DE SAÍDA DA REDE

```
resposta2=postmnmx(resposta1,min_d,max_d);   saída da rede (Resposta não-  
normalizada)  
resposta2f=medfilt1(resposta2,1)
```

MOSTRA RESPOSTA DA REDE || RESPOSTA DESEJADA ||

```
resposta3=[d' resposta2]  
plot(resposta3);  
camadas  
ativações
```

CALCULANDO O ERRO RELATIVO ENTRE A RESPOSTA DA REDE E A RESPOSTA DESEJADA

```
erro_relativo=abs(100*(resposta3(:,1)-resposta3(:,2))./resposta3(:,1)));
```

MOSTRA RESPOSTA DA REDE || RESPOSTA DESEJADA || ERRO RELATIVO

```
resposta4=[d' resposta2 erro_relativo];
```

CALCULANDO O ERRO RELATIVO MÉDIO E A VARIÂNCIA

```
Erro_Medio = mean(erro_relativo)  
Desvio_Padiao = std(erro_relativo)  
variancia = Desvio_Padiao
```

PLOTANDO A CURVA DO ERRO EM FUNÇÃO DAS ÉPOCAS

```
plot(Erro_Medio);  
xlabel('Epocas de Treinamento');  
ylabel('Erro Quadratico Medio');  
title('Desempenho do Erro');  
plot(Mt1(:,1),resposta2)  
ylabel('perdas cobre');  
xlabel('RAT');  
disp('pause.....')  
pause;  
plot(Mt1(:,3),resposta2)  
ylabel('perdas cobre');  
xlabel('Iex');  
disp('pause.....')  
pause;  
bar(resposta3)  
ylabel('Pcu')  
xlabel('AMOSTRAS')  
title('Saída desejada x Saída da rede:generalização')
```


ALGORITMO PARA TESTE DE RNA (Transformador: 75 KVA)

```
clear all;
```

```
load net_pcu_5nova7;  arquivo que contem net, máximos e mínimos.
```

Matriz dos dados de teste

	RAT	RBT	Iex	Temp	Vcc	Pcu
Mt=	38.68	7.14	7.53	29.0	432.81	1083
	40.83	7.31	7.76	30.5	436.89	1106
	38.52	7.28	7.44	24.3	434.26	1072
	38.72	7.08	6.79	24.0	439.56	1077
	40.07	7.41	7.50	32.5	441.77	1110
	40.30	7.45	7.43	19.5	440.51	1045
	39.08	7.42	7.96	25.5	440.28	1092
	38.45	7.19	6.28	28.5	430.53	1080
	38.94	7.07	5.56	28.0	436.57	1086
	39.37	7.12	6.84	28.0	437.72	1094];

```
% vetorização.....
```

```
vet_max_RAT = Linspace(max(Mt(:,1)),max(Mt(:,1)),10);
vet_max_RBT = Linspace(max(Mt(:,2)),max(Mt(:,2)),10);
vet_max_Iex = Linspace(max(Mt(:,3)),max(Mt(:,3)),10);
vet_max_Temp = Linspace(max(Mt(:,4)),max(Mt(:,4)),10);
vet_max_Vcc = Linspace(max(Mt(:,5)),max(Mt(:,5)),10);
vet_max_Pcu = Linspace(max(Mt(:,6)),max(Mt(:,6)),10);
```

```
vet_min_RAT = Linspace(min(Mt(:,1)),min(Mt(:,1)),10);
vet_min_RBT = Linspace(min(Mt(:,2)),min(Mt(:,2)),10);
vet_min_Iex = Linspace(min(Mt(:,3)),min(Mt(:,3)),10);
vet_min_Temp = Linspace(min(Mt(:,4)),min(Mt(:,4)),10);
vet_min_Vcc = Linspace(min(Mt(:,5)),min(Mt(:,5)),10);
vet_min_Pcu = Linspace(min(Mt(:,6)),min(Mt(:,6)),10);
```

```
escala_RAT = Linspace(min(Mt(:,1)),max(Mt(:,1)),10); % linearizado....do
mínimo ao máximo em 12 steps....
```

```
escala_RBT = Linspace(min(Mt(:,2)),max(Mt(:,2)),10);
escala_Iex = Linspace(min(Mt(:,3)),max(Mt(:,3)),10);
escala_Temp = Linspace(min(Mt(:,4)),max(Mt(:,4)),10);
escala_Vcc = Linspace(min(Mt(:,5)),max(Mt(:,5)),10);
escala_Pcu = Linspace(min(Mt(:,6)),max(Mt(:,6)),10);
```

```
soma_RAT=cumsum(Mt(:,1));
soma_RBT=cumsum(Mt(:,2));
soma_Iex=cumsum(Mt(:,3));
soma_Temp=cumsum(Mt(:,4));
soma_Vcc=cumsum(Mt(:,5));
soma_Pcu=cumsum(Mt(:,6));
```

```
media_RAT = Linspace(soma_RAT(10)/10,soma_RAT(10)/10,10);
media_RBT = Linspace(soma_RBT(10)/10,soma_RBT(10)/10,10);
media_Iex = Linspace(soma_Iex(10)/10,soma_Iex(10)/10,10);
media_Temp = Linspace(soma_Temp(10)/10,soma_Temp(10)/10,10);
media_Vcc = Linspace(soma_Vcc(10)/10,soma_Vcc(10)/10,10);
media_Pcu= Linspace(soma_Pcu(10)/10,soma_Pcu(10)/10,10);
```

MATRIZ M DE TESTE

GRAFICO 1 Pcu X Vcc

Simulação 1: PCu x Vcc e demais variáveis com valores médios

```
X= [media_RAT
    media_RBT
    media_Iex
    media_Temp
    escala_Vcc];      Vetor com dados lineares
d=[ escala_Pcu];    valor linearizado de escala_PT - Vetor de saída
```

```
X=tramnmx(X,min_x,max_x);      Normaliza as Entradas da Matriz de Teste
resposta1_med=sim(net,X)';      Simula a saída da rede (Resposta normalizada)
resposta2_med=postmnmx(resposta1_med,min_d,max_d);    saída da rede (Resposta
não-normalizada)
plot(escala_Vcc,resposta2_med);
resposta3=[d' resposta2_med];
```

PÓS-PROCESSANDO OS DADOS DE SAÍDA DA REDE

```
resposta2=postmnmx(resposta1_med,min_d,max_d); % saída da rede (Resposta não-
normalizada)
```

```
MOSTRA RESPOSTA DA REDE || RESPOSTA DESEJADA ||
resposta3=[d' resposta2];
```

Calculando o erro relativo entre a resposta da rede e a resposta desejada

```
erro_relativo=abs(100*(resposta3(:,1)-resposta3(:,2))./resposta3(:,1));
%Mostra resposta da rede, resposta desejada, erro relativo
resposta4=[d' resposta2 erro_relativo];
%Calculando o erro relativo médio e a variância
Erro_Medio=mean(erro_relativo)
Desvio_Padiao=std(erro_relativo)
variância=Desvio_Padiao^2
```

Simulação 2: PCu x Vcc e demais variáveis em máximos

```
X=[vet_max_RAT
   vet_max_RBT
   vet_max_Iex
   vet_max_Temp
   escala_Vcc]; - Vetor com dados lineares
d=[ escala_Pcu]; valor linearizado de escala_PT - Vetor de saída

X=tramnmx(X,min_x,max_x);      Normaliza as Entradas da Matriz de Teste
resposta1_max=sim(net,X)';      Simula a saída da rede (Resposta normalizada)
resposta2_max=postmnmx(resposta1_max,min_d,max_d); saída da rede (Resposta
não-normalizada)
plot(escala_Vcc,resposta2_max);
```

Simulação 3: PCu x Vcc e demais variáveis em mínimos

```
X=[vet_min_RAT
   vet_min_RBT
   vet_min_Iex
   vet_min_Temp
   escala_Vcc]; Vetor com dados lineares
d=[ escala_Pcu]; valor linearizado de escala_PT Vetor de saída
X=tramnmx(X,min_x,max_x);      Normaliza as Entradas da Matriz de Teste
resposta1_min=sim(net,X)';      Simula a saída da rede (Resposta normalizada)
resposta2_min=postmnmx(resposta1_min,min_d,max_d);
plot(escala_Vcc,resposta2_min);
plot(escala_Vcc,resposta2_min,'-o',escala_Vcc,resposta2_max,'-
x',escala_Vcc,resposta2_med,'-.')
ylabel('Perda Cobre');
```



```
xlabel('Vcc');
disp('.....pause ..... Vcc x Pcu');
pause;
```

GRAFICO 2 RAT x PCu

Simulação 1: PCu x RAT e demais variáveis com valores médios

```
X=[escala_RAT
    media_RBT
    media_Iex
    media_Temp
    media_Vcc]; Vetor com dados lineares
d=[ escala_Pcu]; valor linearizado de escala_PT - Vetor de saída

X=tramnmx(X,min_x,max_x); Normaliza as Entradas da Matriz de Teste
resposta1_med=sim(net,X); Simula a saída da rede (Resposta normalizada)
resposta2_med=postmnmx(resposta1_med,min_d,max_d); saída da rede (Resposta
não-normalizada)
plot(escala_RAT,resposta2_med);
resposta3=[d' resposta2_max];
```

Simulação 2: PCu x RAT e demais variáveis em máximos

```
X=[escala_RAT
    vet_max_RBT
    vet_max_Iex
    vet_max_Temp
    vet_max_Vcc]; Vetor com dados lineares
d=[ escala_Pcu]; valor linearizado de escala_PT - Vetor de saída
X=tramnmx(X,min_x,max_x); Normaliza as Entradas da Matriz de Teste
resposta1_max=sim(net,X); Simula a saída da rede (Resposta normalizada)
resposta2_max=postmnmx(resposta1_max,min_d,max_d); saída da rede (Resposta
não-normalizada)
plot(escala_RAT,resposta2_max);
```

Simulação 3: Pcu x RAT com variação de perda a vazio e demais variáveis em máximos

```
X=[escala_RAT
    vet_min_RBT
```



```

vet_min_Iex
vet_min_Temp
vet_min_Vcc]; Vetor com dados lineares
d=[ escala_Pcu]; valor linearizado de escala_PT - Vetor de saída

X=tramnmx(X,min_x,max_x); Normaliza as Entradas da Matriz de Teste
resposta1_min=sim(net,X); Simula a saída da rede (Resposta normalizada)
resposta2_min=postmnmx(resposta1_min,min_d,max_d); saída da rede (Resposta
não-normalizada)
plot(escala_RAT,resposta2_min);

plot(escala_RAT,resposta2_min,'-o',escala_RAT,resposta2_max,'-
x',escala_RAT,resposta2_med,'-.')
ylabel('Perda Cobre');
xlabel('RAT')
disp ('.....pause .....PCu x RAT');
pause

```

GRAFICO 3 .PCu X RBT.

Simulação 1: Pt x Pvazio com variação de perda a vazio e demais variáveis com valores médios

```

X= [media_RAT
escala_RBT
media_Iex
media_Temp
media_Vcc]; Vetor com dados lineares
d=[ escala_Pcu]; valor linearizado de escala_PT - Vetor de saída

X=tramnmx(X,min_x,max_x); Normaliza as Entradas da Matriz de Teste
resposta1_med=sim(net,X); Simula a saída da rede (Resposta normalizada)
resposta2_med=postmnmx(resposta1_med,min_d,max_d); saída da rede (Resposta
não-normalizada)
plot(escala_RBT,resposta2_med);
resposta3=[d' resposta2_max];

```

Simulação 2: PCu x RBT e demais variáveis em máximos

```

X= [vet_max_RAT
escala_RBT
vet_max_Iex
vet_max_Temp
vet_max_Vcc]; Vetor com dados lineares

```

```
d=[ escala_Pcu];      valor linearizado de escala_PT      - Vetor de saída

X=tramnmx(X,min_x,max_x);      Normaliza as Entradas da Matriz de Teste
resposta1_max=sim(net,X)';      Simula a saída da rede (Resposta normalizada)
resposta2_max=postmnmx(resposta1_max,min_d,max_d); saída da rede (Resposta
não-normalizada)
plot(escala_RBT,resposta2_max);
```

Simulação 3: Pt x Pvazio com variação de perda a vazio e demais variáveis em máximos

```
X=[vet_min_RAT
  escala_RBT
  vet_min_Iex
  vet_min_Temp
  vet_min_Vcc];      Vetor com dados lineares
d=[ escala_Pcu];      valor linearizado de escala_PT      Vetor de saída

X=tramnmx(X,min_x,max_x);      Normaliza as Entradas da Matriz de Teste
resposta1_min=sim(net,X)';      Simula a saída da rede (Resposta normalizada)
resposta2_min=postmnmx(resposta1_min,min_d,max_d); saída da rede (Resposta
não-normalizada)
plot(escala_RBT,resposta2_min);

plot(escala_RBT,resposta2_min,'-o',escala_RBT,resposta2_max,'-
x',escala_RBT,resposta2_med,'-.')
ylabel('Perda Cobre');
xlabel('RBT');
disp ('....pause .....RBT x Pcu');
```

pause

GRAFICO 4 PCu X Iex

Simulação 1: Pt x Pvazio com variação de perda a vazio e demais variáveis com valores médios

```
X=[media_RAT
  media_RBT
  escala_Iex
  media_Temp
  media_Vcc];      Vetor com dados lineares
d=[ escala_Pcu];      valor linearizado de escala_PT      Vetor de saída
```

```

X=tramnmx(X,min_x,max_x);      Normaliza as Entradas da Matriz de Teste
resposta1_med=sim(net,X)';      Simula a saída da rede (Resposta normalizada)
resposta2_med=postmnmx(resposta1_med,min_d,max_d); saída da rede (Resposta
não-normalizada)
plot(escala_lex,resposta2_med);

```

Simulação 2: PCu x I_{lex} e demais variáveis em máximos

```

X=[vet_max_RAT
  vet_max_RBT
  escala_lex
  vet_max_Temp
  vet_max_Vcc];      Vetor com dados lineares
d=[ escala_Pcu];      valor linearizado de escala_PT      Vetor de saída

```

```

X=tramnmx(X,min_x,max_x);      Normaliza as Entradas da Matriz de Teste
resposta1_max=sim(net,X)';      Simula a saída da rede (Resposta normalizada)
resposta2_max=postmnmx(resposta1_max,min_d,max_d); saída da rede (Resposta
não-normalizada)
plot(escala_lex,resposta2_max);

```

Simulação 3: PCu x I_{lex} e demais variáveis em mínimos

```

X=[vet_min_RAT
  vet_min_RBT
  escala_lex
  vet_min_Temp
  vet_min_Vcc];      Vetor com dados lineares
d=[ escala_Pcu];      valor linearizado de escala_PT      Vetor de saída

```

```

X=tramnmx(X,min_x,max_x);      Normaliza as Entradas da Matriz de Teste
resposta1_min=sim(net,X)';      Simula a saída da rede (Resposta normalizada)
resposta2_min=postmnmx(resposta1_min,min_d,max_d); saída da rede (Resposta
não-normalizada)
plot(escala_lex,resposta2_min);

```

```

plot(escala_lex,resposta2_min,'-o',escala_lex,resposta2_max,'-
x',escala_lex,resposta2_med,'-.')
ylabel('Perda Cobre');
xlabel('Ilex');

```

```

disp ('....pause .....Iex x Pcu');

```

GRAFICO 5 Pcu X Temp

Simulação 1: PCu x Temp e demais variáveis com valores médios

```

X= [media_RAT
    media_RBT
    media_Iex
    escala_Temp
    media_Vcc];      Vetor com dados lineares
d=[ escala_Pcu];     valor linearizado de escala_PT      -      Vetor de saída

X=tramnmx(X,min_x,max_x);      Normaliza as Entradas da Matriz de Teste
resposta1_med=sim(net,X)';      Simula a saída da rede (Resposta normalizada)
resposta2_med=postmnmx(resposta1_med,min_d,max_d); saída da rede (Resposta
não-normalizada)
plot(escala_Temp,resposta2_med);
  
```

Simulação 2: PCu x Temp e demais variáveis em máximos

```

X= [vet_max_RAT
    vet_max_RBT
    vet_max_Iex
    escala_Temp
    vet_max_Vcc];      Vetor com dados lineares
d=[ escala_Pcu];     valor linearizado de escala_PT      -      Vetor de saída

X=tramnmx(X,min_x,max_x);      Normaliza as Entradas da Matriz de Teste
resposta1_max=sim(net,X)';      Simula a saída da rede (Resposta normalizada)
resposta2_max=postmnmx(resposta1_max,min_d,max_d); saída da rede (Resposta
não-normalizada)
plot(escala_Temp,resposta2_max);
  
```

Simulação 3: PCu x Temp e demais variáveis em mínimos

```

X= [vet_min_RAT
    vet_min_RBT
    vet_min_Iex
    escala_Temp
    vet_min_Vcc];      Vetor com dados lineares
d=[ escala_Pcu];     valor linearizado de escala_PT      -      Vetor de saída

X=tramnmx(X,min_x,max_x);      Normaliza as Entradas da Matriz de Teste
resposta1_min=sim(net,X)';      Simula a saída da rede (Resposta normalizada)
  
```



```
resposta2_min=postmnmx(resposta1_min,min_d,max_d); saída da rede (Resposta
não-normalizada)
plot(escala_Temp,resposta2_min);

plot(escala_Temp,resposta2_min,'-o',escala_Temp,resposta2_max,'-
x',escala_Temp,resposta2_med,'-.')
ylabel('Perda Cobre');
xlabel('Temperatura');

disp ('....pause .....');

pause;
bar(resposta3)
ylabel('Perda Cobre');
xlabel('AMOSTRAS');
disp ('....pause .....');
pause;
bar(resposta4)
ylabel('Perda Cobre');
xlabel('AMOSTRAS');
```

APÊNDICE B

Este apêndice mostra a folha de relatório dos ensaios de transformadores da empresa INCOTRAZA – Indústria e comércio de transformadores Zago Ltda, que serviu como base de dados para a implementação da rede neural utilizada neste trabalho.

INCOTRAZA
INDÚSTRIA E COMÉRCIO DE TRANSFORMADORES ZAGO
LTD.

RELATÓRIO DOS ENSAIOS DE TRANSFORMADORES

ENSAIO DE ROTINA DO TRANSFORMADOR COM AS CARACTERÍSTICAS ABAIXO:

Número: 21606	Frequência:[Hz]: 60	Corrente A.T. [A]: 3,14
Potência[kVA]: 75,0	Tensões A.T. [k V]: 13,80 a 10,20	Corrente B. T. [A]: 196,82
Fases : 3	Tensões B.T. [V]: 220/127	Data da Fabricação: 09/04/01
Ligação: Triângulo /Estrela	Derivações: 7	Estado: Novo
Tipo: Aéreo Convencional	A. T. Ligada em [k V]: 13,8	Peso [Kg]: 357
Modelo:	A. T. Ligada em [V]: 220	

ENSAIO DE RESISTÊNCIA DOS ENROLAMENTOS DESLOCAMENTO ANGULAR

H1H2: 36,30 [OHMS]	X1X2: 9,52 [mOHMS]
H1H3: 36,16 [OHMS]	X1X3: 9,49 [mOHMS]
H2H3: 36,30 [OHMS]	X2X3: 9,41 [mOHMS]
Temperatura Ambiente [°C]: 34,0	

Deslocamento Angular: 30 graus

RESISTÊNCIA DE ISOLAMENTO

TENSÃO APLICADA

TENSÃO INDUZIDA

Leitura AT/BT [MOHMS]: 10000
 Leitura AT/MASSA [MOHMS]: 10000
 Leitura BT/MASSA [MOHMS]: 7500
 Tensão do Megômetro [V]: 2500

AT/BT à massa [k V]: 34
 BT/AT à massa [k V]: 34
 Frequência [Hz]: 60
 Tempo de Ensaio [s]: 60

Tensão Induzida [V]: 440
 Frequência [Hz]: 120
 Tempo de Ensaio [s]: 60
 Método de Ensaio: Normal

ENSAIO DE RELAÇÃO DE TRANSFORMAÇÃO

Tap [V]:	13800	13200	12600	12000	11400	10800	10200
Fase 1:	108,72	103,98	99,26	94,55	89,83	85,09	80,37
Fase 2:	108,73	103,98	99,27	94,55	89,84	85,12	80,38
Fase 3:	108,72	103,98	99,26	94,55	89,83	85,08	80,37
Erro [%]:	0,08	0,06	0,07	0,08	0,10	0,11	0,09

ENSAIO A VAZIO

Tensão de Ensaio [V]: 220
Corrente de Excitação [A]: 6,62
Corrente de Excitação [%]: 3,37
Perdas em vazio [W]: 318

VALORES CORRIGIDOS A 75 [°C]

Perdas no Cobre [W]: 1290
Perdas Totais [W]: 1608
Rendimento a plena Carga [%]: 97,5
Impedância de Curto Circuito [%]: 3,40

ENSAIO DE CURTO CIRCUITO

Corrente de curto circuito [A]: 3,14
Tensão de Curto Circuito [V]: 454,97
Potência de Curto Circuito [W]: 1130
Temperatura Ambiente [°C]: 34,0

ENSAIO DE PINTURA

Espessura da Camada : (NBR 5440)
Valores medidos:
P. Interna Fundo:40 P. Externa Fundo:50
P. Acabamento: 60 unidade: [microns]
Aderência (NBR 11003) Grau: X1Y1
Resultado: Satisfatório

ENSAIOS DO ÓLEO ISOLANTE

Tipo de Óleo: tipo A
Rigidez Dielétrica: 40,00 [kV] (NBR 6869)
Tensão superficial: 43,00 [mN/m] (MB 320)
Teor de Água: 25,00 [ppm] (NBR 5755)
Densidade: 0,865 (NBR 7148)
Ind. Neutralização: <0,01 [mgKOH/g] (MB 101)
F.P. A 100 [°C]: 0,20 [%] (ASTM D 924)

ESTANQUEIDADE E RESISTÊNCIA À PRESSÃO

Pressão [Kgf/cm²]: 0,7 Tempo [Horas]: 1

DATA

INSPETOR

ENGENHEIRA RESPONSÁVEL
MARIA GORETTI ZAGO



0810001095

