

UNIVERSIDADE FEDERAL DO MARANHÃO  
CENTRO DE CIÊNCIAS EXATAS E TECNOLOGIA  
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA DE ELETRICIDADE

**METODOLOGIA PARA REDUÇÃO DE  
CUSTOS NA MANUTENÇÃO DOS  
COMUTADORES DE TAP SOB CARGA  
DOS TRANSFORMADORES DE  
POTÊNCIA DE EXTRA ALTA TENSÃO  
DA ELETRONORTE**

**RAIMUNDO NONATO ROSA FILHO**

São Luís - MA, Brasil

MARÇO 2005

# **METODOLOGIA PARA REDUÇÃO DE CUSTOS NA MANUTENÇÃO DOS COMUTADORES DE TAP SOB CARGA DOS TRANSFORMADORES DE POTÊNCIA DE EXTRA ALTA TENSÃO DA ELETRONORTE**

Dissertação de Mestrado submetida à Coordenação do Programa de Pós-Graduação  
em Engenharia de Eletricidade da UFMA como parte dos requisitos para  
obtenção ao título de Mestre em Engenharia Elétrica  
na área de Sistemas de Energia.

Por

**RAIMUNDO NONATO ROSA FILHO**

**MARÇO, 2005**

**METODOLOGIA PARA REDUÇÃO DE  
CUSTOS NA MANUTENÇÃO DOS  
COMUTADORES DE TAP SOB CARGA  
DOS TRANSFORMADORES DE  
POTÊNCIA DE EXTRA ALTA TENSÃO  
DA ELETRONORTE**

RAIMUNDO NONATO ROSA FILHO

DISSERTAÇÃO APROVADA EM 31/03/2005

Prof. Dr. Vicente Leonardo Paucar Casas, UFMA  
(Orientador)

Prof. Dr. Osvaldo Ronald Saavedra Méndez, UFMA  
(Co-Orientador)

Dr. Carlos Julio Dupont, CEPTEL  
(Membro da Banca Examinadora)

Prof. Dra. Maria da Guia da Silva, UFMA  
(Membro da Banca Examinadora)

**METODOLOGIA PARA REDUÇÃO DE  
CUSTOS NA MANUTENÇÃO DOS  
COMUTADORES DE TAP SOB CARGA  
DOS TRANSFORMADORES DE  
POTÊNCIA DE EXTRA ALTA TENSÃO  
DA ELETRONORTE**

MESTRADO

**Área de Concentração: SISTEMAS DE ENERGIA ELÉTRICA**

RAIMUNDO NONATO ROSA FILHO

Orientador: Prof. Dr. Vicente Leonardo Paucar Casas

Co-Orientador: Prof. Dr. Osvaldo Ronald Saavedra Méndez

Programa de Pós-Graduação  
em Engenharia de Eletricidade da  
Universidade Federal do Maranhão

*Para Waldimeiry de Jesus Castro Rosa e nosso filho Leonardo Castro Rosa pela paciência, carinho e amor sempre demonstrados.*

*Em memória de Mariana Guimarães Rosa mãe dedicada a quem devo grande parte da vontade e esforços alcançados na elaboração deste trabalho, pai Raimundo Nonato Rosa grande orientador*

# AGRADECIMENTOS

Ao Prof. Dr. Vicente Leonardo Paucar Casas pela compreensão, apoio, orientação na condução da pesquisa e desenvolvimento deste trabalho. Pois somente com sua dedicação no transcorrer deste trabalho pode alcançar os objetivos traçados na sua etapa final.

A Centrais Elétricas do Norte do Brasil S.A. – ELETRONORTE, pela compreensão e liberação para os estudos de desenvolvimento deste trabalho.

A MR (Machinenfabrik Reinhausen) fabricante do comutador de Tap GI-3022 objeto do estudo deste trabalho especificamente ao Sr. Yousej Pfliff.

Ao Gerente da Regional de Transmissão do Maranhão - CMA, Eng. José Ribamar Lobato Santana pela cooperação e incentivo e ao Eng. Turenne Ribeiro Junior da ELETRONORTE que muito contribui com coleta de dados e apoio nas atividades de campo.

Aos meus colegas Manfred Bedriñana, Marcos Rider, Anselmo, Julio César Roma Buzar e todos os amigos do GSP (Grupo de Sistemas de Potência) e do Curso de Pós-Graduação, pela sua amizade e cooperação durante toda a minha permanência no curso.

Aos professores do Curso de Pós-Graduação: Maria da Guia da Silva, Osvaldo Ronald Saavedra Méndez e José Eduardo Onoda Pessanha pela amizade, apoio e compreensão.

# RESUMO

Neste trabalho é proposta uma metodologia para redução de custo de manutenção nos comutadores de tap sob carga (OLTC) dos transformadores de potência de extra alta tensão. A metodologia está baseada na utilização de redes neurais artificiais (RNA) para o processamento inteligente dos sinais de entrada dos comutadores. As redes neurais adequadamente treinadas permitem criar um sistema de informação e diagnóstico dedicado a OLTC que podem interpretar e diagnosticar os componentes através das entradas em tempo real de forma a, postergar os intervalos de manutenção, prevendo quando o OLTC deverá sofrer intervenção de manutenção baseada na condição do OLTC. Foi adotada uma arquitetura de RNA de multiperceptron na qual a entrada considera um vetor com 22 entrada e apenas uma saída com o status da condição do OLTC em função do tempo de operação. Essa informação de saída é utilizada para determinar os períodos de manutenção dos comutadores de tap. É realizada uma aplicação do sistema proposto considerando o comutador de tap sob carga de um banco de autotransformador de 500/230/13.8kV, 600MVA da Centrais Elétricas do Norte do Brasil S/A( ELETRONORTE) e os resultados indicam as vantagens da manutenção baseada na condição usando RNA.

**Palavras chaves:** Sistemas elétricos de potência, comutador de tap sob carga, manutenção de transformadores, manutenção baseada na condição, redes neurais artificiais.

# ABSTRACT

In this work a methodology for reduction of maintenance cost in the on-load tap changers (OLTC) of extra high voltage is proposed. The methodology is based on the use of Artificial Neural Networks (ANN) for the intelligent processing of input signals of the commutator. The neural nets adequately trained allow to create an information system and dedicated diagnosis of the OLTC. This system can interpret and diagnosis the components through the real time input signals in order to delay the power transformer maintenance intervals, foreseeing when the OLTC is going to maintenance have intervention based on its condition. It has been adopted a multiperceptron ANN architecture in which the input vector has 22 components and the output considers only one component with the status of the OLTC condition in function of its operation time. This output information is used to determine the periods of maintenance of the commutators. It is reported an application of the proposed system considering the on load tap changer of an autotransformer bank of 500/230/13.8 kV, 600MVA of Centrais Elébricas do Norte do Brasil S/A (ELETRONORTE). The results indicate the advantages of the maintenance based on the condition using ANN.

**Keywords:** Electrical power systems, on load tap changer, power transformer maintenance, condition-based maintenance, artificial neural networks.

# SUMÁRIO

<b>Lista de Tabelas .....</b>	<b>xii</b>
<b>Lista de Figuras.....</b>	<b>xiv</b>
<b>Abreviaturas .....</b>	<b>xviii</b>
<b>1. Introdução.....</b>	<b>1</b>
1.1. Generalidades .....	1
1.2. Formulação do problema .....	2
1.3. Objetivos.....	3
1.4. Justificativa.....	4
1.5. Metodologia.....	7
1.6. Revisão bibliográfica e antecedentes.....	8
1.7. Estrutura do trabalho .....	11
<b>2. Redes neurais para o diagnóstico da condição de comutadores de tap sob     carga .....</b>	<b>13</b>
2.1. Introdução.....	13
2.2. Redes neurais artificiais em manutenção.....	14
2.2.1. Conceitos de redes neurais artificiais.....	14
2.2.2. Aplicação de redes neurais em sistemas de energia elétrica.....	19
2.2.3. Aplicação de redes neurais em manutenção .....	20

2.3.	Conceitos de manutenção de OLTC .....	20
2.3.1.	Aspectos gerais dos OLTC .....	21
2.3.1.1	Condições de serviço... ..	20
2.3.1.2	Características nominais do OLTC.....	22
2.3.1.3	Projeto e construção do OLTC .....	24
2.3.1.4	Descrição das partes do OLTC .....	25
2.3.1.5	Mecanismo de acionamento motorizado.....	28
2.3.2.	Princípio de funcionamento do comutador de tap sob carga .....	30
2.3.3.	Conceitos básicos de manutenção de OLTC .....	38
2.3.4.	Práticas de manutenção de OLTC .....	39
2.3.4.1	Atividades de manutenção preventivas baseadas no tempo (TBM).....	39
2.3.4.2	Atividades de manutenção preditivas baseadas na condição (CBM)..	41
2.4.	Síntese das categorias de falhas dos comutadores de tap sob carga.....	48
2.5.	Modelo proposto de RNA para diagnóstico da condição de OLTC.....	50
2.5.1.	Estrutura do modelo da rede neural artificial.....	50
2.5.2.	Coleta de dados e separação em conjuntos .....	55
2.5.3.	Treinamento e teste da RNA.....	57
2.5.4.	Integração da RNA .....	60
<b>3.</b>	<b>Simulação do modelo proposto e discussão de resultados.....</b>	<b>61</b>
3.1.	Introdução .....	61
3.2.	Implementação da RNA .....	61
3.3.	Resultados de treinamento e teste.....	62
<b>4.</b>	<b>Conclusões.....</b>	<b>79</b>

4.1. Conclusões.....	79
4.2. Contribuições.....	81
4.3. Trabalhos Futuros .....	81
<b>Apêndices.....</b>	<b>83</b>
A. Topologia do sistema DianE.....	84
B. Dados usados nos testes.....	84
B.1 Dados de Entrada Reais.....	84 <u>6</u>
B.2 Dados de Entrada Normalizados.....	<u>93</u>
<b>Referências bibliográficas .....</b>	<b><u>97</u></b>

# LISTA DE TABELAS

<b>Tabela 2.1:</b>	<b>Condições de serviço dos comutadores de tap sob carga.....</b>	<b>21</b>
<b>Tabela 2.2:</b>	<b>Descrição das características elétricas e mecânicas do OLTC GI-3022.....</b>	<b>24</b>
<b>Tabela 2.3:</b>	<b>Características técnicas do mecanismo de acionamento motorizado. ....</b>	<b>30</b>
<b>Tabela 2.4:</b>	<b>Resultados de atividades de manutenção baseada na condição.....</b>	<b>43</b>
<b>Tabela 2.5:</b>	<b>Resultados de ensaios de óleo isolante, comutador MR GI-3022.....</b>	<b>47</b>
<b>Tabela 2.6:</b>	<b>Síntese das principais categorias de falhas dos comutadores de tap sob carga.....</b>	<b>49</b>
<b>Tabela 2.7:</b>	<b>Critério de saída da rede neural com o diagnóstico da condição do OLTC.....</b>	<b>55</b>
<b>Tabela 3.1:</b>	<b>Resultados da etapa de treinamento e teste para topologia 5-5-1.....</b>	<b>63</b>
<b>Tabela 3.2:</b>	<b>Resultados da etapa de treinamento e teste para topologia 5-10-1... </b>	<b>64</b>
<b>Tabela 3.3:</b>	<b>Resultados da etapa de treinamento e teste para topologia 10-10-1. </b>	<b>65</b>

**Tabela 3.4: Resultados da etapa de treinamento e teste para topologia 15-10-1. 66**

**Tabela 3.5: Resultados da etapa de treinamento e teste para topologia 20-10-1. 67**

# LISTA DE FIGURAS

<b>Figura 1.1:</b>	<b>Impacto do OLTC na disponibilidade e custo de manutenção de transformadores. ....</b>	<b>6</b>
<b>Figura 2.1:</b>	<b>Modelo matemático do neurônio artificial não-linear. [DILL96].....</b>	<b>17</b>
<b>Figura 2.2:</b>	<b>Arquitetura multiperceptron MLP de duas camadas.....</b>	<b>18</b>
<b>Figura 2.3:</b>	<b>Aplicações de RNA em sistemas elétricos de potência. [DILL96].....</b>	<b>19</b>
<b>Figura 2.4:</b>	<b>OLTC de um autotransformador 500/230/13.8 kV da subestação São Luis II da ELETRONORTE. ....</b>	<b>22</b>
<b>Figura 2.5:</b>	<b>Detalhe das partes principais do OLTC GI-3022.....</b>	<b>28</b>
<b>Figura 2.6:</b>	<b>Fotografia e diagrama mostrando as partes principais do comutador tipo “G”. ....</b>	<b>31</b>
<b>Figura 2.7:</b>	<b>Fotografia e diagrama mostrando o detalhe dos componentes do cabeçote do comutador de derivações.....</b>	<b>32</b>
<b>Figura 2.8:</b>	<b>Fotografia e diagrama mostrando o detalhe dos componentes da chave comutadora. ....</b>	<b>33</b>

<b>Figura 2.9:</b>	<b>Fotografia e diagrama mostrando o detalhe dos componentes do seletor e pré-seletor. ....</b>	<b>34</b>
<b>Figura 2.10:</b>	<b>Fotografia e diagrama mostrando os componentes da chave comutadora e a sua localização no transformador. ....</b>	<b>35</b>
<b>Figura 2.11:</b>	<b>Fotografia mostrando os componentes do conjunto da chave comutadora isolada. ....</b>	<b>36</b>
<b>Figura 2.12:</b>	<b>Diagrama mostrando os componentes do seletor e pré-seletor, isolados. . . . .</b>	<b>36</b>
<b>Figura 2.13:</b>	<b>Fotografia na qual é visualizada a transmissão do seletor de tap.....</b>	<b>37</b>
<b>Figura 2.14:</b>	<b>Produção de arco elétrico e acúmulo de partículas degradando o óleo isolante.....</b>	<b>44</b>
<b>Figura 2.15:</b>	<b>Interferência da água no óleo. ....</b>	<b>45</b>
<b>Figura 2.16:</b>	<b>Gráfico de acompanhamento do teor de água.....</b>	<b>46</b>
<b>Figura 2.17:</b>	<b>Estrutura para a modelagem da arquitetura da rede neural artificial proposta.....</b>	<b>53</b>

<b>Figura 2.18: Dados de entrada e arquitetura da rede neural artificial para diagnóstico da condição de OLTC.....</b>	<b>54</b>
<b>Figura 3.1: Curva representativa do treinamento e teste para topologia 5-5-1. .</b>	<b>63</b>
<b>Figura 3.2: Curva representativa do treinamento e teste para topologia 5-10-1.</b>	<b>64</b>
<b>Figura 3.3: Curva representativa do treinamento e teste para topologia 10-10-1.....</b>	<b>65</b>
<b>Figura 3.4: Curva representativa do treinamento e teste para topologia 15-10-1.....</b>	<b>66</b>
<b>Figura 3.5: Curva representativa do treinamento e teste para topologia 20-10-1.....</b>	<b>67</b>
<b>Figura 3.6: Processo de treinamento para o melhor caso (caso 18) da topologia 5-5-1.....</b>	<b>69</b>
<b>Figura 3.7: Comparação de resultados das etapas de treinamento e teste para o melhor caso (caso 18) da topologia 5-5-1. ....</b>	<b>70</b>
<b>Figura 3.8: Processo de treinamento para o melhor caso (caso 11) da topologia 5-10-1.....</b>	<b>71</b>

<b>Figura 3.9:</b>	<b>Comparação de resultados das etapas de treinamento e teste para o melhor caso (caso 11) da topologia 5-10-1. ....</b>	<b>72</b>
<b>Figura 3.10:</b>	<b>Processo de treinamento para o melhor caso (caso 12) da topologia 10-10-1. ....</b>	<b>73</b>
<b>Figura 3.11:</b>	<b>Comparação de resultados das etapas de treinamento e teste para o melhor caso (caso 12) da topologia 10-10-1. ....</b>	<b>74</b>
<b>Figura 3.12:</b>	<b>Processo de treinamento para o melhor caso (caso 15) da topologia 15-10-1. ....</b>	<b>75</b>
<b>Figura 3.13:</b>	<b>Comparação de resultados das etapas de treinamento e teste para o melhor caso (caso 15) da topologia 15-10-1. ....</b>	<b>76</b>
<b>Figura 3.14:</b>	<b>Processo de treinamento para o melhor caso (caso 16) da topologia 20-10-1. ....</b>	<b>77</b>
<b>Figura 3.15:</b>	<b>Comparação de resultados das etapas de treinamento e teste para o melhor caso (caso 16) da topologia 20-10-1. ....</b>	<b>78</b>

# ABREVIATURAS

ANEEL	<i>Agencia Nacional de Energia Elétrica</i>
ALUMAR	Consortio de Alumínio do Maranhão
ALBRAS	Consortio de Alumínio Brasileiro
CPST	Contrato de prestação de serviço na transmissão
CEPEL	Centro de Pesquisa de Energia Elétrica.
COS	<i>Centro de Operação do Sistema</i>
CVRD	Companhia do Vale do Rio Doce
CMA	Regional de Transmissão do Maranhão
CAPES	Coordenação de Aperfeiçoamento de Pessoal de Nível Superior
CBM	<i>Condition based maintenance</i>
DianE	<i>Sistema de análise e diagnóstico de equipamentos.</i>
EAT/EHV	<i>Extra-alta tensão</i>
ENTE	<i>Empresa Norte de Transmissão de Energia</i>
EATE	<i>Empresa Amazonense de Transmissão de Energia</i>
ELETRONORTE	Centrais Elétricas do Norte do Brasil S/A
IEC	International Electrotechnical Commission
MLP	<i>Multilayer perceptron</i>
MR	Maschinenfabrik Reinhausen
NOVATRANS	<i>Novatrans Energia S/A</i>
ONS	<i>Operador Nacional do Sistema</i>
OLTC	<i>On-load tap changer</i>
PCA	Principal component analysis
PM	<i>Planned maintenance</i>
RNA	<i>Redes neurais artificiais</i>
SOM	Self organizing map
TBM	Manutenção baseada no tempo ( <i>time based maintenance</i> )
UFMA	Universidade Federal do Maranhão
UHE	<i>Usina hidrelétrica</i>

# 1. INTRODUÇÃO

## 1.1. Generalidades

O setor elétrico no mundo todo está se deparando com uma tendência de descentralização e/ou desverticalização, passando a ser constituído de diversos agentes, com suas próprias decisões, influenciando no comportamento do desempenho dos custos de manutenção [SWIF95] através do contrato de prestação de serviço na transmissão (CPST) gerenciado por um órgão operativo tal como o Operador Nacional do Sistema (ONS) que otimiza a produção e transmissão de energia elétrica frente a uma curva diária de demanda.

A desregulamentação pode propiciar uma abertura de novos negócios e mercado para a Centrais Elétricas do Norte do Brasil S.A. - ELETRONORTE, como por exemplo, um aumento de oferta de energia elétrica junto aos centros consumidores a partir da conexão de produtores independentes de fonte térmica e/ou hidráulica. No entanto, um sistema elétrico como o brasileiro com uma forte base hídrica, ainda terá de se valer das redes de transmissão para escoar sua produção.

As decisões negociadas entre produtores e comercializadores são efetivadas via o sistema de transmissão. Isto faz com que a ELETRONORTE, detentora das interligações nos sistema de transmissão Norte/Nordeste e Norte/Sul, adquira um poder que influencie nas relações comerciais entre os agentes produtores e os consumidores. Assim, por exemplo, em 2004 a ELETRONORTE assinou dois contratos para fornecimento de energia elétrica com as empresas de alumínio ALUMAR e ALBRAS, dois grandes consumidores de energia elétrica. Esses dois contratos foram os maiores contratos de venda e compra de energia no mundo.

Surge no entanto um problema que é a otimização dos custos de manutenção [SWIF95] e a qualidade na operação da rede básica de transmissão, visando reduzir as perdas e estabelecer um equilíbrio financeiro entre despesa e receita. Nesta ótica

precisa-se de um método sistemático para manter alto nível de serviço ao consumidor com um nível de risco aceitável. A condição do impacto ou severidade da manutenção e a probabilidade produzem índices que, realmente representam o risco do sistema. Portanto a neutralidade comercial da rede de transmissão é alvo a ser perseguido pelos órgãos reguladores do Governo, para que não haja ineficiência econômica, ou alguma espécie de poder de mercado, por ser o sistema de transmissão, ainda um monopólio natural.

A definição de preço pelo uso e/ou acesso ao sistema de transmissão tem como propósito básico atingir a eficiência econômica para o setor elétrico, maximizando as utilidades dos agentes dentro das suas funções objetivas.

As soluções obtidas estão sujeitas a restrições tanto técnicas, originadas no equipamento como a indisponibilidade para manutenção dos comutadores de tap sob carga (OLTC: *on-load tap changer*) [IEEE86] [JONE98] [WALT93] como econômicas (contrato CPST) que devem refletir no estado da condição ótima de operação do sistema de potência considerando as características físicas da rede de transmissão e a disponibilidade dos transformadores de potência [IEEE86] [WETZ00].

## **1.2. Formulação do problema**

O custo dos comutadores de tap sob carga, também chamados de comutadores de derivações ou OLTC neste trabalho, pode representar de 5 a 10% do custo de capital de um projeto de um transformador de potência [KANG01]. Já sua performance operacional é a confiabilidade crítica (modos de falha) do projeto, pois a falta de manutenção do comutador de tap pode levar à perda total do transformador [SPEN95]. Manutenção é uma realidade para a vida útil de um transformador em operação em qualquer parte do mundo [YOUN98]. O comutador sob carga é considerado o acessório que mais tem contribuído com a perda de transformadores no mundo, com 40% no total de falhas.

Hoje em dia os processos de manutenção estabelecidos pelos fabricantes de comutadores [MR1990] adotam inspeções de rotina baseadas no número de comutações, que basicamente controlam a frequência e duração de retirada dos transformadores do sistema, representando uma grande proporção no custo de

manutenção. Essas retiradas podem ainda representar o aumento do risco da falha do comutador de tap sob carga, por falha no processo de manutenção induzida pelas equipes de manutenção e operação [KANG01].

Portanto, baseados na busca de uma boa performance para o serviço de manutenção dos comutadores e qualidade padrão dos projetos com a utilização da norma IEC214, procura-se um diagnóstico e monitoramento das condições de operação contínua do comutador visando a redução nos custos de manutenção e operação [HAND01] [WETZ00].

### **1.3. Objetivos**

Objetivo geral:

Contribuir com o desenvolvimento de metodologias computacionais para o processo de manutenção de equipamentos de sistemas de potência procurando a redução da indisponibilidade do transformador.

Objetivos específicos:

Desenvolver uma metodologia computacional que leve a reduzir os custos de manutenção no comutador de tap sob carga dos transformadores e autotransformadores de potência de extra-alta tensão (EAT ou EHV: *extra high voltage*) e melhorar o diagnóstico para tomada de decisão dos centros de operação e manutenção [JONE98] [LEWI95] com vistas a possibilitar a operação econômica e confiável do sistema de transmissão. A metodologia deve considerar características de um sistema de inteligência artificial de forma que emule a atuação de um especialista humano no diagnóstico da condição da manutenção e operação, e ainda subsidiando as tomadas de decisão [WANG00] [HUSA01].

Aplicar a metodologia proposta aos comutadores sob carga dos transformadores e autotransformadores de extra-alta tensão (de 230 a 500 kV) da ELETRONORTE, para cada um dos sistemas e subsistemas do OLTC (acionamento, transmissão, chave de carga, tanque e óleo isolante) que o constituem, visando manter o transformador em operação com o menor custo e com menos impacto em situações de perturbação do sistema de transmissão [LEIB98][SWIF95]. Com essa finalidade neste trabalho foi

utilizado o comutador de tap tipo GI-3022 do fabricante MR dos bancos de autotransformadores de potência 500/230/13.8 kV, 600 MVA, atualmente em operação na subestação São Luis II da ELETRONORTE [MR1990].

Contribuir com o desenvolvimento de uma metodologia para diagnóstico da condição dos comutadores de tap sob carga de maneira que possa ser integrada ao sistema DianE (Sistema de Análise e Diagnóstico de Equipamentos) o qual foi desenvolvido pelo CEPEL/ELETRONORTE e que atualmente encontra-se em processo de implantação e acompanhamento na ELETRONORTE. O DianE está coletando, integrando e centralizando informações de todos os transformadores no COS (Centro de Operação do Sistema) da ELETRONORTE em Brasília.

#### **1.4. Justificativa**

Com a desregulamentação do setor elétrico brasileiro surge um problema: os transformadores de extra-alta tensão passam a pertencer à rede básica do sistema elétrico, gerido pelo Operador Nacional do Sistema e pela Agência Nacional de Energia Elétrica (ANEEL) que é o agente regulador e fiscalizador das normas operacionais que estabeleceram relações contratuais entre empresas transmissoras e usuários de energia elétrica.

Neste contexto a ELETRONORTE passou a ser administrada por Contrato de Prestação de Serviço na Transmissão, CPST, e passa a ser remunerada pela disponibilidade do equipamento e a pagar multa pela indisponibilidade do equipamento. Essa multa pode ser equivalente a 150% vezes a receita para as primeiras 5 horas de desligamento não programado e, 10% vezes a receita para as horas seguintes e 10% vezes a receita para desligamentos programados que receberia pelo aluguel de uso, dessa forma, todo programa atual de manutenção terá que se adequar ao novo cenário.

Na Subestação São Luis II da ELETRONORTE, que opera em 500/230/13.8 kV, 1800 MVA, encontram-se os comutadores sob carga dos autotransformadores aos quais se aplicarão os testes de simulação deste trabalho. A Subestação São Luís II supre de energia elétrica o maior consumidor privado do Brasil, a ALUMAR (Consórcio de Alumínio do Maranhão), a CVRD (Companhia do Vale do Rio Doce), a cidade de São Luís e a Subestação na cidade de Miranda no Estado do Maranhão, através de seis

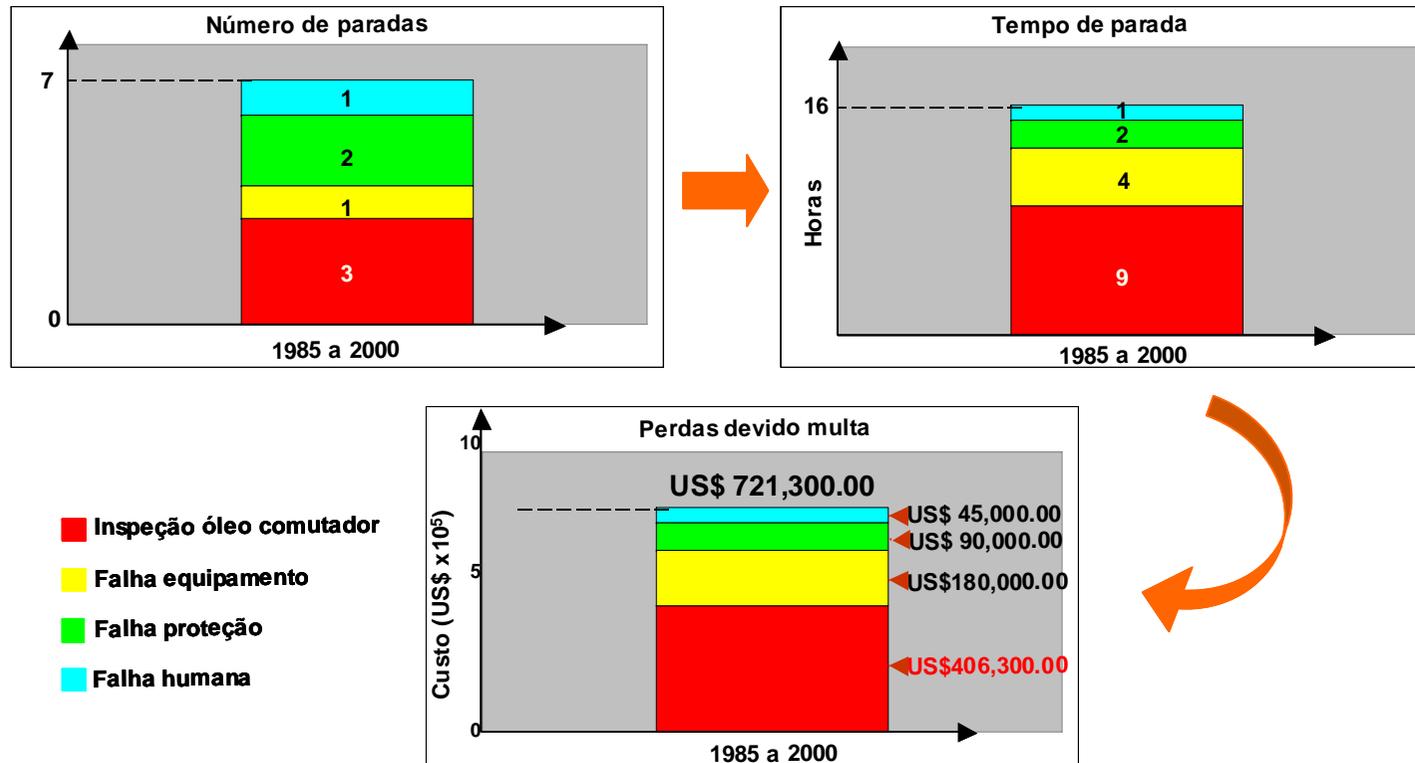
linhas de transmissão em 230 kV. A ELETRONORTE é uma empresa de economia mista na qual o Governo Federal participa com 51% das ações. Fica localizada no norte do Brasil, atuando em 56% do território nacional com geração e transmissão de energia elétrica. Sua principal usina hidrelétrica (UHE) Tucuruí, tem uma capacidade instalada de 4000 MW (12 unidades de 330 MW cada mais 02 unidades auxiliares de 20 MW cada) na sua primeira etapa já em operação comercial desde 1984. Encontra-se em fase de construção a sua segunda etapa com a qual passará a ter em 2005 uma capacidade instalada final de 7960 MW (mais 12 unidades de 330 MW na segunda etapa). A UHE Tucuruí está interligada com o sistema de transmissão de 500 kV Norte/Sul e Norte/Nordeste nas subestações de Imperatriz e Presidente Dutra localizadas no estado do Maranhão, respectivamente. Estão também os acessantes Empresa Norte de Transmissão de Energia (ENTE), Empresa Amazonense de Transmissão de Energia S.A. (EATE) e NOVATRANS Energia S.A., todos em 500 kV.

É evidente a necessidade de determinar, numa empresa como a ELETRONORTE, uma metodologia que inclua a modelagem dos custos de manutenção, as restrições técnicas e econômicas com todos os sistemas do comutador sob carga, que possam interferir no desempenho da sua função principal do transformador. Como vantagens dessa proposta metodológica podemos destacar as seguintes melhorias na gestão estratégica da diretoria de operação, por exemplo para a partir de 2005, tais como:

- 1) Implementar uma sistemática de acompanhamento de custos de todos os processos;
- 2) Atuar na redução de perdas e custos;
- 3) Promover a eficácia do módulo PM (*Planned Maintenance* ou Manutenção Planejada) para obtenção dos custos e, de dados estatísticos da manutenção;
- 4) Implantar centro integrado de manutenção.

Na Figura 1.1 é visualizada a justificativa do impacto do OLTC na disponibilidade e incremento no custo de manutenção, mais as perdas de faturamento (por indisponibilidade mais multas) do correspondente transformador. O comutador afeta a função principal do transformador.

## ELEVADO NÚMERO DE PARADAS DO AUTOTRANSFORMADOR No. 01 PARA INSPEÇÃO DO COMUTADOR, PROVOCANDO ALTAS PERDAS PARA A PLANTA



**Figura 1.1:** Impacto do OLTC na disponibilidade e custo de manutenção de transformadores.

(Fonte: TPM – ELETRONORTE)

## **1.5. Metodologia**

Entre as hipóteses a considerar: avaliar a condição da função e padrões de desempenho de um ativo no seu contexto presente de operação é uma alternativa utilizada na manutenção de equipamentos, comparativamente é um método que pode apresentar melhores resultados e uma diminuição nos custos de manutenção, em relação a outras técnicas de manutenção e diagnóstico. Pretende-se estender essas considerações para o caso de transformadores de potência, especificamente para os comutadores de derivações ou comutadores de tap sob carga. Mais outra hipótese é que em diversas áreas de manutenção em engenharia são obtidos modelos matemáticos do equipamento aos quais podem ser aplicadas técnicas de solução baseadas em ciência da computação, otimização e matemática para resolver problemas de manutenção [HARR97].

Em relação à metodologia de trabalho, a pesquisa foi desenvolvida no laboratório de sistemas de potência do Departamento de Engenharia de Eletricidade da UFMA e com um autotransformador de 500 kV da subestação São Luís II da ELETRONORTE regional do Maranhão.

Este trabalho foi desenvolvido considerando a metodologia de pesquisa de campo, consulta aos dados de operação e manutenção, consulta aos catálogos dos fabricantes dos comutadores de tap dos transformadores EHV [MR1990] da Regional de Transmissão do Maranhão – CMA, com o desenvolvimento de uma metodologia baseada na pesquisa de sistemas inteligentes para diagnosticar falhas e defeitos. O diagnóstico foi realizado através da instalação de sondas em diversos pontos para coleta de dados, para a modelagem dos custos de manutenção, incluindo as restrições técnicas e econômicas [KANG01] [LEWI95]. Foi desenvolvido um protótipo de software de um sistema baseado em Redes Neurais Artificiais (RNA), que implemente a metodologia para um acompanhamento apurado dos custos [SWIF95], com vistas à melhoria do planejamento econômico e confiável da operação e manutenção do sistema de transmissão.

## 1.6. Revisão bibliográfica e antecedentes

Nesta seção será apresentado um breve resumo sobre o estado da arte dos métodos atualmente utilizados para diagnóstico com redes neurais artificiais em manutenção de comutadores sob carga de transformadores no Brasil e no mundo.

No Brasil, conforme consulta ao banco de teses da CAPES (Coordenação de Aperfeiçoamento de Pessoal de Nível Superior), não existem trabalhos desenvolvidos com a aplicação de redes neurais no diagnóstico dos comutadores sob tap dos transformadores extra-alta tensão. No mundo, direta e indiretamente, sobre o assunto existem vários trabalhos científicos publicados em revistas e eventos especializados. A seguir descreve-se os trabalhos mais relevantes.

Monitoramento *on-line* dos comutadores de tap utilizando sinais de vibração para detectar as condições de desgaste dos contatos [KANG01]. Foi desenvolvido um monitoramento de posição através de sensores óticos que detectam a posição dos comutadores em função da resolução da escala tomando-se como referência o fundo de escala, dessa forma qualquer falta mecânica comprometerá a operação do comutador que não mudara o tap [LEWI95].

Monitoramento do comutador de tap visando a implantação de programa de manutenção preventiva para detectar os problemas que podem ocorrer impedindo a atuação do relé diferencial do transformador [JONE98]. O monitoramento de descargas parciais em grandes transformadores tem sido uma boa experiência na China, Canadá e Japão com a instalação de sensores de ultra-som que têm sido utilizados para localizar faltas e a extensão da avaria na isolação [WEIP98]. Como o comutador de tap ou OLTC é um dos mais problemáticos componentes dos transformadores de potência, a detecção de falhas incipientes nos OLTC é um desafio para as habilidades dos grupos de manutenção preditiva. Dessa forma, esse artigo trata da abordagem com inteligência artificial onde a análise é usada para encontrar os principais gases relativos às condições de falta e as redes neurais são usadas para melhorar a performance do diagnóstico. O desenvolvimento dessas técnicas pode ser integrado dentro dos transformadores de potência como um sistema de diagnóstico de falhas incipientes [WANG00].

A infra-estrutura em manutenção elétrica de componentes baseadas no tempo é corretiva e de modo crescente está sendo substituída pela manutenção baseada na condição (CBM: *condition based maintenance*) a fim de reduzir custos de manutenção preservando a confiabilidade e o desempenho da qualidade. O princípio da CBM consiste em que o equipamento seja avaliado por inspeção e diagnóstico e que as ações da manutenção sejam usadas somente quando necessário. Também, as inspeções e diagnósticos podem ser programados e ajustados para avaliar a condição do equipamento. A implementação da manutenção baseada na condição requer um adequado diagnóstico e avaliação das condições das ferramentas que estão disponíveis e são adequadamente integradas aos programas de manutenção [WETZ00]. Tem sido mostrado que os comutadores sob tap são a causa majoritária de falhas em serviço e conseqüentemente melhorar a confiabilidade dos OLTC é essencial para assegurar a confiabilidade dos transformadores de potência. Existe, portanto, a necessidade de sistemas de monitoramento da OLTC os quais podem ser prontamente usados pelos engenheiros de manutenção não somente para avaliar as condições do equipamento mais também para verificar a qualidade da manutenção.

Com a pesquisa de peças falhadas dentro de velhas OLTC em sistemas elétricos de distribuição e transmissão, a inspeção tem sido conduzida associada com empresas locais de fornecimento de energia. O resultado dessas inspeções mostrou que manutenções incorretas e a idade dos componentes têm contribuído significativamente no número de falhas em alguns tipos de OLTC. Essas inspeções têm mostrado que muito poucas falhas incipientes foram identificadas durante a manutenção. A maioria das falhas tem ocorrido quando o comutador de tap estava em serviço e o transformador tem sido removido de operação incorrendo significativamente a um custo adicional. O sistema de monitoramento da condição irá reduzir o risco de falha e contribuir rumo a uma considerável redução do custo de manutenção [KANG01].

Todos os sistemas e plantas estão sujeito a desgastes e deterioração geral. Isto causa ao equipamento a interrupção da função principal. Quando o equipamento interromper a função principal e não estiver disponível para uso conclui-se que falhou. A planta tem, portanto, três estados: o estado de funcionamento, estado de defeito (falha potencial) e o estado falhado.

A tarefa da manutenção consiste fundamentalmente da observação da condição para identificar defeitos ou o começo do defeito e, proceder a atividades de correção dos defeitos.

O custo de manutenção tem sido otimizado quando atividades corretivas são retardadas até o momento imediatamente anterior ao equipamento falhar. Avaliação da condição deve ser alguma advertência, para que não se proceda a manutenção antes da necessidade verdadeira de fazê-la.

Assim, um tempo de espera é exigido requerido para fornecer um tempo durante o qual os dados da manutenção podem ser alocados e fornecer uma margem de segurança antes que o equipamento falhe.

Lyonnet identificou três estratégias de manutenção [HAND01]:

- 1) Manutenção corretiva
- 2) Manutenção preventiva, baseada no período
- 3) Manutenção preditiva, baseada na condição

O monitoramento do comutador sob carga torna-se atrativo para aumentar a confiabilidade e reduzir o custo de manutenção pela eliminação das inspeções internas no seletor e o inaceitável desvio de operação da chave. Os mais importantes parâmetros são aquelas medições que detectam movimento mecânico, medição de tempo de operação e corrente do resistor de transição, e o período de comutação. Sistemas foram desenvolvidos para comutadores de tap, tais como: vibração e elevação de temperatura no óleo [LEIB98] [LEWI95].

Um resumo das principais categorias de falhas das chaves de carga foram catalogadas tendo-se como as mais severas as falhas mecânicas e aquelas associadas à idade dos componentes, os quais resultam em perda de sincronismo dentro dos seletores ou entre seletor e chave de carga da mesma fase [SPEN95]. Na mesma categoria são mostradas as falhas por operação incompleta da chave. Ambas cobrem invariavelmente uma falha catastrófica do comutador de tap e transformador. Estas falhas causam por vasta maioria as quebras nos comutadores de tap e são causados por idade de

componentes ou projeto inadequado ou controle de qualidade durante a fabricação ou durante o processo de montagem na construção [KANG01].

As causas das quebras comumente influenciadas pela manutenção, estão limitadas por um pequeno número, das maiores quebras. A solução é sustentável por um treinamento especializado.

Quebras causadas por crescimento do carbono são comumente detectáveis pela análise de “gascromatografia” e “físicoquímica” ou durante o processo de operação e manutenção [BOLH02].

O diagnóstico automático para comutadores de tap requer técnicas confiáveis que podem ser classificadas com a medição de sinais de vibração, usando um acelerômetro montado no tanque [WALT93]. Neste paper os autores investigam a classificação automática de sinais de vibração usando um mapa auto-organizativo (SOM: *self organizing map*) e, desenvolvem características para a obtenção de procedimentos, que podem extrair características de uma assinatura de vibração original. Os propósitos da assinatura SOM podem ser classificados e avaliados com os dados estabelecidos para uma classe de tipo de OLTC. A aplicação resulta em descobrir as vantagens do SOM para um número de tarefas do OLTC em diagnóstico da condição [WALT93].

## **1.7. Estrutura do trabalho**

No Capítulo 1 são apresentadas uma introdução com a formulação da proposta do projeto de pesquisa e os aspectos gerais sobre manutenção de transformadores no novo mercado elétrico.

O Capítulo 2 trata dois aspectos, o problema de diagnóstico de chaves de carga de transformadores de potência e a metodologia proposta de um sistema inteligente baseado em redes neurais artificiais aplicadas para resolver o problema de diagnóstico da condição dos comutadores de tap sob carga de transformadores de potência.

No capítulo 3 é aplicada a metodologia proposta para realizar o diagnóstico da condição de um autotransformador de potência em 500 kV, da Subestação São Luís II da ELETRONORTE. Os resultados obtidos são analisados e discutidos.

No Capítulo 4 são apresentadas às conclusões e contribuição do presente trabalho de pesquisa, assim como uma lista de possíveis trabalhos futuros.

# 2. REDES NEURAIS PARA O DIAGNÓSTICO DA CONDIÇÃO DE COMUTADORES DE TAP SOB CARGA

## 2.1. Introdução

O transformador de potência é fundamental na indústria elétrica. Sua função principal não é apenas elevar ou abaixar a tensão nas subestações de extra-alta tensão para permitir a transmissão de energia usando tensões elevadas. Ele também tem a função de manter as tensões do sistema dentro de valores permitidos pelos padrões de qualidade.

Os transformadores de potência podem ter derivações que possibilitam a obtenção de tensões nominais dentro dos limites estabelecidos pelas normas elétricas. Um equipamento essencial é o comutador de derivações (*tap changer*) o qual permite elevar ou abaixar a tensão um pouco além dos níveis nominais. A alteração automática de uma derivação a outra, ou de um tap a outro, pode ser realizada através do comutador de tap sob carga ou *On-Load Tap Change (OLTC)*. O comutador de derivações sob carga é um dos principais componentes responsáveis pelo normal funcionamento do transformador de potência.

A complexidade funcional do OLTC e o grande número de operações diárias a que é submetido durante a sua operação faz dele um dos principais causadores de falhas dos transformadores de potência.

Estão disponíveis várias técnicas para manutenção de transformadores e de comutadores de tap, algumas técnicas são no modo on-line e outras off-line. Recentemente com o advento da reestruturação do setor elétrico e o conceito de mercado elétrico competitivo, além de confiabilidade e segurança é importante a economia. Nesse sentido a manutenção “cobrou” uma transcendência ainda maior, em que além do objetivo de manter o equipamento em funcionamento, o aspecto de economia vem ganhando maior interesse. Novos métodos estão sendo propostos e outros existentes vêm sendo melhorados.

Neste capítulo são apresentados inicialmente conceitos sobre redes neurais artificiais e sobre manutenção e diagnóstico de transformadores de potência e comutadores de tap. A seguir é proposta uma metodologia baseada em redes neurais artificiais para o diagnóstico da condição do comutador de tap sob carga.

## **2.2. Redes neurais artificiais em manutenção**

Em manutenção de equipamentos de sistemas de energia elétrica, tal como, os transformadores de potência, existem metodologias que permitem auxiliar na manutenção, no planejamento da manutenção, no diagnóstico, dentre outras.

Neste trabalho será proposto um sistema inteligente baseado em redes neurais artificiais para o diagnóstico da condição de comutadores de tap sob carga. Com essa finalidade, nesta seção são revisados os conceitos básicos das redes neurais artificiais e algumas aplicações dentro do planejamento e operação dos sistemas elétricos de potência, bem como na manutenção dos equipamentos tal como o transformador de potência.

### **2.2.1. Conceitos de redes neurais artificiais**

Redes neurais artificiais é uma área de ciência da computação que propõe sistemas inteligentes baseados na interligação de neurônios artificiais os quais são modelos matemáticos abstraídos a partir do comportamento do neurônio biológico e do cérebro humano. Esta área, que também é conhecida como computação neural, representa uma alternativa aos métodos computacionais clássicos, baseada na idéia de

desenvolver ferramentas que emulem características dos sistemas neurais biológicos como a robustez, flexibilidade, adaptabilidade e estabilidade [SAGE90].

O cérebro é um processador altamente complexo, não linear e paralelo que é capaz de realizar algumas tarefas, tais como o reconhecimento de padrões, a percepção, ou o controle de movimentos [CHUR92] com maior eficiência e velocidade que os computadores atuais. Essas operações são realizadas graças à capacidade que tem o cérebro de estabelecer suas próprias regras, o que é normalmente conhecido como “experiência”.

O sistema nervoso consegue acumular a experiência ou “aprender” mediante um procedimento que lhe permite adaptar-se ao ambiente. Estes processos estão relacionados intimamente com as estruturas básicas que conformam o cérebro, chamadas neurônios [HAYK98]. Elas, apesar de serem elementos de processamento extremamente simples, conseguem incrementar significativamente seu poder através da formação de imensas redes. É precisamente nas interligações dos neurônios que é armazenado o conhecimento.

Em geral uma rede neural artificial é uma máquina projetada para resolver uma tarefa particular através de um processo de aprendizado, da mesma forma que seria feita pelo cérebro, baseada na interconexão massiva de unidades de processamento simples, os denominados neurônios artificiais.

Uma definição mais formal do ponto de vista da RNA como máquina adaptável foi proposta por Aleksander e Morton [ALEK90]: “Uma rede neural é um processador distribuído, altamente paralelo, composto por unidades de processamento simples, os quais têm a capacidade natural de armazenar conhecimento experimental e disponibilizá-lo para ser usado”.

As RNA têm duas semelhanças básicas com o cérebro:

a) o conhecimento é adquirido do ambiente através de um processo de aprendizado,

b) as ligações interneurais, assim como as ligações sinápticas são usadas para armazenar o conhecimento adquirido.

As redes neurais reagem, aprendem, e se auto-organizam. Portanto em lugar dos algoritmos convencionais usados nos computadores comuns baseados na arquitetura de Von Neumann, elas são treinadas mediante um conjunto de regras que definem o modo de ajuste de seus parâmetros de forma a obter a resposta para a qual foram projetadas [SCHA97].

A rede neural reage em paralelo a eventos que são percebidos pelas suas entradas, e as respostas em lugar de estarem predefinidas por um modelo matemático ou um algoritmo armazenado na memória, são obtidas pela inter-relação de todos os neurônios. Portanto, o poder da rede neural encontra-se distribuído na sua topologia, o que as tornam robustas e tolerantes a falhas, já que o erro produzido por um elemento defeituoso será compensado pela atividade neural global. Uma outra característica interessante das redes neurais é a capacidade de generalização, a qual pode ser definida como a habilidade de fornecer respostas razoáveis em casos para os quais não foram treinadas [HAYK98].

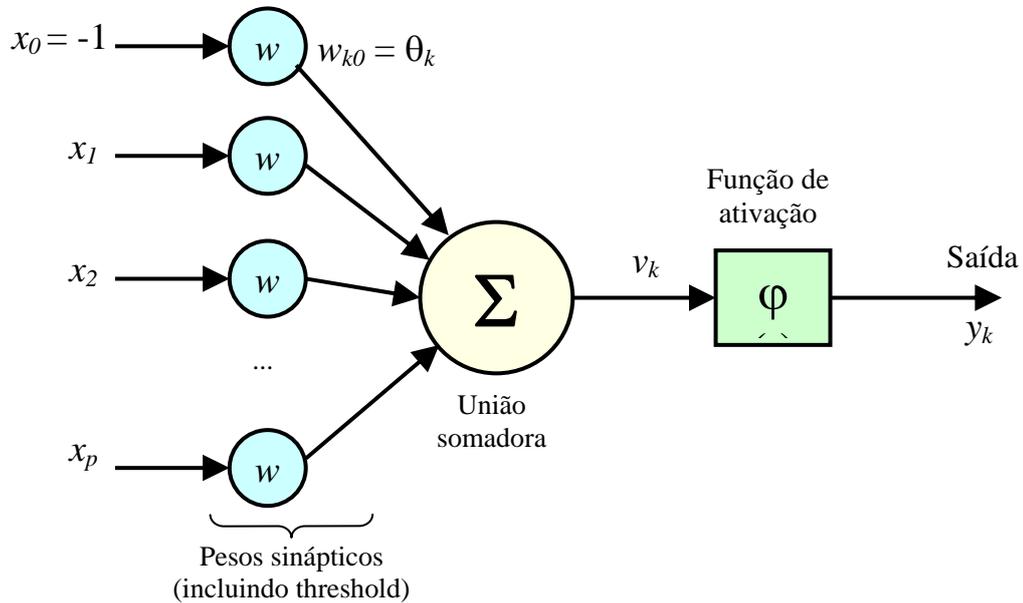
Além das características anteriormente assinaladas, existem outras propriedades que fazem as RNA interessantes na solução de problemas altamente complexos:

- Aproximador de funções não-lineares,
- Mapeamento entrada-saída e reconhecimento de padrões,
- Adaptabilidade, e;
- Simplicidade de análise e projeto.

Contudo, as RNA não se apresentam como um substituto dos computadores convencionais, e sim como um complemento onde o desempenho destes tem apresentado limitações, como por exemplo na classificação e reconhecimento de padrões, processamento de imagens, reconhecimento de voz. Os computadores de estrutura seqüencial continuarão sendo utilizados na realização de cálculos matemáticos por sua precisão e rapidez.

A unidade básica das redes neurais artificiais é o neurônio artificial, o qual está representado esquematicamente na Figura 2.1. O neurônio recebe informação de entrada

através de um número de nós de entrada, logo após processa essa informação e emite uma saída.



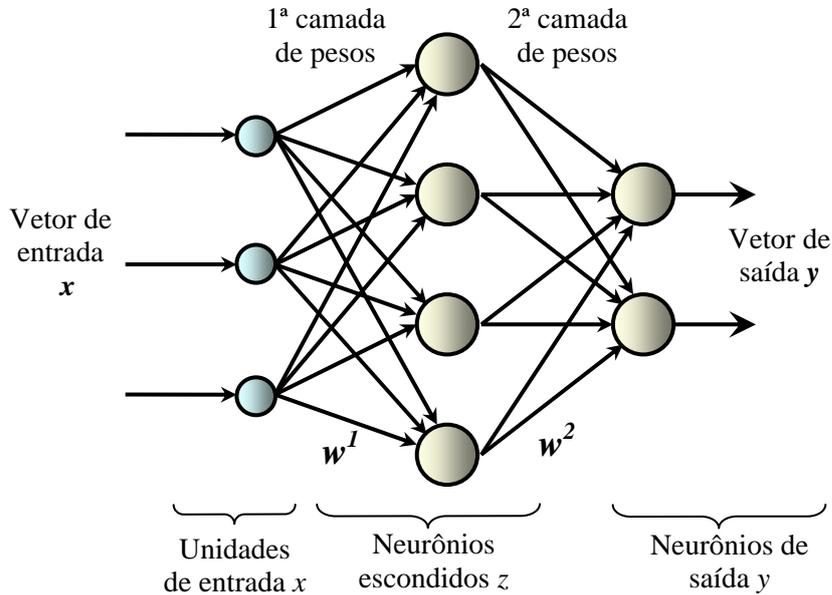
**Figura 1.2:** Modelo matemático do neurônio artificial não-linear. [DILL96]

O processamento é realizado em duas etapas: na primeira os valores de entrada são combinados linearmente, a seguir o resultado é usado como o argumento de uma função de ativação não-linear e derivável. No processo são usados os pesos atribuídos para cada conexão e um termo polarizador (*threshold*).

Os neurônios estão organizados e definem a arquitetura da rede. Neste trabalho adotou-se a arquitetura mais conhecida atualmente, o perceptron multicamada ou MLP (*multilayer perceptron*), tal como o MLP de duas camadas de neurônios mostrado na Figura 2.2. Uma arquitetura MLP de três camadas de neurônios pode ser suficiente para resolver problemas complexos em engenharia elétrica. Já o número de neurônios dependerá da dimensão do problema.

O cálculo ou estimação dos parâmetros livres ou pesos sinápticos é denominado o treinamento da rede e é feita mediante a minimização de uma função de erro. Um dos primeiros algoritmos propostos de treinamento é o algoritmo de retropropagação de erros (*back-propagation of errors*) o qual usa uma técnica do gradiente (*steepest-*

*descent*) para minimizar a função de erro. Um número de algoritmos de treinamento, tanto de primeira como de segunda ordem, estão disponíveis na literatura.



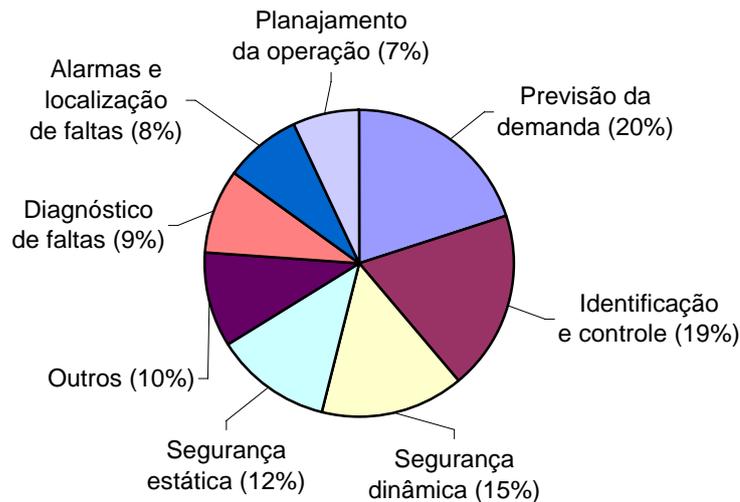
**Figura 1.3:** Arquitetura multiperceptron MLP de duas camadas.

A aprendizagem da rede neural é feita apresentando um conjunto de exemplos para treinamento e um conjunto de exemplos para teste. No caso do algoritmo back-propagation o procedimento é conduzido em duas fases, na primeira é realizado o cálculo *feed-forward* para frente para determinar o erro na saída e na segunda fase o erro é retropropagado para atrás de maneira que os pesos sinápticos sejam alterados segundo a contribuição de cada peso no erro. Essa contribuição é estimada através de expressões obtidas usando derivadas.

A grande característica das RNA é que elas são capazes de obter um modelo implícito do problema a ser resolvido via treinamento adequado. A capacidade de generalização também faz das RNA superiores a outros métodos estatísticos em aplicações típicas de aproximação e mapeamento de funções. As RNA nem sempre precisam de todas as variáveis de entrada, algumas podem ser dispensadas sem comprometer a validade da solução do problema, essa flexibilidade é uma vantagem para modelar processos ou sistemas que não possuem informação completa de entrada.

### 2.2.2. Aplicação de redes neurais em sistemas de energia elétrica

As redes neurais artificiais estão sendo desenvolvidas e aplicadas com sucesso nas diversas áreas da engenharia. Na Figura 2.3 são mostradas as diferentes áreas de sistemas elétricos de potência em que as RNA vêm sendo aplicadas.



**Figura 1.4:** Aplicações de RNA em sistemas elétricos de potência. [DILL96]

Uma das primeiras aplicações de redes neurais em sistemas elétricos de potência foi proposta na área de análise de segurança dinâmica [SOBA89]. Posteriormente mais outras aplicações em diversas áreas da engenharia de potência têm sido verificadas, tanto para aplicações on-line quanto off-line.

A previsão da demanda tem-se tornado uma das áreas mais promissoras da aplicação prática de RNA em sistemas de potência [HIPPO1]. Isto é principalmente motivado pela falta de ferramentas automáticas e o ganho econômico da utilização das redes neurais artificiais. A atividade de pesquisa em outra maior área como: segurança estática e dinâmica tenta explorar a redução de dados e a capacidade de classificação das RNA em combinação com técnicas clássicas. [DILL96], [ELSH96], [ISAP99]

### **2.2.3. Aplicação de redes neurais em manutenção**

Na literatura técnica estão disponíveis diversas aplicações de redes neurais artificiais em manutenção de equipamentos. Especificamente na área de sistemas de energia elétrica a utilização de RNA dentro de metodologias para diagnóstico da condição e de manutenção tem sido aplicada a geradores, máquinas de indução e transformadores. Em problemas que envolvem metodologias para previsão, as RNA também tem sido aplicadas.

Assim, por exemplo, em [DONG04] é considerada a aplicação de análise de componente principal (PCA: *principal component analysis*) para realizar a previsão da condição de um sistema de alimentação de água em uma planta de geração. Em [FARR01] é realizada a avaliação de transformadores usados e reparados com RNA. Uma aplicação de redes neurais para o diagnóstico de falhas em transformadores é relatada em [ZHAN98].

Como pode ser visto, existem aplicações de redes neurais na área de manutenção, o que permite visualizar que para o problema proposto é factível a aplicação de redes neurais como base de uma metodologia para diagnóstico da condição de transformadores de potência.

### **2.3. Conceitos de manutenção de OLTC**

A manutenção dos comutadores de tap sob carga de transformadores de potência EAT pode ser definida seguindo práticas estabelecidas pelos padrões e normas existentes [IEC89], bem como pela prática adotada pelas concessionárias de eletricidade nas quais estão instalados os respectivos equipamentos. No entanto, existem basicamente algumas tendências técnicas para a realização da manutenção.

Nesta seção serão descritos os aspectos básicos sobre as principais características construtivas e de funcionamento dos comutadores sob carga além de conceitos e critérios relevantes sobre manutenção de comutadores sob carga bem como sobre a prática da manutenção adotada em comutadores típicos existentes na ELETRONORTE.

### 2.3.1. Aspectos gerais dos OLTC

Os comutadores de tap sob carga ou OLTC têm aplicação padrão nos transformadores de potência juntamente com seu mecanismo de acionamento. Estão principalmente relacionados com as chaves de carga imersas em óleo isolante de transformadores de acordo com a IEC 296, mas também podem ser usadas imersas em gás isolante na medida que as condições forem aplicáveis. Na Figura 2.4 é mostrado o OLTC do autotransformador utilizado nesta pesquisa.

#### 2.3.1.1 Condições de serviço [IEC89]

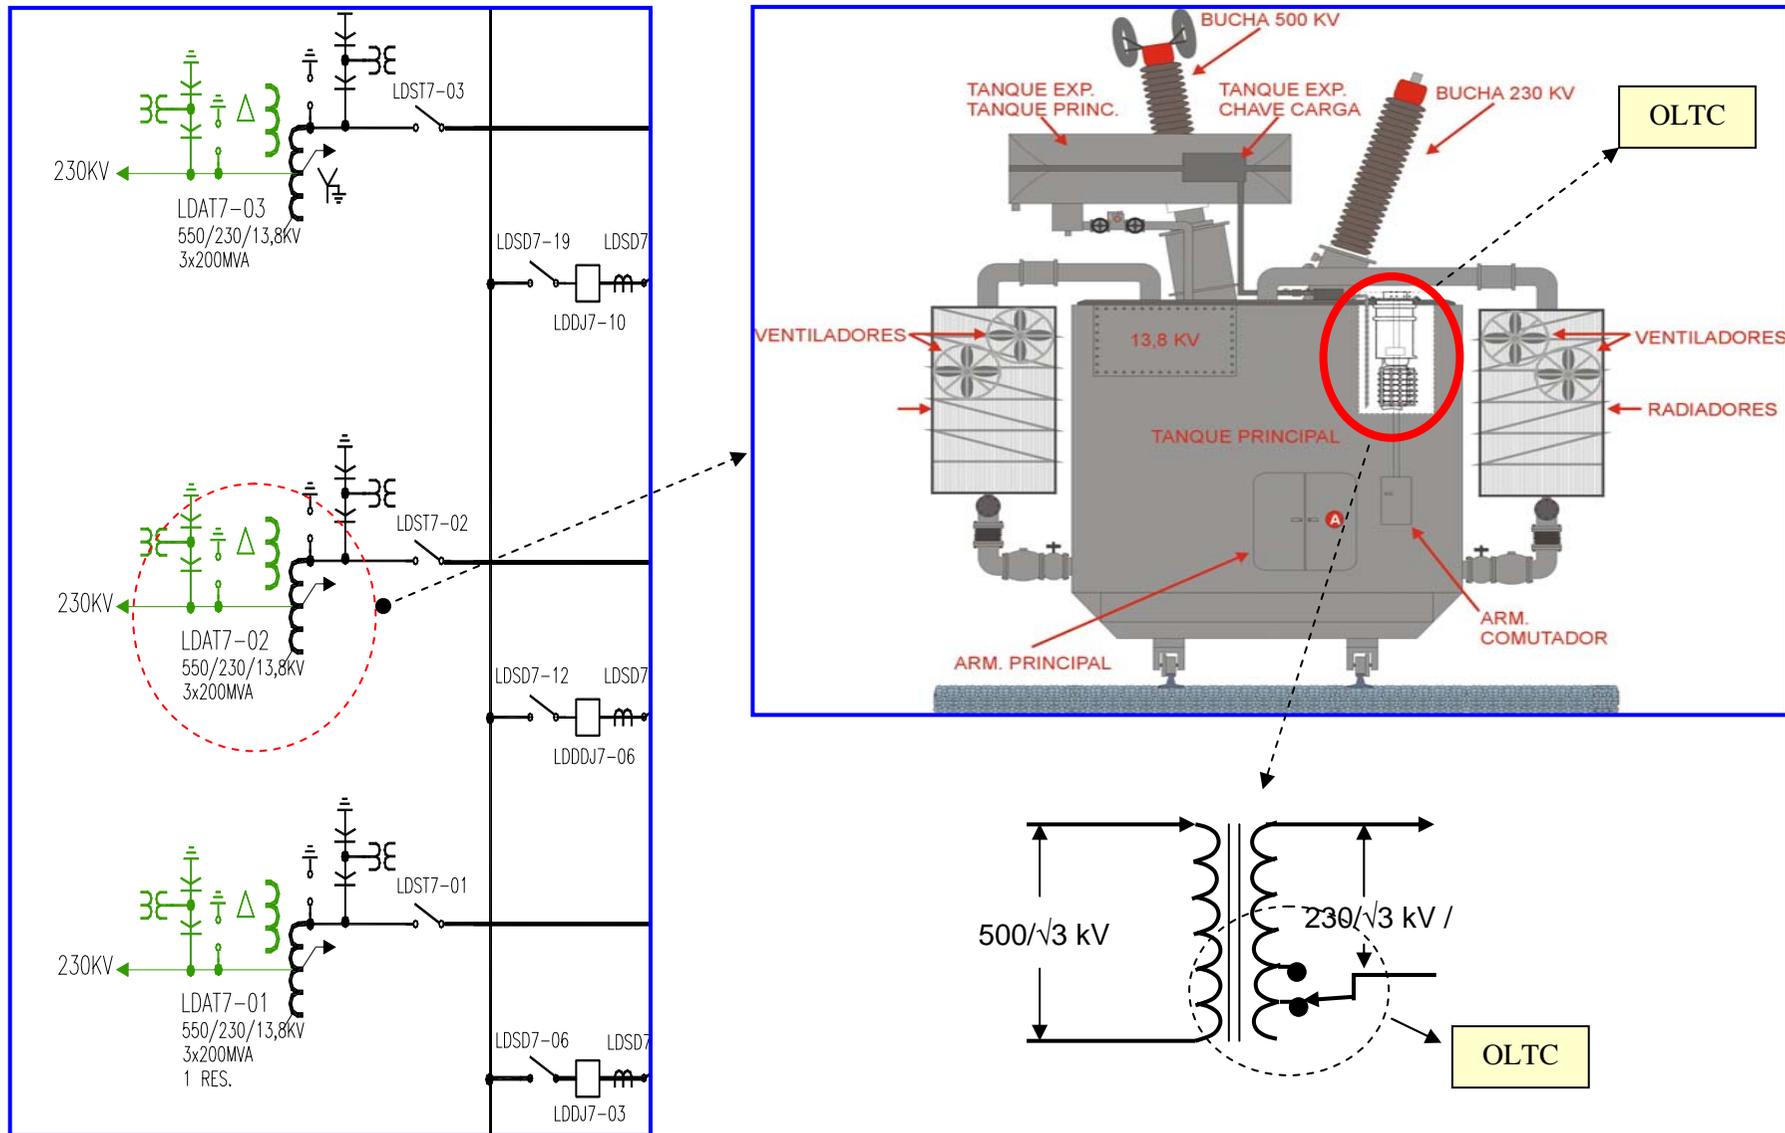
- Exceto em condições mais onerosas especificadas pelo comprador, considera-se apropriado que as chaves de carga operem na faixa de temperatura indicada na Tabela 2.1.

**Tabela 1.1:** Condições de serviço dos comutadores de tap sob carga.

Chave de carga no meio ambiente	Temperatura	
	Mínima	Maximo
Ar	-25°C	40°C
Óleo	-25°C	100°C

O valor de 100°C especificado na Tabela 2.1 está baseado na temperatura ambiente de 40°C como especificado na publicação IEC 76.

- A temperatura do mecanismo de acionamento do OLTC, sem uma outra condição especial especificada pelo comprador, deve ser satisfatória para operar em uma temperatura ambiente na faixa de -25°C a 40°C.
- Em condições de sobrecarga as chaves de carga devem ser selecionadas para cumprir o padrão e instaladas de acordo com a subclasse 2.3.2 da publicação da IEC 542 sendo compatíveis com o carregamento do transformador de potência de acordo com a publicação da IEC 354, onde a temperatura do óleo é detalhada.



**Figura 1.5:** OLTC de um autotransformador 500/230/13.8 kV da subestação São Luis II da ELETRONORTE.

### 2.3.1.2 Características nominais do OLTC [IEC89]

a) As características elétricas dos comutadores sob carga são dadas por:

- Corrente nominal
- Máxima corrente nominal
- Tensão nominal de uma comutação
- Máxima tensão nominal de uma comutação
- Frequência nominal
- Nível de isolamento nominal

Na Tabela 2.2 são apresentadas como exemplo as características elétricas e mecânicas do equipamento OLTC GI-3022 usado nos estudos.

b) Inter-relação entre a corrente nominal e a tensão nominal de uma comutação. A elevação máxima de corrente de uma chave de carga existente pode ser determinada para diferentes combinações de valores de correntes nominais e corresponde a tensão nominal de uma comutação. Quando o valor da tensão nominal de uma comutação é referência para especificar o valor da corrente nominal então ela passa a ser chamada de “tensão nominal de comutação pertinente”. [IEC89]

**Tabela 1.2:** Descrição das características elétricas e mecânicas do OLTC GI-3022.

Modelo do comutador de tap sob carga	GI-3022
Número de pólos	1
Corrente máxima (A)	3000
Corrente de curto-circuito (kA)	
Térmica:	30
Dinâmica	75
Máxima tensão de tap (V)	5000
Capacidade máxima do comutador (kVA)	6500
Frequência nominal (Hz)	60
Posições de operação	35
Isolação para terra (kV)	420
Tensão máxima (kV)	420
Tensão máxima de impulso para onda (kV, 1.2/50)	1425
Potência nominal – frequência resistente a tensão (kV, 50 Hz, 1 minuto)	630
Compartimento de óleo da chave	Pressão de prova 0.3 bar (teste de pressão 0.6 bar)
Deslocamento de óleo (litros)	1200
Quantidade de óleo (litros)	880
Peso aproximado (kg)	2200
Procedimento de secagem	Vácuo com temperatura máx. até 110°C
Acionamento motorizado	MA7

Fonte: Fabricante MR

### 2.3.1.3 Projeto e construção do OLTC [IEC89]

- Compartimento de óleo para chave de carga e chave seletora.

O compartimento de óleo da chave de carga ou chave seletora deve ser impermeável a óleo e deve ser apropriado a resistir pressão e vácuo. Estes valores devem ser mostrados e declarados pelos fabricantes.

- Medidor de nível de óleo.

O compartimento de óleo para chave de carga ou chave seletora com expansão integral do volume ou conservadores separados para estes compartimentos, quando providos mostram ser fornecidos com medidor de nível de óleo.

- Dispositivo de proteção para aumento de pressão.

Um ou mais dispositivos de proteção podem seguir estas aplicações:

- a) Relé de controle de fluxo de óleo.

Este relé que é instalado entre a tubulação do cabeçote da chave de carga e o conservador de óleo, irá responder por um pré-determinado fluxo de óleo e permitindo *trip* (desligamento) do transformador.

- b) Relé de sobre-pressão.

O relé de sobre-pressão irá responder ao evento de pressão no compartimento de óleo da chave de carga ou chave seletora para um valor excedido pré-determinado, e permitindo *trip* do transformador.

- c) Dispositivo de alívio de pressão.

Este dispositivo abrirá quando a pressão pré-determinada for excedida protegendo a chave de carga ou chave seletora no compartimento de óleo.

- d) Dispositivo de proteção contra transitórios de sobretensão da chave de carga.

O fabricante da chave de carga deve mostrar os detalhes das características de proteção os quais devem ser fixados durante os testes do transformador. Quando os gaps de arco são usados, tomar o cuidado de assegurar que as descargas serão extintas automaticamente.

#### 2.3.1.4 Descrição das partes do OLTC [IEC89]

Os comutadores de derivações em carga são dispositivos muito importantes para a adequada operação de sistemas elétricos e processos industriais. Eles permitem a troca de relação de operação de um transformador, para controle da tensão sem necessidade de desligamento do mesmo. A continuação são descritas as partes do OLTC e são incluídos conceitos associados a seu funcionamento.

*Comutador de derivações em carga:*

Dispositivo para mudança das ligações das derivações de um enrolamento, adequado para operação energizada ou sem carga. Consiste geralmente de uma chave comutadora um inversor de transição e um seletor de derivações, este ultimo provido ou não de um pré-seletor sendo o conjunto operador pelo mecanismo de acionamento.

*Chave comutadora (chave de carga):* Dispositivo utilizado com seletor de derivações para estabelecer e interromper correntes em circuitos já selecionados.

*Chave seletora:* Dispositivo capaz de estabelecer corrente, ser percorrido por ela e interrompê-la, combinando as funções de um seletor de derivações e de uma chave comutadora.

*Pré-seletor:* Dispositivo destinado a ser percorrido por corrente, mas não estabelecer ou interrompê-la, utilizando em conjunto com um seletor de derivações ou com uma chave seletora para permitir utilizar os seus contatos e as derivações a serem ligadas mais de uma vez no decorrer do deslocamento de uma posição extrema a outra.

*Impedância de transição:* Resistor ou indutor que compreende um ou mais elementos que ligam a derivação em uso à derivação a ser posta em uso, a fim de transferir a carga daquela para esta sem interrupção ou modificação sensível da

corrente de carga, limitando ao mesmo tempo a corrente de circulação durante o tempo em que ambas as derivações são usadas.

*Mecanismo de acionamento:* Dispositivo que assegura o movimento do comutador. Este mecanismo pode compreender um dispositivo independente de armazenamento de energia para imprimir a velocidade adequada e assegurar a realização completa da operação de mudança da derivação.

*Conjunto de contatos:* Par ou combinações de pares de contatos individuais fixos ou móveis, cuja operação é substancialmente simultânea e que é percorrido pela corrente do comutador.

*Contatos principais:* Conjunto de contatos que não tenham impedância de transição em série entre o enrolamento do transformador e os mesmos.

*Contatos de transição (auxiliares):* Conjunto de contatos que tenham impedância de transição em série entre o enrolamento do transformador e os mesmos.

*Corrente de circulação:* Parte da corrente que circula pela impedância de transição durante o tempo em que duas derivações ficam ligadas entre si no decorrer de uma comutação, por efeito da diferença de tensão entre as mesmas.

*Corrente comutada:* Corrente que circula em cada conjunto de contatos principais ou de transição, incorporados à chave seletora ou à comutadora, imediatamente antes da separação dos contatos.

*Comutação:* Seqüência completa de movimentos desde o início até o fim de uma mudança de derivações.

*Ciclo de operação:* Seqüência de operações de um comutador a partir de uma extremidade da sua faixa de regulagem até a outra e de retorno a sua posição inicial.

Na Figura 2.5 é apresentado um diagrama esquemático do OLTC GI3022 mostrando o detalhamento das suas partes principais.

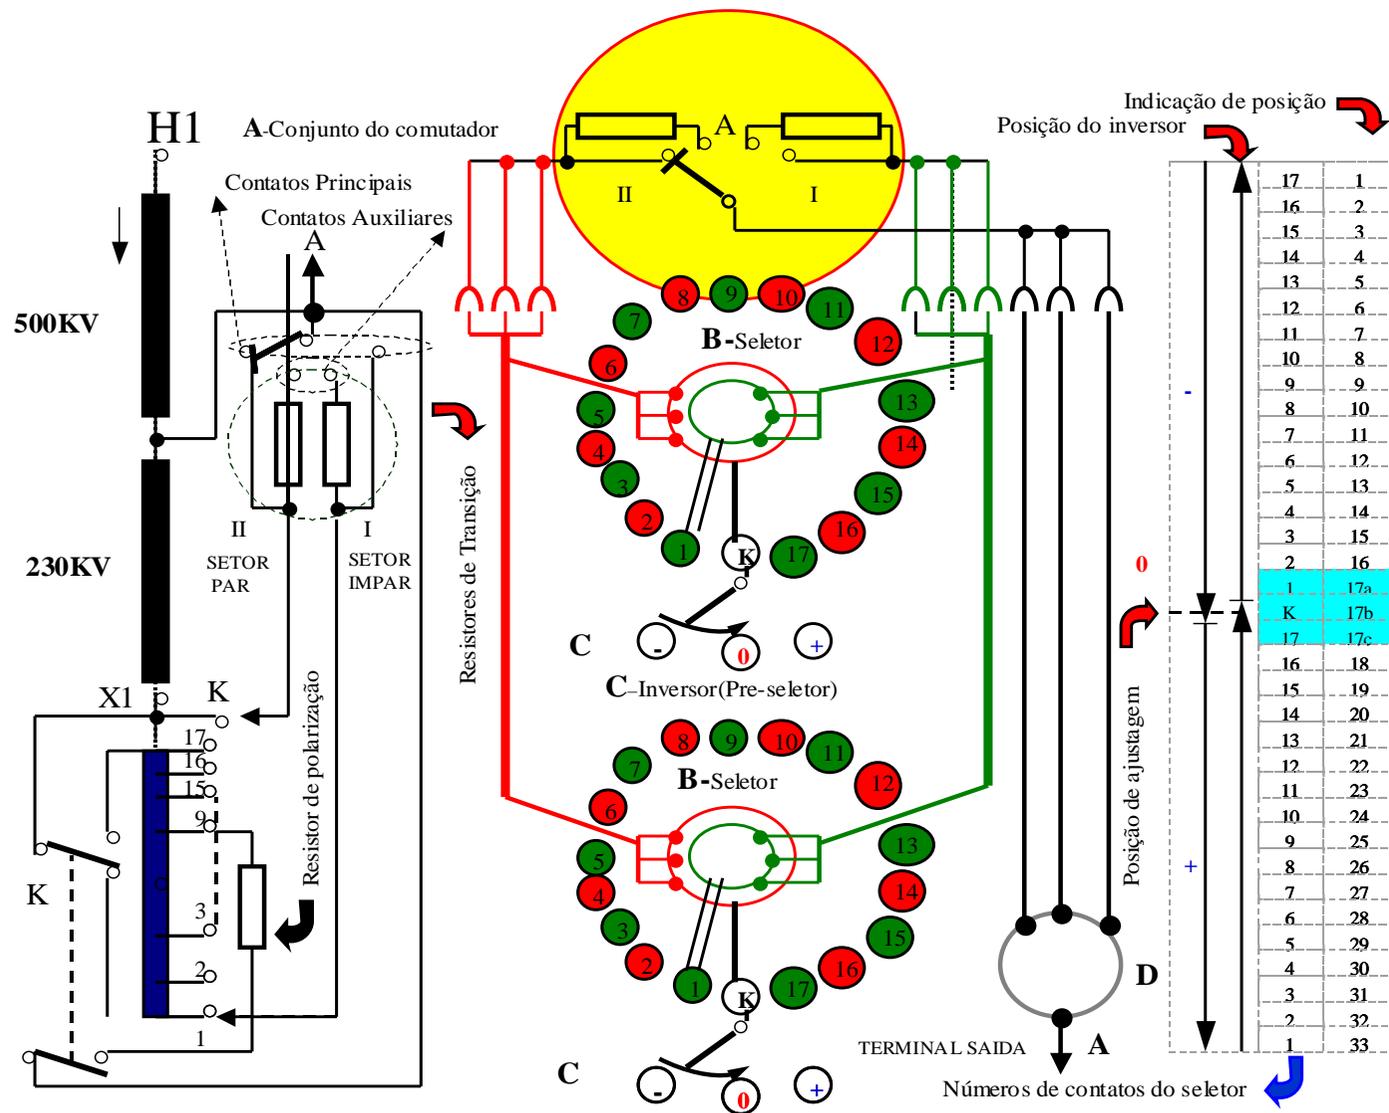


Figura 1.6: Detalhe das partes principais do OLTC GI-3022.

### *2.3.1.5 Mecanismo de acionamento motorizado.*

#### a) Generalidades.

O acionamento motorizado tem a finalidade de colocar o comutador de tap sob carga na posição de serviço desejada.

Na caixa de proteção do acionamento motorizado estão contidas todas as peças mecânicas e elétricas, necessárias à operação de um comutador de tap sob carga. O comando se processa baseado sobre o princípio de comutação gradativa “passo a passo”, ou seja, num processo de mudança por tap iniciado através de um único impulso de comando, o qual faz com que a comutação se processa até o fim.

Dispositivos elétricos e mecânicos de segurança impedem a passagem do acionamento além do curso normal. Uma ampla série de dispositivos de segurança e controle facilita o funcionamento correto em serviço.

O acionamento motorizado pode ser equipado com motores de acionamento de diversas potências, de modo que qualquer junção de comutadores de tap sob carga pode ser feita.

O acionamento motorizado pode opcionalmente ser fornecido montado em alojamento tipo MA7/8 (que apresenta uma carcaça maior).

#### b) Características técnicas.

- Potência
- Corrente
- Frequência
- Rotação
- Número de revoluções do eixo acionador para cada comutação
- Duração de cada comutação
- Momento de torção do eixo acionador

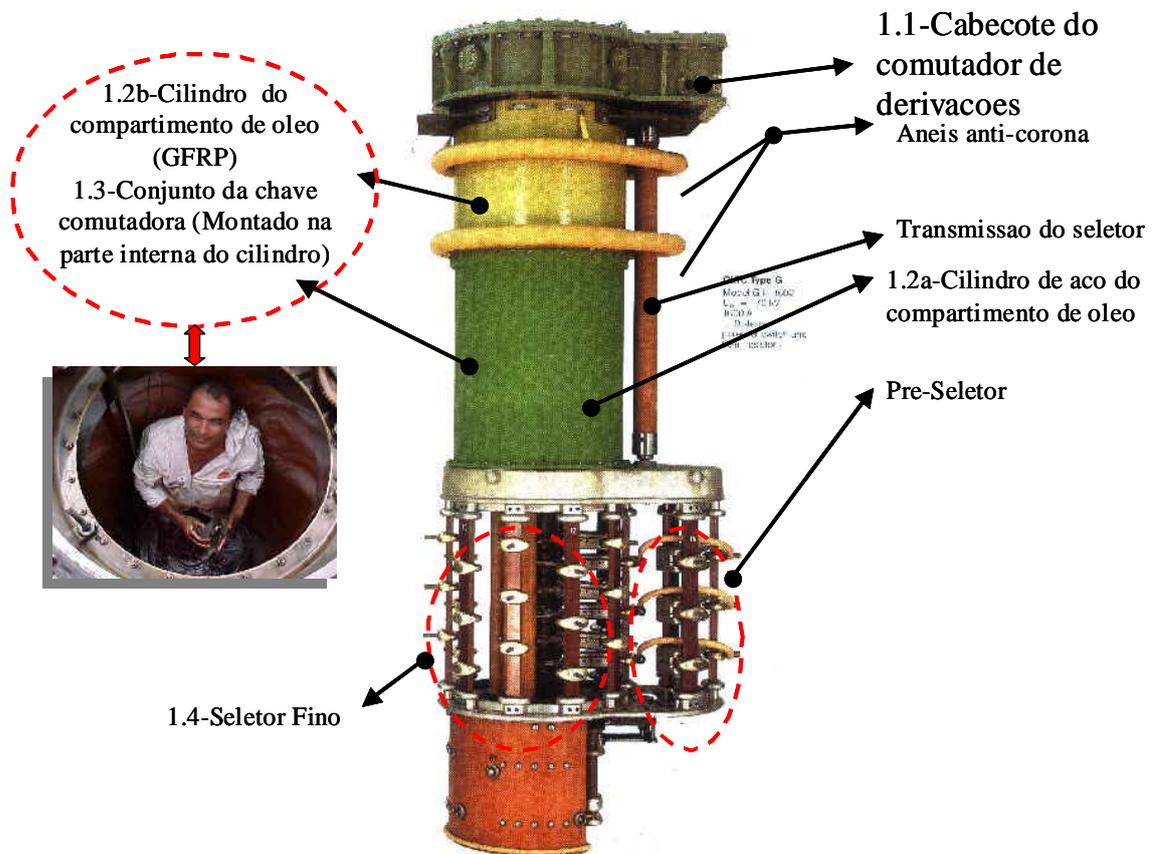
- Número de revoluções da manivela para cada comutação
- Número máximo de posições de serviço

**Tabela 1.3:** Características técnicas do mecanismo de acionamento motorizado.

Dados nominais do motor	0,75KW	1,1 KW	2,2 KW	3,0 KW
Tensão	220/380V trifásico			
Corrente	3,4/2,0A	5,0/2,8A	8,4/4,4A	11,3/6,5A
Frequência.	60Hz			
Rotação	1.800rpm			
Momento de torção do eixo acionador	18Nm	26Nm	52Nm	70Nm
Numero de revoluções da manivela para cada comutação	33	33	54	54
Numero máximo de posição de serviço	35			

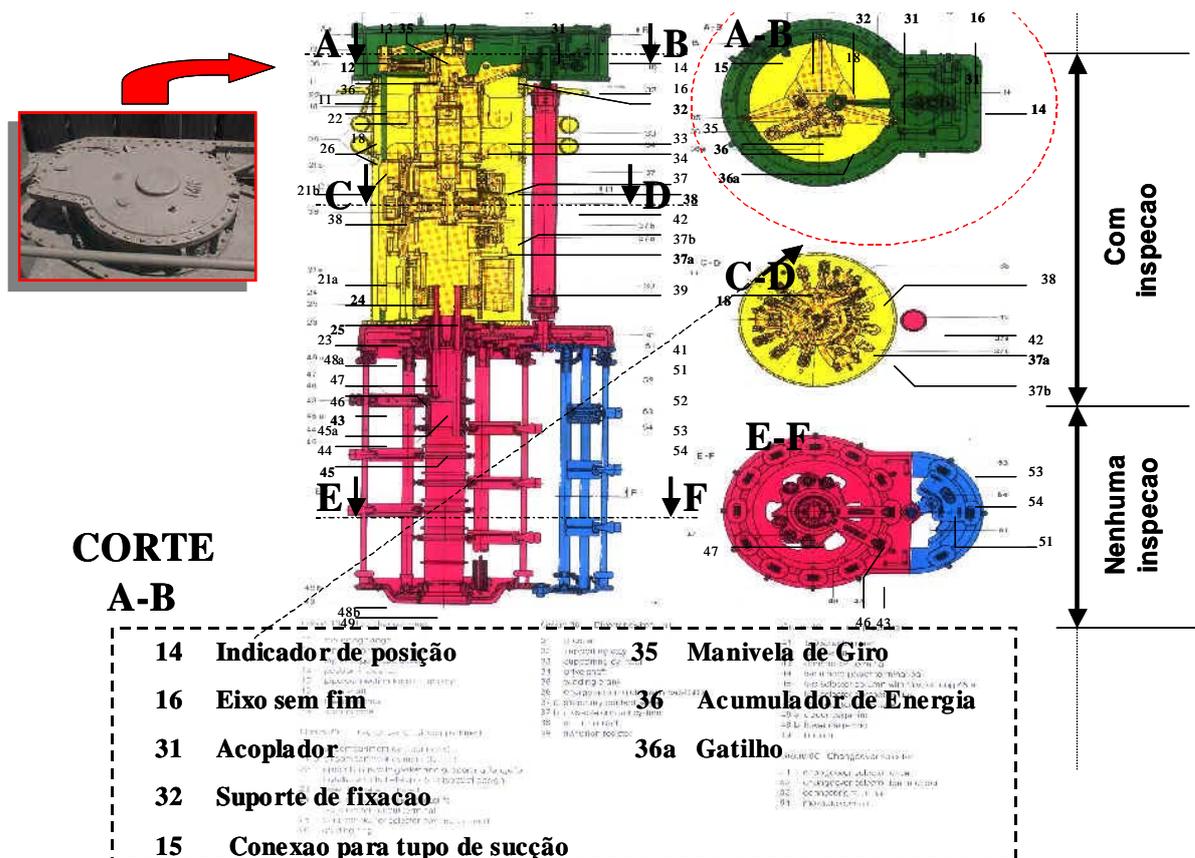
### 2.3.2. Princípio de funcionamento do comutador de tap sob carga

Numa mudança de derivações, primeiramente escolhe-se através do seletor, a derivação desejada do enrolamento de regulação. Logo, então, a chave comutadora, efetua a ligação da derivação que conduzia a corrente para a nova derivação escolhida. Durante esta operação rápida de comutação, ocorre que, o degrau do enrolamento de regulação envolvido, está sendo curto-circuitado por resistências ôhmicas por tempo curtíssimo. Desta forma a comutação é efetuada sem interrupção de corrente. Na fotografia e o diagrama indicados na Figura 2.6 são mostradas as partes principais do OLTC, com as partes superiores montadas sobre o tanque principal do transformador (cabecote do comutador de derivações); a parte externa ao tanque da chave de carga que funciona imerso dentro do óleo do transformador. [MR1990]

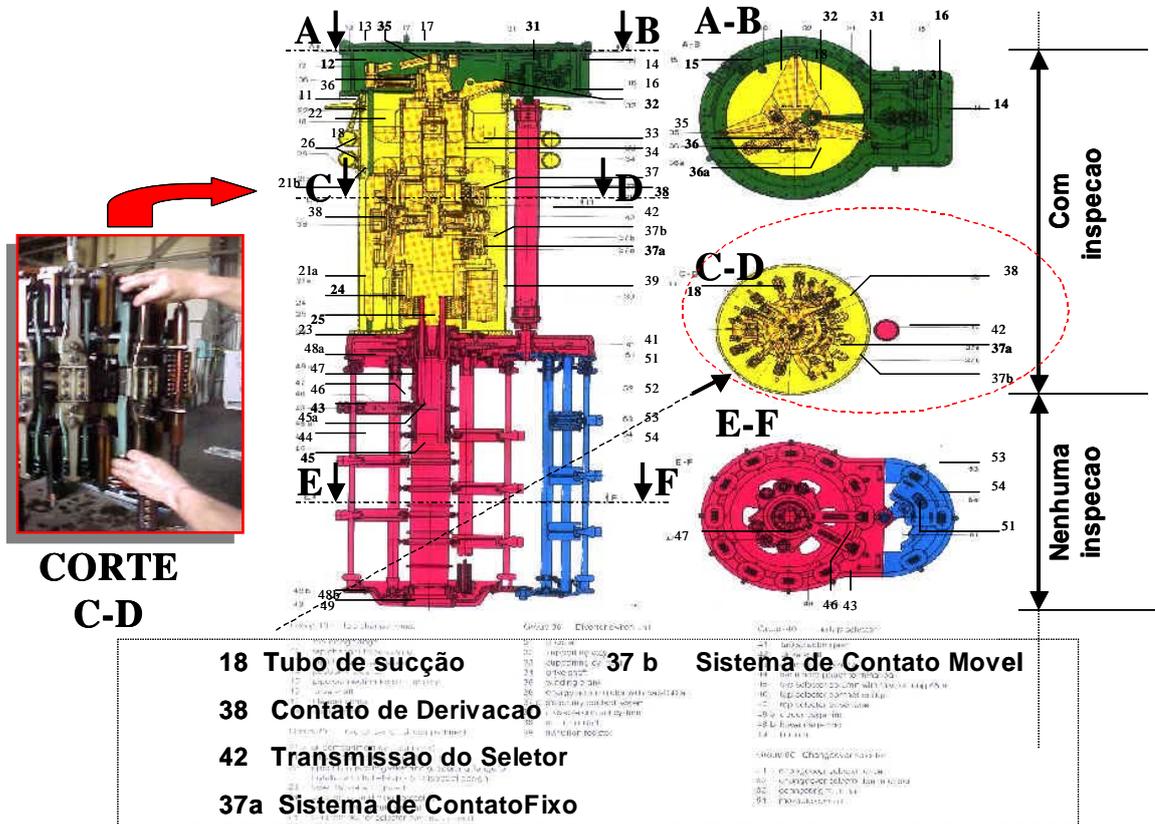


**Figura 1.7:** Fotografia e diagrama mostrando as partes principais do comutador tipo “G”.

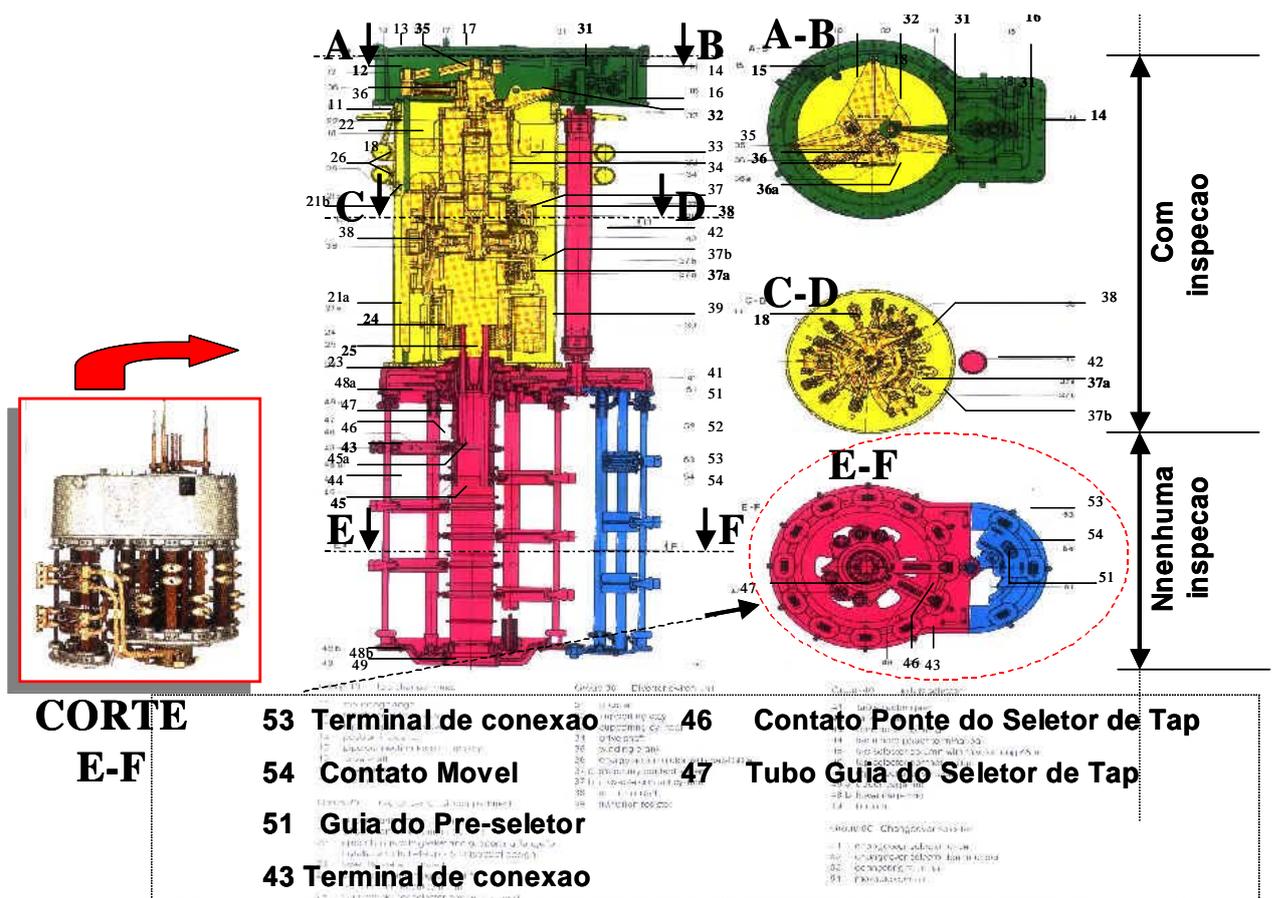
Nas Figuras 2.7 e 2.8 são mostrados os componentes do cabeçote do comutador de derivações e os componentes da chave comutadora, respectivamente. Na Figura 2.9 é mostrado o detalhe dos componentes do seletor e pré-seletor.



**Figura 1.8:** Fotografia e diagrama mostrando o detalhe dos componentes do cabeçote do comutador de derivações.

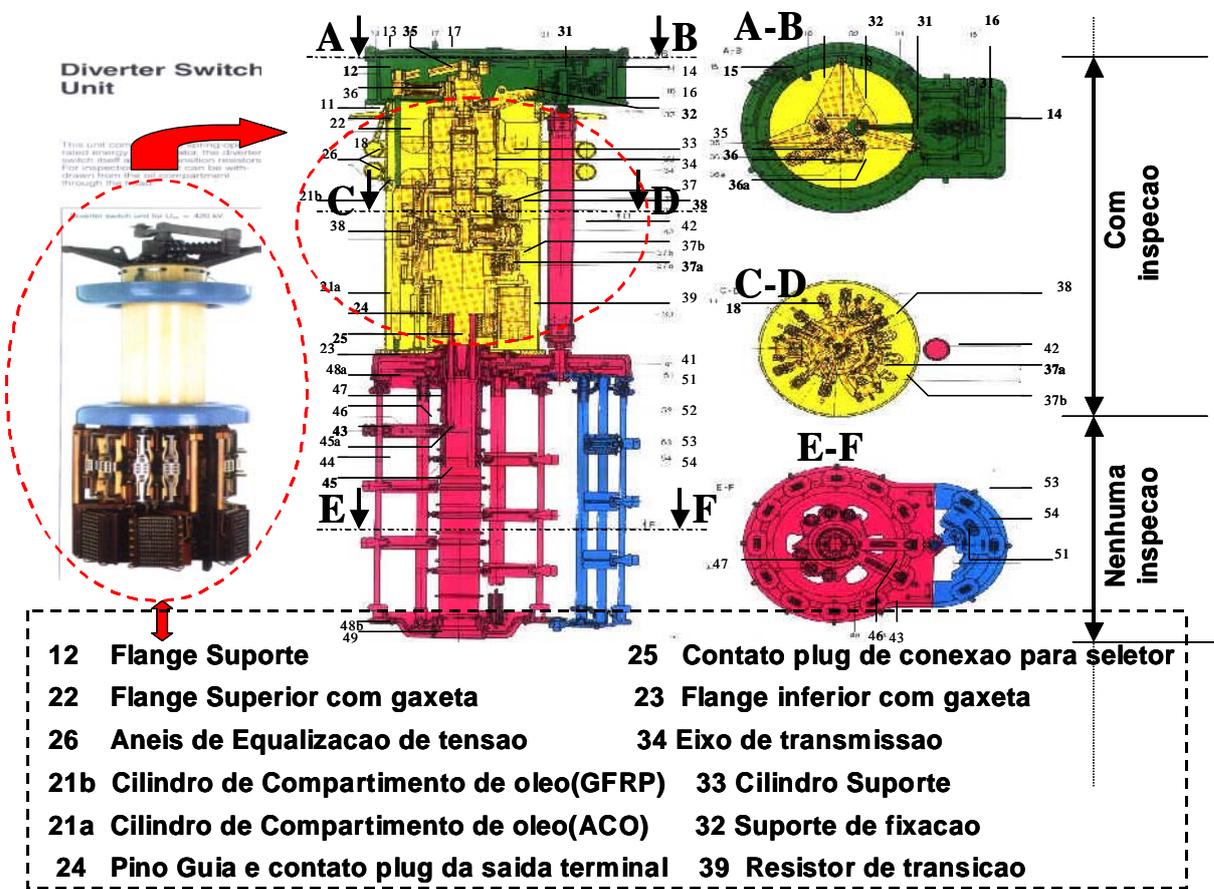


**Figura 1.9:** Fotografia e diagrama mostrando o detalhe dos componentes da chave comutadora.

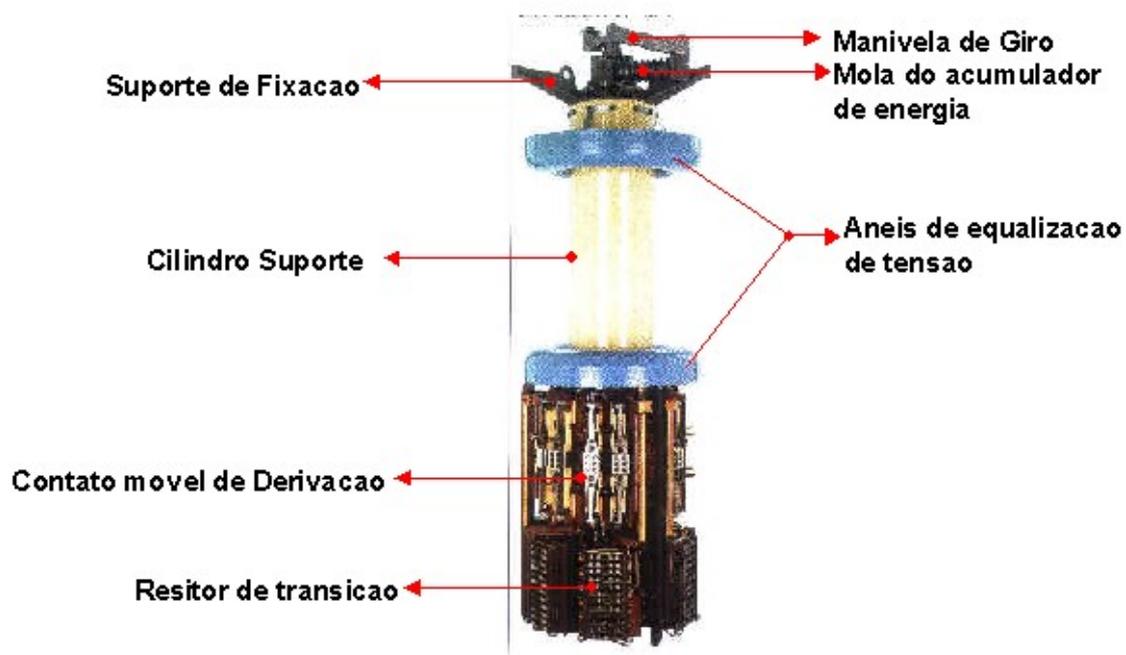


**Figura 1.10:** Fotografia e diagrama mostrando o detalhe dos componentes do seletor e pré-seletor.

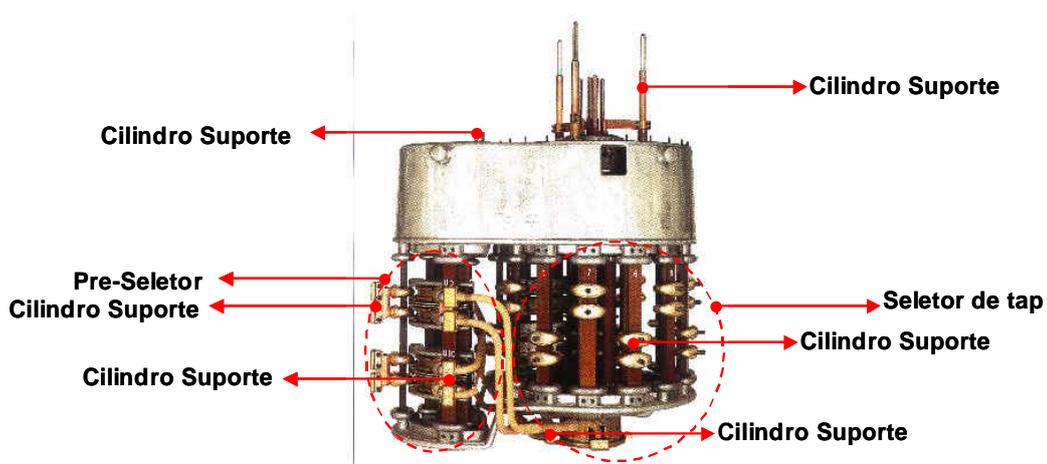
Na Figura 2.10 é mostrado o detalhe dos componentes do conjunto da chave comutadora dentro do transformador. Já na Figura 2.11 são mostrados os componentes da chave comutadora isoladamente. Os componentes do seletor e pré-seletor, isoladamente ou fora do transformador, são mostrados na Figura 2.12. A transmissão do seletor do tap é mostrado na Figura 2.13.



**Figura 1.11:** Fotografia e diagrama mostrando os componentes da chave comutadora e a sua localização no transformador.

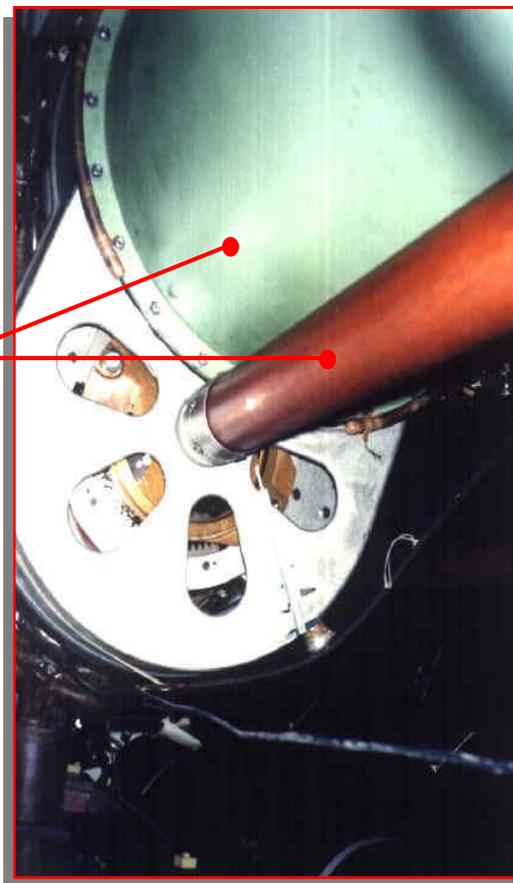


**Figura 1.12:** Fotografia mostrando os componentes do conjunto da chave comutadora isolada.



**Figura 1.13:** Diagrama mostrando os componentes do seletor e pré-seletor, isolados.

**Acoplamento da transmissão  
do seletor de tap e cilindro do  
compartimento de óleo (aço)  
visto na parte interna do  
autotransformador**



**Figura 1.14:** Fotografia na qual é visualizada a transmissão do seletor de tap.

### **2.3.3. Conceitos básicos de manutenção de OLTC**

A manutenção de comutadores de derivações de transformadores se restringe, fundamentalmente, à chave comutadora e ao mecanismo de acionamento motorizado. O seletor e o pré-seletor praticamente não necessitam de manutenção porque seus contatos não sofrem a ação do arco elétrico e suas partes, em geral, não se desgastam.

Esse tipo de serviço exige: pessoal bem treinado para realizá-lo; conhecimento detalhado da estrutura e do funcionamento do comutador e do correspondente mecanismo de acionamento motorizado; disponibilidade de peças de reserva e óleo mineral isolante; e ferramentas, instrumentos e equipamentos adequados.

O conhecimento detalhado da estrutura e do funcionamento do comutador e do mecanismo de acionamento motorizado poderá ser adquirido nos cursos específicos e completado no acompanhamento dos trabalhos de manutenção feitos pelas equipes responsáveis pelos mesmos.

Uma revisão do comutador pode ser realizada em aproximadamente 8 horas. O cilindro da chave comutadora não deve ficar exposto ao ar por mais de 10 horas pois pode absorver umidade e ficar com a resistência de isolamento prejudicada.

Em seqüência, são reproduzidas algumas recomendações de fabricantes as quais servem de orientação geral para a realização desses serviços.

As manutenções das chaves comutadoras estão divididas em duas categorias conforme é mostrado a seguir.

#### *Manutenção baseada no tempo (TBM)*

São as manutenções periódicas realizadas pelo número de comutações ou/e no tempo o que ocorrer primeiro.

#### *Manutenção baseada na condição (CBM).*

São as manutenções aperiódicas realizadas na condição do óleo isolante coletado para análise de teor de água e rigidez dielétrica caso encontra-se fora dos valores especificados pelo fabricante o comutador deve ser retirado de operação para substituição do óleo.

#### **2.3.4. Práticas de manutenção de OLTC**

Todas as práticas de manutenção utilizadas pela ELETRONORTE nos comutadores sob carga GI-3022 instalados nos bancos de autotransformadores 500/230/13.8 kV, 600 MVA na subestação de São Luis II fornecedor de energia para a companhia ALUMAR, CVRD, cidade de São Luis e Subestação da cidade de Miranda são subdivididas nas manutenções preventivas baseadas no tempo, TBM, em que as chaves são inspecionadas com a substituição de peças de acordo com o número de operações do comutador de tap, fornecidos pelo fabricante “MR (Maschinenfabrik Reinhausen)” e as manutenções preditivas baseadas na condição, CBM, onde são retiradas amostras de óleo do comutador para que seja realizada análise físico-química (rigidez dielétrica, teor de água) e gascromatografia visando o monitoramento off line das suas condições de operação.

##### *2.3.4.1 Atividades de manutenção preventivas baseadas no tempo (TBM).*

###### *a) Manutenção preventiva de 35.000 operações. [MR1990]*

Neste tipo de manutenção são realizados os seguintes trabalhos:

- 1- medições nos contatos principais para verificar as condições de desgaste e, confirmação se os valores encontrados estão dentro do especificado pelo fabricante.
- 2- medições nos resistores de transição para confirmar, se estão conforme especificado pelo fabricante.
- 3- verificar estado de conservação da junta superior da tampa do comutador sob tap e, substituição caso necessário.
- 4- substituição de 1200 litros de óleo isolante do tanque do comutador sob tap, após teste de rigidez dielétrica que será considerado normal para valores superiores a 40 kV.
- 5- substituição dos contra pinos 4x40 da chave de carga

- 6- realizada limpeza geral na parte interna do tanque e,na chave de carga.
- 7- realizados testes funcionais no acionamento motorizados tipo MA7.
- 8- realizadas anotações do numero de operações acumulativas e, número de recomendadas para a próxima intervenção.

*b) Manutenção preventiva de 70.000 operações. [MR1990]*

Nesta manutenção são realizados os seguintes trabalhos:

- 1- São realizados todos os procedimentos de 1 a 8 da manutenção de 35.000 operações.
- 2- substituição de todas as travas para fixação da chave de carga
- 3- substituição do jogo de presilhas da biela do acumulador de energia da chave de carga
- 4- substituição de todas as travas de fixação da parte superior com a parte inferior da chave de carga
- 5- substituição de todos os pinos elásticos da chave de carga
- 6- substituição de todas as porcas autotravantes da chave de carga

*c) Manutenção preventiva de 100.000 operações. [MR1990]*

Nesta manutenção são realizados os seguintes trabalhos:

- 1- realizados todos os procedimentos de 1 a 8 da manutenção de 35.000 operações.
- 2- substituição da mola do acumulador de energia da chave de carga
- 3- substituição da mola do gatilho da chave de carga
- 4- substituição da blindagem das arruelas pratos da chave de carga
- 5- substituição dos tubos de conexão da chave de carga

6- substituição dos parafusos especiais da chave de carga

*d) Manutenção preventiva de 250.000 operações. [MR1990]*

Nesta manutenção são realizados os seguintes trabalhos:

- 1- realizados todos os procedimentos de 1 a 8 da manutenção de 35.000 operações.
- 2- substituição do jogo de mola prato do amortecedor do acumulador de energia da chave de carga
- 3- substituição do jogo de mola prato do amortecedor do contato shunt da chave de carga
- 4- substituição do jogo de cabo flexível de ligação dos resistores de transição da chave de carga
- 5- substituição do parafuso com batedor do contato shunt da chave de carga
- 6- substituição do contato principal fixo e móvel da chave de carga
- 7- substituição da bucha da chave de carga

*e) Manutenção preventiva de 400.000 operações. [MR1990]*

Nesta manutenção são realizadas as desmontagens gerais da chave para verificar e medir as folgas existentes, o desgaste dos batedores dos contatos shunt, bem como, a existência de trincas no eixo de acionamento da chave de carga. O tanque é inspecionado para verificar a existência de trincas, caso seja encontrado qualquer anormalidade a chave só retorna a operação com troca da peça defeituosa.

- 1- realizado teste de estanqueidade com ar seco ou nitrogênio seco a pressão de 0,3bar por um período de 24 horas para verificar estado da junta entre o tanque do comutador e o suporte do seletor e pré-seletor instalados no interior do tanque do autotransformador.

2- realizados todos os procedimentos de 1 a 8 da manutenção de 35.000 operações.

3- no acionamento motorizados tipos MA7 são realizados os seguintes trabalhos:

- a. no armário de comando/controle são substituídos os seguintes componentes: contactores k3 tipo 3th8355-oan1; k1, k2 tipo 3tf4222-oan1; k20 tipo 3th8244-oan1, disjuntor Q1 tipo 3vu0300-omk00; conjunto de chaves micro switches S12, S13, S14; chave de emergência S15; borracha de vedações das portas.
- b. no redutor são trocadas as juntas com substituição do óleo lubrificante.
- c. na transmissão de acionamento são substituído os rolamentos 6205 e 1205, lubrificação das caixas de engrenagens com substituição dos oring's efetuando seu alinhamento.

#### *2.3.4.2 Atividades de manutenção preditivas baseadas na condição (CBM).*

##### *a) Atividade de coleta, análise e diagnóstico físico-químico*

As chaves de carga GI-3022 são montadas em tanques separados do tanque principal do autotransformador o que permite o seu acompanhamento e monitoramento com a coleta de 1000 ml de óleo isolante do comutador a cada 3 meses para que seja feito o ensaio físico-químico (rigidez dielétrica, teor de água) conforme os resultados mostrados na Tabela 2.4.

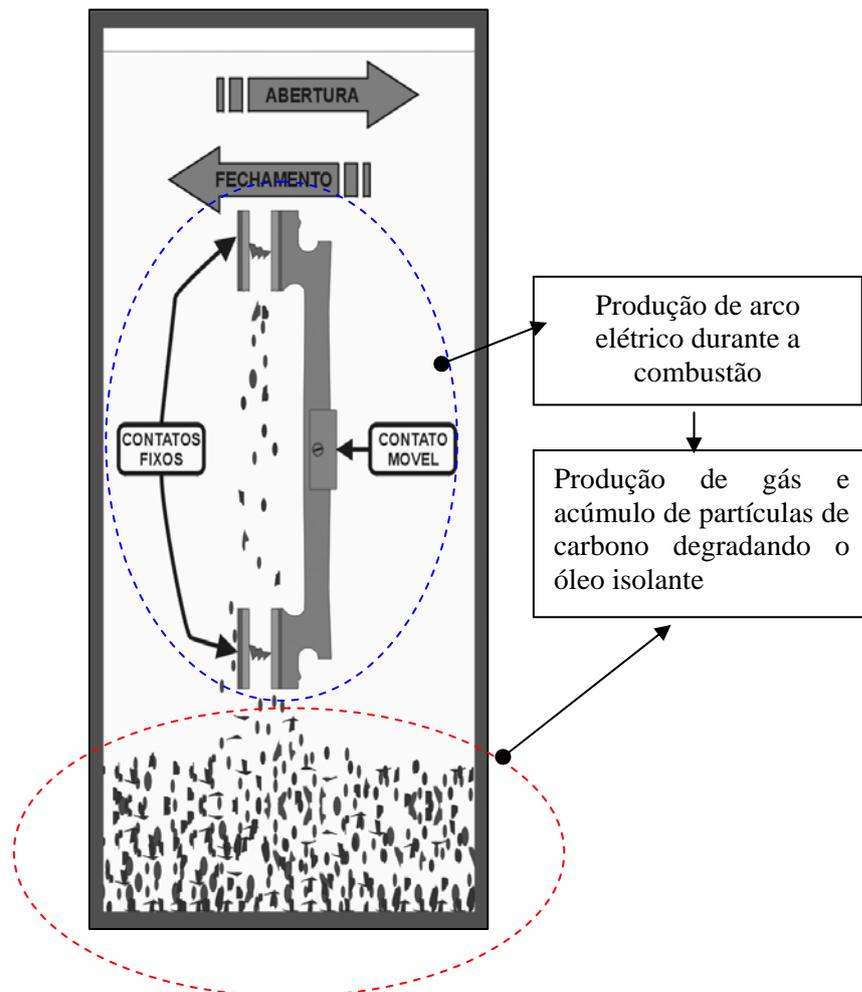
**Tabela 1.4:** Resultados de atividades de manutenção baseada na condição.

Equipamento: Comutador de tap sob carga Tensão: 230kV Número de série: SP18290(LDAT7-1A)		data da coleta: 14/10/02
		data do ensaio: 15/10/2002
ensaios realizados	resultados	valores limites
		230 kV
Cor (ASTM D1500)		
ind.de neutralização (MB101) mgKOH/g		
rigidez dielétrica (ASTM D877) kV	53	> 40
Fat. de potência a 25° C (ASTM D924%).		
fat. de potência a 100° C (ASTM D924%)		
Tensão interfacial (MB 320) Din/cm		
Conteúdo de água (ASTM D1533) ppm	5	< 20
Densidade (MB 104) g/cm		
<b>Resultados: normais</b>		

Estes resultados nos permitem acompanhar a degradação do óleo isolante ocorrida pela produção de arco elétrico, um fenômeno que produz contaminantes com o aumento do número de comutações, tais como:

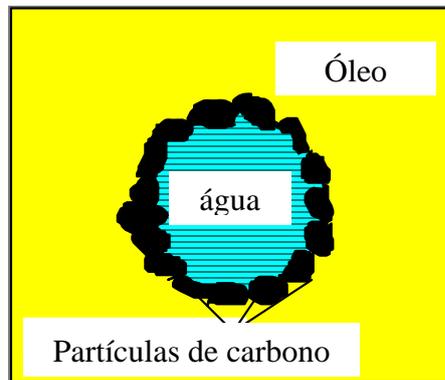
- carbono.
- água.
- partículas sólidas da isolação e componentes.
- degradação de produtos do óleo, tais como álcoois, aldeídos e cetonas, os quais podem degradar resinas, vernizes, laca e, causar diversos depósitos.

Esses contaminantes são condutivos e irão reduzir as propriedades isolantes do óleo, resultando numa baixa performance da sua rigidez dielétrica, determinando a substituição da carga de óleo da chave e inspeção detalhada nos contatos para verificação dos desgastes e batedores de fins de curso (ver Figura 2.14).



**Figura 1.15:** Produção de arco elétrico e acúmulo de partículas degradando o óleo isolante.

O conteúdo de água no óleo dos comutadores é causado pelo efeito das partículas de carbono na isolação do óleo sob tensão, pode emulsificar umidade e aumentar a solubilidade no óleo, conforme mostrado na Figura 2.15.

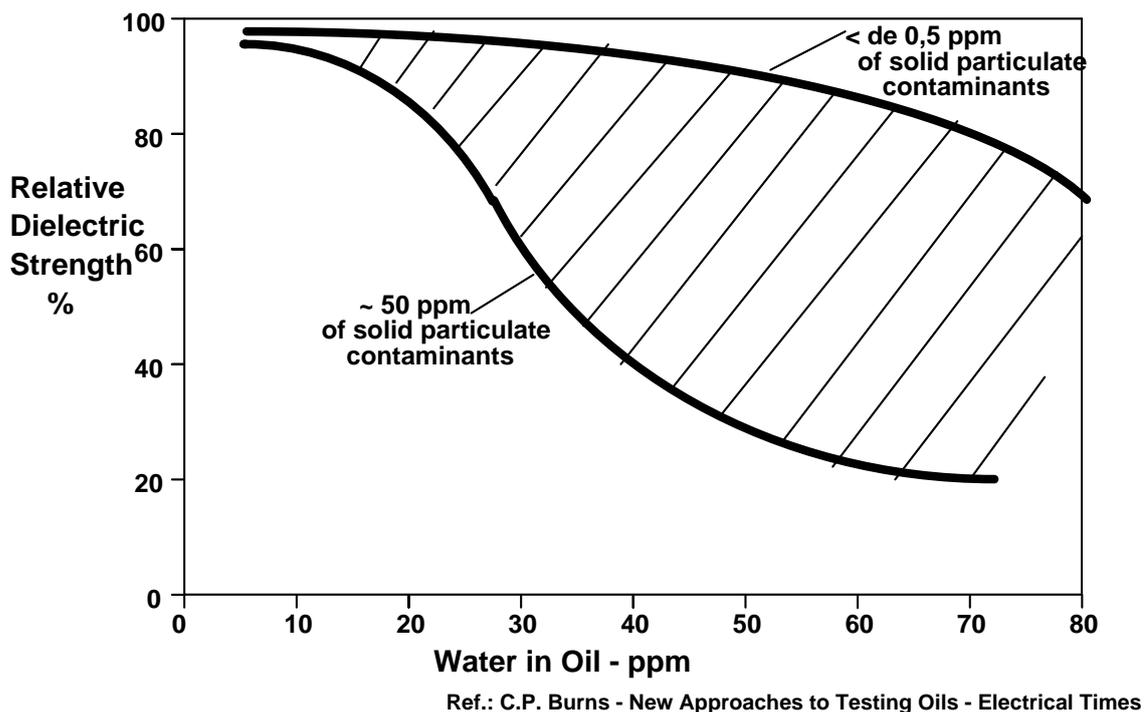


**Figura 1.16:** Interferência da água no óleo.

A solubilidade de água pode reduzir a força dielétrica e estimular a formação de carbono. O acúmulo de partículas de carbono pode causar *tracking* (centelhamento) promovendo descargas contínuas, contribuindo para o aumento da temperatura do comutador de tap.

Desta forma fazemos o acompanhamento do teor de água no óleo que nos dará o diagnóstico da sua degradação bem como o aumento do tamanho da sedimentação de partículas de carbono que pode se expandir com a evolução de água.

Conforme mostrado no diagrama da Figura 2.16 mantemos a faixa de 0 a 20 ppm de teor de água como normal para sua operação satisfatória.



**Figura 1.17:** Gráfico de acompanhamento do teor de água.

*b) Atividade de coleta, análise e diagnóstico gascromatográfico do óleo.*

O acompanhamento do diagnóstico dos gases quentes dissolvidos (hidrogênio, etano, etileno, metano, acetileno, monóxido de carbono e dióxido de carbono) pode nos mostrar através do crescimento do gás chave acetileno a evolução da temperatura do comutador, bem como, quebras causadas pelo crescimento das partículas de carbono provenientes do efeito do arco elétrico sob o óleo. Este arco elétrico de alta energia depende do nível de desgaste dos contatos e, do estado da erosão formada nas superfícies dos contatos principais, durante o processo de comutação.

Os valores que determinam que o comutador deve ser inspecionado devido às condições severas de concentração de partículas no óleo nos mostra valores de acetileno acima de 10000 ppm. Na Tabela 2.5 são mostrados os resultados de ensaios gascromatográfico de óleo isolante coletados no comutador de tap fabricante “MR” tipo GI-3022, com valores satisfatórios de operação.

**Tabela 1.5:** Resultados de ensaios de óleo isolante, comutador MR GI-3022.

<b>Identificação do equipamento</b>	
Equipamento: autotransformador	Tensão: 500 kV
Fabricante: BBC	Potência (MVA): 200
Instalação: CMAU	Número de série: SP18290
Data da coleta: 20/08/2002	Data da análise: 29/08/2002
Ponto de amostragem: óleo coletado do comutador “MR” GI-3022	
<b>Ensaio</b>	<b>Resultados</b>
Hidrogênio (H <sub>2</sub> )-ppm	12.268
Oxigênio (O <sub>2</sub> )-ppm	11.088
Nitrogênio (N <sub>2</sub> )-ppm	92.327
Metano (CH <sub>4</sub> )-ppm	38
Monóxido de carbono (CO)-ppm	4.913
Dióxido de carbono (CO <sub>2</sub> )-ppm	341
Etileno (C <sub>2</sub> H <sub>4</sub> )-ppm	3.648
Etano (C <sub>2</sub> H <sub>6</sub> )-ppm	336
Acetileno (C <sub>2</sub> H <sub>2</sub> )-ppm	3.241
Total de gases-ppm	128.200
<b>Diagnóstico: normais</b>	

As manutenções desenvolvidas em comutadores de tap sob carga na ELETRONORTE estão migrando gradualmente e cautelosamente das manutenções baseadas no tempo, TBM, para as manutenções baseadas na condição [BOLH02],[DILL96],[HAND01],[SEN95],[WETZ00], CBM, com monitoramento off line do óleo com o acompanhamento das inspeções realizadas conforme solicitações do fabricante “MR”, que interagem com a manutenção implementando melhorias contínuas no projeto com a substituição dos componentes que se deterioram com a idade e se desgastam com o número de operações. As experiências em manutenções de comutadores sob carga constituem um processo em constante evolução tecnológica [BOLH02],[JONE98],[HAYK98],[LEWI95],[KANG01],[SCHA97],[YOUN98] no qual constatamos um número razoavelmente grande de falhas mecânicas que necessitam do

desenvolvimento de sondas confiáveis, para que possa ser realizado um monitoramento on line de seus componentes.

#### **2.4. Síntese das categorias de falhas dos comutadores de tap sob carga**

Descrevemos uma síntese das principais categorias de falhas dos comutadores de tap sob carga observadas nos últimos 10 anos, 1995 a 2005, acompanhando e detectando os principais tipos de defeito, as suas causas, os resultados apresentados e suas principais conseqüências no transformador de potencia. A síntese (ver Tabela 2.6) tem sido elaborada a partir da experiência prática do autor em atividades de manutenção de transformadores de potência e OLTC na ELETRONORTE.

O status de monitorar o comutador de tap torna-se atrativo para aumentar a confiabilidade e reduzir o custo de manutenção pela eliminação de inspeção interna no comutador e inaceitável variação de desvio de operação.

Os mais importantes parâmetros para monitorar são aqueles nos quais detectam movimento do mecanismo de acionamento; medida de desvio do tempo de operação e corrente do resistor de transição.

Os sistemas devem ser on line para ser eficazes e de maneira ideal deve ter aplicação universal para todos os comutadores de tap existentes incluindo nas linhas de projeto.

**Tabela 1.6:** Síntese das principais categorias de falhas dos comutadores de tap sob carga.

Tipo de defeito	Causa Base	Resultado	Conseqüências
1-Falha mecânica na haste de acoplamento, guias componentes e acessórios. 2-Falhas nos componentes do contator suporte.	1-Projeto inadequado: Controle de qualidade deficiente na fabricação ou lugar de montagem. 2-Idade do componente ou fadiga	1-Perda de acionamento e sincronismo entre a chave e o seletor.  2-Perda de contato.	1-Arcos de falta no seletor e/ou chave.  2-Falha principal na mudança de tap/transformador
3-Chave opera lentamente ou incompleta.	3.1- Projeto inadequado ou Controle de qualidade. 3.2-Componente deteriorado.	3-Operação lenta ou incompleta da chave.	3.1-Arcos de falta no seletor e/ou chave.  3.2-Falha principal na mudança de tap/transformador
4-Aumento do carvão/Arco por pirólise	4.1- Projeto inadequado e/ou infrequente uso da chave de carga	4-Falha no seletor de tap	4.1-Gás no seletor e/ou falha por arco. 4.2-Possibilidade de maior falha
5-Falha do separador	5-Causado por manutenção.	5-Separador quebrado (rachado)	5-Maior falha do comutador sob carga ou transformador.
6-Ligações ou resistor de transição	6- Projeto inadequado, uso ou período de vida do componente	6-Superaquecimento ou falta por formação de gás	6-Retirada não planejada para inspeção.
7-Variedades de defeitos menores (falha de fixação, falha de vedação, erosão de contato e falha de articulações correntes)	7.1-- Projeto inadequado. 7.2-Período de vida de componentes. 7.3-Manutenção inadequada	7.1-Vazamento de óleo ou entrada de água. 7.2- Superaquecimento	7.1-Transtorno geral. 7.2-Sobre-aquecimento. 7.3-Retirada não planejada

## 2.5. Modelo proposto de RNA para diagnóstico da condição de OLTC

Uma das principais características das redes neurais é a sua capacidade de generalização em que, por exemplo, dado um conjunto de dados de treinamento e de teste e após a realização de um treinamento e teste bem sucedidos, a rede neural será capaz de estimar o resultado para dados de entrada que não foram utilizados durante o treinamento, desde que o intervalo do domínio dos dados de entrada seja similar ao utilizado durante o treinamento.

Além da capacidade de generalização, as RNA são flexíveis nas grandezas ou sinais de entradas fornecidas. Isto é, se uma determinada entrada não for utilizada, a RNA ainda poderá resolver o problema, talvez sem a precisão mais fina a ser conseguida, porém sendo capaz de produzir resultados ainda válidos.

O problema de diagnóstico da condição de OLTC é parte importante da manutenção dos transformadores e autotransformadores de potência. Esse problema é resolvido por especialistas humanos que realizam um conjunto de atividades de análise e diagnóstico que levam a diagnosticar adequadamente a condição do comutador. Dentro de domínios bem definidos, um sistema de inteligência artificial pode realizar tarefas com sucesso similar às aquelas produzidas por especialistas humanos. Neste caso, uma RNA é considerada uma alternativa para poder realizar esse tipo de tarefa.

### 2.5.1. Estrutura do modelo da rede neural artificial

Atualmente a arquitetura de rede neural artificial mais utilizada é o perceptron multicamada (*multilayer perceptron*), enquanto que o algoritmo de treinamento preferido é o *back-propagation* dentro de um paradigma de treinamento supervisionado. Neste trabalho é proposta uma RNA não-linear de perceptron multicamada *feedforward* (sem realimentação) para diagnosticar a condição de comutadores de tap sob carga de transformadores de grande potência. A finalidade do diagnóstico da condição é justamente evitar atividades de manutenção desnecessárias, dessa maneira os custos na manutenção poderão ser minimizados.

A característica não-linear do problema a ser resolvido levou a considerar a adoção de uma RNA não-linear em que as funções de ativação dos neurônios das

camadas escondidas são funções não-lineares do tipo sigmóide e nos neurônios da camada de saída as funções de ativação são funções lineares. A definição da configuração de redes neurais é ainda considerada uma arte, que requer grande experiência dos projetistas.

Em vista de que estão disponíveis na ELETRONORTE dados históricos sobre a manutenção dos seus transformadores de grande potência e os seus OLTC, a utilização do paradigma de treinamento supervisionado tem justificativa prática.

Portanto, a rede neural proposta é uma rede convencional e básica, considera-se que outros tipos de redes neurais podem ser utilizados com sucesso para resolver o mesmo problema.

Na Figura 2.17 é apresentada a estrutura do modelo da rede neural artificial proposta a ser usada para o diagnóstico da condição do comutador de tap, incluindo as grandezas e os blocos a serem abstraídos e representados pela rede neural. Considera-se que uma rede neural de perceptron composta de duas camadas escondidas de neurônios pode resolver um problema altamente não-linear em engenharia elétrica [PAUC02], tal como o problema de diagnóstico da condição de comutadores de tap sob carga.

São considerados nove módulos de diagnóstico e estimativa:

- Módulo 1: Envelhecimento do OLTC.
- Módulo 2: Falhas elétricas e falhas mecânicas.
- Módulo 3: Falhas induzidas por manutenção e falhas de regulação do sistema.
- Módulo 4: Análise físico-química.
- Módulo 5: Análise gascromatográfica.
- Módulo 6: Envelhecimento acelerado dos componentes.
- Módulo 7: Óleo deteriorado.
- Módulo 8: Arco elétrico.

- Módulo 9: Diagnóstico final da condição do OLTC.

Na Figura 2.18 é apresentada a configuração final da rede neural artificial para o problema de diagnóstico da condição do comutador de tap visando a redução de custos de manutenção de transformadores de potência de EAT na ELETRONORTE.

O total de entradas consideradas foi de 22 (ver Figura 2.17) as quais consideram:

- Módulo 1: → 4 entradas.
- Módulo 2: → 4 entradas
- Módulo 3: → 2 entradas
- Módulo 4: → 3 entradas.
- Módulo 5: → 9 entradas (ver Tabela 2.5, ensaios).

Os módulos 6, 7 e 8 não precisam ser representados através de redes neurais intermediárias pois as camadas intermediárias de neurônios têm a capacidade de obter o modelo implícito do comportamento desses módulos bem como dos outros módulos. Já o módulo 9 apenas servirá para ponderar o sinal de saída para valores adequados ao usuário do sistema inteligente. Preliminarmente foram consideradas redes neurais separadas para modelar os blocos 6, 7 e 8 mas não foi vantajoso em comparação com o modelo da Figura 2.18. Alguns testes iniciais de validação cruzada permitiram desconsiderar essa alternativa de utilizar várias redes neurais para os correspondentes blocos dos módulos 6, 7 e 8. Validação cruzada é uma técnica estatística que no caso de redes neurais, um número de arquiteturas de RNA são testadas mediante treinamento rápido (*fast training*) principalmente tentando encontrar o número mais adequado de neurônios em cada camada escondida (*hidden layer*).

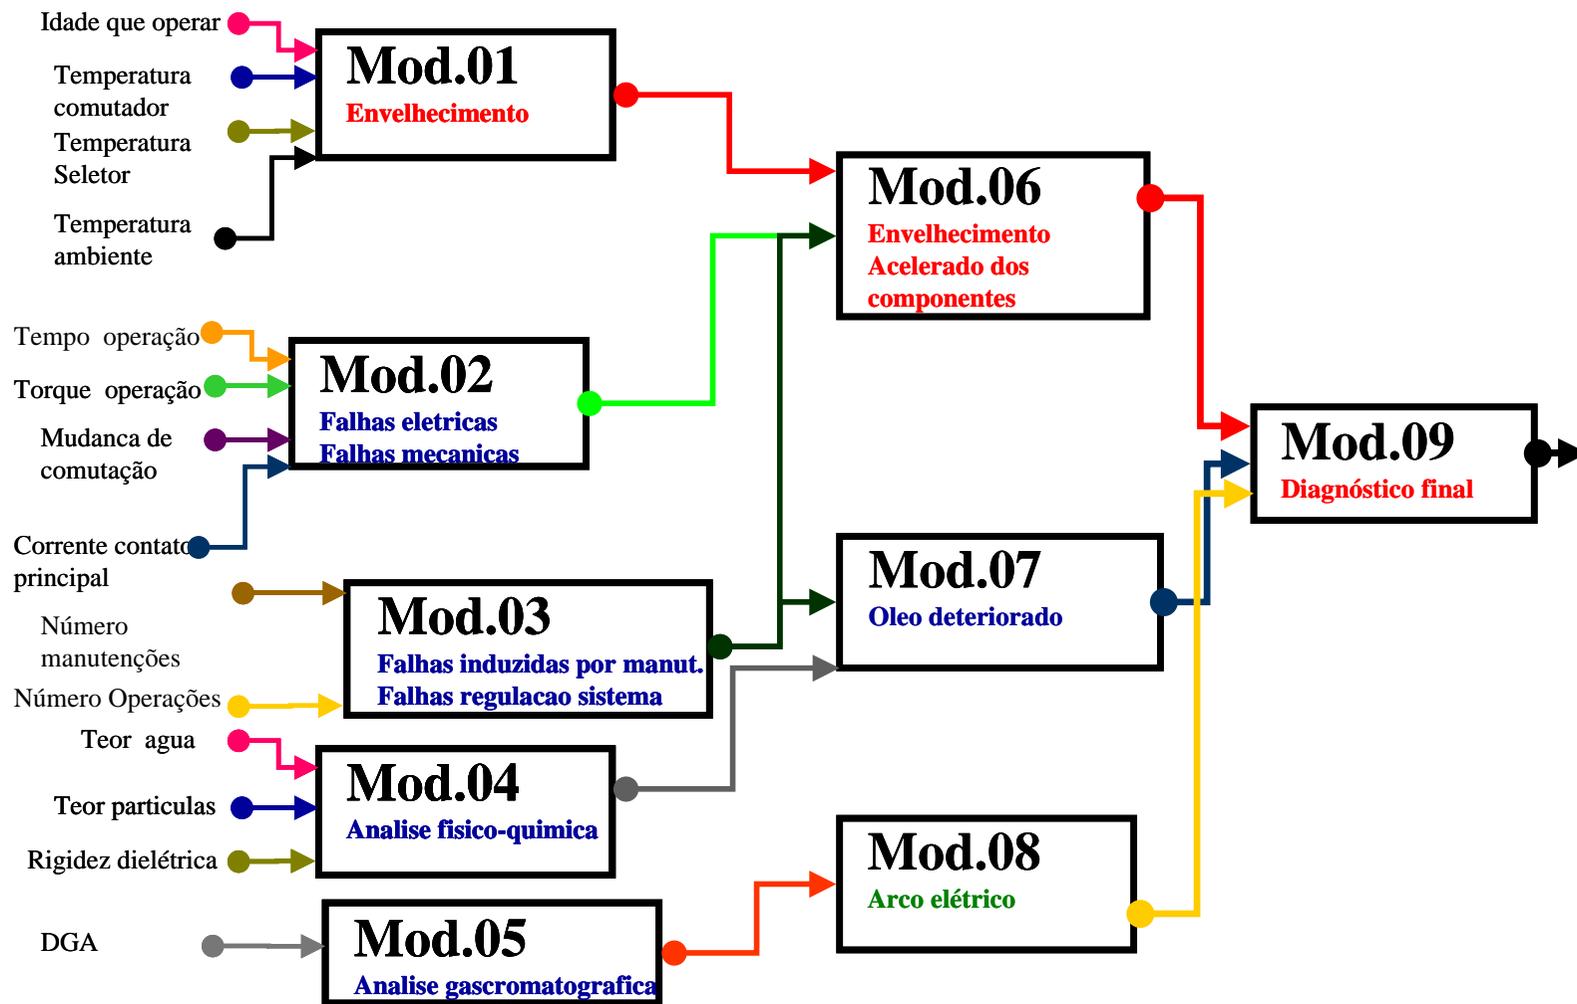
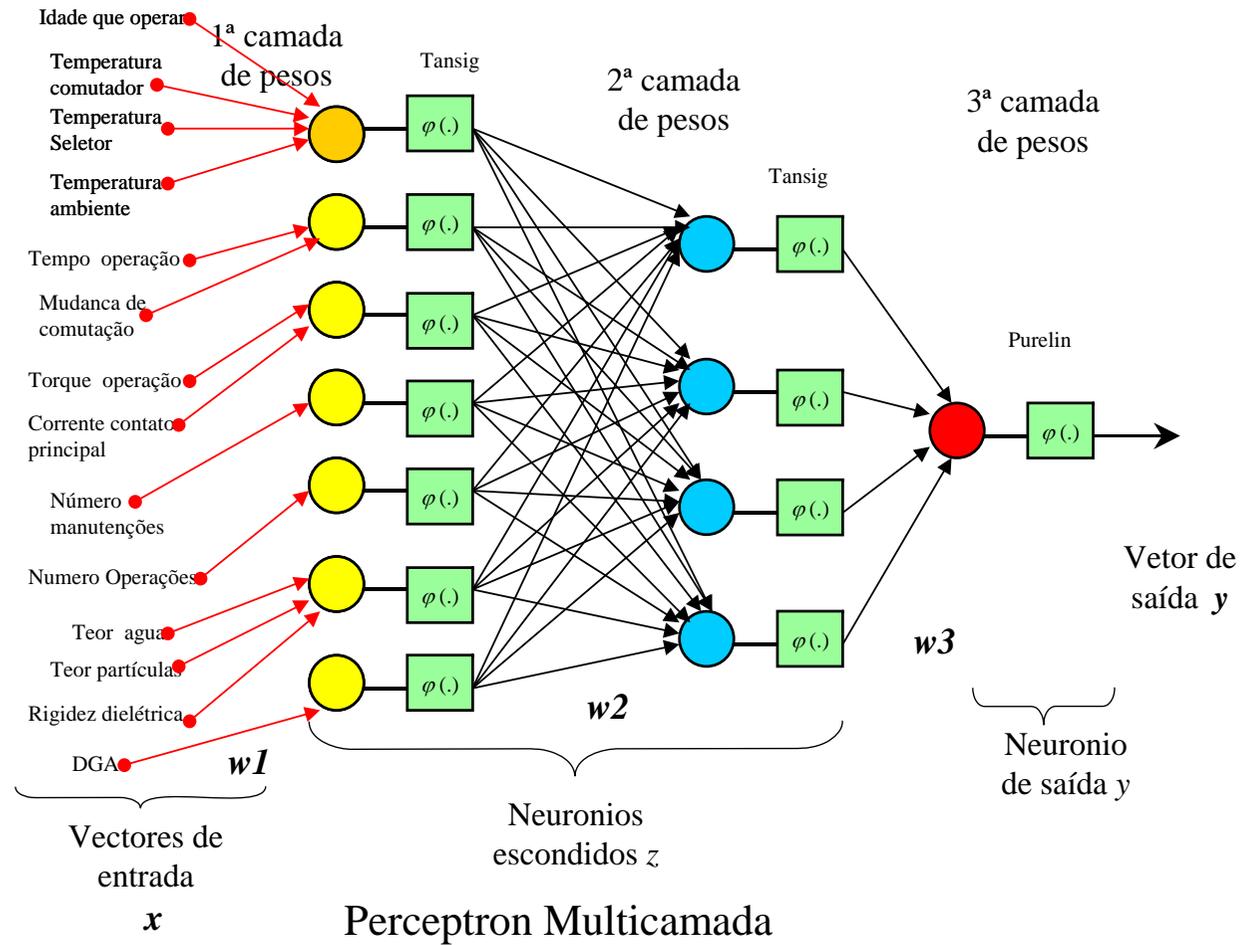


Figura 1.18: Estrutura para a modelagem da arquitetura da rede neural artificial proposta.



**Figura 1.19:** Dados de entrada e arquitetura da rede neural artificial para diagnóstico da condição de OLTC.

Ao longo do tempo de funcionamento on line do comutador de tap o sistema inteligente baseado em RNA será capaz de prever as condições de operação através de um ranking de uma única saída variando na faixa de 0 a 1, sendo quantificado e qualificado segundo indicado na Tabela 2.7.

**Tabela 1.7:** Critério de saída da rede neural com o diagnóstico da condição do OLTC.

<b>Critério de saída do método proposto</b>			
Status	Condição	Faixa [y]	Medida tomada pela produção
“D” 	Ruim	0-0.25	Retirar de operação imediata para manutenção
“C” 	Regular	0.26-0.50	Inspeccionar “in loco” manter ou retirar de operação conforme parecer da manutenção/operação
“B” 	Bom	0.56-0.75	Inspeccionar “in loco” manter em e operação conforme parecer da manutenção/operação
“A” 	Muito bom	0.76-1.0	Manter em operação

### 2.5.2. Coleta de dados e separação em conjuntos

Um passo importante e fundamental dentro do processo de desenvolvimento de redes neurais artificiais é a coleta de dados relativos ao problema, neste caso o diagnóstico da condição de OLTC, e a sua separação em um conjunto de dados de treinamento mais um conjunto de dados de teste.

Esta tarefa da coleta requer uma análise cuidadosa sobre o problema para minimizar ambigüidades e erros nos dados. Além disso, os dados coletados devem ser significativos e cobrir amplamente o domínio do problema, não devem cobrir apenas as operações normais ou rotineiras, mas também as exceções e as condições no limite do domínio do problema.

Na ELETRONORTE estão disponíveis dados históricos da manutenção dos seus transformadores e comutadores de tap. Esses dados nem sempre podem ser utilizados diretamente para o treinamento e teste das redes neurais, precisam ser pré-processados e acondicionados de maneira a serem aproveitados de forma conveniente. Os conceitos de normalização, escalonamento e ponderação são adotados, isso devido existirem dados com maior influência do que outros. Por outro lado, também existe informação histórica da manutenção e que somente pode ser adequada pelos especialistas em manutenção. Assim, por exemplo, são eles que devem definir uma condição do OLTC ou do transformador a partir de um conjunto específico de dados. A partir dos respectivos dados de entrada à rede neural o especialista deverá emitir sua decisão sobre o diagnóstico da condição do OLTC transformada numericamente dentro de uma escala de 0 a 1.

Normalmente, os dados coletados são separados em duas categorias: dados de treinamento, que serão utilizados para o treinamento da rede e dados de teste, que serão utilizados para verificar sua performance sob condições reais de utilização. Além dessa divisão, pode-se usar também uma subdivisão do conjunto de treinamento, criando um conjunto de validação, utilizado para verificar a eficiência da rede quanto a sua capacidade de generalização durante o treinamento, e podendo ser empregado como critério de parada do treinamento. O conjunto de dados para validação cruzada permitirá definir a arquitetura mais adequada da rede neural. Na validação cruzada é definida primeiramente o número de camadas intermediárias de neurônios e seguidamente o número de neurônios em cada camada. Infelizmente nem sempre é possível definir com exatidão o número de neurônios por cada camada. Não existe uma fórmula analítica para determinar o número de neurônios por cada camada, ainda é uma arte.

Após determinar os dados de treinamento, eles podem ser colocados em ordem aleatória para prevenção de tendências associadas à ordem de apresentação dos dados à RNA. Além disso, pode ser necessário pré-processar estes dados, através de normalizações, escalonamentos e conversões de formato para torná-los mais apropriados à sua utilização na rede.

Do conjunto total de dados, por exemplo um 70% é considerado para dados de treinamento e o restante 30% para teste. Quanto maior for o número de dados tanto de

treinamento quanto de teste, é melhor para a obtenção de resultados mais precisos. No caso do problema presente do diagnóstico da condição do OLTC não existe um grande número de dados históricos porque o número de manutenções de transformadores leva um bom tempo. Porém considera-se que o número é suficiente para realizar um treinamento adequado das redes neurais. Esse número de dados (vetor de entrada e saída desejada) deve ser capaz de simular o comportamento não linear do problema a ser resolvido. Assim, por exemplo, se o problema a ser resolvido pela RNA fosse o mapeamento da função seno no intervalo de 0 a  $2\pi$  então pelo menos uns 40 pontos ou dados (entre treinamento e teste) pode ser adequado.

### 2.5.3. Treinamento e teste da RNA

#### a) *Treinamento da rede neural*

Em mais de 80% das aplicações de redes neurais é utilizado o algoritmo de treinamento *back-propagation*, este método baseado no *steepest-descent* está considerado dentro dos métodos de primeira ordem pois utilizam informação do gradiente (primeira derivada). Outros métodos de treinamento que utilizam informação da segunda derivada e que pertencem à família dos métodos de otimização de segunda ordem têm sido desenvolvidos e estão disponíveis na literatura.

Neste trabalho será utilizado um algoritmo de treinamento de RNA baseado no método de otimização de segunda ordem Levenberg-Marquardt (LM). A atualização dos pesos será feita com o LM enquanto que o processo de treinamento será o de retropropagação do erro (*back-propagation of error*), em que na primeira etapa (*feedforward*) é calculado o erro na saída e na segunda etapa o erro na saída é retropropagado (*backward*) de atrás para frente camada por camada. [HAYK98]

Nesta fase, seguindo o algoritmo de treinamento escolhido, serão ajustados os pesos das conexões. É importante considerar, nesta fase, alguns aspectos tais como a inicialização da rede, o modo de treinamento e o tempo de treinamento. Uma boa escolha dos valores iniciais dos pesos da rede pode diminuir o tempo necessário para o treinamento. Normalmente, os valores iniciais dos pesos da rede são números aleatórios uniformemente distribuídos, em um intervalo definido. A escolha errada destes pesos pode levar a uma saturação prematura. Nguyen e Widrow encontraram uma função que

pode ser utilizada para determinar valores iniciais melhores que valores puramente aleatórios. Em vista de que os programas computacionais foram desenvolvidos com o Toolbox de redes neurais do Matlab, várias das considerações mencionadas são levadas em conta.

Quanto ao modo de atualização dos pesos sinápticos, pode ser via atualização ponto a ponto (*pattern by pattern*) ou atualização por lotes ou batelada (*batch*). Na prática é mais utilizado o modo padrão devido ao menor armazenamento de dados, além de ser menos suscetível ao problema de mínimos locais, devido à pesquisa de natureza estocástica que realiza. Por outro lado, no modo batelada se tem uma melhor estimativa do vetor gradiente, o que torna o treinamento mais estável. A eficiência relativa dos dois modos de treinamento depende do problema que está sendo tratado. No caso presente o modo foi preferido o primeiro de ponto a ponto.

Quanto ao tempo de treinamento, vários fatores podem influenciar a sua duração, porém sempre será necessário utilizar algum critério de parada. O critério de parada do algoritmo *back-propagation* não é bem definido, e geralmente é utilizado um número máximo de épocas ou iterações. Mas, devem ser considerados a taxa de erro quadrático médio (MSE: *mean square error*) e a capacidade de generalização da rede ou erro simples (saída desejada – saída calculada), por cada época. Uma época é a apresentação do conjunto de dados de treinamento.

Durante as primeiras épocas do treinamento é adotado o embaralhamento dos dados com a finalidade de prevenir efeitos de memorização da rede neural. Essa apresentação dos dados em ordem aleatória ajuda a um maior esforço da rede neural para ela não cair na memorização e tentar generalizar.

Pode ocorrer que em um determinado instante do treinamento a generalização comece a degenerar, causando o problema de sobre-treinamento (*over-training*), ou seja, a rede se especializa no conjunto de dados do treinamento e perde a capacidade de generalização. Um número excessivo de neurônios também pode causar esse efeito de sobre-treinamento em que o erro em lugar de diminuir consistentemente após um certo número de épocas de treinamento, ele se satura e começa a aumentar. O efeito contrário de sub-treinamento (*under-training*) pode ser causado por um número insuficiente de

neurônios ou por falta de treinamento em que a rede neural ainda não consegue aprender o suficiente para produzir o erro mínimo desejado.

O treinamento deve ser interrompido quando a rede apresentar uma boa capacidade de generalização e quando o erro de convergência for suficientemente pequeno, ou seja, menor que um erro admissível de tolerância. Assim, deve-se encontrar um ponto ótimo de parada com erro mínimo e capacidade de generalização máxima.

O método de otimização Levenberg-Marquardt adotado para atualizar os pesos sinápticos é suficientemente poderoso para garantir que o treinamento será muito mais rápido que o *back-propagation* proposto por Werbos e ainda produzir resultados mais precisos pela sua característica de ser um método de otimização que encontra ótimos globais e não apenas locais.

#### *b) Teste da rede neural*

Durante esta fase o conjunto de dados de teste é utilizado para determinar a performance da rede treinada utilizando dados que não foram previamente apresentados à rede neural.

A performance da rede, medida nesta fase, é uma boa indicação de sua performance real. Devem ser considerados ainda outros testes como análise do comportamento da rede utilizando entradas especiais e análise dos pesos atuais da rede, pois se existirem valores muito pequeno, as conexões associadas podem ser consideradas insignificantes e assim serem eliminadas (*prunning*). De modo inverso, valores substantivamente maiores que os outros poderiam indicar que houve sobre-treinamento da rede.

Quando os erros produzidos pelos dados de teste são muitos maiores que os erros do treinamento, então pode ter acontecido que a rede neural não teve um treinamento adequado ou a sua arquitetura ou o número de neurônios é insuficiente ou existe um excesso deles. Também pode acontecer que a rede neural teve um excessivo treinamento e ela passou a memorizar em lugar de generalizar, nesse caso ela apenas será capaz de estimar com muita precisão os dados do treinamento enquanto os de teste terão erros grandes.

Esse compromisso entre generalizar sem memorizar deve ser conseguido após um certo número de treinamentos validados com os testes.

Quando os erros para os dados de teste são algo maiores que os erros de treinamento considera-se que esse treinamento foi adequado. Com a finalidade de garantir uma rede neural completamente testada deveria ser realizado um número de treinamentos e testes, por exemplo, uns 50 com resultados aproximadamente similares para chegar à conclusão que a rede neural está adequada para ser aplicada definitivamente. Posteriormente quando a RNA estiver em funcionamento real, re-treinamentos podem ser necessários quando sejam verificados novos dados.

#### **2.5.4. Integração da RNA**

Finalmente, com a rede treinada e avaliada, ela pode ser integrada em um sistema do ambiente operacional da aplicação. Para maior eficiência da solução, este sistema deverá conter facilidades de utilização como interface conveniente e facilidades de aquisição de dados através de planilhas eletrônicas, interfaces com unidades de processamento de sinais, ou arquivos padronizados. Uma boa documentação do sistema e o treinamento de usuários são necessários para o sucesso do mesmo. Além disso, o sistema deve periodicamente monitorar sua performance e fazer a manutenção da rede neural quando for necessário ou indicar aos projetistas a necessidade de re-treinamento. Outras melhorias poderão ainda ser sugeridas quando os usuários forem se tornando mais familiares com o sistema, estas sugestões poderão ser muito úteis em novas versões ou em novos produtos.

# **3. SIMULAÇÃO DO MODELO PROPOSTO E DISCUSSÃO DE RESULTADOS**

## **3.1. Introdução**

O modelo proposto no Capítulo 2 de uma rede neural artificial para o diagnóstico da condição do comutador de tap sob carga deve servir como base para a implementação de um sistema inteligente que possa auxiliar na manutenção baseada na condição de transformadores de potência e os seus componentes, tal como o OLTC.

Neste capítulo serão descritos os aspectos da implementação da RNA com o modelo proposto, logo após são apresentados os resultados dos testes aplicativos para o comutador do autotransformador MR GI-3022 da subestação São Luís II da ELETRONORTE. Cabe ressaltar que os dados utilizados correspondem a um OLTC real atualmente em operação.

## **3.2. Implementação da RNA**

O processo de implementação do modelo de RNA proposto foi desenvolvido através de uma aplicação (programa computacional) no ambiente de programação MATLAB versão 6.5 e foi usado o Toolbox de Redes Neurais Artificiais.

Para treinar a RNA foi usado o método feed-forward back-propagation enquanto a atualização dos pesos foi através do método de otimização de segunda ordem Levenberg-Marquardt.

Foi escolhida a configuração de neurônios de perceptron de 3 camadas, sendo duas camadas intermediárias ou escondidas não-lineares e a terceira a camada de saída com função de ativação linear.

Também foram selecionados 45 pares  $(x, y)$ , sendo  $x$  o vetor de entrada, no caso composto por 22 componentes,  $y$  é o vetor de saída de apenas uma componente: o diagnóstico da condição do OLTC. O conjunto dos 45 pares de dados é o total da coleta de dados. Desses 45 dados, 40 foram utilizados para treinamento e os 5 restantes para a etapa de teste da rede neural treinada. Os 5 dados de teste foram escolhidos aleatoriamente para cada caso de treinamento.

Na seguinte seção são apresentados os resultados das etapas de treinamento e teste para diferentes topologias (número de neurônios por camada), para um limite de 10.000 épocas e considerando diferentes erros limites de treinamento. Dependendo do valor de cada limite erro (tolerância) de treinamento a rede neural pode realizar o treinamento em diferente número de épocas.

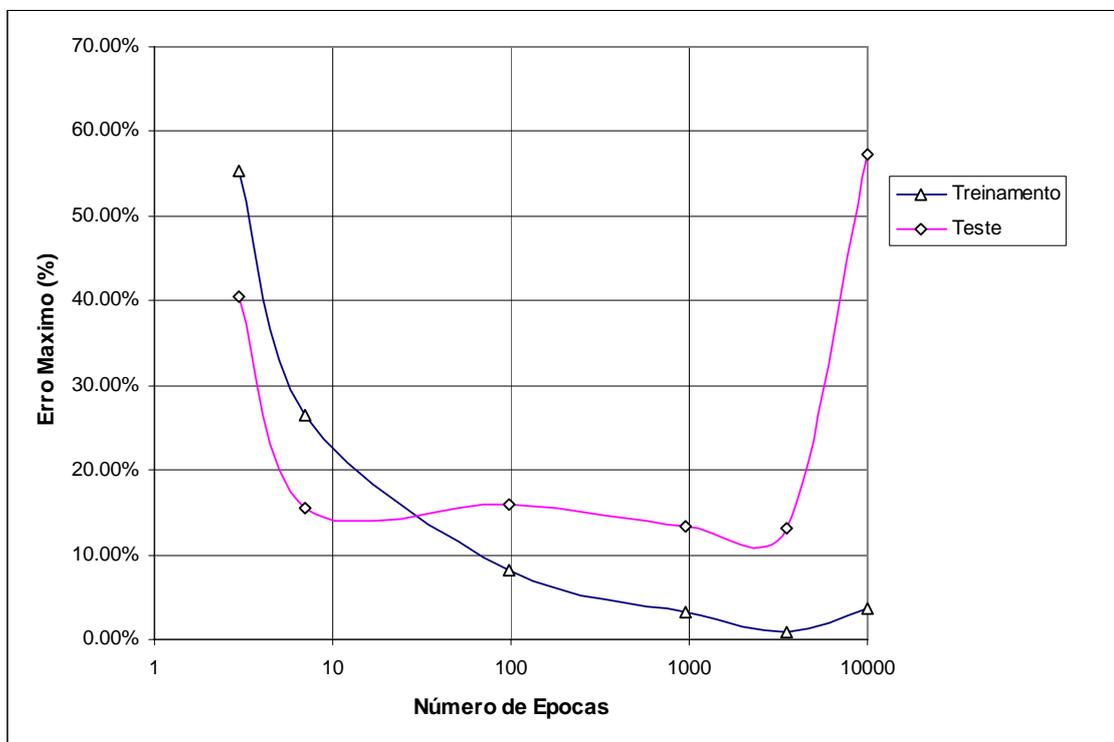
### **3.3. Resultados de treinamento e teste**

Para obter uma RNA adequada nas etapas de treinamento e teste foram usadas as seguintes cinco topologias (neurônios na 1ª camada escondida, neurônios na 2ª camada escondida, neurônios na camada de saída): 5-5-1, 5-10-1, 10-10-1, 15-10-1 e 20-10-1. Para cada topologia foram usados diferentes erros limites do treinamento (MSE):  $10^{-1}$ ,  $10^{-2}$ ,  $10^{-3}$ ,  $10^{-4}$ ,  $10^{-5}$ ,  $10^{-6}$  e  $10^{-7}$  e para cada erro foram simulado 3 treinamentos, este último para reconhecer as simulações mais estáveis.

A seguir nas Tabelas 3.1 a 3.5, e Figuras 3.1 a 3.5, são apresentados os resultados destas etapas.

**Tabela 1.8:** Resultados da etapa de treinamento e teste para topologia 5-5-1.

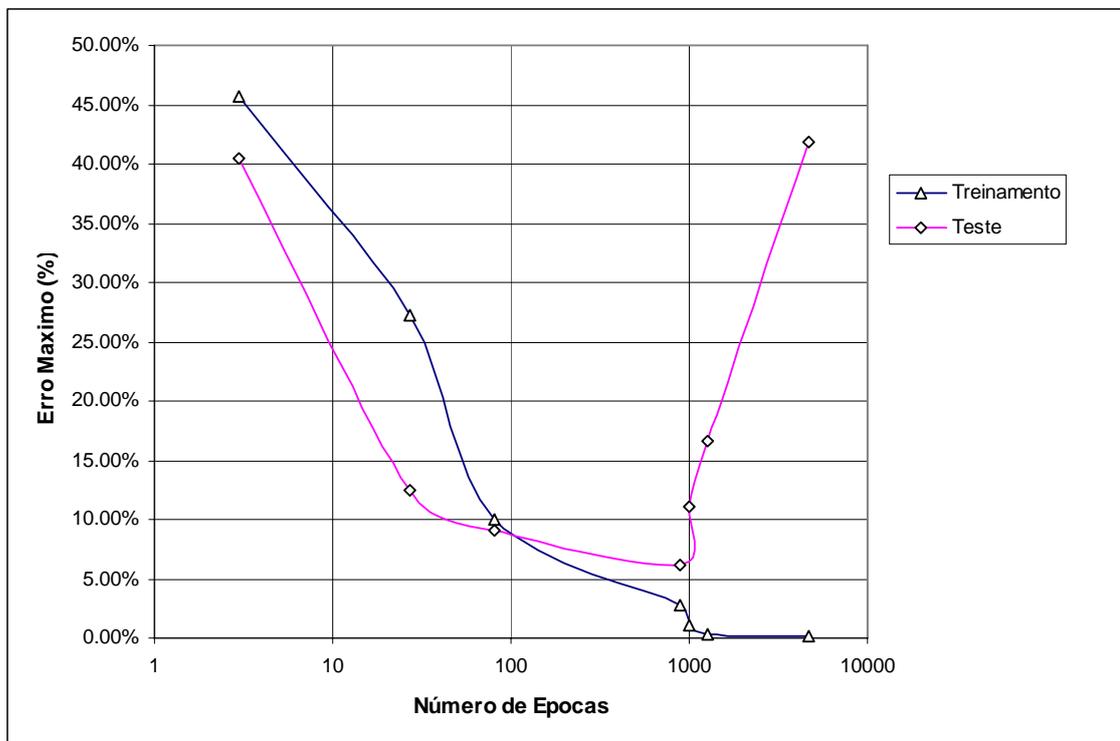
Identificacao do Caso	Etapa de Treinamento				Etapa Teste		
	Erro Limite	Erro Atingido	Numero de Epocas	Erro Maximo (%)	Numero de Entrada	Erro Maximo (%)	Numero de Entrada
Caso1	10 <sup>^-1</sup>	4.671E-02	1	52.65%	20	41.94%	1
Caso2	10 <sup>^-1</sup>	9.215E-02	0	48.58%	33	59.70%	1
Caso3	10 <sup>^-1</sup>	4.545E-02	3	55.36%	20	40.54%	3
Caso4	10 <sup>^-2</sup>	8.760E-03	7	20.12%	18	26.33%	1
Caso5	10 <sup>^-2</sup>	9.629E-03	7	26.47%	20	15.40%	1
Caso6	10 <sup>^-2</sup>	8.126E-03	5	25.22%	20	19.94%	1
Caso7	10 <sup>^-3</sup>	9.936E-04	741	10.14%	33	598.30%	1
Caso8	10 <sup>^-3</sup>	9.951E-04	98	8.15%	16	15.88%	1
Caso9	10 <sup>^-3</sup>	9.893E-04	49	8.81%	26	18.00%	1
Caso10	10 <sup>^-4</sup>	1.000E-04	1245	3.25%	38	20.39%	1
Caso11	10 <sup>^-4</sup>	1.000E-04	957	3.17%	38	13.30%	1
Caso12	10 <sup>^-4</sup>	9.920E-05	776	2.93%	38	16.81%	3
Caso13	10 <sup>^-5</sup>	1.000E-05	3486	0.88%	4	13.22%	1
Caso14	10 <sup>^-5</sup>	0.000041	10000	2.11%	12	4758.94%	1
Caso15	10 <sup>^-5</sup>	0.0000168	10000	1.69%	13	44.75%	1
Caso16	10 <sup>^-6</sup>	0.0000644	10000	3.75%	37	57.39%	3
Caso17	10 <sup>^-6</sup>	0.0003632	10000	4.49%	35	459.40%	1
Caso18	10 <sup>^-6</sup>	0.000059	10000	3.51%	37	9.21%	3
Caso19	10 <sup>^-7</sup>	0.0000541	10000	3.22%	37	23654.96%	1
Caso20	10 <sup>^-7</sup>	0.0007599	10000	10.08%	33	3770.24%	1
Caso21	10 <sup>^-7</sup>	0.0001068	10000	4.26%	37	7804.68%	1



**Figura 1.20:** Curva representativa do treinamento e teste para topologia 5-5-1.

**Tabela 1.9:** Resultados da etapa de treinamento e teste para topologia 5-10-1.

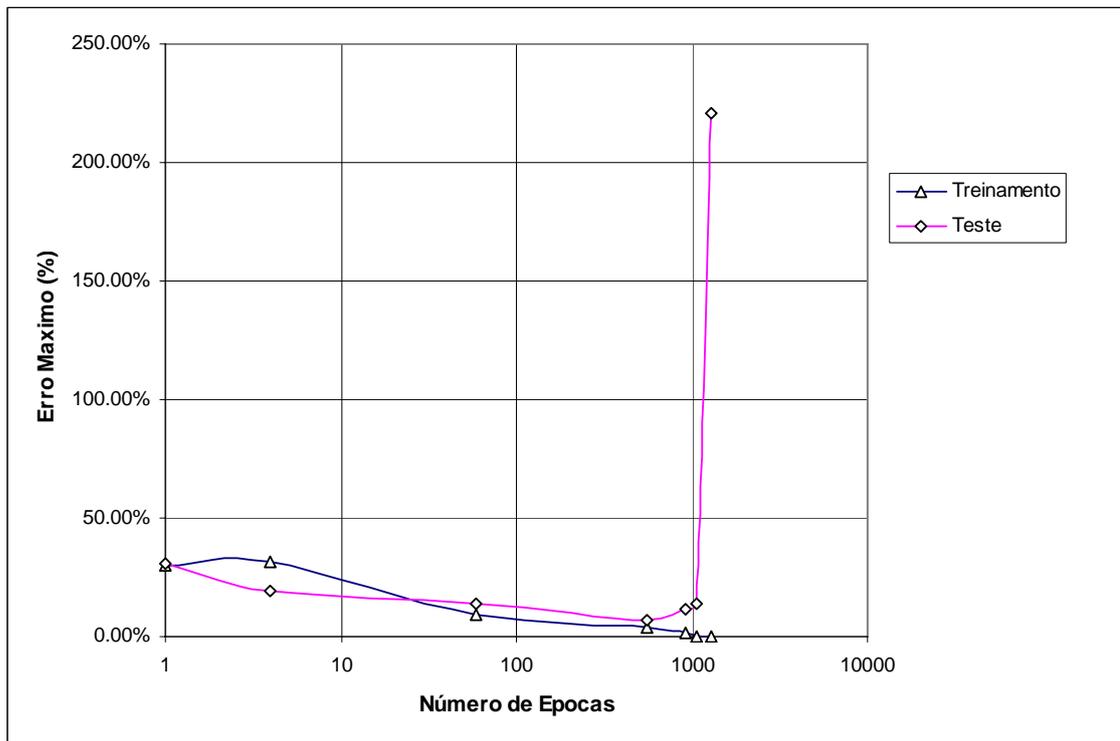
Identificacao do Caso	Etapa de Treinamento				Etapa Teste		
	Erro Limite	Erro Atingido	Numero de Epocas	Erro Maximo (%)	Numero de Entrada	Erro Maximo (%)	Numero de Entrada
Caso1	10 <sup>^</sup> (-1)	6.099E-02	3	45.70%	33	40.54%	5
Caso2	10 <sup>^</sup> (-1)	6.549E-03	6	19.53%	20	44.87%	1
Caso3	10 <sup>^</sup> (-1)	9.499E-02	1	69.33%	20	58.43%	3
Caso4	10 <sup>^</sup> (-2)	9.794E-03	11	27.20%	20	15.65%	1
Caso5	10 <sup>^</sup> (-2)	9.544E-03	27	27.21%	26	12.53%	3
Caso6	10 <sup>^</sup> (-2)	8.331E-03	53	26.54%	20	28.80%	1
Caso7	10 <sup>^</sup> (-3)	9.815E-04	101	8.84%	33	14.67%	1
Caso8	10 <sup>^</sup> (-3)	9.950E-04	37	8.48%	33	16.07%	1
Caso9	10 <sup>^</sup> (-3)	9.834E-04	81	10.00%	33	9.11%	1
Caso10	10 <sup>^</sup> (-4)	9.990E-05	1434	4.04%	37	67.56%	1
Caso11	10 <sup>^</sup> (-4)	1.000E-04	878	2.81%	30	6.12%	2
Caso12	10 <sup>^</sup> (-4)	9.940E-05	481	3.00%	38	17.60%	4
Caso13	10 <sup>^</sup> (-5)	9.500E-06	1860	0.77%	11	16.38%	1
Caso14	10 <sup>^</sup> (-5)	0.00001	1555	1.30%	11	51.94%	1
Caso15	10 <sup>^</sup> (-5)	0.00001	993	1.15%	21	11.02%	4
Caso16	10 <sup>^</sup> (-6)	0.000001	2122	0.40%	6	205.21%	1
Caso17	10 <sup>^</sup> (-6)	0.000001	3510	0.43%	8	8.74%	3
Caso18	10 <sup>^</sup> (-6)	0.0000008	1260	0.30%	13	16.64%	4
Caso19	10 <sup>^</sup> (-7)	0.0000001	2095	0.11%	7	24.66%	1
Caso20	10 <sup>^</sup> (-7)	0.0000001	2771	0.14%	4	89.88%	1
Caso21	10 <sup>^</sup> (-7)	0.0000001	4717	0.14%	7	41.85%	1



**Figura 1.21:** Curva representativa do treinamento e teste para topologia 5-10-1.

**Tabela 1.10:** Resultados da etapa de treinamento e teste para topologia 10-10-1.

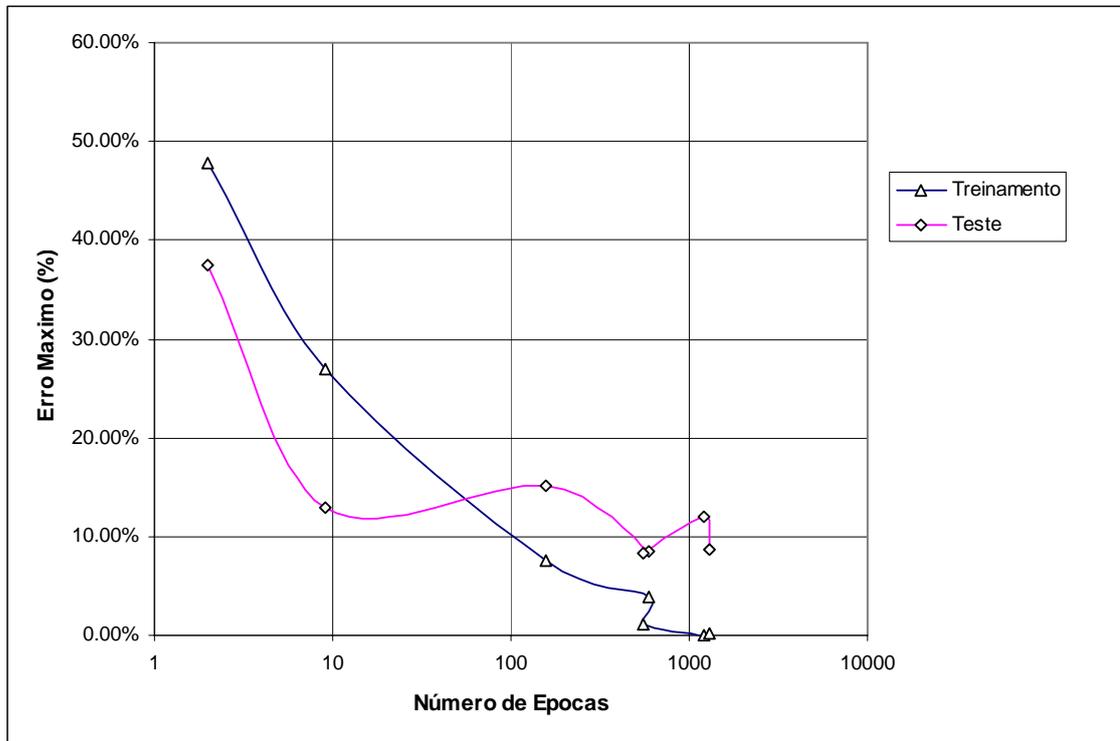
Identificacao do Caso	Etapa de Treinamento				Etapa Teste		
	Erro Limite	Erro Atingido	Numero de Epocas	Erro Maximo (%)	Numero de Entrada	Erro Maximo (%)	Numero de Entrada
Caso1	10 <sup>^</sup> (-1)	6.753E-02	1	57.86%	20	44.98%	3
Caso2	10 <sup>^</sup> (-1)	2.979E-02	1	29.73%	26	30.45%	1
Caso3	10 <sup>^</sup> (-1)	8.361E-02	3	52.86%	33	41.59%	5
Caso4	10 <sup>^</sup> (-2)	8.780E-03	4	31.56%	26	19.53%	1
Caso5	10 <sup>^</sup> (-2)	8.850E-03	3	23.88%	20	20.76%	1
Caso6	10 <sup>^</sup> (-2)	4.270E-03	4	17.38%	26	20.04%	1
Caso7	10 <sup>^</sup> (-3)	9.900E-04	206	8.12%	26	15.58%	1
Caso8	10 <sup>^</sup> (-3)	1.000E-03	59	8.93%	26	13.84%	1
Caso9	10 <sup>^</sup> (-3)	9.900E-04	30	8.81%	33	17.65%	1
Caso10	10 <sup>^</sup> (-4)	1.000E-04	1208	4.17%	37	8.22%	2
Caso11	10 <sup>^</sup> (-4)	1.000E-04	482	3.10%	38	13.02%	1
Caso12	10 <sup>^</sup> (-4)	1.000E-04	549	4.09%	36	7.16%	3
Caso13	10 <sup>^</sup> (-5)	1.000E-05	1151	1.08%	12	9.24%	2
Caso14	10 <sup>^</sup> (-5)	0.00001	794	1.19%	38	17.46%	4
Caso15	10 <sup>^</sup> (-5)	0.00001	926	1.35%	21	11.66%	4
Caso16	10 <sup>^</sup> (-6)	0.000001	3522	0.39%	38	13.61%	4
Caso17	10 <sup>^</sup> (-6)	0.000001	1278	0.32%	12	12.98%	1
Caso18	10 <sup>^</sup> (-6)	0.000001	1062	0.25%	16	14.07%	2
Caso19	10 <sup>^</sup> (-7)	0.00000001	737	0.12%	7	11.62%	4
Caso20	10 <sup>^</sup> (-7)	0.00002	10000	2.33%	39	972.29%	3
Caso21	10 <sup>^</sup> (-7)	0.00000001	1277	0.10%	16	220.55%	2



**Figura 1.22:** Curva representativa do treinamento e teste para topologia 10-10-1.

**Tabela 1.11:** Resultados da etapa de treinamento e teste para topologia 15-10-1.

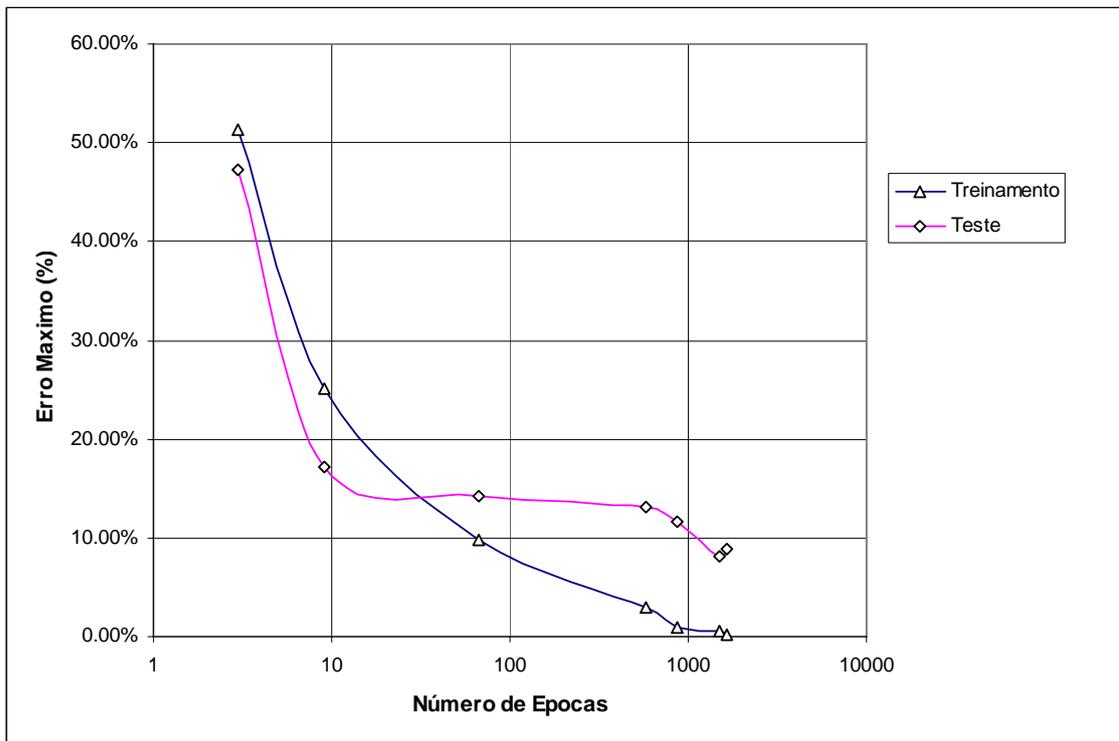
Identificacao do Caso	Etapa de Treinamento				Etapa Teste		
	Erro Limite	Erro Atingido	Numero de Epocas	Erro Maximo (%)	Numero de Entrada	Erro Maximo (%)	Numero de Entrada
Caso1	10 <sup>^-1</sup>	6.157E-02	3	46.03%	33	38.33%	5
Caso2	10 <sup>^-1</sup>	6.448E-02	2	47.79%	33	37.54%	4
Caso3	10 <sup>^-1</sup>	8.515E-02	1	49.25%	20	40.70%	5
Caso4	10 <sup>^-2</sup>	9.733E-03	9	26.90%	20	12.98%	1
Caso5	10 <sup>^-2</sup>	8.914E-03	8	24.84%	26	24.66%	1
Caso6	10 <sup>^-2</sup>	8.199E-03	4	24.79%	20	20.59%	1
Caso7	10 <sup>^-3</sup>	9.923E-04	163	9.86%	33	16.61%	1
Caso8	10 <sup>^-3</sup>	9.966E-04	156	7.56%	33	15.15%	1
Caso9	10 <sup>^-3</sup>	9.593E-04	68	9.93%	33	12.25%	3
Caso10	10 <sup>^-4</sup>	9.990E-05	594	3.94%	37	8.45%	3
Caso11	10 <sup>^-4</sup>	9.980E-05	471	3.27%	38	8.91%	3
Caso12	10 <sup>^-4</sup>	9.990E-05	409	4.21%	37	9.32%	4
Caso13	10 <sup>^-5</sup>	9.900E-06	1986	1.24%	37	17.81%	4
Caso14	10 <sup>^-5</sup>	0.00001	1520	0.78%	15	19.06%	4
Caso15	10 <sup>^-5</sup>	0.0000083	556	1.06%	38	8.31%	4
Caso16	10 <sup>^-6</sup>	0.0000009	978	0.24%	15	30.65%	2
Caso17	10 <sup>^-6</sup>	0.0000001	1206	0.04%	3	12.08%	4
Caso18	10 <sup>^-6</sup>	0.0000009	1113	0.45%	38	28.57%	2
Caso19	10 <sup>^-7</sup>	0.0000001	1295	0.10%	31	8.68%	4
Caso20	10 <sup>^-7</sup>	0.0000001	1260	0.11%	38	8.82%	4
Caso21	10 <sup>^-7</sup>	0.0000001	1042	0.11%	3	9.60%	4



**Figura 1.23:** Curva representativa do treinamento e teste para topologia 15-10-1.

**Tabela 1.12:** Resultados da etapa de treinamento e teste para topologia 20-10-1.

Identificacao do Caso	Etapa de Treinamento				Etapa Teste		
	Erro Limite	Erro Atingido	Numero de Epocas	Erro Maximo (%)	Numero de Entrada	Erro Maximo (%)	Numero de Entrada
Caso1	10 <sup>^-1</sup>	8.204E-02	1	57.65%	20	64.75%	1
Caso2	10 <sup>^-1</sup>	8.474E-02	1	70.88%	20	58.05%	1
Caso3	10 <sup>^-1</sup>	8.014E-02	3	51.26%	36	47.21%	5
Caso4	10 <sup>^-2</sup>	7.823E-03	9	25.08%	26	17.18%	1
Caso5	10 <sup>^-2</sup>	9.933E-03	5	27.64%	20	16.26%	1
Caso6	10 <sup>^-2</sup>	8.758E-03	3	29.19%	20	21.03%	1
Caso7	10 <sup>^-3</sup>	9.895E-04	67	9.85%	33	14.29%	1
Caso8	10 <sup>^-3</sup>	9.934E-04	53	7.43%	33	16.34%	1
Caso9	10 <sup>^-3</sup>	9.961E-04	72	10.10%	33	16.30%	1
Caso10	10 <sup>^-4</sup>	9.980E-05	749	2.77%	38	10.11%	4
Caso11	10 <sup>^-4</sup>	9.970E-05	581	3.01%	38	13.07%	2
Caso12	10 <sup>^-4</sup>	9.960E-05	728	3.32%	38	10.45%	4
Caso13	10 <sup>^-5</sup>	1.000E-05	500	0.72%	21	10.48%	4
Caso14	10 <sup>^-5</sup>	0.0000097	688	1.07%	31	21.81%	2
Caso15	10 <sup>^-5</sup>	0.0000099	866	1.02%	38	11.67%	4
Caso16	10 <sup>^-6</sup>	0.000001	1503	0.48%	38	8.09%	3
Caso17	10 <sup>^-6</sup>	0.0000006	623	0.26%	36	18.23%	4
Caso18	10 <sup>^-6</sup>	0.000001	2375	0.45%	39	28.36%	2
Caso19	10 <sup>^-7</sup>	0.0000001	1289	0.11%	7	11.32%	3
Caso20	10 <sup>^-7</sup>	0.0000001	1629	0.14%	3	8.89%	5
Caso21	10 <sup>^-7</sup>	0.0000001	1267	0.12%	6	153.94%	2



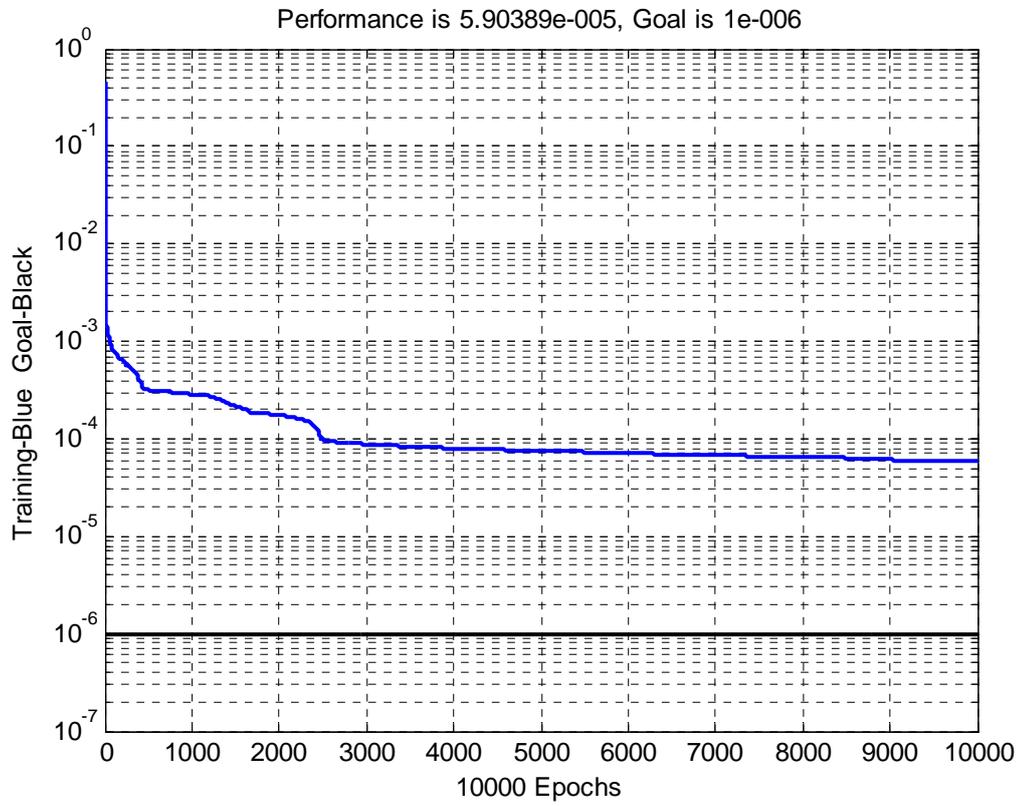
**Figura 1.24:** Curva representativa do treinamento e teste para topologia 20-10-1.

Das curvas mostradas nas Figuras 3.1 a 3.5 pode se observar que a curva obtida correspondente ao treinamento possui a forma de uma hipérbole, em que conforme é diminuído o erro limite de treinamento (devido ao aumento do número de épocas) o erro máximo (entre valor simulado e o valor real) diminui. As curvas das etapas de teste possuem um mínimo local que deve ser tomado como melhor caso, devido que o erro máximo entre o valor simulado e o valor real diminui com o numero de épocas no início, e depois aumenta ao aumentar o número de épocas

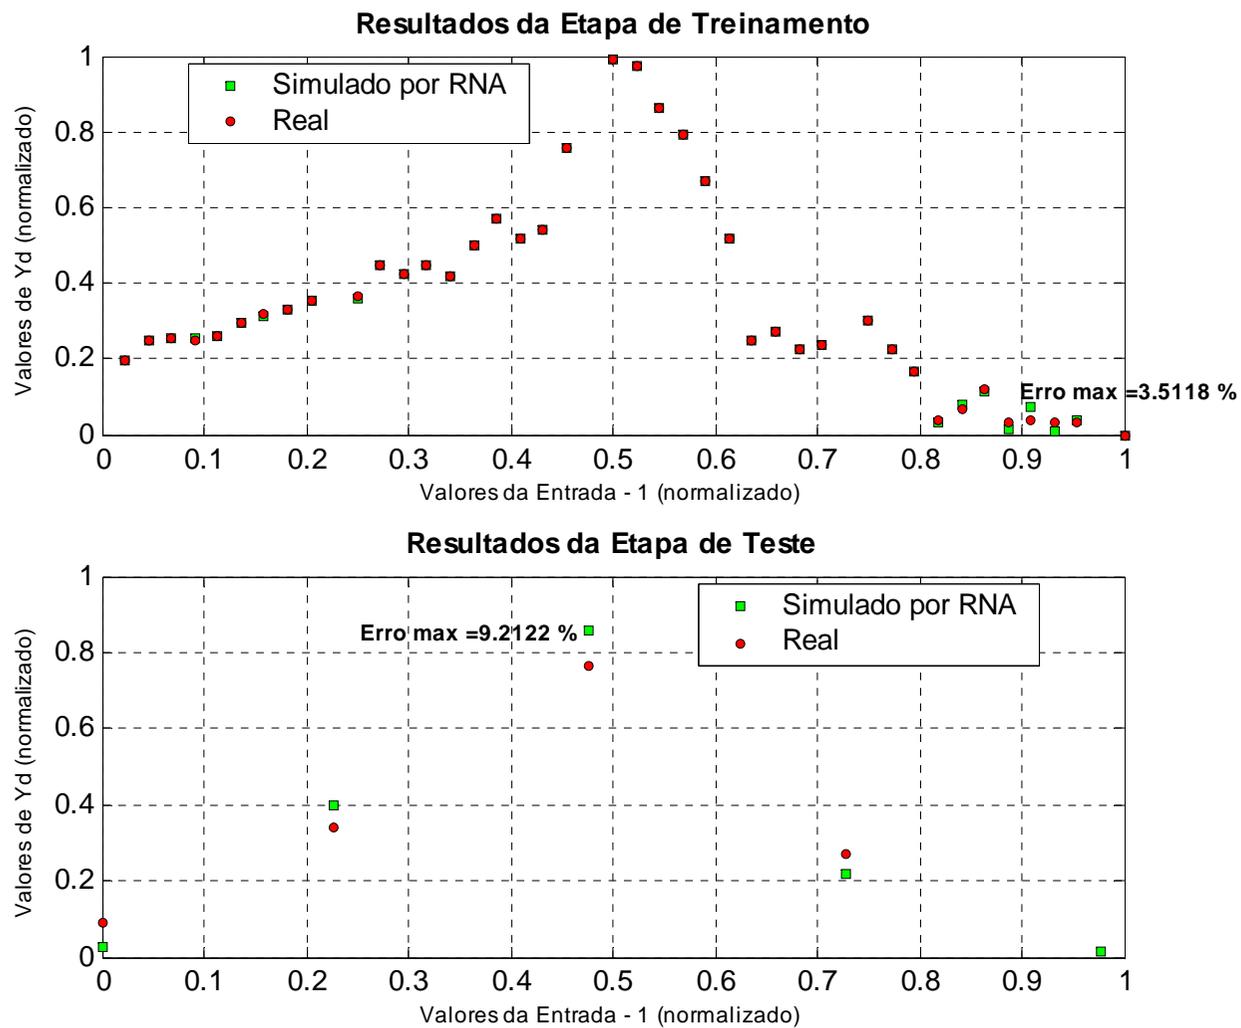
De cada topologia é escolhido o melhor caso, isto significa escolher os menores erros máximos da etapa de teste.

Nas Figuras 3.6 a 3.15 são apresentadas as curvas de performance do processo de treinamento e a comparação dos valores simulados pela RNA com os valores reais (obtidos da coleta de dados), isto último obtido para a entrada 1 (idade de operação) e para as diferentes topologias que estão sendo consideradas.

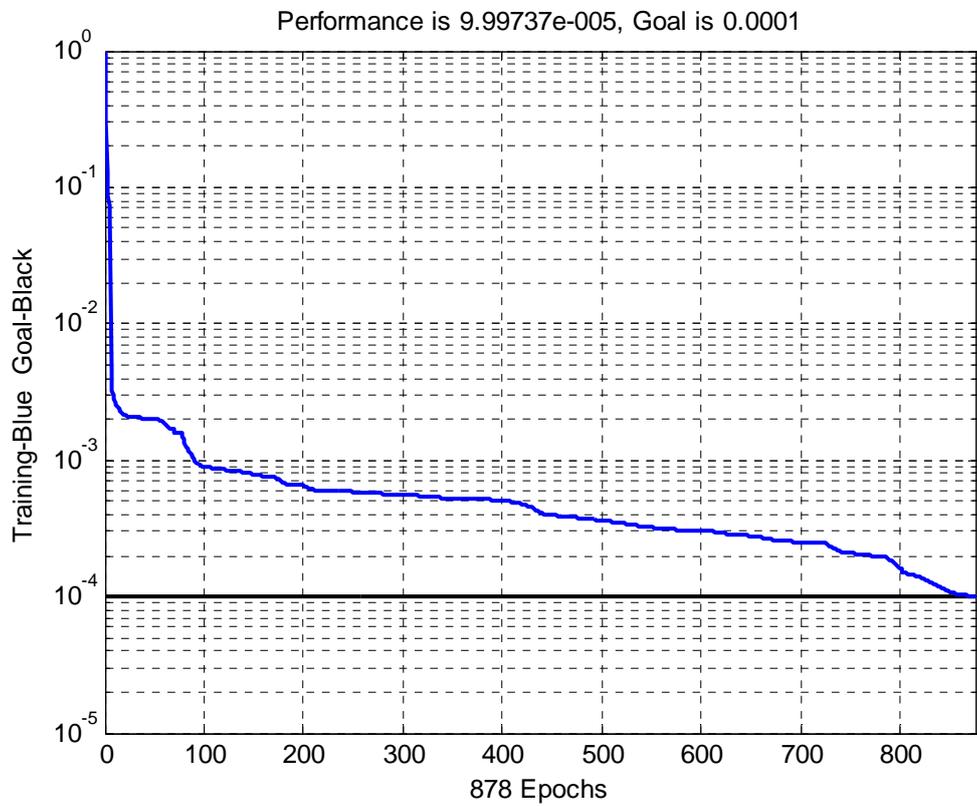
Entre todas as topologias simuladas e erros atingidos, a topologia 5-10-1 possui o menor erro (6.12%) para um erro limite do treinamento de  $10^{-4}$ .



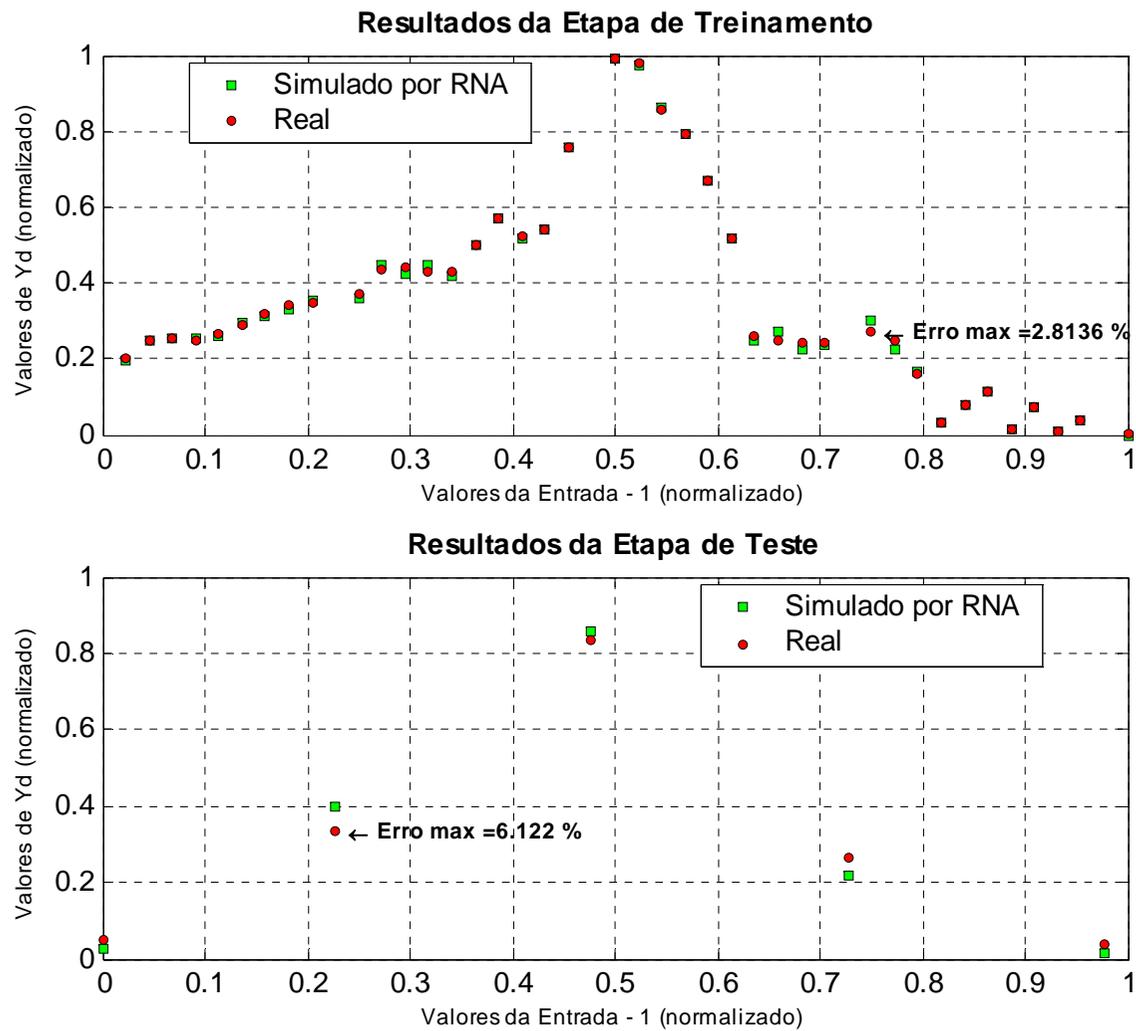
**Figura 1.25:** Processo de treinamento para o melhor caso (caso 18) da topologia 5-5-1.



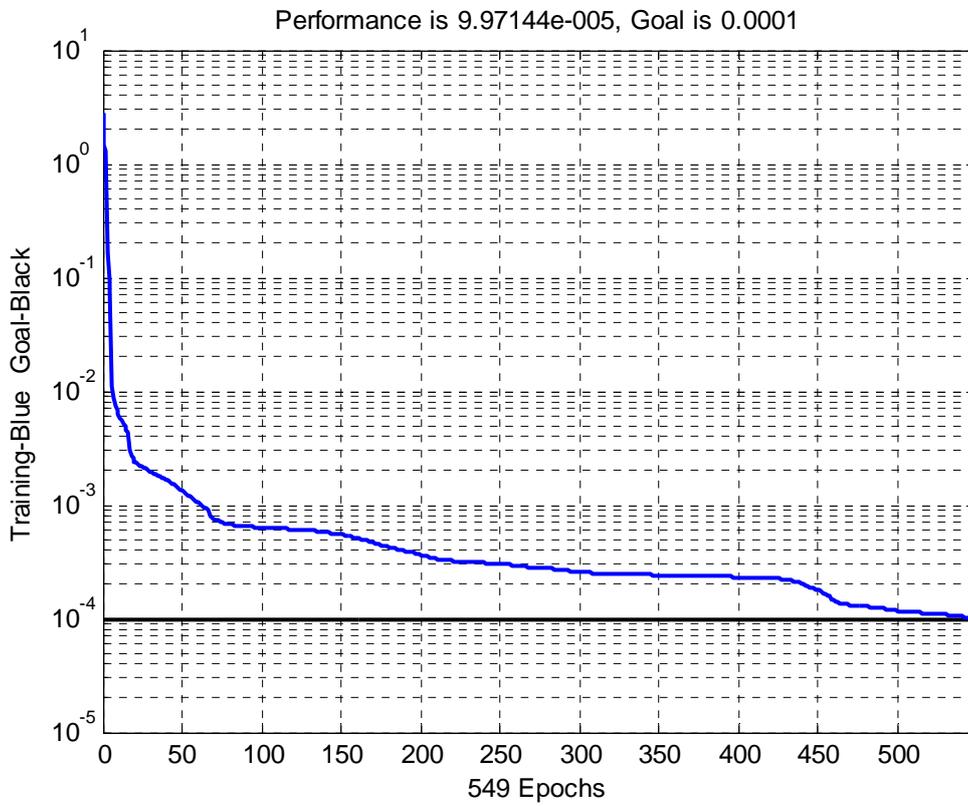
**Figura 1.26:** Comparação de resultados das etapas de treinamento e teste para o melhor caso (caso 18) da topologia 5-5-1.



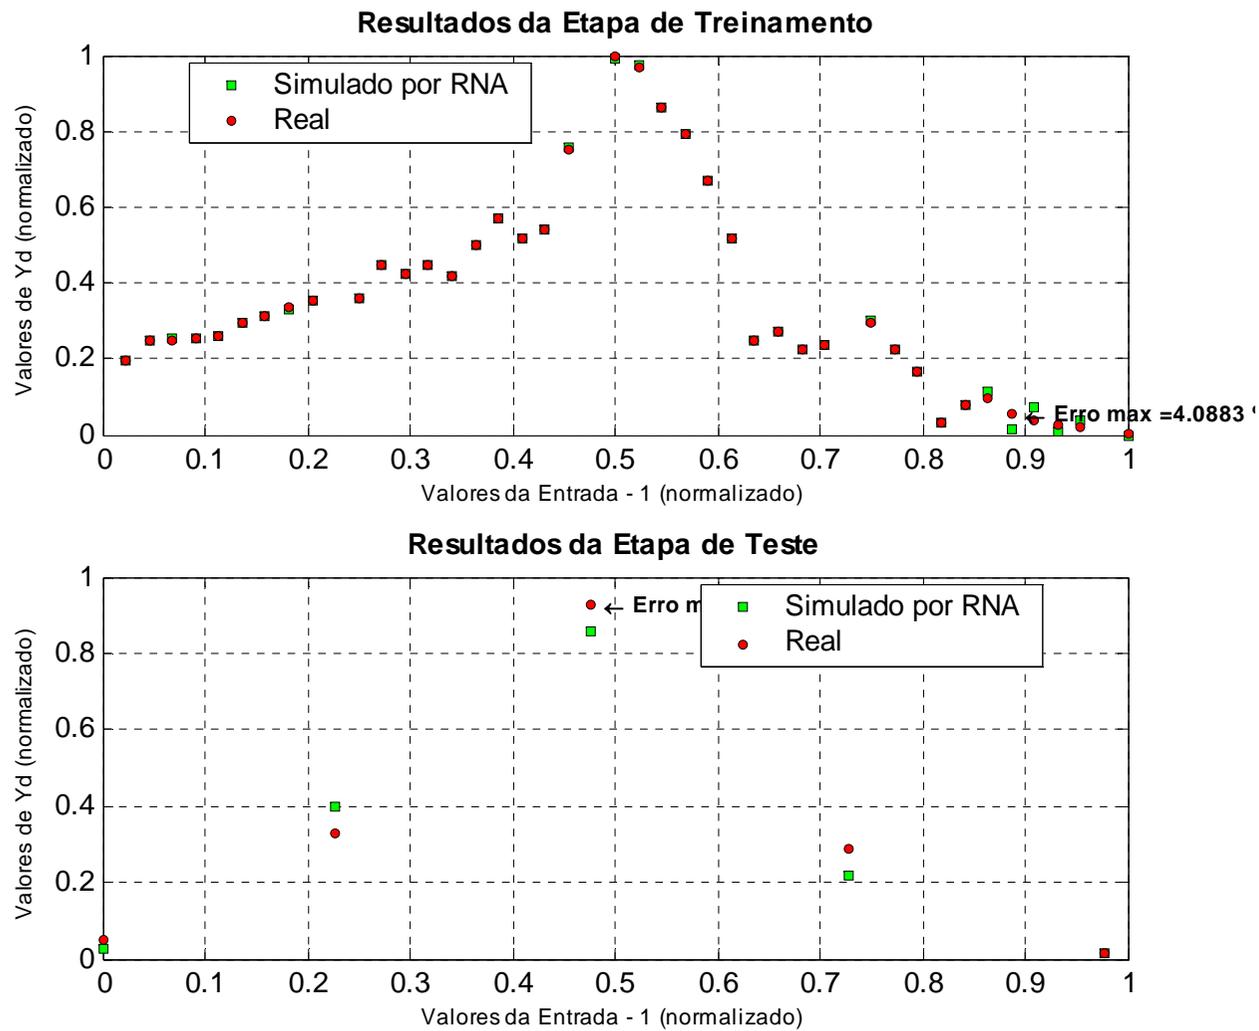
**Figura 1.27:** Processo de treinamento para o melhor caso (caso 11) da topologia 5-10-1.



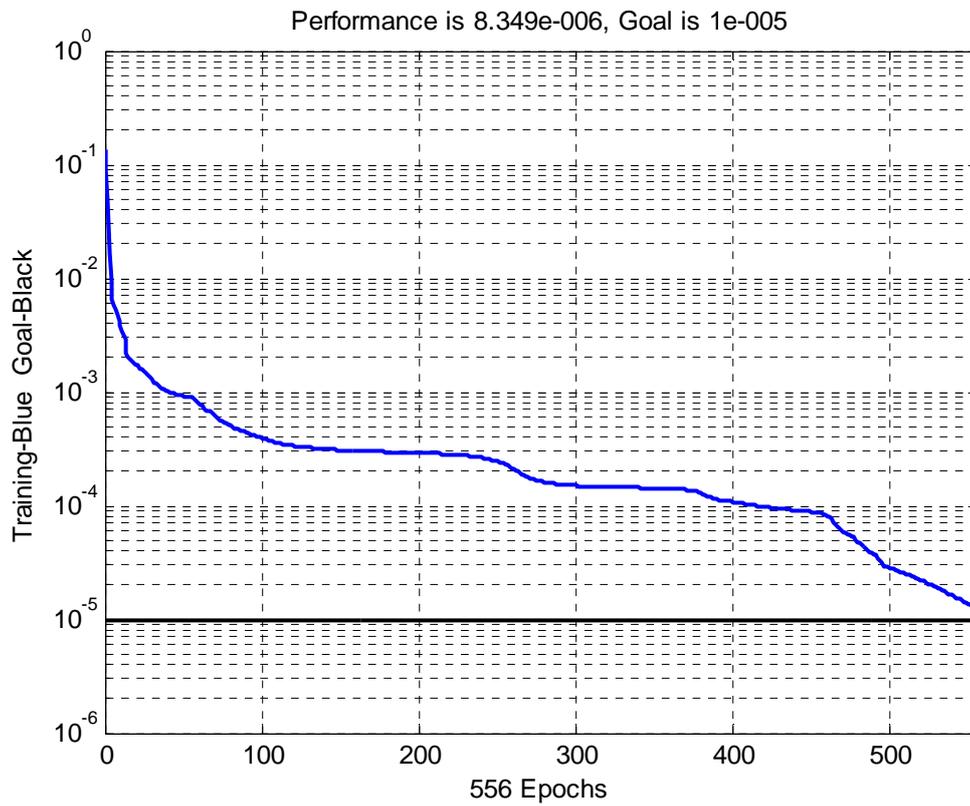
**Figura 1.28:** Comparação de resultados das etapas de treinamento e teste para o melhor caso (caso 11) da topologia 5-10-1.



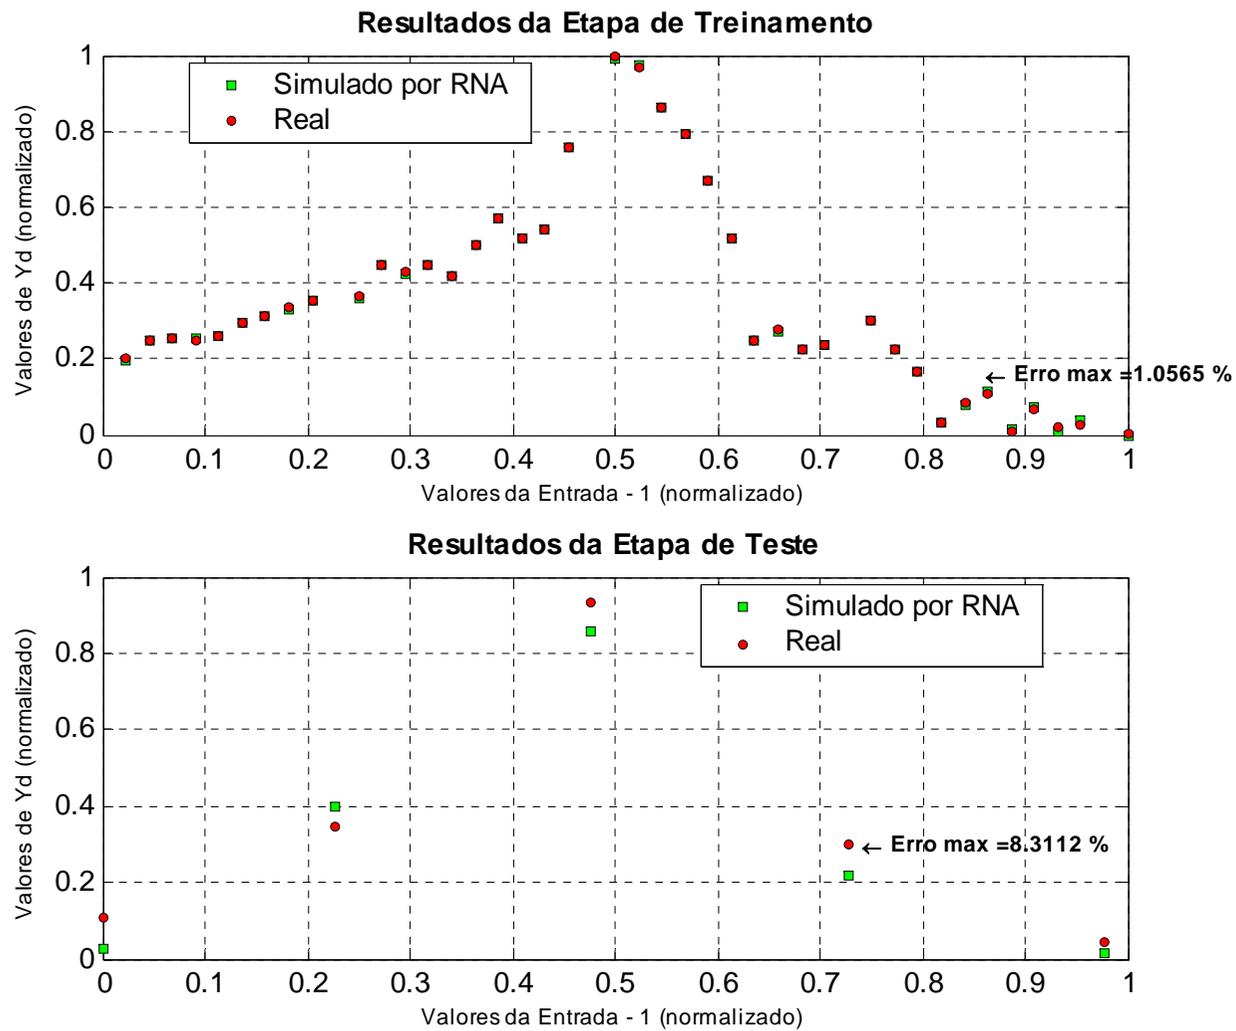
**Figura 1.29:** Processo de treinamento para o melhor caso (caso 12) da topologia 10-10-1.



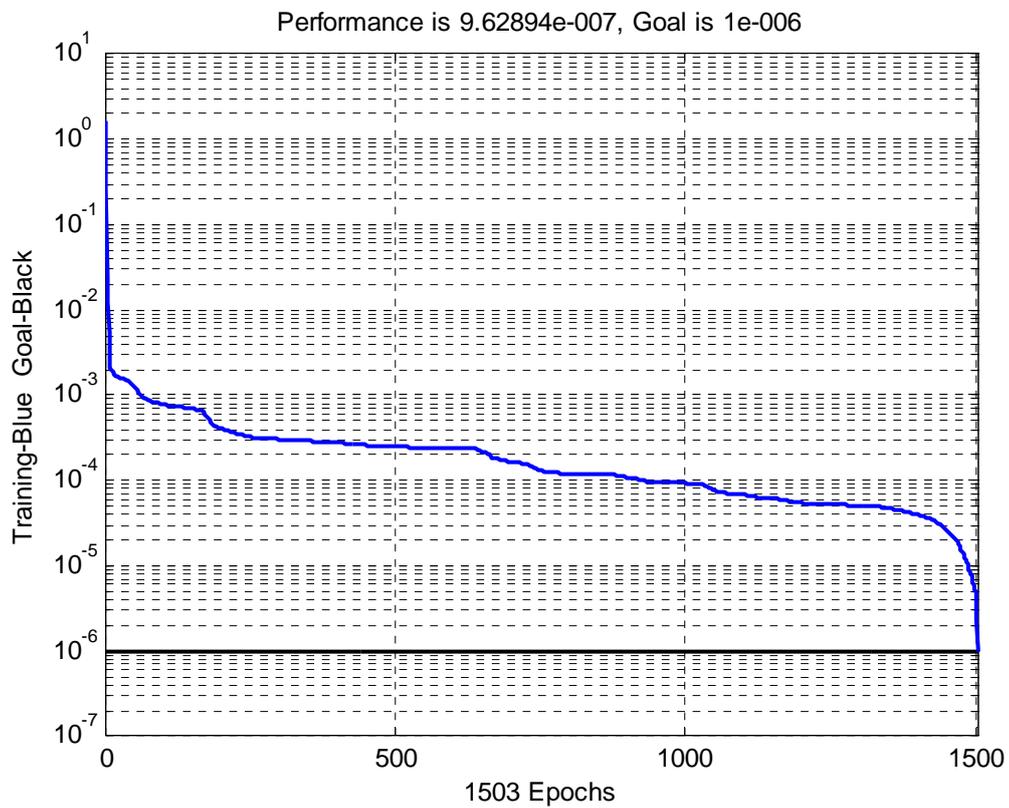
**Figura 1.30:** Comparação de resultados das etapas de treinamento e teste para o melhor caso (caso 12) da topologia 10-10-1.



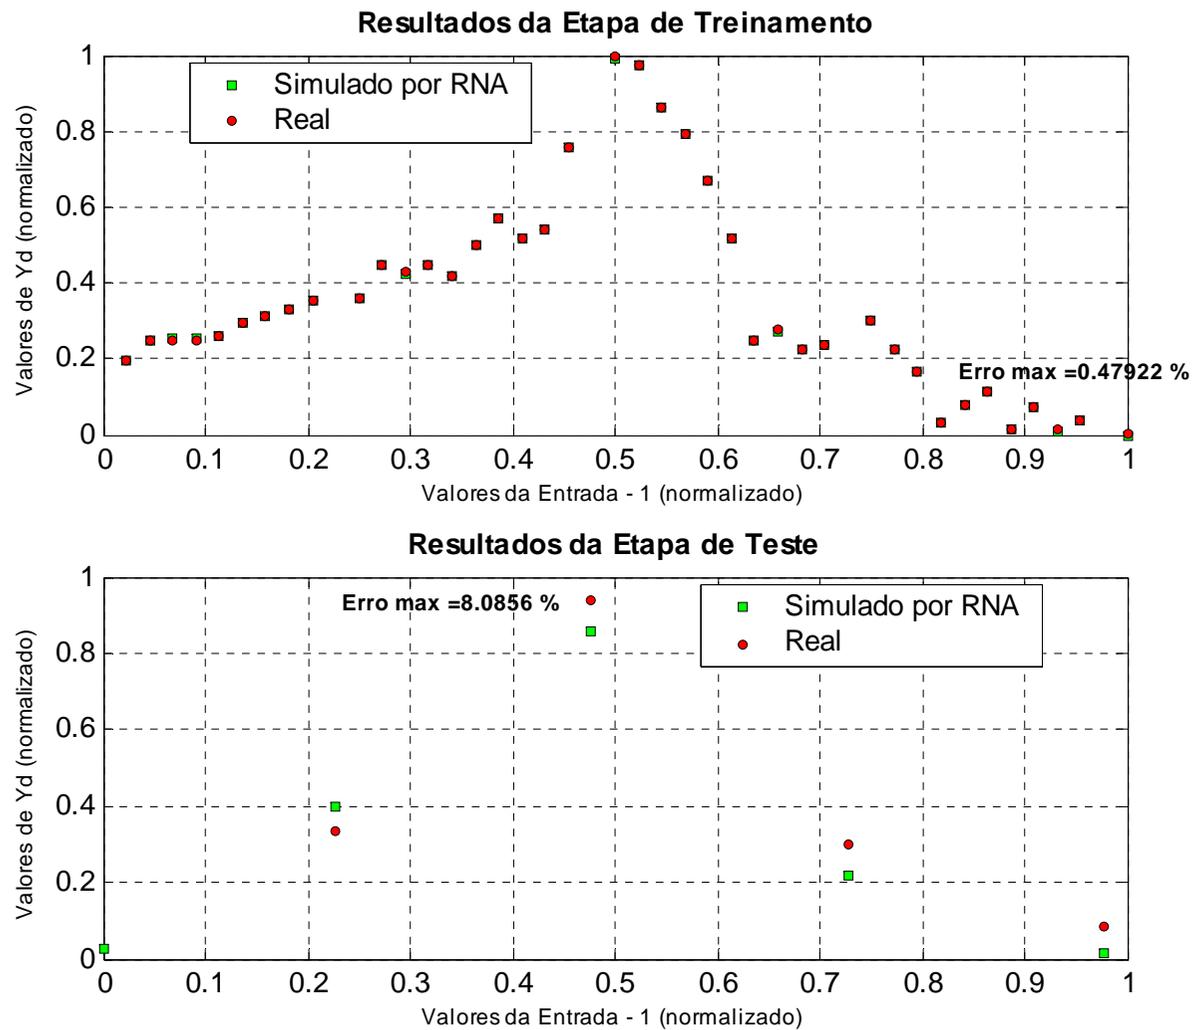
**Figura 1.31:** Processo de treinamento para o melhor caso (caso 15) da topologia 15-10-1.



**Figura 1.32:** Comparação de resultados das etapas de treinamento e teste para o melhor caso (caso 15) da topologia 15-10-1.



**Figura 1.33:** Processo de treinamento para o melhor caso (caso 16) da topologia 20-10-1.



**Figura 1.34:** Comparação de resultados das etapas de treinamento e teste para o melhor caso (caso 16) da topologia 20-10-1.

# 4. CONCLUSÕES

## 4.1. Conclusões

As conclusões do presente trabalho são as seguintes:

E proposta uma metodologia baseada em redes neurais artificiais para análise e diagnóstico da condição de OLTC. Esse sistema de informação e diagnóstico permite interpretar e diagnosticar os componentes através das entradas em tempo real e postergar os intervalos de manutenção, prevendo quando o comutador deverá sofrer intervenção de manutenção baseada na condição. A RNA adotada considerou uma arquitetura de perceptron multicamada.

Algumas das vantagens que pode oferecer a utilização de um sistema inteligente baseado em redes neurais para o diagnóstico da condição de OLTC são:

- O sistema inteligente permanentemente instalado (dados em tempo real) pode gerenciar a vida útil do OLTC viabilizando a disponibilidade dos dados (entrada e saída) a qualquer instante. As medidas dos testes coletados no tempo podem ser acolhidas para pré-ajustes nas entradas do modelo das redes neurais.
- Foco único nas características de funcionamento real com os sinais de entrada em tempo real de vários sensores instalados no OLTC.
- Quando integrado no sistema DianE, eliminar-se-á a necessidade dos custos de armazenamento de dados do OLTC, como também a centralização de dados e informação.
- Impacto na redução de custo de manutenção dos comutadores de tap dos transformadores de potência EAT na ELETRONORTE.

- O método proposto viabiliza a migração da manutenção baseada no tempo (TBM) para a manutenção baseada na condição (CBM) de OLTC.

O uso de RNA para a previsão da manutenção de OLTC, via o diagnóstico da condição, é uma alternativa viável segundo os resultados obtidos na comparação entre valores simulados e os valores reais. O modelo não impõe nenhuma restrição à entrada de sinais ou a aquisição dos modos de falha. O modelo proposto não necessita informar o histórico de manutenção do equipamento, bem como, as características relativas à operação do mesmo.

É importante ressaltar que foi escolhida uma rede perceptron de 3 camadas devido a estabelecer um ponto de início na escolha da melhor topologia e, esta representação foi a mais adequada dentre outras que foram simuladas. Estas redes são aplicadas para reconhecimentos de padrões e como aproximador universal de funções, uma vez que pode aproximar funções não-lineares. Para esta representação foram escolhidas as funções de ativação seguintes: tansigmoide, tansigmoide e linear para as camadas 1, 2 e 3, respectivamente.

Das curvas de resultados para a etapa de treinamento, o erro máximo (entre as diferentes entradas) entre o valor simulado pela RNA e o valor real, apresenta uma diminuição apreciável conforme o erro limite de treinamento diminui ou aumenta o número de épocas; assim as curvas tomam a forma de uma exponencial decrescente.

Das curvas de resultados para a etapa de teste, o erro máximo (entre as diferentes entradas) entre o valor simulado pela RNA e o valor real, apresenta inicialmente uma diminuição apreciável até chegar a um mínimo local, daí o erro aumenta, tudo isto conforme o erro limite de treinamento diminui ou aumenta o número de épocas, assim as curvas tomam a forma de uma parábola.

Dentre as diferentes topologias simuladas com validação cruzada, a topologia de RNA 5-10-1 (5, 10 e 1 neurônios nas camadas 1, 2 e 3, respectivamente) apresentou o menor erro máximo (6.12%) e maior estabilidade de resultados. Isto último devido que a alternativa 5-5-1 possui erros próximos a 6% porém na etapa de treinamento foi usado um número de épocas maior ao limite (10000 épocas), o que pode presumir um maior grau de instabilidade na atualização dos pesos da rede neural.

## **4.2. Contribuições**

As principais contribuições do presente trabalho são os seguintes:

A proposta de uma síntese de categorias de falhas de comutadores de tap sob carga, a qual foi obtida da experiência do autor em atividades de manutenção de transformadores.

A proposta de uma estrutura de blocos para análise e diagnóstico da condição de OLTC que simula a seqüência de atividades de um especialista humano.

A proposta e implementação de uma rede neural artificial que abstrai a estrutura de blocos de diagnóstico da condição de OLTC.

A aplicação bem sucedida do sistema inteligente baseado em redes neurais para o diagnóstico da condição de um comutador de tap sob carga de um autotransformador 500/230/13.8 kV de alta potência (banco de 600 MVA) da subestação São Luís II da ELETRONORTE.

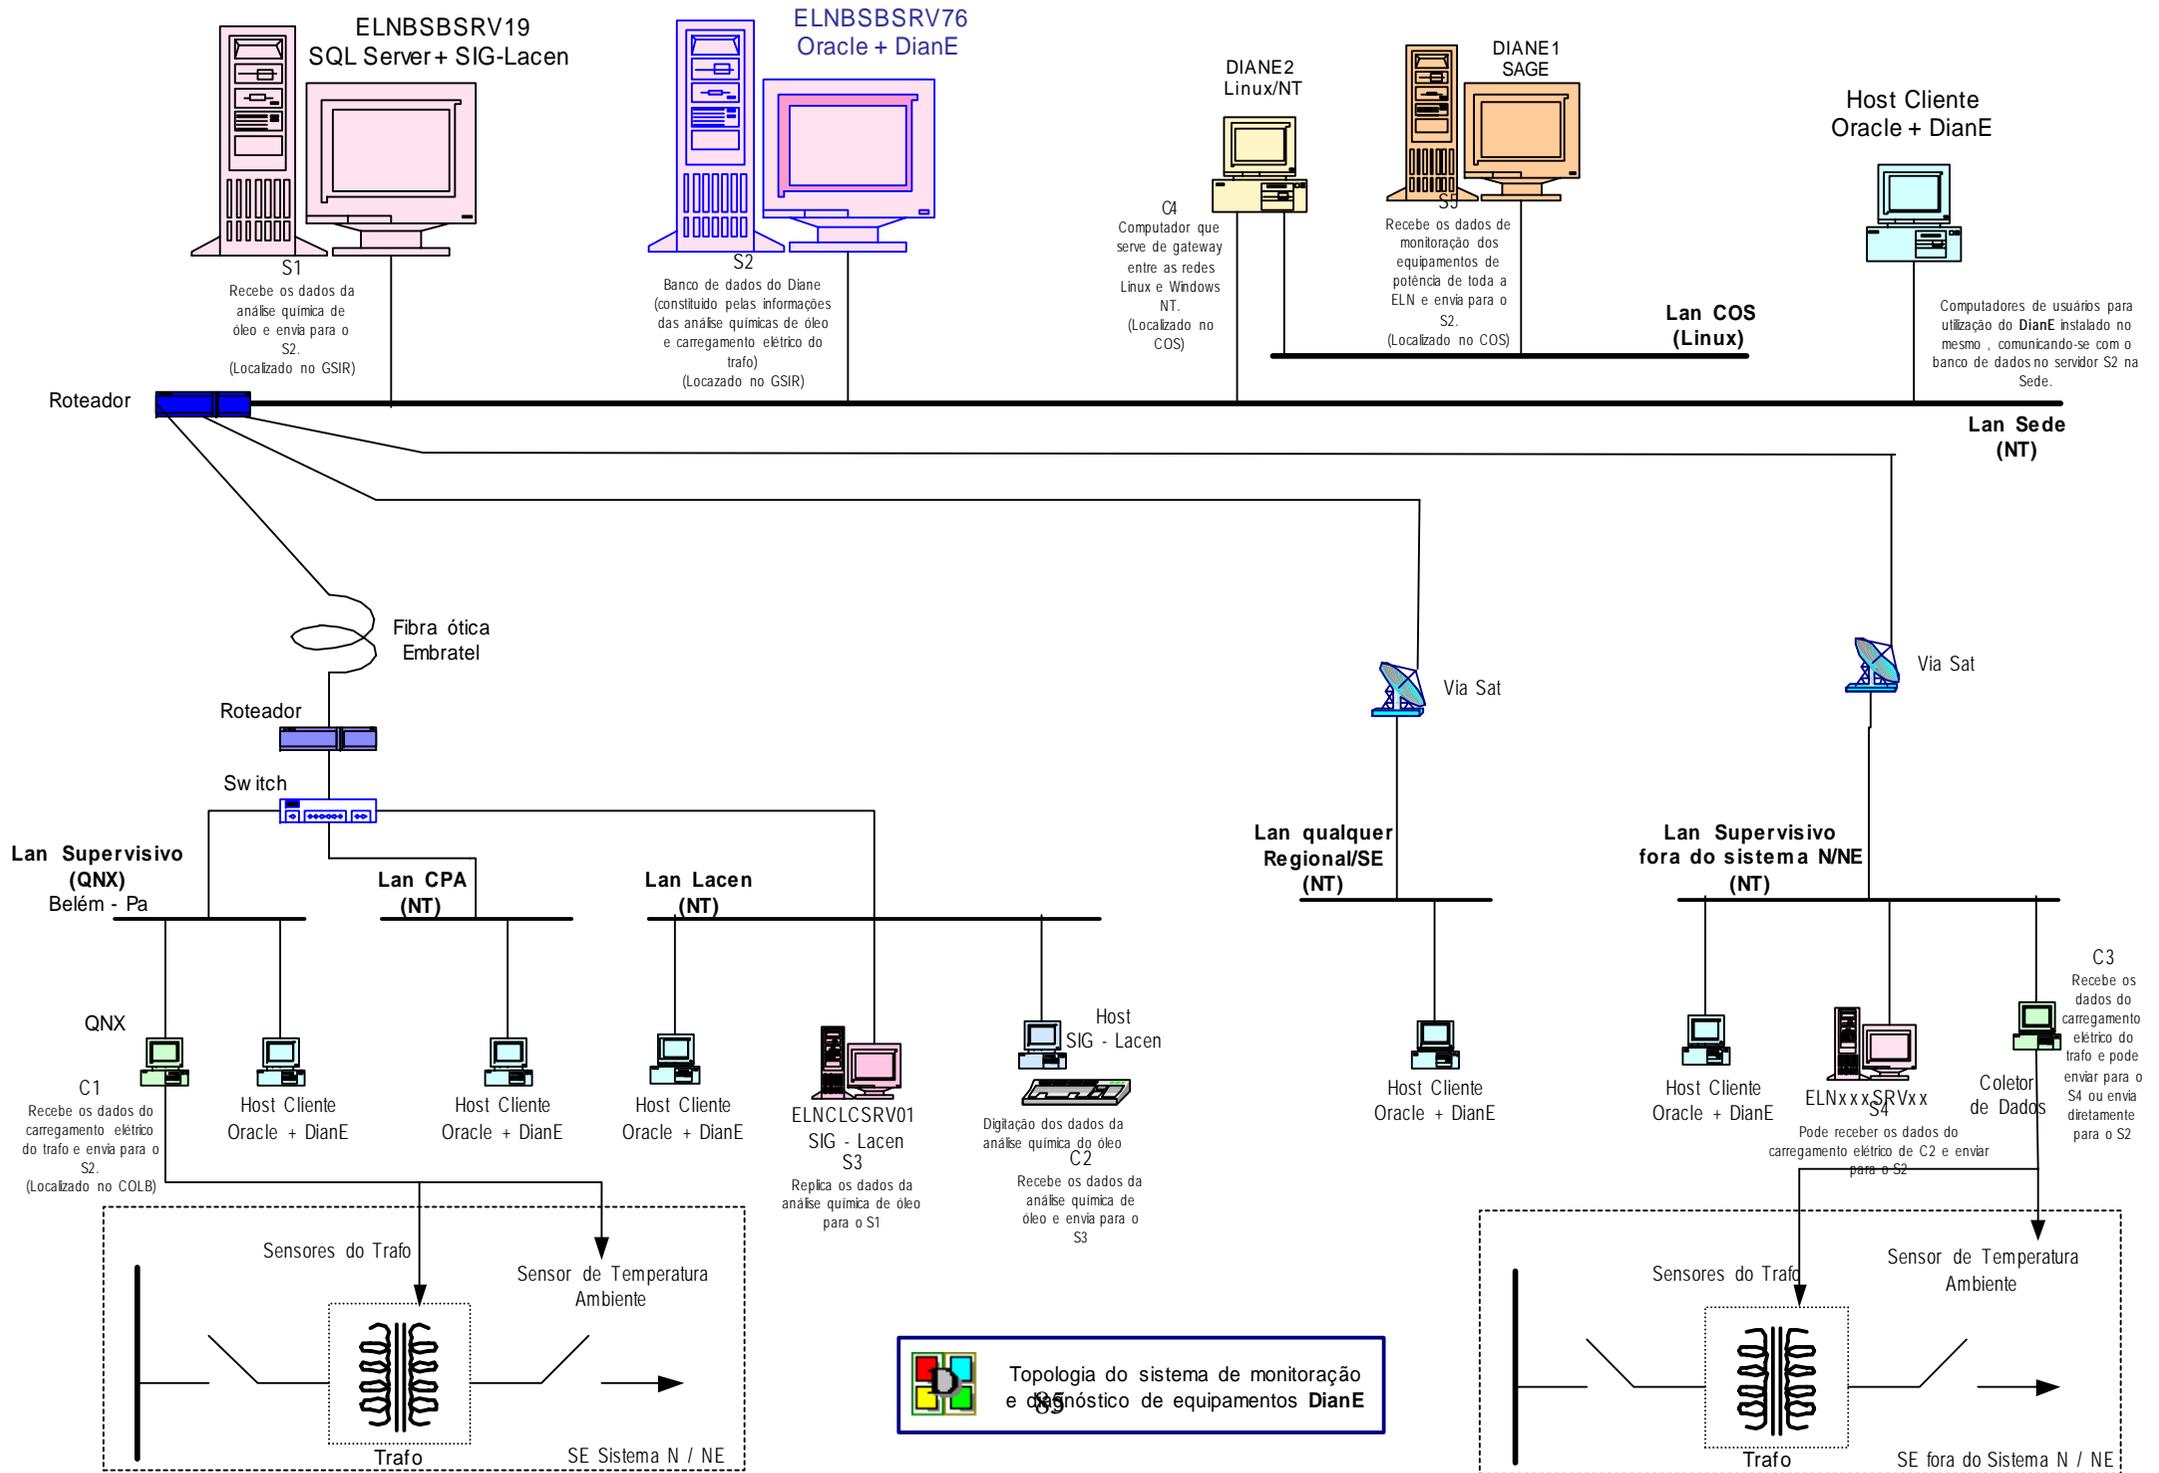
## **4.3. Trabalhos Futuros**

- Estabelecer mais outras análises ou simulações para outras entradas e conferir o comportamento da rede neural com estas novas condições. Isto pode provocar certo grau de compromisso entre as entradas e a saída esperada.
- Representar mediante duas ou mais saídas as diversas circunstâncias da decisão de manutenção de OLTC isto é, além de fornecer informação da decisão final de manutenção, estabelecer indicadores sobre o estado do OLTC e ações de manutenção preventiva.
- Dado o problema de representação matemática da questão da previsão da manutenção de OLTC, pode se tentar propor alternativas dentro da área de inteligência artificial além das redes neurais, isto é usar diferentes tipos de sistemas inteligentes.
- Integrar o modelo proposto ao sistema de diagnóstico de equipamentos – DianE, desenvolvido pelo CEPEL.

- Integrar na saída da RNA um sistema com trip de desligamento no transformador, quando algumas falhas mecânicas ocorrerem no OLTC.
- Implantar o programa computacional melhorado e ampliado num autotransformador piloto na subestação de São Luis II.

# APÊNDICES

## **A. Topologia do sistema DianE**



## B. DADOS USADOS NOS TESTES

### B.1- Dados de Entrada Reais

	E1	E2	E3	E4	E5	E6	E7
P1	1	2	3	4	5	6	7
P2	10	12	14	16	18	20	22
P3	10	12	14	16	18	20	22
P4	-25	-20	-15	-10	-5	0	2
P5	4.500	4.523	4.545	4.568	4.591	4.614	4.636
P6	46.800	47.036	47.273	47.509	47.745	47.982	48.218
P7	218.000	218.545	219.091	219.636	220.182	220.727	221.273
P8	100.000	145.727	191.455	237.182	282.909	328.636	374.364
P9	3.000	3.023	3.045	3.068	3.091	3.114	3.136
P10	1	2	3	4	5	6	7
P11	20000	30909	41818	52727	63636	74545	85455
P12	1	2	3	4	5	6	7
P13	1	2	3	4	5	6	7
P14	15.000	16.023	17.045	18.068	19.091	20.114	21.136
P15	1000.000	2113.636	3227.273	4340.909	5454.545	6568.182	7681.818
P16	500.000	943.182	1386.364	1829.545	2272.727	2715.909	3159.091
P17	500.000	943.182	1386.364	1829.545	2272.727	2715.909	3159.091
P18	500.000	943.182	1386.364	1829.545	2272.727	2715.909	3159.091
P19	500.000	943.182	1386.364	1829.545	2272.727	2715.909	3159.091
P20	500.000	943.182	1386.364	1829.545	2272.727	2715.909	3159.091
P21	500.000	943.182	1386.364	1829.545	2272.727	2715.909	3159.091
P22	0.000	0.114	0.227	0.341	0.455	0.568	0.682
Yd	0.0284	0.1987	0.2498	0.2516	0.2515	0.2597	0.296
Ye							

	E8	E9	E10	E11	E12	E13	E14
P1	8	9	10	11	12	13	14
P2	24	26	28	30	32	34	36
P3	24	26	28	30	32	34	36
P4	4	6	8	10	12	14	16
P5	4.659	4.682	4.705	4.727	4.750	4.773	4.795
P6	48.455	48.691	48.927	49.164	49.400	49.636	49.873
P7	221.818	222.364	222.909	223.455	224.000	224.545	225.091
P8	420.091	465.818	511.545	557.273	603.000	648.727	694.455
P9	3.159	3.182	3.205	3.227	3.250	3.273	3.295
P10	8	9	10	11	12	13	14
P11	96364	107273	118182	129091	140000	150909	161818
P12	8	9	10	11	12	13	14
P13	8	9	10	11	12	13	14
P14	22.159	23.182	24.205	25.227	26.250	27.273	28.295
P15	8795.455	9909.091	11022.727	12136.364	13250.000	14363.636	15477.273
P16	3602.273	4045.455	4488.636	4931.818	5375.000	5818.182	6261.364
P17	3602.273	4045.455	4488.636	4931.818	5375.000	5818.182	6261.364
P18	3602.273	4045.455	4488.636	4931.818	5375.000	5818.182	6261.364
P19	3602.273	4045.455	4488.636	4931.818	5375.000	5818.182	6261.364
P20	3602.273	4045.455	4488.636	4931.818	5375.000	5818.182	6261.364
P21	3602.273	4045.455	4488.636	4931.818	5375.000	5818.182	6261.364
P22	0.795	0.909	1.023	1.136	1.250	1.364	1.477
Yd	0.3147	0.3333	0.352	0.3976	0.3623	0.4468	0.4268
Ye							

	E15	E16	E17	E18	E19	E20	E21
P1	15	16	17	18	19	20	21
P2	38	40	42	44	46	48	50
P3	38	40	42	44	46	48	50
P4	18	20	22	24	26	28	30
P5	4.818	4.841	4.864	4.886	4.909	4.932	4.955
P6	50.109	50.345	50.582	50.818	51.055	51.291	51.527
P7	225.636	226.182	226.727	227.273	227.818	228.364	228.909
P8	740.182	785.909	831.636	877.364	923.091	968.818	1014.545
P9	3.318	3.341	3.364	3.386	3.409	3.432	3.455
P10	15	16	17	18	19	20	21
P11	172727	183636	194545	205455	216364	227273	238182
P12	15	16	17	18	19	20	21
P13	15	16	17	18	19	20	21
P14	29.318	30.341	31.364	32.386	33.409	34.432	35.455
P15	16590.909	17704.545	18818.182	19931.818	21045.455	22159.091	23272.727
P16	6704.545	7147.727	7590.909	8034.091	8477.273	8920.455	9363.636
P17	6704.545	7147.727	7590.909	8034.091	8477.273	8920.455	9363.636
P18	6704.545	7147.727	7590.909	8034.091	8477.273	8920.455	9363.636
P19	6704.545	7147.727	7590.909	8034.091	8477.273	8920.455	9363.636
P20	6704.545	7147.727	7590.909	8034.091	8477.273	8920.455	9363.636
P21	6704.545	7147.727	7590.909	8034.091	8477.273	8920.455	9363.636
P22	1.591	1.705	1.818	1.932	2.045	2.159	2.273
Yd	0.4453	0.4162	0.5022	0.5707	0.52023	0.5389	0.7557
Ye							

	E22	E23	E24	E25	E26	E27	E28
P1	22	23	24	25	26	27	28
P2	52	54	56	58	60	62	64
P3	52	54	56	58	60	62	64
P4	32	34	36	38	40	41	42
P5	4.977	5.000	5.023	5.045	5.068	5.091	5.114
P6	51.764	52.000	52.236	52.473	52.709	52.945	53.182
P7	229.455	230.000	230.545	231.091	231.636	232.182	232.727
P8	1060.273	1106.000	1151.727	1197.455	1243.182	1288.909	1334.636
P9	3.477	3.500	3.523	3.545	3.568	3.591	3.614
P10	22	23	24	25	26	27	28
P11	249091	260000	270909	281818	292727	303636	314545
P12	22	23	24	25	26	27	28
P13	22	23	24	25	26	27	28
P14	36.477	37.500	38.523	39.545	40.568	41.591	42.614
P15	24386.364	25500.000	26613.636	27727.273	28840.909	29954.545	31068.182
P16	9806.818	10250.000	10693.182	11136.364	11579.545	12022.727	12465.909
P17	9806.818	10250.000	10693.182	11136.364	11579.545	12022.727	12465.909
P18	9806.818	10250.000	10693.182	11136.364	11579.545	12022.727	12465.909
P19	9806.818	10250.000	10693.182	11136.364	11579.545	12022.727	12465.909
P20	9806.818	10250.000	10693.182	11136.364	11579.545	12022.727	12465.909
P21	9806.818	10250.000	10693.182	11136.364	11579.545	12022.727	12465.909
P22	2.386	2.500	2.614	2.727	2.841	2.955	3.068
Yd	0.8576	0.994	0.9713	0.8632	0.7929	0.6697	0.518
Ye							

	E29	E30	E31	E32	E33	E34	E35
P1	29	30	31	32	33	34	35
P2	66	68	70	72	74	76	78
P3	66	68	70	72	74	76	78
P4	43	44	45	46	47	48	49
P5	5.136	5.159	5.182	5.205	5.227	5.250	5.273
P6	53.418	53.655	53.891	54.127	54.364	54.600	54.836
P7	233.273	233.818	234.364	234.909	235.455	236.000	236.545
P8	1380.364	1426.091	1471.818	1517.545	1563.273	1609.000	1654.727
P9	3.636	3.659	3.682	3.705	3.727	3.750	3.773
P10	29	30	31	32	33	34	35
P11	325455	336364	347273	358182	369091	380000	390909
P12	29	30	31	32	33	34	35
P13	29	30	31	32	33	34	35
P14	43.636	44.659	45.682	46.705	47.727	48.750	49.773
P15	32181.818	33295.455	34409.091	35522.727	36636.364	37750.000	38863.636
P16	12909.091	13352.273	13795.455	14238.636	14681.818	15125.000	15568.182
P17	12909.091	13352.273	13795.455	14238.636	14681.818	15125.000	15568.182
P18	12909.091	13352.273	13795.455	14238.636	14681.818	15125.000	15568.182
P19	12909.091	13352.273	13795.455	14238.636	14681.818	15125.000	15568.182
P20	12909.091	13352.273	13795.455	14238.636	14681.818	15125.000	15568.182
P21	12909.091	13352.273	13795.455	14238.636	14681.818	15125.000	15568.182
P22	3.182	3.295	3.409	3.523	3.636	3.750	3.864
Yd	0.2494	0.2743	0.2243	0.2369	0.2182	0.3023	0.2243
Ye							

	E36	E37	E38	E39	E40	E41	E42
P1	36	37	38	39	40	41	42
P2	80	82	84	86	88	90	92
P3	80	82	84	86	88	90	92
P4	50	51	52	53	54	55	56
P5	5.295	5.318	5.341	5.364	5.386	5.409	5.432
P6	55.073	55.309	55.545	55.782	56.018	56.255	56.491
P7	237.091	237.636	238.182	238.727	239.273	239.818	240.364
P8	1700.455	1746.182	1791.909	1837.636	1883.364	1929.091	1974.818
P9	3.795	3.818	3.841	3.864	3.886	3.909	3.932
P10	36	37	38	39	40	41	42
P11	401818	412727	423636	434545	445455	456364	467273
P12	36	37	38	39	40	41	42
P13	36	37	38	39	40	41	42
P14	50.795	51.818	52.841	53.864	54.886	55.909	56.932
P15	39977.273	41090.909	42204.545	43318.182	44431.818	45545.455	46659.091
P16	16011.364	16454.545	16897.727	17340.909	17784.091	18227.273	18670.455
P17	16011.364	16454.545	16897.727	17340.909	17784.091	18227.273	18670.455
P18	16011.364	16454.545	16897.727	17340.909	17784.091	18227.273	18670.455
P19	16011.364	16454.545	16897.727	17340.909	17784.091	18227.273	18670.455
P20	16011.364	16454.545	16897.727	17340.909	17784.091	18227.273	18670.455
P21	16011.364	16454.545	16897.727	17340.909	17784.091	18227.273	18670.455
P22	3.977	4.091	4.205	4.318	4.432	4.545	4.659
Yd	0.1686	0.0306	0.0802	0.1112	0.0119	0.0738	0.0113
Ye							

	E43	E44	E45				
P1	43	44	45				
P2	94	96	98				
P3	94	96	98				
P4	57	58	59				
P5	5.455	5.477	5.500				
P6	56.727	56.964	57.200				
P7	240.909	241.455	242.000				
P8	2020.545	2066.273	2112.000				
P9	3.955	3.977	4.000				
P10	43	44	45				
P11	478182	489091	500000				
P12	43	44	45				
P13	43	44	45				
P14	57.955	58.977	60.000				
P15	47772.727	48886.364	50000.000				
P16	19113.636	19556.818	20000.000				
P17	19113.636	19556.818	20000.000				
P18	19113.636	19556.818	20000.000				
P19	19113.636	19556.818	20000.000				
P20	19113.636	19556.818	20000.000				
P21	19113.636	19556.818	20000.000				
P22	4.773	4.886	5.000				
Yd	0.0374	0.0167	0				
Ye							

## B.2- DATOS DE ENTRADA NORMALIZADOS

	E1	E2	E3	E4	E5	E6	E7	E8	E9	E10	E11
P1	0.022	0.0444	0.0666	0.0889	0.1111	0.1333	0.1555	0.178	0.2	0.2222	0.244
P2	0.1	0.1205	0.1409	0.1614	0.1818	0.2023	0.2227	0.243	0.2636	0.2841	0.305
P3	0.1	0.1205	0.1409	0.1614	0.1818	0.2023	0.2227	0.243	0.2636	0.2841	0.305
P4	-0.56	-0.52	-0.485	-0.449	-0.414	-0.379	-0.343	-0.308	-0.273	-0.237	-0.202
P5	0.818	0.8221	0.8263	0.8304	0.8345	0.8387	0.8428	0.847	0.8511	0.8552	0.859
P6	0.818	0.8221	0.8263	0.8304	0.8345	0.8387	0.8428	0.847	0.8511	0.8552	0.859
P7	0.9	0.9023	0.9045	0.9068	0.9091	0.9114	0.9136	0.916	0.9182	0.9205	0.923
P8	0.472	0.4837	0.4957	0.5077	0.5197	0.5317	0.5437	0.556	0.5678	0.5798	0.592
P9	0.75	0.7557	0.7614	0.767	0.7727	0.7784	0.7841	0.79	0.7955	0.8011	0.807
P10	0.022	0.0444	0.0666	0.0889	0.1111	0.1333	0.1555	0.178	0.2	0.2222	0.244
P11	0.002	0.0247	0.0474	0.07	0.0927	0.1154	0.1381	0.161	0.1835	0.2061	0.229
P12	0.022	0.0444	0.0666	0.0889	0.1111	0.1333	0.1555	0.178	0.2	0.2222	0.244
P13	0.022	0.0444	0.0666	0.0889	0.1111	0.1333	0.1555	0.178	0.2	0.2222	0.244
P14	0.25	0.267	0.2841	0.3011	0.3182	0.3352	0.3523	0.369	0.3864	0.4034	0.421
P15	0.02	0.0423	0.0645	0.0868	0.1091	0.1314	0.1536	0.176	0.1982	0.2205	0.243
P16	0.025	0.0472	0.0693	0.0915	0.1136	0.1358	0.1801	0.202	0.2244	0.2466	0.269
P17	0.025	0.0472	0.0693	0.0915	0.1136	0.1358	0.1801	0.202	0.2244	0.2466	0.269
P18	0.025	0.0472	0.0693	0.0915	0.1136	0.1358	0.1801	0.202	0.2244	0.2466	0.269
P19	0.025	0.0472	0.0693	0.0915	0.1136	0.1358	0.1801	0.202	0.2244	0.2466	0.269
P20	0.025	0.0472	0.0693	0.0915	0.1136	0.1358	0.1801	0.202	0.2244	0.2466	0.269
P21	0.025	0.0472	0.0693	0.0915	0.1136	0.1358	0.1801	0.202	0.2244	0.2466	0.269
P22	0	0.0227	0.0455	0.0682	0.0682	0.0909	0.1364	0.159	0.1818	0.2045	0.227
Yd	0.028	0.1987	0.2498	0.2516	0.2515	0.2597	0.296	0.315	0.3333	0.352	0.398
Ye											

	E12	E13	E14	E15	E16	E17	E18	E19	E20	E21	E22
P1	0.2667	0.2889	0.3111	0.3333	0.3555	0.3778	0.4	0.4222	0.4444	0.4667	0.49
P2	0.325	0.3455	0.3659	0.3864	0.4068	0.4273	0.4477	0.4682	0.4886	0.5091	0.53
P3	0.325	0.3455	0.3659	0.3864	0.4068	0.4273	0.4477	0.4682	0.4886	0.5091	0.53
P4	-0.167	-0.131	-0.096	-0.0606	-0.0252	0.0101	0.0455	0.0808	0.1162	0.1515	0.19
P5	0.8635	0.8676	0.8718	0.8759	0.88	0.8842	0.8883	0.8925	0.8966	0.9007	0.9
P6	0.8635	0.8676	0.8718	0.8759	0.88	0.8842	0.8883	0.8925	0.8966	0.9007	0.9
P7	0.925	0.9273	0.9295	0.9295	0.9341	0.9364	0.9386	0.9409	0.9432	0.9455	0.95
P8	0.6038	0.6158	0.6278	0.6398	0.6518	0.6638	0.6758	0.6878	0.6998	0.7118	0.72
P9	0.8125	0.8182	0.8239	0.8295	0.8352	0.8409	0.8466	0.8523	0.858	0.8636	0.87
P10	0.2667	0.2889	0.3111	0.3333	0.3555	0.3778	0.4	0.4222	0.4444	0.4667	0.49
P11	0.2515	0.2742	0.2969	0.3195	0.3422	0.3649	0.3876	0.4103	0.433	0.4556	0.48
P12	0.2667	0.2889	0.3111	0.3333	0.3555	0.3778	0.4	0.4222	0.4444	0.4667	0.49
P13	0.2667	0.2889	0.3111	0.3333	0.3555	0.3778	0.4	0.4222	0.4444	0.4667	0.49
P14	0.4375	0.4545	0.4716	0.4886	0.5057	0.5227	0.5398	0.5568	0.5739	0.5909	0.61
P15	0.265	0.2873	0.3095	0.3318	0.3541	0.3764	0.3986	0.4209	0.4432	0.4655	0.49
P16	0.2909	0.3131	0.3352	0.3574	0.3795	0.4017	0.4239	0.446	0.4682	0.4903	0.51
P17	0.2909	0.3131	0.3352	0.3574	0.3795	0.4017	0.4239	0.446	0.4682	0.4903	0.51
P18	0.2909	0.3131	0.3352	0.3574	0.3795	0.4017	0.4239	0.446	0.4682	0.4903	0.51
P19	0.2909	0.3131	0.3352	0.3574	0.3795	0.4017	0.4239	0.446	0.4682	0.4903	0.51
P20	0.2909	0.3131	0.3352	0.3574	0.3795	0.4017	0.4239	0.446	0.4682	0.4903	0.51
P21	0.2909	0.3131	0.3352	0.3574	0.3795	0.4017	0.4239	0.446	0.4682	0.4903	0.51
P22	0.25	0.2727	0.2955	0.3182	0.3409	0.3636	0.3864	0.4091	0.4318	0.4545	0.48
Yd	0.3623	0.4468	0.4268	0.4453	0.4162	0.5022	0.5707	0.52023	0.5389	0.7557	0.86
Ye											

	E23	E24	E25	E26	E27	E28	E29	E30	E31	E32	E33
P1	0.5111	0.533	0.5555	0.5778	0.6	0.6222	0.6444	0.6667	0.6887	0.7111	0.7333
P2	0.55	0.571	0.5909	0.6114	0.6318	0.6523	0.6727	0.6932	0.7136	0.7341	0.7545
P3	0.55	0.571	0.5909	0.6114	0.6318	0.6523	0.6727	0.6932	0.7136	0.7341	0.7545
P4	0.2222	0.258	0.293	0.3283	0.3637	0.399	0.4344	0.4697	0.5051	0.5404	0.5758
P5	0.909	0.913	0.9173	0.9214	0.9255	0.9297	0.9338	0.938	0.9421	0.9462	0.9504
P6	0.909	0.913	0.9173	0.9214	0.9255	0.9297	0.9338	0.938	0.9421	0.9462	0.9504
P7	0.95	0.952	0.9545	0.9568	0.9591	0.9614	0.9636	0.9659	0.9682	0.9705	0.9727
P8	0.7359	0.748	0.7599	0.7719	0.7839	0.7959	0.8079	0.8199	0.8319	0.8439	0.8559
P9	0.875	0.881	0.8864	0.892	0.8977	0.9034	0.9091	0.9148	0.9205	0.9261	0.9318
P10	0.5111	0.533	0.5555	0.5778	0.6	0.6222	0.6444	0.6667	0.6889	0.7111	0.7333
P11	0.501	0.524	0.5464	0.569	0.5917	0.6144	0.6371	0.6598	0.6825	0.7051	0.7278
P12	0.5111	0.533	0.5555	0.5778	0.6	0.6222	0.6444	0.6667	0.6889	0.7111	0.7333
P13	0.5111	0.533	0.5555	0.5778	0.6	0.6222	0.6444	0.6667	0.6889	0.7111	0.7333
P14	0.625	0.642	0.6591	0.6761	0.6932	0.7102	0.7273	0.7443	0.7614	0.7784	0.7955
P15	0.51	0.532	0.5545	0.5768	0.5991	0.6214	0.6436	0.6659	0.6882	0.7105	0.7327
P16	0.5347	0.557	0.579	0.6011	0.6233	0.6455	0.6676	0.6898	0.7119	0.7341	0.7562
P17	0.5347	0.557	0.579	0.6011	0.6233	0.6455	0.6676	0.6898	0.7119	0.7341	0.7562
P18	0.5347	0.557	0.579	0.6011	0.6233	0.6455	0.6676	0.6898	0.7119	0.7341	0.7562
P19	0.5347	0.557	0.579	0.6011	0.6233	0.6455	0.6676	0.6898	0.7119	0.7341	0.7562
P20	0.5347	0.557	0.579	0.6011	0.6233	0.6455	0.6676	0.6898	0.7119	0.7341	0.7562
P21	0.5347	0.557	0.579	0.6011	0.6233	0.6455	0.6676	0.6898	0.7119	0.7341	0.7562
P22	0.5	0.523	0.5455	0.5682	0.5909	0.6136	0.6364	0.6591	0.6818	0.7045	0.7273
Yd	0.994	0.971	0.8632	0.7929	0.6697	0.518	0.2494	0.2743	0.2243	0.2369	0.2182
Ye											

	E34	E35	E36	E37	E38	E39	E40	E41	E42	E43	E44	E45
P1	0.7556	0.7778	0.8	0.8222	0.8444	0.8667	0.8889	0.9111	0.9333	0.9556	0.9778	1
P2	0.775	0.7955	0.8159	0.8364	0.8568	0.8773	0.8977	0.9182	0.9386	0.9591	0.9795	1
P3	0.775	0.7955	0.8364	0.8568	0.8773	0.8977	0.9182	0.9386	0.9591	0.9591	0.9795	1
P4	0.6111	0.6445	0.6818	0.7172	0.7525	0.7879	0.8232	0.8586	0.8939	0.9293	0.9646	1
P5	0.9545	0.9586	0.9628	0.9669	0.971	0.9752	0.9793	0.9835	0.9876	0.9917	0.9959	1
P6	0.9545	0.9586	0.9628	0.9669	0.971	0.9752	0.9793	0.9835	0.9876	0.9917	0.9959	1
P7	0.975	0.9773	0.9795	0.9818	0.9841	0.9864	0.9886	0.9909	0.9932	0.9955	0.9977	1
P8	0.8679	0.8799	0.8919	0.9039	0.916	0.928	0.94	0.952	0.964	0.976	0.988	1
P9	0.9375	0.9432	0.9489	0.9545	0.9602	0.9659	0.9716	0.9773	0.983	0.9886	0.9943	1
P10	0.7556	0.7778	0.8	0.8222	0.8444	0.8667	0.8889	0.9111	0.9333	0.9556	0.9778	1
P11	0.7505	0.7732	0.7959	0.8185	0.8412	0.8639	0.8866	0.9093	0.932	0.9546	0.9773	1
P12	0.7556	0.7778	0.8	0.8222	0.8444	0.8667	0.8889	0.9111	0.9333	0.9556	0.9778	1
P13	0.7556	0.7778	0.8	0.8222	0.8444	0.8667	0.8889	0.9111	0.9333	0.9556	0.9778	1
P14	0.8125	0.8295	0.8466	0.8636	0.8807	0.8977	0.9148	0.9318	0.9489	0.9659	0.983	1
P15	0.755	0.7773	0.7995	0.8218	0.8441	0.8664	0.8886	0.9109	0.9332	0.9555	0.9777	1
P16	0.7784	0.8006	0.8227	0.8449	0.867	0.867	0.8892	0.9114	0.9335	0.9557	0.9778	1
P17	0.7784	0.8006	0.8227	0.8449	0.867	0.867	0.8892	0.9114	0.9335	0.9557	0.9778	1
P18	0.7784	0.8006	0.8227	0.8449	0.867	0.867	0.8892	0.9114	0.9335	0.9557	0.9778	1
P19	0.7784	0.8006	0.8227	0.8449	0.867	0.867	0.8892	0.9114	0.9335	0.9557	0.9778	1
P20	0.7784	0.8006	0.8227	0.8449	0.867	0.867	0.8892	0.9114	0.9335	0.9557	0.9778	1
P21	0.7784	0.8006	0.8227	0.8449	0.867	0.867	0.8892	0.9114	0.9335	0.9557	0.9778	1
P22	0.75	0.7727	0.7955	0.8182	0.8409	0.8636	0.8864	0.9091	0.9318	0.9545	0.9773	1
Yd	0.3023	0.2243	0.1686	0.0306	0.0802	0.1112	0.0119	0.0738	0.0113	0.0374	0.0167	0
Ye												

# REFERÊNCIAS BIBLIOGRÁFICAS

- [ALEK90] I. Aleksander and H. Morton, *An introduction to neural computing*, Chapman and Hall, London, 1990.
- [BOLH02] J. P. Van Bolhuis, E. Gulski and J. J.Smit, “Monitoring and Diagnostic of Transformer Solid Insulation”, *IEEE Transactions on Power Delivery*, pp.528-536, Vol.17, No.2, April 2002.
- [CHUR92] P.S. Churchland, T.J. Sejnowski, *The computational Brain*, Cambridge, MA: MIT Press, 1992.
- [DILL96] T.S. Dillon and D. Niebur, *Neural Networks Applications in Power Systems*, CRL Publishing Ltd., London, 1996.
- [DONG04] Y. Dong, Y. Gu, K. Yang and J. Zhang, “Applying PCA to establish artificial neural network for condition prediction on equipment in power plant”, Fifth World Congress on Intelligent Control and Automation – WCICA-2004, Vol. 2, pp.1715-1719, June 2004.
- [ELSH96] M. El-Sharkawi and D. Niebur, “Artificial Neural Networks with Applications to Power Systems”, IEEE PES 96 TP 112-0, 1996.
- [FARR01] M. Farrokhi and M. Rafiee, “Evaluation of used and repaired power transformers using neural networks”, Transmission and Distribution Conference and Exposition, 2001 IEEE/PES, Vol. 1, pp.143-146, 2001.
- [HAND01] B. Handley, M. Redfern and S.White, “On Load Tap Changer Conditioned Based Maintenance”, *IEE Proc. Gener. Transm. and Distrib.*, pp. 296-300, Vol. 148, No.4, July 2001.
- [HARR97] D. Harris and M. P. Saravolac, “Condition Monitoring in Power Transformer”, IEE Colloquium on Condition Monitoring of Large Machines and Power Transformers, pp.7/1-7/3, June 1997.

- [HAYK98] S. Haykin, *Neural Networks: a comprehensive foundation*, 2nd.ed., Prentice Hall, 1998.
- [HIPPO1] H.S. Hippert, C.E. Pedreira and R.C. Souza, "Neural networks for short-term load forecasting: a review and evaluation", *IEEE Transactions on Power Systems*, Vol.16, No.1, pp.44-45, Feb. 2001.
- [HUSA01] E. Husain, M. M. Moshin and Satyaprakash, "Transformer Insulation Condition Monitoring Artificial Using Neural Network," Proceedings of the 2001 IEEE 7th International Conference on Solid Dielectrics, pp.295-298, June 2001.
- [IEC89] IEC60214, "On-load tap-changers", International Standard, Electrotechnical, 3<sup>rd</sup> edition, 1989.
- [IEEE86] IEEE "Guide goes reporting failure it dates it goes power transformers and shunt reactors on electric utility power systems", ANSI-IEEE STD C57.117, 1986.
- [ILIC98] D. Marija Ilic, F. D. Galiana and L. H. Fink, *Power Systems Restructuring Engineering and Economics*, Kluwer International Series in Engineering & Computer Science, 448, 1998.
- [ISAP99] ISAP, Proceedings of the International Conference "Intelligent Systems Applications to Power Systems", ISAP-1999: Rio de Janeiro, Brazil; ISAP-2001: Budapest, Hungary.
- [JONE98] W. H. Jones and M. C. Stansbury, "Power Quality Monitoring Enhances preventive Maintenance Program: Detecting Substation Transformer Tap Changer Problem", IEEE Conference on Industrial Equipment, pp.1-6, 1998.
- [KANG01] P. Kang and D. Birtwhistle, "Condition Monitoring of Power Transformer on Load Tap changers. Part 1: Automatic Condition Diagnostics", *IEE Proc. Gener. Transm. Distrib.*, vol.148, no.4, pp. 301-306, July 2001.

- [KANG01] P. Kang and D. Birtwhistle, "On Line Condition Monitoring of Tap Changers Field Experience", CIRED-2001, June 2001, Conference Publication No. 482, 2001.
- [LAPW95] J.A. Lapworth, P.N. Jarman and I.R. Funnell, "Condition assessment techniques for large power transformers"; Second International Conference on the Reliability of Transmission and Distribution Equipment, pp.85-90, Mar. 1995
- [LEIB98] T. Leibfried, "On line Monitors Keep Transformers in Service", *IEEE Computer Applications in Power*, vol.11, no.3, pp. 36-42 July 1998.
- [LEWI95] K.G. Lewis, R.E. Jones and G.R. Jones, "THE tap changer monitoring system incorporating optical sensors", IEE Conference Publication, Reliability of Transmission and Distribution Equipment, pp.97-102, 1995.
- [MR1990] Handbook of the "Maschinenfabrik Reinhhausen, Gebruder Scheubeck GmbH&Co.KG", Vol.1, Service department, 1990.
- [PAUC02] V. L. Paucar and M. J. Rider, "Artificial Neural Networks for Solving the Power Flow Problem in Electric Power Systems," *Electric Power Systems Research*, vol. 62, no. 2, pp. 139-144, 2002.
- [SAGE90] A.P. Sage, *Concise encyclopedia of information processing in systems and organization*, New York: Pergamon, 1990.
- [SCHA97] R.J. Schalkoff, *Artificial Neural Networks*, The McGraw-Hill Companies, 1997.
- [SCHW00] F.C. Schweppe, M.C. Caramanis, R.D. Tabors and R.E. Bohn, *Spot Pricing of Electricity*, Kluwer Academic Publishers, 2000.
- [SOBA89] D.J. Sobajic and Y. Pao, "Artificial Neural-Net Based Dynamic Security Assessment for Electric Power Systems", *IEEE Transactions on Power Systems*, vol.4, no.1, pp. 220-228, Feb. 1989.

- [SPEN95] G. Spence and A. C. Hall, "On Load Tap Changers Current Experience and Future Development. Users Experience and Perspective", The National Grid Company, pp. 1-6, Oct. 1995.
- [SWIF95] G. Swift and T. Molinski, "Power Transformer Life - Cycle Cost Reduction", Canadian Electrical Association Technology Seminar, Toronto, Canada, Nov.1995.
- [WALT93] C. T. Walters, "Failed Transformer: Replace or Repair," IEE Pub. CH3331-6/93/0000-0127, pp.127-129, 1993.
- [WANG00] Z. Y. Wang and P. J.Griffin, "Artificial Intelligence in OLTC Fault Dissolved Gas in Oil Information", IEEE Pub.0-7803-6420-1/00, pp.2423-2427, 2000.
- [WEIP98] Ma Weiping, Zheng Lianghua and Wang Shuo, "Research on On-line PD Monitoring System Goes Large Power Transformer", Proceedings of 1998 International Symposium on Electrical Insulating Materials, pp.505-508, Japan, 1998.
- [WETZ00] J. M. Wetzer, G. J. Cliteur, W. R. Rutgers and H. F. A.Verhaart, "Diagnostic and Condition Assessment-Techniques Goes Condition Based Maintenance", International Conference on Electrical Insulation and Dielectric Phenomena, pp. 47-51, 2000.
- [YOUN98] W. Young, "Transformer life Management Condition Monitoring", IEE Colloquium on Transformer Life Management, pp.2/1-2/4, UK, Oct. 1998.
- [ZHAN98] Y. Zhang, X. Ding, Y. Liu, and P. J. Griffin, "An artificial neural approach to transformer fault diagnosis," *IEEE Trans. on Power Delivery*, vol. 11, no. 4, Oct. 1998.