

**PONTIFÍCIA UNIVERSIDADE CATÓLICA DO PARANÁ
CENTRO DE CIÊNCIAS EXATAS E DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA DE
PRODUÇÃO E SISTEMAS**

CAMILA DA COSTA SILVEIRA

**ABORDAGEM DE CLASSIFICAÇÃO DE DADOS APLICADA NO DIAGNÓSTICO
DE FALHAS INCIPIENTES EM TRANSFORMADORES DE POTÊNCIA**

CURITIBA

2012

CAMILA DA COSTA SILVEIRA

**ABORDAGEM DE CLASSIFICAÇÃO DE DADOS APLICADA NO DIAGNÓSTICO
DE FALHAS INCIPIENTES EM TRANSFORMADORES DE POTÊNCIA**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia de Produção e Sistemas – PPGEPS, Área de concentração: Modelagem, Controle e Automação de Sistemas, da Escola Politécnica, da Pontifícia Universidade Católica do Paraná, como requisito à obtenção do título de mestre em Engenharia de Produção e Sistemas.

Orientador: Prof. Dr. Leandro dos Santos Coelho

CURITIBA

2012

CAMILA DA COSTA SILVEIRA

**ABORDAGEM DE CLASSIFICAÇÃO DE DADOS APLICADA NO DIAGNÓSTICO
DE FALHAS INCIPIENTES EM TRANSFORMADORES DE POTÊNCIA**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia de Produção e Sistemas – PPGEPS, Área de concentração: Modelagem, Controle e Automação de Sistemas, da Escola Politécnica, da Pontifícia Universidade Católica do Paraná, como requisito à obtenção do título de mestre em Engenharia de Produção e Sistemas.

COMISSÃO EXAMINADORA

Prof. Dr. Leandro dos Santos Coelho

Prof. Julio Cesar Nievola, PhD
Pontifícia Universidade Católica do Paraná

Prof. Dr. Roberto Zanetti Freire
Pontifícia Universidade Católica do Paraná

Curitiba, 28 de setembro de 2012.

Dedico aos meus pais que desde os meus
primeiro passos sempre fizeram o melhor
para a minha formação

AGRADECIMENTOS

Agradeço à Deus por estar sempre presente, me concedendo oportunidades, me guiando e dando forças.

Agradeço aos meus pais pelos sacrifícios realizados em meu benefício e pelo constante esforço de fazer o que julgavam certo para o meu desenvolvimento.

Agradeço ao meu pai, cuja sede pelo conhecimento e vontade de aprender serviu-me exemplo. Com toda a certeza, esta característica eu herdei de você.

Agradeço à minha mãe pelo apoio e pela torcida nos momentos que a minha vida tomou rumos completamente novos.

Agradeço ao meu marido pelo encorajamento, paciência e companheirismo. No seu mais lindo sorriso e no seu mais sincero olhar eu sempre encontrei forças para encarar a vida de uma forma diferente e seguir em frente.

Agradeço ao professor Leandro que sempre demonstrou acreditar no meu potencial. Faltam-me palavras para expressar a minha gratidão pela sua paciência, confiança e incentivo.

Agradeço à Robert Bosch Ltda. e aos meus colegas de trabalho que sempre entenderam as minhas ausências para a conclusão deste estudo.

Agradeço à bolsa do projeto ANEEL – PETROBRAS – UFPR pelo apoio financeiro durante o desenvolvimento deste projeto.

À todos aqueles que pensaram positivamente pelo êxito desta dissertação.

“O primeiro dever da inteligência é
desconfiar dela mesma”

(Albert Einstein)

RESUMO

Os transformadores de potência são considerados componentes fundamentais em um sistema de fornecimento de energia elétrica. Além de ser um componente oneroso, precisa estar em perfeitas condições de funcionamento para que não interfira no sistema de transmissão de energia. Por ser extremamente importante no sistema elétrico, a ocorrência de falhas pode ter sérias consequências; sobretudo aquelas falhas que ocorrem sem qualquer aviso prévio, que por suspender abruptamente o fornecimento de energia, acabam impactando diretamente na economia. Por isso, é essencial o monitoramento das condições operativas dos transformadores. Deve-se garantir que o fornecimento de energia seja feito de modo contínuo. Neste caso, existem diversas metodologias convencionais capazes de avaliar o estado operativo de um transformador. Basicamente, estas metodologias baseiam-se na análise de gases dissolvidos no óleo isolante do transformador de potência. Através do acompanhamento do aumento da taxa de concentração dos gases é possível identificar condições anormais do óleo dos transformadores. No entanto, estas metodologias são caracterizadas por imprecisões e incertezas. Por isso, para evitar as inconsistências de diagnóstico, utiliza-se métodos baseados em inteligência computacional em conjunto com alguns métodos convencionais. Neste caso, pretende-se implementar algoritmos de classificação de dados para o diagnóstico de falhas incipientes em transformadores de potência. Três técnicas foram avaliadas: classificador Naïve Bayes com seleção de característica sequencial, um sistema LS-SVM (*least squares support vector machines*) e uma rede neural probabilística. Os classificadores Bayesianos são considerados classificadores estatísticos que podem definir se um padrão de teste pertence a uma determinada classe ou não. O classificador Naïve Bayes baseia-se na “independência condicional”, onde assume que o efeito do valor de um atributo em uma dada classe é independente dos valores dos outros atributos, proporcionando desta forma, simplicidade no seu cálculo. O algoritmo SVM baseia-se em conceitos de modelos lineares e aprendizagem baseada em instâncias. A LS-SVM proposta por Suykens é uma modificação da SVM, que diminui a complexidade matemática e o tempo computacional ao utilizar um sistema de equações lineares e a função de custo baseada em mínimos quadrados. As redes neurais artificiais baseiam-se na minimização do risco empírico, possibilitando o mapeamento de entrada-saída e aprendizagem de conjuntos linearmente inseparáveis. A rede neural probabilística proposta por Specht é um algoritmo baseado na rede neural de base radial e função de distribuição de probabilidade. Dentre as metodologias abordadas, o classificador Naïve Bayes foi o que obteve mais acertos e a rede neural probabilística foi a que teve o menor tempo médio de execução (aprendizado mais classificação).

Palavras-chave: Diagnóstico e previsão de falhas incipientes em transformadores de potência; Reconhecimento de padrões; Classificação de dados.

ABSTRACT

Power transformers are considered key components in the electrical power systems. Beyond of being a costly component, it must be in perfect working conditions to not crash the transmission system. Being considered extremely important in the electrical system, failures occurrences can cause serious consequences; especially those failures that occur without warning, which can suddenly interrupt the power supply, bringing high impact in the economy. Therefore, it is essential the monitoring of the transformer operational conditions. The continuous power supply must be ensured. In this case, there are several conventional methodologies able to evaluate the transformer operational status. Basically, these methodologies are based in the dissolved gas in oil-immersed transformers analysis. By monitoring the increase of gas concentration rate it is possible to identify unusual conditions in the transformer oil. However, these methodologies are characterized by inaccuracies and uncertainties. Therefore, in order to avoid diagnosis inconsistencies, it is possible to combine methodologies based on computational intelligence with conventional methodologies. In this case, it is intended to implement classification algorithms for power transformer incipient faults diagnostics. Three techniques were studied: Naïve Bayes classification of microarray data, LS-SVM (least squares support vector machines) and probabilistic neural networks. Bayesian classifiers are considered statistical classifiers that can define whether a test pattern belongs to a given class or not. Naïve Bayes classifier is based on the “conditional independence”, which assumes that an attribute value effect in a given class is independent of others attribute values, providing in this way, simplicity in calculation. The SVM algorithm is based on linear models and instance-based learning. The LS-SVM proposed by Suykens is a SVM modification, which reduces the mathematical complexity and computational time when using a system of linear equations and least squares cost function. Artificial neural networks are based on the empirical risk minimization, allowing the input-output mapping and linearly inseparable sets learning. The probabilistic neural network proposed by Specht is an algorithm based on radial basis neural networks and probability distribution function. Among the methodologies discussed, the Naïve Bayes classifier had the best result and probabilistic neural network had the lowest average execution time (learning and classification).

Key-words: Power Transformer Incipient Fault Diagnosis; Clustering; Data Classification.

LISTA DE ILUSTRAÇÕES

Figura 1 – Esquema de distribuição de energia elétrica.....	2
Figura 2 – Transformador de potência de grande porte	2
Figura 3 – Esquema básico de um transformador.....	6
Figura 4 – Representação gráfica do método de Duval	18
Figura 5 – Classificação de padrão	41
Figura 6 – Classe de hiperplanos com um hiperplano ótimo.....	50
Figura 7 – Identificação da margem ρ e dos vetores suporte sobre a linha pontilhada	52
Figura 8 – Representação do mapeamento realizado no espaço de entrada para o espaço de características n -dimensional	54
Figura 9 – Representação de uma função complexa com presença de mínimos locais e de uma função convexa com um mínimo global	57
Figura 10 – Arquitetura básica de rede neural probabilística	61

LISTA DE QUADROS

Quadro 1 – Tipos de falhas <i>versus</i> proporção relativa dos gases principais.....	16
Quadro 2 – Interpretação dos gases dissolvidos no óleo.....	19
Quadro 3 – Resumo comparativo dos artigos da seção “2.5.2 Artigos Científicos em Periódicos e Conferências/Congressos”	30
Quadro 4 – Alguns campos de aplicação de classificação de padrões.....	40

LISTA DE TABELAS

Tabela 1 – Critério de identificação da falha de Dörnemburg	12
Tabela 2 – Concentração dos gases para validação do método de Dörnemburg	13
Tabela 3 – Concentração dos gases para identificação de condição de normalidade para o método Dörnemburg, segundo IEEE	13
Tabela 4 – Definição dos códigos do método de Rogers	14
Tabela 5 – Diagnóstico do método de Rogers em função do código	15
Tabela 6 – Funções núcleo para mapeamento dos dados do espaço de entrada para o espaço de características	55
Tabela 7 – Desempenho dos classificadores	66
Tabela 8 – Tempo médio de execução (aprendizado + classificação)	66

LISTA DE ABREVIATURAS E SIGLAS

ABNT	Associação Brasileira de Normas Técnicas
ABNT NBR	Norma Brasileira aprovada pela ABNT
AE	<i>Acoustic emission</i> – emissão acústica
ALM	<i>Adaptive learning rate and momentum</i> – taxa de aprendizagem adaptável e <i>momentum</i>
ART	<i>Adaptive resonance theory</i> – teoria da ressonância adaptativa
ARTMAP	<i>Predictive ART</i> – Rede ART que utiliza aprendizado supervisionado incremental
BP	<i>Backpropagation</i>
C ₂ H ₂	Acetileno
C ₂ H ₄	Etileno
C ₂ H ₆	Etano
CEEE	Companhia Estadual de Energia Elétrica (do Rio Grande do Sul)
CEI	<i>Commission Electrotechnique Internationale</i> – Comissão Eletrotécnica Internacional
CI	Circuito Integrado
CIGRE	<i>Conseil international des grands réseaux électriques</i> – Conselho Internacional de Grandes Sistemas Elétricos
CH ₄	Metano
CMAC	<i>Cerebellar model articulation controller</i> – modelo funcional do cerebelo
CO	Monóxido de carbono
CO ₂	Dióxido de carbono
COELCE	Companhia Energética do Ceará
CW	<i>Circulating water</i> – sistema de circulação de água
DGA	<i>Dissolved gas analysis</i> – análise de gases dissolvidos no óleo
FAM	<i>Fuzzy ARTMAP</i>
FDD	<i>Fault detection and diagnosis</i> – detecção e diagnóstico de falhas
FWNN	<i>Fuzzy wavelet neural network</i> – rede neuro-fuzzy-wavelet
GCA	<i>Grey clustering analysis</i> – análise de clusterização cinza
GM	<i>Grey model</i> – modelo cinza

H ₂	Hidrogênio
IEC	<i>International Electrotechnical Commission</i> – Comissão Eletrotécnica Internacional
IEC TC	<i>IEC Technical Committees</i> – Comitê Técnico da IEC
IEEE	<i>Institute of Electrical and Electronics Engineers</i> – Instituto de Engenheiros Eletricistas e Eletrônicos
KEPCO	<i>Korea Electric Power Corporation</i>
LS	<i>Least squares</i> – mínimos quadrados
LS-SVM	<i>Least squares support vector machines</i> – máquinas de vetores de suporte por mínimos quadrados
MGM	<i>Modified grey model</i> – modelo “cinza” modificado
MLP	<i>Multilayer perceptron</i> – perceptrons de múltiplas camadas
N ₂	Nitrogênio
O ₂	Oxigênio
OLTC	<i>On load tap charger</i> – comutador de derivação em carga
PAD	<i>Pulsed amperometric detection</i> – detecção amperométrica pulsada
PD	<i>Partial discharge</i> – descargas parciais
PNN	<i>Probabilistic neural networks</i> – rede neural probabilística
ppm	Partes por milhão
PPO	<i>Polyphenol oxidase</i> – polifenoloxidase
PSO	<i>Particle swarm optimization</i> – otimização de enxame de partículas
PUCRS	Pontifícia Universidade Católica do Rio Grande do Sul
RAS	<i>Recycled activated sludge</i> – lodo ativado reciclado
RBF	<i>Radial basis function</i> – função de base radial gaussiana
RecBFN	<i>Rectangular basis function network</i> – função de base retangular
RNA	Redes neurais artificiais
RS	<i>Rough set</i> – conjuntos aproximados
RTR	<i>Refined three ratio method</i> – método refinado das três razões
RVM	<i>Recovery voltage measurements</i> – tensão de retorno
SE	Sistema especialista
SE-FNTDS	<i>Symbiotic evolution-based fuzzy-neural transformer diagnostic system</i> – diagnóstico de transformadores através de um algoritmo neuro-fuzzy baseado em evolução simbiótica

SEP	Sistema elétrico de potência
SRM	<i>Structural risk minimization</i> – minimização do risco estrutural
SVM	<i>Support vector machines</i> – máquinas de vetores de suporte
Tainpower	<i>Taiwan Power Company</i>
TCG	<i>Total combustible gas</i> – total de gases combustíveis
TPC	<i>Taiwan Power Company</i>
TS	Takagi-Sugeno
UFC	Universidade Federal do Ceará
UFPA	Universidade Federal do Pará
UFPR	Universidade Federal do Paraná
UFSC	Universidade Federal de Santa Catarina
UNIFEI	Universidade Federal de Itajubá
UTE	Usina termelétrica
VC	Vapnik-Chervonenkis

SUMÁRIO

1 INTRODUÇÃO.....	1
1.1 OBJETIVOS.....	4
1.1.1 Objetivo Geral	4
1.1.2 Objetivos Específicos.....	4
1.1.3 Estrutura do Trabalho	5
2 REVISÃO DA LITERATURA.....	6
2.1 TRANSFORMADOR.....	6
2.2 MATERIAIS E LÍQUIDOS ISOLANTES	7
2.2.1 Papel Isolante.....	7
2.2.2 Óleo Mineral Isolante.....	7
2.3 FALHAS INCIPIENTES EM TRANSFORMADORES DE POTÊNCIA	9
2.4 ANÁLISE DE GASES DISSOLVIDOS NO ÓLEO (<i>DISSOLVED GAS ANALYSIS</i> – <i>DGA</i>) – MÉTODOS CONVENCIONAIS	10
2.4.1 Critério de Dörnemburg	12
2.4.2 Critério de Rogers.....	14
2.4.3 Método do Gás Chave (<i>Key Gas Method</i>).....	15
2.4.4 Triângulo de Duval (<i>Duval's Triangle</i>).....	17
2.4.5 International Standard IEC/CEI 60599: 1999 + A1:2007	18
2.5 INTELIGÊNCIA ARTIFICIAL APLICADO NO DIAGNÓSTICO DE FALHAS INCIPIENTES.....	20
2.5.1 Dissertações e Teses	20
2.5.2 Artigos Científicos em Periódicos e Conferências/Congressos	22
3 CLASSIFICAÇÃO E RECONHECIMENTO DE PADRÕES	37
3.1 CONCEITOS PRELIMINARES	37
3.2 RECONHECIMENTO DE PADRÕES	39
3.3 ETAPAS DA CLASSIFICAÇÃO DE DADOS.....	42
3.4 ESTIMAÇÃO DA QUALIDADE DE UM CLASSIFICADOR.....	42
3.5 APRENDIZAGEM DE MÁQUINA.....	43
3.6 TÉCNICAS UTILIZADAS NESTE TRABALHO	44
4 TÉCNICAS DE CLASSIFICAÇÃO	46
4.1 CLASSIFICADOR DE NAÏVE BAYES.....	46
4.1.1 Teorema de Bayes	46

4.1.2 Algoritmo Naïve Bayes.....	47
4.2 SUPPORT VECTOR MACHINES (SVM).....	49
4.2.1 Least Squares Support Vector Machines (LS-SVM)	53
4.3 REDE NEURAL PROBABILÍSTICA	59
4.3.1 Estratégia de Bayes na classificação de padrões	59
4.3.2 Estrutura da Rede Neural Probabilística	61
5 APLICAÇÃO DAS METODOLOGIAS	63
5.1 DADOS UTILIZADOS	63
5.2 METODOLOGIA	64
5.3 RESULTADOS.....	65
6 CONCLUSÃO	67
REFERÊNCIAS.....	68
APÊNDICE A – TABELAS ADAPTADAS DE DUVAL E DEPABLO, 2001	76
APÊNDICE B – TABELAS ADAPTADAS DE DUVAL E DEPABLO, 2001	84

1 INTRODUÇÃO

A sociedade, atualmente, depende cada vez mais da energia elétrica, tendo esta, portanto, um papel vital na economia. A interrupção do fornecimento da energia elétrica pode causar uma série de efeitos danosos aos seus usuários, como por exemplo: perda de produção, danos aos equipamentos/instalações, interrupção de sistemas automatizados, apagões que impactam na rotina do dia-a-dia, entre outros. Em muitos desses casos, as concessionárias de energia podem ser obrigadas a pagar indenizações aos seus consumidores finais dependendo da extensão do dano causado pela interrupção. Desta maneira, essas empresas procuram garantir o fornecimento de energia de forma contínua.

Em linhas gerais, um Sistema Elétrico de Potência (SEP) é formado por várias estações geradoras conectadas através de linhas de transmissão a grandes centros de carga. Através do sistema de distribuição (formado por linhas de distribuição e transformadores) a potência é entregue ao consumidor final (COURY, 2011).

Conforme ilustrado na Figura 1, a energia elétrica passa por sucessivas transformações de tensão, desde a sua geração até ser entregue ao seu destino. Logo após a geração de energia elétrica, a mesma é conduzida por cabos até uma subestação elevadora, onde transformadores elevam o valor da tensão elétrica. Com este nível de tensão, a eletricidade pode percorrer longas distâncias pelas linhas de transmissão, até chegar próximo aos centros consumidores. Por fim, as subestações abaixadoras reduzem novamente o valor da tensão para os padrões de consumo do usuário local (residência, indústrias, entre outros) (COURY, 2011).




Figura 1 – Esquema de distribuição de energia elétrica
Fonte: PAIXÃO, 2006

“Transformadores são um dos principais e mais caros componentes de um sistema de potência e desempenham papel fundamental nas etapas que antecedem a entrega de energia elétrica aos consumidores finais” (CASTILLO, 2003). A Figura 2 mostra o esquema de um transformador de potência de grande porte.



Figura 2 – Transformador de potência de grande porte
Fonte: SOUZA, 2008

O transformador de potência, além de ser oneroso, precisa estar em perfeitas condições de funcionamento para que não interfira no sistema de transmissão de energia.

Considerando que a receita de empresas fornecedoras de energia elétrica depende única e exclusivamente da disponibilidade de seus equipamentos e instalações, é essencial que o fornecimento de energia seja feito sem interrupções a fim de evitar prejuízos e diminuir a receita devido à indisponibilidade dos equipamentos.

Somando-se a isso, a demanda por energia é cada vez maior, originando dessa maneira, numa sobrecarga ao sistema de potência. Esta sobrecarga pode comprometer ainda mais um sistema que atualmente é composto por um número considerável de transformadores de potência em diferentes estágios de envelhecimento.

“Normalmente os transformadores possuem projeto de vida de 20 a 35 anos. Na prática, a vida útil dos transformadores pode ser estendida, desde que submetidos a condições e a programas de manutenções apropriados” (MORAIS, 2010).

Por muitos anos, através de programas de manutenção preventiva, realizavam-se inspeções e testes nos transformadores de potência em intervalos de tempo regulares (normalmente sugeridos pelo fabricante ou determinados através da experiência da própria concessionária). Esta prática, apesar de ter evitado muitas falhas, pode ter gerado muitas vezes a manutenção desnecessária do equipamento, infundindo desperdício de recursos humanos e financeiros e causando desligamentos dispensáveis do equipamento. Assim, este método vem sendo substituído pela manutenção somente quando as condições do equipamento a requerem (SOUZA, 2008; MORAIS, 2010).

De tal modo, torna-se necessário o monitoramento e a utilização de ferramentas de diagnóstico para avaliar o “estado operativo dos sistemas e equipamentos elétricos, com o intuito de aumentar a sua confiabilidade” e reduzir o número de paradas programadas e/ou eventuais (MORAIS, 2004).

1.1 OBJETIVOS

Neste tópico são apresentados: o objetivo geral do trabalho e o desdobramento do objetivo principal em objetivos secundários (também chamados específicos).

1.1.1 Objetivo Geral

Tendo como base dados históricos da análise de características de óleo de transformadores da PETROBRAS e outras fontes da literatura (DUVAL e dePABLO, 2001), esta dissertação tem como objetivo abordar a classificação destes dados para realizar um diagnóstico de falhas incipientes em transformadores de potência.

1.1.2 Objetivos Específicos

Como objetivos específicos, têm-se:

- Estudar e aprofundar o conhecimento relacionado às principais falhas incipientes em um transformador de potência;
- Estudar e aprofundar o conhecimento relacionado aos métodos convencionais de interpretação da análise dos gases dissolvidos e dos métodos padronizados para o diagnóstico de falhas incipientes;
- Estudar alguns algoritmos de classificação e implementá-los em um ambiente computacional (neste caso, adotando o Matlab da Mathworks);
- Analisar os dados de análises cromatográficas e utilizar ferramentas computacionais para realizar a classificação.

1.1.3 Estrutura do Trabalho

Esta dissertação está organizada em 6 capítulos. No **Capítulo 1** foi apresentada uma breve introdução à respeito da importância dos transformadores de potência. No **Capítulo 2** é apresentada a revisão bibliográfica referente ao tema, sendo subdividida em: a) descrição do transformador, b) tipos de isolamento do transformador, c) tipos de falhas incipientes, d) metodologias convencionais de análise de gases e e) técnicas inteligentes que estão sendo utilizadas atualmente e que foram encontradas na literatura. O **Capítulo 3** descreve os conceitos relacionados à aprendizagem de máquina. O **Capítulo 4** aborda as metodologias que foram escolhidas para o estudo. O **Capítulo 5** apresenta os resultados da aplicação das metodologias escolhidas na base de dados da PETROBRAS. Por fim, no **Capítulo 6** é discutida a conclusão deste trabalho.

2 REVISÃO DA LITERATURA

Este capítulo apresenta toda a revisão bibliográfica relacionada ao transformador de potência. Desta forma, este capítulo apresenta uma descrição sobre o transformador, o tipo de material constituinte e o tipo de isolamento. Além disso, detalha-se as falhas que podem ser identificadas nos transformadores, bem como as metodologias tradicionais utilizada para o reconhecimento das falhas incipientes. Por fim, devido à difusão na academia, é apresentada também uma revisão bibliográfica de diversas metodologias inteligentes que já foram aplicadas e que estão relacionadas aos sistemas de transmissão de energia.

2.1 TRANSFORMADOR

Segundo a ABNT NBR 5356:1993, transformador é “um equipamento elétrico estático que, por indução eletromagnética, transforma tensão e corrente alternada entre dois ou mais enrolamentos, sem mudança de frequência”.

O transformador de potência é um “transformador cuja finalidade principal é transformar energia elétrica entre partes de um sistema de potência”.

Ele funciona baseado no princípio da indução mútua.




Figura 3 – Esquema básico de um transformador
Fonte: PAIXÃO, 2006

A Figura 3 mostra de maneira simplificada o funcionamento do transformador. Neste caso, aplica-se uma tensão (V_A) e uma corrente elétrica na bobina A (também denominada de primário). Em seguida, induz-se um campo magnético no núcleo do

transformador que, por consequência, faz surgir na bobina B (também denominada de secundário) uma corrente elétrica e uma tensão V_B . O controle da tensão é dependente no número de espiras em cada bobina (PAIXÃO, 2006).

2.2 MATERIAIS E LÍQUIDOS ISOLANTES

Em subestações de média, alta ou extra alta tensão costuma-se utilizar a celulose impregnada com óleo mineral isolante para o isolamento elétrico (ZIRBES *et al.*, 2005).

A isolação elétrica em equipamentos de alta tensão tem como função primária minimizar o fluxo de corrente entre condutores submetidos a diferenciais de potencial elétrico, suportando o campo elétrico resultante. Deve, ainda, apresentar propriedades mecânicas, térmicas e químicas apropriadas ao cumprimento de sua função (ZIRBES *et al.*, 2005).

2.2.1 Papel Isolante

Para a isolação elétrica pode-se utilizar vários tipos de papel. Os principais tipos de materiais celulósicos empregados no isolamento dos transformadores são (MILASCHI, 1984 *apud* MORAIS, 2004):

- Papel Kraft – feito de fibra de madeira;
- Papel Manilha – feito de fibras de madeira e cânhamo;
- Papelão Kraft – feito de fibra de madeira;
- *Pressboard* – feito de papelão com fibra de algodão.

A constante dielétrica, o fator de dissipação e rigidez dielétrica são as principais propriedades elétricas deste tipo de material isolante (KHALIFA, 1990 *apud* MORAIS, 1994).

2.2.2 Óleo Mineral Isolante

Grandes transformadores possuem uma estrutura complexa composta pela parte ativa (núcleo e bobinas), óleo mineral isolante (na sua grande maioria), tanque

e acessórios. A função do óleo mineral isolante é entrar entre as partes ativas para mantê-las isoladas e refrigeradas (PAIXÃO, 2006).

O óleo mineral isolante é composto quimicamente por: uma mistura de hidrocarbonetos (em sua maioria) e de não hidrocarbonetos em pequena proporção (também chamados de heterocompostos) (MILASCH, 1984 *apud* BARBOSA, 2007).

Em equipamentos elétricos, o óleo mineral possui basicamente a função de meio isolante (evita o aparecimento e garante a extinção de arcos elétricos) e refrigerante (dissipa o calor gerado). As principais propriedades físicas do óleo mineral são: cor, ponto de fulgor, ponto de fluidez, densidade, viscosidade, ponto de anilina, tensão interfacial e solubilidade da água no óleo (MILASCH, 1984 *apud* BARBOSA, 2007).

Além disso, leva-se também em consideração as propriedades elétricas, tais como: rigidez dielétrica e o fator de potência, sendo a rigidez dielétrica o parâmetro mais importante no estudo do desempenho do óleo isolante (MORAIS, 2004).

Segundo MILASCH, 1984 (*apud* BARBOSA, 2007):

Rigidez dielétrica: é a tensão alternada na qual ocorre a descarga disruptiva na camada de óleo situada entre dois eletrodos e em condições perfeitamente determinadas. A rigidez dielétrica do óleo é pouco afetada pela água nele dissolvida. Por outro lado, a água livre em suspensão no óleo diminui acentuadamente sua rigidez dielétrica, sendo que em um óleo deteriorado, a água livre tem maior possibilidade de ficar em suspensão que no óleo novo. Outro fator que contribui para a redução da rigidez dielétrica são as partículas sólidas em suspensão (fibras celulósicas, carvão, poeira, etc.).

Fator de potência: o fator de potência do óleo mineral isolante é igual ao cosseno do ângulo de fase ou o seno do ângulo de perdas do mesmo. Este aumenta de valor na medida em que a deterioração do óleo progride. O fator de potência nos informa uma ideia da quantidade de corrente que flui pelo óleo e que é uma medida de sua contaminação e de sua deterioração.

Algumas destas propriedades físicas, além de servirem como parâmetros de projeto de isolamento, são utilizados também na avaliação e acompanhamento do óleo em serviço, indicando possível contaminação, estimativas da sua deterioração ou determinação de suas condições funcionais (MORAIS, 2004).

Desta maneira, pode-se considerar o óleo mineral isolante como o principal indicador da “saúde” dos transformadores (CASTILLO, 2003).

2.3 FALHAS INCIPIENTES EM TRANSFORMADORES DE POTÊNCIA

Conforme já exposto, o transformador de potência é muito importante no sistema elétrico e a ocorrência de falhas pode ter sérias consequências; sobretudo aquelas falhas que ocorrem sem qualquer aviso prévio, que por suspender abruptamente o fornecimento de energia, acaba impactando diretamente na economia (LIMA, 2005).

Ao longo do tempo, mesmo sob condições normais de operação, a capacidade de isolamento sofre uma redução podendo até falhar (incapacidade de realizar a sua função). “Os processos que atuam no sentido de acelerar a redução de capacidade do isolamento, quando em sua fase bem inicial, são denominadas de falhas incipientes” (ZIRBES *et al.*, 2005).

Pode-se considerar como falhas incipientes aquelas que estão em estágio inicial e promovem a decomposição do material isolante. Os principais gases gerados no interior do transformador e que são geralmente objetos de estudos para caracterizar as falhas incipientes são (LIMA, 2005):

- Metano – CH_4 ;
- Etano – C_2H_6 ;
- Etileno – C_2H_4 ;
- Acetileno – C_2H_2 ;
- Hidrogênio – H_2 ;
- Gás carbônico – CO_2 ;
- Monóxido de carbono – CO .

As falhas incipientes podem ser classificadas em (BARBOSA, 2007):

- Falhas térmicas – relacionadas ao sobreaquecimento de componentes do equipamento;
- Falhas elétricas – relacionados à descargas internas no equipamento.

2.4 ANÁLISE DE GASES DISSOLVIDOS NO ÓLEO (*DISSOLVED GAS ANALYSIS – DGA*) – MÉTODOS CONVENCIONAIS

Os departamentos de manutenção das concessionárias de energia realizam o monitoramento e diagnóstico em transformadores de potência com o objetivo de prevenir ou antecipar desligamentos indesejados (SOUZA, 2008).

Algumas das falhas que podem acontecer em um transformador podem ser causadas pelo estado do seu isolamento elétrico. Por isso mesmo, esforços vêm sendo empregados no sentido de identificar falhas nos transformadores de forma antecipada (ARAGÃO, 2009).

Dentre os métodos utilizados na identificação de falhas incipientes em transformadores de potência, pode-se citar os seguintes:

- Avaliação físico-química: que determina o estado do óleo;
- Análise cromatográfica: que verifica possíveis falhas no equipamento.

Estes dois tipos de análises dão uma clara visão da qualidade do isolamento. A análise dos gases dissolvidos no óleo isolante (DGA) é um grande aliado no diagnóstico de falhas incipientes em transformadores de potência (CASTILLO, 2003; BARBOSA, 2007).

A DGA nada mais é do que a análise e o cálculo da concentração dos gases dissolvidos no óleo em partes por milhão (ppm).

Com a DGA é possível avaliar a condição de operação do isolamento, sendo possível identificar eventuais processos de falha que possam estar ocorrendo. Além disso, é possível identificar as falhas que acontecem a partir de sobreaquecimento do isolamento ou a partir de descargas elétricas no seu interior (MORAIS, 2004).

Óleos isolantes sofrem deterioração, seja devido a esforços elétricos, térmicos ou mesmo devido ao envelhecimento natural, produzindo assim gases combustíveis no interior do transformador, o que pode tornar-se bastante perigoso ou mesmo fatal. Portanto, a detecção de certos gases gerados em um transformador imerso em óleo é, frequentemente, a primeira indicação de um mau funcionamento que pode, se não corrigido, levar o transformador a uma falha (LIMA, 2005).

Dentre os principais fenômenos relacionados aos gases gerados no interior dos transformadores de potência, pode-se citar: arcos, corona, descargas elétricas de baixa energia, sobreaquecimentos no óleo e na celulose, entre outros. De

maneira geral, esses fenômenos ocorrem ao mesmo tempo e levam à decomposição dos materiais isolantes resultando na formação de vários gases combustíveis e não combustíveis (LIMA, 2005).

Para a medição dos gases gerados utiliza-se um equipamento chamado cromatógrafo que mede a concentração dos gases dissolvidos no óleo isolante e expressa a medida em partes por milhão (ppm) volume/volume de óleo, medidas à temperatura de 23 °C (CASTILLO, 2003).

Através do acompanhamento da concentração dos gases (em ppm) e da sua taxa de geração (em ppm/dia) é possível identificar condições anormais do óleo dos transformadores (LIMA, 2005).

No entanto, devido à diversidade de transformadores existentes no mercado (diferentes fabricantes, diferentes tamanhos e sujeitos à diferentes tipos de carregamento), inúmeras fontes de literatura relatam que o método DGA é muito dependente da decisão final de um especialista, sendo necessário portanto, na maioria dos casos, que cada transformador seja avaliado de forma particular (LIMA, 2005).

Cada empresa adota um ou mais métodos para a interpretação dos resultados obtidos na análise cromatográfica para emitir o diagnóstico de falhas incipientes (CASTILLO, 2003).

Do ponto de vista operacional, os procedimentos de detecção e análise dos gases devem seguir o seguinte procedimento (IEEE C57.194, 1991 *apud* MORAIS, 2004):

- a) Detecção: detectar a geração de algum gás que excede as quantidades consideradas “normais” e utilizar critérios apropriados que possam identificar as possíveis anormalidades que por ventura estejam ocorrendo;
- b) Avaliação: avaliar o impacto desta anormalidade no funcionamento do transformador, usando um conjunto de critérios ou recomendações;
- c) Ação: recomendar ação, que vai desde a confirmação da existência da falha com análise suplementar, redução da carga, ou até mesmo a retirada da unidade de serviço.

Todos os fenômenos relacionados à formação de gases em transformadores e sua correlação com as falhas incipientes são caracterizados por imprecisões, incertezas nas medidas e não linearidades não modeladas. Portanto, métodos convencionais de interpretação da análise dos gases combinados com métodos baseados em inteligência computacional, em especial os sistemas nebulosos e neurais, podem ser empregados de forma eficiente para o diagnóstico automático de falhas incipientes (LIMA, 2005).

Na literatura é possível encontrar diversas técnicas para interpretação da análise cromatográfica, dentre as quais pode-se citar: método de gás chave, método das razões de Dörnenburg e método das razões de Rogers, que serão descritos a seguir (IEEE C57.104, 1991 *apud* MORAIS, 2004; LIMA, 2005 e CASTILLO, 2003; ABNT NBR 7274:1983 *apud* OSTERMANN, 2006).

2.4.1 Critério de Dörnenburg

O critério de Dörnenburg está baseado nas relações CH_4/H_2 , $\text{C}_2\text{H}_2/\text{C}_2\text{H}_4$, $\text{C}_2\text{H}_6/\text{C}_2\text{H}_2$ e $\text{C}_2\text{H}_2/\text{CH}_4$ e, com este critério, é possível detectar três tipos de falhas: superaquecimento local (pontos quentes), descargas parciais e outros tipos de descargas (falhas elétricas) (IEEE C57.104, 1991 *apud* MORAIS, 2004; LIMA, 2005 e CASTILLO, 2003).

Tabela 1 – Critério de identificação da falha de Dörnenburg

TIPO DE FALHA	RELAÇÕES ENTRE CONCENTRAÇÕES DE GASES			
	Relações principais		Relações auxiliares	
	CH_4/H_2	$\text{C}_2\text{H}_2/\text{C}_2\text{H}_4$	$\text{C}_2\text{H}_6/\text{C}_2\text{H}_2$	$\text{C}_2\text{H}_2/\text{CH}_4$
Ponto quente	>1	<0,75	>0,4	<0,3
Descarga parcial	<0,1	----	>0,4	<0,3
Outros tipos de descarga	<1 e >0,1	>0,75	<0,4	>0,3

Fonte: MORAIS, 2004 e LIMA, 2005

Com base neste critério, é possível determinar se a relação de gases dissolvidos está dentro dos valores estabelecidos. A suspeita da existência de uma falha incipiente acontece se uma ou mais razões excederem os limites pré-estabelecidos (CASTILLO, 2003).

Muitas vezes, a implementação deste método resulta em casos sem diagnóstico, pois as quatro relações de gases propostas não abrangem todas as combinações de gases dissolvidos possíveis (CASTILLO, 2003).

A Tabela 2 delinea os dados de concentração de gases individualmente para a validação de aplicação deste método. Para utilizar a Tabela 1, no mínimo um dos gases que compõe as relações principais deve ter uma concentração superior ao dobro do valor da Tabela 2 e, além disso, para relações auxiliares, pelo menos um dos gases deve ter uma concentração superior ao constante na mesma tabela (MORAIS, 2004).

Tabela 2 – Concentração dos gases para validação do método de Dörnemburg

Tipos de gás	H₂	CH₄	C₂H₆	C₂H₄	C₂H₂
Concentração ppm (v/v)	200	50	15	60	15

Fonte: MORAIS, 2004

A IEEE C57.104-1991 apresenta também a Tabela 3 para identificar condições de normalidade do transformador. Ou seja, se nenhuma das concentrações de gases que compõem as relações principais alcançar uma concentração superior ao dobro do valor da Tabela 3, e, além disso, se para as relações auxiliares nenhuma destas concentrações for maior do que algum dos valores constante na mesma tabela, o transformador está dentro das condições de normalidade da operação (MORAIS, 2004).

Tabela 3 – Concentração dos gases para identificação de condição de normalidade para o método Dörnemburg, segundo IEEE

Tipos de gás	H₂	CH₄	C₂H₆	C₂H₄	C₂H₂
Concentração ppm (v/v)	100	120	65	50	35

Fonte: MORAIS, 2004

2.4.2 Critério de Rogers

O critério de Rogers utiliza as seguintes relações: CH_4/H_2 , $\text{C}_2\text{H}_4/\text{C}_2\text{H}_6$, $\text{C}_2\text{H}_2/\text{C}_2\text{H}_4$ e $\text{C}_2\text{H}_6/\text{CH}_4$. O diagnóstico de falhas é emitido por meio de um esquema de codificações simples baseado em faixas de relação (CASTILLO, 2003).

Este método apresenta-se por meio de duas tabelas. Na Tabela 4 estabelece-se um código em função da faixa de valores obtidos para as relações gasosas. Já na Tabela 5, baseando-se na combinação dos códigos, determina-se o diagnóstico final da amostra (IEEE C57.104, 1991 *apud* MORAIS, 2004).

Tabela 4 – Definição dos códigos do método de Rogers

RELAÇÃO DE GASES	FAIXA DE VARIAÇÃO	CÓDIGO
CH_4/H_2	$\leq 0,1$	5
	$> 0,1 ; < 1$	0
	$> 1 ; < 3$	1
	≥ 3	2
$\text{C}_2\text{H}_6/\text{CH}_4$	< 1	0
	≥ 1	1
$\text{C}_2\text{H}_4/\text{C}_2\text{H}_6$	< 1	0
	$> 1 ; < 3$	1
	≥ 3	2
$\text{C}_2\text{H}_2/\text{C}_2\text{H}_4$	$< 0,5$	0
	$\geq 0,5 ; < 3$	1
	≥ 3	2

Fonte: MORAIS, 2004

Tabela 5 – Diagnóstico do método de Rogers em função do código

CH ₄ /H ₂	C ₂ H ₆ /CH ₄	C ₂ H ₄ / C ₂ H ₆	C ₂ H ₂ / C ₂ H ₄	Diagnóstico
0	0	0	0	Deterioração normal
5	0	0	0	Descargas parciais
1 / 2	0	0	0	Sobreaquecimento – abaixo de 150 °C
1 / 2	1	0	0	Sobreaquecimento de 150 °C – 200 °C
0	1	0	0	Sobreaquecimento de 200 °C – 300 °C
0	0	1	0	Sobreaquecimento de condutores
1	0	1	0	Correntes de circulação nos enrolamentos
1	0	2	0	Correntes de circulação no núcleo e tanque, sobreaquecimento em conexões
0	0	0	1	Descarga contínua
0	0	1 / 2	1 / 2	Arco com alta energia
0	0	2	2	Descarga contínua de baixa potência
5	0	0	1 / 2	Descarga parcial envolvendo o papel

Fonte: MORAIS, 2004

2.4.3 Método do Gás Chave (*Key Gas Method*)

O método do gás chave baseia-se no valor percentual dos gases para diagnosticar falhas incipientes em transformadores. Este método baseia-se nas quantidades relativas de cada gás gerado no transformador ao ser submetido a esforços térmicos e/ou elétricos (BARBOSA, 2007).

Segue a seguir o quadro que indica as proporções relativas dos gases principais para cinco tipos gerais de falhas.

Quadro 1 – Tipos de falhas *versus* proporção relativa dos gases principais

(continua)

Descrição	Gráfico														
Arco no óleo Grandes quantidades de H_2 e C_2H_2 são produzidas, com pequenas quantidades de CH_4 e C_2H_4. CO_2 e CO também podem ser formados caso a falha envolva celulose. O óleo poderá ser carbonizado. Gás chave: Acetileno (C_2H_2)	Arco no óleo <table border="1"> <thead> <tr> <th>Gás</th> <th>% Combustíveis</th> </tr> </thead> <tbody> <tr> <td>CO</td> <td>0,01</td> </tr> <tr> <td>H_2</td> <td>60</td> </tr> <tr> <td>CH_4</td> <td>5</td> </tr> <tr> <td>C_2H_6</td> <td>1,6</td> </tr> <tr> <td>C_2H_4</td> <td>3,3</td> </tr> <tr> <td>C_2H_2</td> <td>30</td> </tr> </tbody> </table>	Gás	% Combustíveis	CO	0,01	H_2	60	CH_4	5	C_2H_6	1,6	C_2H_4	3,3	C_2H_2	30
Gás	% Combustíveis														
CO	0,01														
H_2	60														
CH_4	5														
C_2H_6	1,6														
C_2H_4	3,3														
C_2H_2	30														
Descargas parciais Descargas elétricas de baixa energia produzem H_2 e CH_4, com pequenas quantidades de C_2H_6 e C_2H_4. Quantidades comparáveis de CO_2 e CO podem resultar de descargas em celulose. Gás chave: Hidrogênio (H_2)	Descargas parciais (corona) no óleo <table border="1"> <thead> <tr> <th>Gás</th> <th>% Combustíveis</th> </tr> </thead> <tbody> <tr> <td>CO</td> <td>0,2</td> </tr> <tr> <td>H_2</td> <td>86</td> </tr> <tr> <td>CH_4</td> <td>13</td> </tr> <tr> <td>C_2H_6</td> <td>0,5</td> </tr> <tr> <td>C_2H_4</td> <td>0,2</td> </tr> <tr> <td>C_2H_2</td> <td>0,1</td> </tr> </tbody> </table>	Gás	% Combustíveis	CO	0,2	H_2	86	CH_4	13	C_2H_6	0,5	C_2H_4	0,2	C_2H_2	0,1
Gás	% Combustíveis														
CO	0,2														
H_2	86														
CH_4	13														
C_2H_6	0,5														
C_2H_4	0,2														
C_2H_2	0,1														
Óleo superaquecido Os produtos da decomposição incluem C_2H_4 e CH_4, juntamente com quantidades menores de H_2 e C_2H_6. Traços de C_2H_2 podem ser formados se a falha é severa ou se envolve contatos elétricos. Gás chave: Etileno (C_2H_4)	Óleo superaquecido <table border="1"> <thead> <tr> <th>Gás</th> <th>% Combustíveis</th> </tr> </thead> <tbody> <tr> <td>CO</td> <td>0,01</td> </tr> <tr> <td>H_2</td> <td>2</td> </tr> <tr> <td>CH_4</td> <td>16</td> </tr> <tr> <td>C_2H_6</td> <td>17</td> </tr> <tr> <td>C_2H_4</td> <td>63</td> </tr> <tr> <td>C_2H_2</td> <td>2</td> </tr> </tbody> </table>	Gás	% Combustíveis	CO	0,01	H_2	2	CH_4	16	C_2H_6	17	C_2H_4	63	C_2H_2	2
Gás	% Combustíveis														
CO	0,01														
H_2	2														
CH_4	16														
C_2H_6	17														
C_2H_4	63														
C_2H_2	2														

Quadro 1 – Tipos de falhas *versus* proporção relativa dos gases principais

(conclusão)

Descrição	Gráfico														
Celulose superaquecida Grandes quantidades de CO₂ e CO são liberadas da celulose superaquecida. Hidrocarbonetos gasosos, como CH₄ e C₂H₄, serão formados se a falha envolver uma estrutura impregnada em óleo. Gás chave: Monóxido de Carbono (CO)	Celulose superaquecida <table border="1"> <thead> <tr> <th>Gás</th> <th>% Combustíveis</th> </tr> </thead> <tbody> <tr> <td>CO</td> <td>92</td> </tr> <tr> <td>H₂</td> <td>6,7</td> </tr> <tr> <td>CH₄</td> <td>1,2</td> </tr> <tr> <td>C₂H₆</td> <td>0,01</td> </tr> <tr> <td>C₂H₄</td> <td>0,01</td> </tr> <tr> <td>C₂H₂</td> <td>0,01</td> </tr> </tbody> </table>	Gás	% Combustíveis	CO	92	H ₂	6,7	CH ₄	1,2	C ₂ H ₆	0,01	C ₂ H ₄	0,01	C ₂ H ₂	0,01
Gás	% Combustíveis														
CO	92														
H ₂	6,7														
CH ₄	1,2														
C ₂ H ₆	0,01														
C ₂ H ₄	0,01														
C ₂ H ₂	0,01														
Eletrólise A decomposição de Hidrogênio (H₂) e da água ou a decomposição da água associada com a ferrugem resulta na formação de grandes quantidades de H₂ com pequenas quantidades de outros gases combustíveis. Gás chave: Hidrogênio (H₂)	Eletrólise <table border="1"> <thead> <tr> <th>Gás</th> <th>% Combustíveis</th> </tr> </thead> <tbody> <tr> <td>CO</td> <td>0,01</td> </tr> <tr> <td>H₂</td> <td>99,9</td> </tr> <tr> <td>CH₄</td> <td>0,01</td> </tr> <tr> <td>C₂H₆</td> <td>0,01</td> </tr> <tr> <td>C₂H₄</td> <td>0,01</td> </tr> <tr> <td>C₂H₂</td> <td>0,01</td> </tr> </tbody> </table>	Gás	% Combustíveis	CO	0,01	H ₂	99,9	CH ₄	0,01	C ₂ H ₆	0,01	C ₂ H ₄	0,01	C ₂ H ₂	0,01
Gás	% Combustíveis														
CO	0,01														
H ₂	99,9														
CH ₄	0,01														
C ₂ H ₆	0,01														
C ₂ H ₄	0,01														
C ₂ H ₂	0,01														

Fonte: ABNT NBR 7274:1983 *apud* OSTERMANN, 2006

2.4.4 Triângulo de Duval (*Duval's Triangle*)

O método de Duval baseia-se na Figura 4. Além disso, utiliza as seguintes relações para a identificação de um ponto no sistema de coordenadas triangulares da Figura 4:

$$\%C_2H_2 = \frac{100x}{x + y + z} \quad \%C_2H_4 = \frac{100y}{x + y + z} \quad \%CH_4 = \frac{100z}{x + y + z}$$

onde

$x = [C_2H_2]$ em ppm;

$y = [C_2H_4]$ em ppm;

$z = [CH_4]$ em ppm.




Figura 4 – Representação gráfica do método de Duval
Fonte: LIMA, 2005

2.4.5 International Standard IEC/CEI 60599: 1999 + A1:2007

A IEC/CEI 60599 é a norma internacional utilizada por diversas empresas e contém um guia para a interpretação da análise de gases dissolvidos no óleo mineral de equipamentos elétricos em serviço.

Esta publicação foi feita por um grupo de especialistas como um resultado da revisão do banco de dados IEC TC 10 e da publicação anterior IEC 599 de 1978 (DUVAL e dePABLO, 2001).

A IEC 60599 sugere um método de diagnóstico semelhante aos anteriormente apresentados, contendo as mesmas relações básicas de concentrações (C_2H_2/C_2H_4 , CH_4/H_2 , C_2H_4/C_2H_6) com uma alteração dos limites e principalmente dos casos característicos de falha.

A classificação de falhas é feita da seguinte forma:

- PD: Descargas parciais;
- D1: Descargas de baixa energia;
- D2: Descargas de alta energia;
- T1: Falha térmica, $t < 300\text{ °C}$;
- T2: Falha térmica, $300\text{ °C} < t < 700\text{ °C}$;
- T3: Falha térmica, $t > 700\text{ °C}$.

Segundo a IEC 60599 a formação de CO_2 e CO no isolamento de papel impregnado com óleo mineral aumentam rapidamente com a temperatura. Quando

relação CO_2/CO é menor do que 3, normalmente considera-se um indicativo de falha com algum grau de carbonização.

Além disso, a última revisão introduziu duas relações adicionais ($\text{C}_2\text{H}_2/\text{H}_2$ e O_2/N_2) para casos de diagnóstico específico:

- $\text{C}_2\text{H}_2/\text{H}_2$: detectar possíveis contaminações relacionadas à comutação em carga;
- O_2/N_2 : detectar aquecimento e oxidação anormal do óleo.

O Quadro 2 mostra a interpretação dos gases dissolvidos no óleo.

Quadro 2 – Interpretação dos gases dissolvidos no óleo

Caso	Falha Característica	$\frac{\text{C}_2\text{H}_2}{\text{C}_2\text{H}_4}$	$\frac{\text{CH}_4}{\text{H}_2}$	$\frac{\text{C}_2\text{H}_4}{\text{C}_2\text{H}_6}$
PD	Descargas parciais (ver notas 3 e 4)	NS ¹⁾	< 0,1	< 0,2
D1	Descargas de baixa energia	> 1	0,1 – 0,5	> 1
D2	Descargas de alta energia	0,6 – 2,5	0,1 – 1	> 2
T1	Falha térmica, $t < 300^\circ\text{C}$	NS ¹⁾	> 1, mas NS ¹⁾	< 1
T2	Falha térmica, $300^\circ\text{C} < t < 700^\circ\text{C}$	< 0,1	> 1	1 – 4
T3	Falha térmica, $t > 700^\circ\text{C}$	< 0,2 ²⁾	> 1	> 4
Nota 1 – Em alguns países, a relação $\text{C}_2\text{H}_2/\text{C}_2\text{H}_6$ é utilizada, preferencialmente à proporção CH_4/H_2. Assim também em alguns países, ligeiras diferenças são utilizadas nos limites. Nota 2 – As relações acima são significativas e deverão ser calculadas somente se pelo menos um dos gases está a uma concentração e a uma taxa de crescimento acima dos valores típicos. Nota 3 – $\text{CH}_4/\text{H}_2 < 0,2$ para descargas parciais em transformadores para instrumentos. $\text{CH}_4/\text{H}_2 < 0,07$ para descargas parciais em buchas. Nota 4 – A decomposição padrão para descargas parciais tem sido relatada como um resultado da decomposição da fina camada de óleo entre as lâminas do núcleo quando a temperatura chega aos 140°C e acima				
¹⁾ Valor não significativo ²⁾ Um acréscimo significativo no valor de C_2H_2 pode indicar que a temperatura do ponto quente é superior a 1000°C.				

Fonte: IEC 60599:1999 *apud* OSTERMANN, 2006

2.5 INTELIGÊNCIA ARTIFICIAL APLICADO NO DIAGNÓSTICO DE FALHAS INCIPIENTES

Os métodos convencionais utilizados na detecção de falhas incipientes no sistema de isolamento de um transformador descritos na seção 2.4 estão difundidos na indústria. No entanto, em alguns casos, esses métodos podem falhar. Normalmente isso acontece quando há mais de uma falha ocorrendo ao mesmo tempo no interior do transformador (LIMA, 2005).

Tendo isso em vista, é possível encontrar atualmente na literatura diversos estudos que procuram unir o conhecimento de métodos convencionais com técnicas de inteligência artificial. Estes sistemas híbridos surgem numa tentativa de trazer diagnósticos mais completos e precisos, procurando superar a falta de diagnóstico existente nas metodologias convencionais. Este capítulo fará uma breve revisão da literatura ligada ao tema deste projeto. Neste contexto, uma vasta pesquisa no que se refere à aplicação de técnicas de inteligência computacional (redes neurais, sistemas nebulosos e algoritmos de otimização) e métodos convencionais para detecção e monitoramento de falhas incipientes em transformadores de potência foram realizadas e estão aqui documentadas.

2.5.1 Dissertações e Teses

Devido à grande importância dos transformadores no cenário econômico nacional (conforme já exposto nos capítulos anteriores), é possível encontrar diversas pesquisas de diferentes instituições brasileiras na mesma área de conhecimento proposto neste projeto. As abordagens adotadas são variadas: CASTILLO (2003) da UFSC (Universidade Federal de Santa Catarina) desenvolveu o protótipo de um sistema especialista (SE) com o objetivo de auxiliar os técnicos e engenheiros de transformadores de potência na emissão de diagnósticos de falhas incipientes nos transformadores principais dos geradores da Usina Hidrelétrica da Itaipu Binacional.

MORAIS (2004) da UFSC baseou-se na utilização de critérios de análise dos gases referenciados em normas, de uma rede neural artificial e de um sistema de

inferência *fuzzy* para fornecer ao usuário final um diagnóstico de falhas em transformadores de potência.

ARANTES (2005) da UNIFEI (Universidade Federal de Itajubá) utilizou informações obtidas de análises cromatográfica dos gases e associou-as à técnica de redes neurais com o objetivo de facilitar a decisão de técnicos e engenheiros de manutenção (permitindo estimar o grau de envelhecimento dos transformadores).

LIMA (2005) da UFC (Universidade Federal do Ceará) apresenta um sistema híbrido com a combinação de sistemas especialistas, sistemas nebulosos e redes neurais artificiais (RNAs) para resolver problemas com a presença de incertezas relacionados ao monitoramento e diagnóstico do sistema de isolamento de transformadores de potência. Neste caso, LIMA (2005) baseou-se em dados históricos de falhas em transformadores da Companhia Energética do Ceará (COELCE), duas arquiteturas de redes neurais, perceptrons de múltiplas camadas (MLP – *multilayer perceptrons*) e funções de base radial (RBF – *radial basis function*) para o reconhecimento de padrões.

PAIXÃO (2006) da UFPR (Universidade Federal do Paraná) apresentou uma ferramenta estatística/computacional capaz de avaliar o óleo isolante em operação, utilizando dados físicos e químicos adquiridos ao longo dos anos. Neste caso, PAIXÃO (2006) baseou-se na técnica estatística de análise discriminante quadrática na área de reconhecimento estatístico de padrões.

FANTIN (2006) da UFPA (Universidade Federal do Pará) desenvolveu um software especialista nebuloso para auxiliar no diagnóstico e assessorar os técnicos e engenheiros a terem uma visão mais clara das condições operativas do transformador. A base deste software é a análise das concentrações de gases dissolvidos no óleo isolante juntamente com a interpretação de testes físico-químicos.

OSTERMANN (2006) da PUCRS (Pontifícia Universidade Católica do Rio Grande do Sul) desenvolveu um sistema de gerenciamento de transformadores de potência que foi implantado na área de transmissão da CEEE (Companhia Estadual de Energia Elétrica). Em sua dissertação, OSTERMANN (2006) apresenta os resultados e benefícios da implantação deste sistema de gerenciamento, detalhando estruturas e módulos do sistema, além de fazer uma rica abordagem sobre a evolução da engenharia de manutenção industrial no Brasil.

BARBOSA (2007) da UFC utilizou dispositivos online de monitoramento para elaborar um sistema de pré-diagnóstico capaz de classificar a gravidade da falha detectada. Após a detecção de uma situação de falha, BARBOSA (2007) utiliza módulos inteligentes via redes neurais e lógica *fuzzy* que são capazes de identificar as falhas internas do equipamento.

2.5.2 Artigos Científicos em Periódicos e Conferências/Congressos

BOOTH e MCDONALD (1998) descreveram a análise de dados de monitoramento de um transformador de tensão. As redes neurais artificiais foram utilizadas tanto na estimativa quanto no modo de classificação para dar uma indicação *online* da condição do transformador de tensão com relação à integridade física de seus enrolamentos.

JOTA *et al.* (1998) utilizaram sistemas inteligentes híbridos no diagnóstico de uma variedade de falhas em um conjunto de equipamentos do sistema elétrico de energia. O motivo para isso é que existem diversas causas para a natureza das falhas e um único algoritmo inteligente não é capaz de classificar estas falhas. Neste caso, combinaram-se abordagens de redes neurais, sistemas especialista e lógica *fuzzy*, desenvolvendo-se o seguinte:

- Um híbrido de rede neural e sistema especialista: com o objetivo de identificar o conteúdo de umidade no isolante óleo-papel de transformadores através de medições de tensão (*recovery voltage measurements* – RVM);
- Um híbrido de rede neural e sistema especialista: com o objetivo de identificar falhas térmicas e degradação da celulose em transformadores a partir de dados DGA;
- Um híbrido de lógica *fuzzy* e sistema especialista: com o objetivo de identificar alta impedância em alimentadores.

FARAG *et al.* (1999) desenvolveram um sistema de monitoramento online de descargas parciais (*partial discharge* – PD) em transformadores (monitorea até quatro transformadores continuamente). Ele usou diversos métodos que rejeitam a interferência e aumenta a sensibilidade à PD. Para a detecção de descargas

parciais, utilizou-se o método de pulsos de corrente, onde a amplitude do impulso PD é diretamente proporcional à quantidade aparente de descarga.

FUENTE e VEJA (1999) utilizaram uma nova proposta para a detecção e diagnóstico de falhas (*fault detection and diagnosis* – FDD) de uma estação de tratamento de esgoto. Este trabalho apresentou um novo método FDD que combina um algoritmo simples baseado em uma técnica de estimativa de parâmetros (que é usado para gerar sinais que indicam falhas), uma rede neural MLP (utilizado para analisar o conteúdo de frequência desses sinais) e um processo adaptativo baseado em uma rede de saída (que ajuda a melhorar a taxa de convergência do identificador). O algoritmo de Hägglung modificado foi utilizado para estimar os parâmetros físicos do processo (por meio de um modelo matemático não linear da planta). Estes dados são submetidos à métodos estatísticos e são utilizados como entrada de uma rede neural que finalmente realiza as tarefas de detecção e diagnóstico.

WAHAB *et al.* (1999) basearam-se nos dados de 12 transformadores que foram monitorados por um período de 8 anos. Desenvolveu-se modelos matemáticos para a tensão de ruptura, acidez total e teor de água em função dos períodos de serviço de cada transformador. Um modelo de regressão linear múltiplo para cada tensão de ruptura do transformador em função do seu conteúdo de água, acidez total e período de serviço foi introduzido e sua adequação foi ilustrada por análise estatística. Outro modelo de regressão linear múltipla foi desenvolvido ao combinar resultados de um grupo de transformadores em um único transformador equivalente. Este modelo foi validado ao prever as propriedades de alguns transformadores e comparando-os com os valores medidos.

BOSWORTH *et al.* (2001) utilizaram a detecção amperométrica pulsada (*pulsed amperometric detection* – PAD) para medir a presença do composto químico chamado “furano”. Este composto é produzido pela quebra termolítica dos isolantes celulósicos e pode indicar a falha em transformadores.

CHEN e LIN (2001) utilizaram abordagens *fuzzy* no diagnóstico de falhas de transformadores como uma complementação à clássica análise de gases dissolvidos em óleo utilizada na detecção de falhas incipientes de transformadores. Os critérios utilizados nesta clássica abordagem são baseados em valores do “conjunto *crisp*” (valores não graduais do tipo “sim ou não”, “tudo ou nada”). Devido à natureza dicotômica dos critérios do “conjunto *crisp*”, transformadores com concentração de

gases semelhantes podem ter diagnósticos diferentes especialmente quando suas concentrações de gases estão em torno do critério limite. Por isso, para lidar com este problema, CHEN e LIN (2001) trabalharam e analisaram dados coletados de transformadores defeituosos, obtendo as funções de pertinência dos padrões de falhas através de métodos *fuzzy* de clusterização. Dentre as metodologias utilizadas estava o método proposto por Takagi-Sugeno.

BODZENTA *et al.* (2002) propuseram um sensor capaz de detectar o gás hidrogênio dissolvido no óleo do transformador. A detecção é feita através das mudanças nas propriedades ópticas e elétricas do filme de palladium ao absorver hidrogênio. O sensor foi testado em diferentes concentrações de hidrogênio, bem como em diferentes temperaturas. Este sensor pode ser utilizado no monitoramento contínuo de sistemas de potência.

MACALPINE *et al.* (2002) utilizaram uma bobina de fibra óptica como um sensor acústico que permite a detecção e localização de descargas parciais em transformadores. Este sensor deve ser isolado e não conter metal para não comprometer a integridade do isolamento do transformador.

YUN *et al.* (2002) mostraram um estudo realizado na Coreia do Sul de gestão de carga de transformadores de poste. Este estudo avaliou quatro equações de regressão diferentes que refletem a demanda de consumo dos clientes (equação linear, quadrática, logarítmica e exponencial). De todas as equações, a que melhor refletiu a demanda dos consumidores foi a quadrática. O objetivo da pesquisa foi melhorar a estimativa da carga de pico de transformadores de poste. A correta estimativa é importante para que se evite sobrecarga do sistema, evitando desta forma uma eventual falha do transformador. Segundo estudos, a estação do ano que possui os maiores picos de carga é o verão (devido a utilização de sistemas de refrigeração). Tendo isso como base, a pesquisa de YUN *et al.* (2002) foi dividida em duas etapas:

- A primeira foi a de modificação da equação de regressão de carga para gerenciamento de carga de transformadores de poste;
- A segunda foi a estimativa da carga de refrigeração requisitada pelos clientes para reduzir os erros de estimativa da carga de pico para transformadores de poste na temporada de verão.

BOSWORTH *et al.* (2003) desenvolveram dois sensores de polifenoloxidase (*polyphenol oxidase* – PPO) que medem o nível de fenol no óleo isolante do

transformador. O fenol é resultante da degradação termolítica da resina fenol-formaldeído.

WANG e HUNG (2003) utilizaram o modelo “cinza” modificado (*modified grey model* – MGM) na previsão de tendências de gases dissolvidos em transformadores de tensão, sendo neste caso possível a detecção de futuras falhas (aumentando a confiabilidade do sistema de tensão). Para verificar a metodologia proposta, 46 conjuntos de dados de transformadores de tensão foram testados, mostrando que este método é simples e eficiente.

HUNG e WANG (2004) utilizaram o modelo de rede neural *cerebellar model articulation controller* (CMAC) no diagnóstico de falhas em transformadores de tensão. Este modelo utiliza a norma IEC 599 para gerar os dados de treinamento. Utilizando a característica de auto-aprendizagem e generalização, este modelo permitiu um diagnóstico de falhas poderoso, simples e eficiente.

KUO *et al.* (2004) utilizaram a combinação de modelamento *fuzzy*, treinamento *backpropagation* e função de evolução simbiótica, gerando sua própria arquitetura *fuzzy*-neural (nome dado pelo autor: *sybiotic evolution-based fuzzy-neural transformer diagnostic system* – SE-FNTDS). No SE-FNTDS cada gene representa um dos parâmetros da rede *fuzzy*-neural. A SE-FNTDS é construída ao selecionar e combinar genes de populações produzidas pela evolução simbiótica. Dados coletados de transformadores em tempo real foram utilizado como *input/output* na geração de regras e treinamento dos dados da rede *fuzzy*-neural.

CASTRO e MIRANDA (2005) desenvolveram um conceito de rede neural artificial (RNA) para o diagnóstico de falha utilizando a análise de gases dissolvidos em óleo (DGA). Na tentativa de superar a limitação da RNA que cria relações entre as variáveis mas não as explica, CASTRO e MIRANDA (2005), utilizaram uma nova metodologia que permitiu mapear uma RNA em um sistema baseado em regras (*rule-base system*) como o sistema de inferência de Takagi-Sugeno (TS – em que a relação das variáveis é representada por meio de regras SE-ENTÃO). Desta forma, tornou-se explícito o conhecimento capturado pela rede neural durante a fase de treinamento, permitindo que os especialistas entendessem como a rede neural atinge um determinado resultado (deixando neste caso de ser vista como uma “caixa-preta”).

GANYUN *et al.* (2005) utilizaram um classificador multicamada de máquinas de vetor de suporte (*support vector machine* – SVM) no diagnóstico de falha de

transformador de tensão. Dados dos cinco gases dissolvidos em óleo foram pré-processados e seis características foram extraídas para SVMs. Estas amostras foram utilizadas no treinamento do classificador multicamada SVM, resultando na identificação e classificação de quatro tipos de falha.

DURASAMY *et al.* (2007) utilizaram lógica *fuzzy* e redes neurais *backpropagation* (BP) na identificação de falhas incipientes em transformadores de energia. A precisão do diagnóstico de falha foi melhorada escolhendo valores adequados de taxa de aprendizagem, fator de *momentum* e funções de ativação. Estes métodos foram comparados com métodos convencionais DGA (Dörnenburg e proporção de gases de Rogers). Neste caso, para a lógica *fuzzy* a função de pertinência triangular apresentou melhores resultados, enquanto que a precisão da rede neural é comparável aos métodos convencionais devido à sua superior capacidade de aprendizagem.

SUN *et al.* (2007) utilizaram um algoritmo *backpropagation* (BP) baseado em redes neurais artificiais (RNA) eficiente com coeficiente de taxa de aprendizagem adaptável e *momentum* (*adaptive learning rate and momentum* – ALM) reduzindo o tempo de treinamento e evitando ficar preso em mínimos locais. Este método capta relações complicadas entre diversos gases dissolvidos e consegue indicar falhas típicas do transformador com maior precisão do que o método convencional BP.

TAN *et al.* (2007) utilizaram um modelo de rede neural híbrida baseado na integração *fuzzy* ARTMAP (FAM) e na função de base retangular (RecBFN) – capaz de aprender e revelar as regras *fuzzy* (nebulosas). Esta metodologia foi aplicada na detecção de falhas e diagnóstico de tarefas de um sistema de circulação de água (*circulating water* – CW) em uma estação de geração de energia.

DONG *et al.* (2008) utilizaram as seguintes metodologias para a análise de diagnóstico de falha de transformadores de tensão: “*rough set*” (RS) e rede neuro-*fuzzy-wavelet* (*fuzzy wavelet neural network* – FWNN) integrados com algoritmo de mínimos quadrados (*least squares* – LS) para ponderação. A abordagem se beneficia da habilidade de redução do conhecimento do RS e da boa habilidade de classificação do diagnóstico da FWNN. O RS integrado com o LS simplifica os parâmetros de entrada do FWNN e extrai regras que satisfazem os critérios predefinidos. Este mecanismo possui uma ótima habilidade na identificação e classificação de falhas.

FEI e SUN (2008) e FEI e ZHANG (2009c) utilizaram a metodologia de máquinas de vetor de suporte – *support vector machine* (SVM) – juntamente com algoritmo genético (SVMG) para o diagnóstico de falha de um transformador de potência. O algoritmo genético foi utilizado para selecionar os parâmetros apropriados do SVM. Foram utilizados dados experimentais de várias empresas de energia elétrica da China na verificação do desempenho do modelo proposto SVMG. Em 2008, esta metodologia foi comparada com o modelo “cinza” (*grey model* – GM) enquanto que em 2009, esta metodologia foi comparada com três proporções de gases IEC, SVM e RNA (redes neurais artificiais). Em ambos os casos, o SVMG mostrou um diagnóstico mais preciso.

KOUFAKIS *et al.* (2008) sugeriram um método para previsão do ciclo de vida de um transformador. Neste caso, ele executou medições da resistência de isolamento em transformadores de distribuição em diversas temperaturas. Estes valores foram utilizados no cálculo do coeficiente térmico de transformadores, servindo de base para a estimativa de vida útil restante do transformador.

MIJALOVIC (2008) propôs um método para avaliar os efeitos das diferentes formas de manutenção preventiva do transformador de potência. Este modelo é capaz de calcular o custo esperado de reparação de falhas e o custo de falhas de corte de carga. Neste modelo, assume-se que o componente pode ter dois modos de falha independentes:

- Um modo de falha casual/inesperado, caracterizado pela distribuição exponencial;
- Um modo de desgaste, com base em dois parâmetros da distribuição Weibull.

FEI *et al.* (2009a) também utilizaram as metodologias de máquinas de vetor de suporte – *support vector machine* (SVM) – juntamente com algoritmo genético (SVMG) para fazer a previsão da proporção de gases: C_2H_2/C_2H_4 , CH_4/H_2 , C_2H_4/C_2H_6 . Da mesma maneira, os resultados experimentais mostraram que o método SVMG atinge maior precisão se comprado com o modelo *grey* e redes neurais artificiais.

FEI *et al.* (2009b) propuseram um modelo de máquinas de vetor de suporte – *support vector machine* (SVM) – juntamente com a metodologia de otimização de enxame de partículas (*particle swarm optimization* – PSO). O PSO-SVM foi aplicado na previsão do teor de gases dissolvidos no óleo do transformador de potência, onde

o PSO foi utilizado para determinar parâmetros do SVM. Para casos com poucas amostras de dados, este modelo mostrou precisão de previsão quando comparado com modelo “cinza” e redes neurais artificiais.

O estudo de KIL *et al.* (2009) baseou-se na análise da frequência dos sinais acústicos produzidos pelas descargas parciais (PD) no óleo isolante e no posicionamento da ocorrência da PD para a realização do diagnóstico do óleo de isolamento de transformadores. Neste caso, foi montado três tipos de sistemas de eletrodos (*needle-plane*, *plane-plane*, *wire-wire*) para simular descargas parciais que podem acontecer no isolamento de óleo do transformador. Um amplificador de ruído e um acoplador foram projetados para detectar o sinal acústico com alta sensibilidade. A posição de ocorrência de PD foi calculado através da diferença de tempo de chegada utilizando três sensores de emissão acústicos.

KUO (2009) propôs uma metodologia para identificação de tipos de defeito em transformadores de resina epóxi através de emissão acústica (AE) com base em ensaios de descargas parciais (*partial discharge* – PD). O estudo foi baseado em uma série de testes de alta tensão conduzidos em transformadores que possuíam defeitos de fabricação para coletar os sinais de AE. As características selecionadas foram extraídas e utilizadas como *input* para o sistema de reconhecimento. De acordo com estas características, a identificação de seu tipo de defeito pode ser feita utilizando o sistema de reconhecimento proposto que combina otimização de enxame de partículas (*particle swarm optimization* – PSO) e redes neurais artificiais (RNA).

LIN *et al.* (2009) utilizaram a análise de clusterização cinza – *grey clustering analysis* (GCA) – para o diagnóstico de falhas de transformadores. Esta metodologia reúne as análises de agrupamento, análise relacional, predicação e de decisão para o “sistema cinza”. Este termo (cinza) indica um sistema onde as informações estão incompletas, pouco claras ou incertas. Partindo de dados de concentração de gases de transformadores da *Taiwan Power Company* (TPC), obteve-se um diagnóstico de falha classificado em: térmicas, elétricas e de degradação do isolamento celulósico. Esta metodologia foi comparada às técnicas de inteligência artificial baseadas em *fuzzy* e RNA. Para mostrar a efetividade do método proposto, casos da TPC e de uma empresa australiana foram escolhidos para a investigação. A vantagem deste método é a sua fácil implementação, pois não necessita determinar variáveis linguísticas, regras de inferência, arquitetura de rede e atribuição de parâmetros.

KUO (2010) propôs um sistema de identificação artificial para classificar o estado de envelhecimento do isolamento do transformador seco encapsulado através do método de impulso de corrente de descargas parciais (PD). Neste caso, utilizou-se um transformador com 15 anos de uso sem histórico de defeito. Este foi submetido a um processo de envelhecimento acelerado até a sua total degradação. Os sinais PD foram recolhidos e após a aplicação de métodos estatísticos, identificou-se as características específicas que representam o estado de envelhecimento. Verificou-se que a obliquidade, curtose, correlação cruzada e assimetria do valor de máxima descarga, valor médio de descarga e os tempos de descarga, podem ser tratados como *input* para o sistema de reconhecimento. O sistema de reconhecimento para identificar o estado de envelhecimento do isolamento combinou as metodologias de rede neural e PSO-BP.

JAZEBI *et al.* (2011) combinaram máquinas de vetor de suporte (*support vector machine* – SVM) e transformada *wavelet*. A aplicação da transformada *wavelet* reduziu amostras de dados para o classificador SVM, reduzindo consequentemente o custo computacional. Além do mais, a transformada de *wavelet* melhorou a eficiência, precisão e velocidade de resposta do SVM. Além disso, algoritmo de clusterização *k-means* e técnicas de otimização de enxame de partículas (PSO) foram aplicadas para ajustar parâmetros SVM. O desempenho deste método foi demonstrado por meio de simulação de diferentes falhas e condições de comutação de um transformador de potência (utilizando o software PSCAD/EMTDC – software utilizado para simular sistemas de potência).

O quadro a seguir apresenta um resumo comparativo dos artigos descritos nesta seção.

Quadro 3 – Resumo comparativo dos artigos da seção “2.5.2 Artigos Científicos em Periódicos e Conferências/Congressos”

(continua)

Referência	Técnica	Dados de entrada do sistema	Saídas do sistema	Observação
BOOTH e MCDONALD (1998)	Rede neural artificial (<i>backpropagation</i>)	Tensão, corrente, dados térmicos, corrente no enrolamento, vibração do núcleo e do enrolamento	Diagnóstico do nível de vibração do enrolamento. Classificação dos dados com “OK” ou “NOK”	---
JOTA <i>et al.</i> (1998)	Redes neurais, sistemas especialista e lógica <i>fuzzy</i>	Medições de tensão e DGA	Detectar umidade, buchas contaminadas e falhas térmicas	---
FARAG <i>et al.</i> (1999)	---	---	Sistema de monitoramento online de descargas parciais	---
FUENTE e VEJA (1999)	Algoritmo modificado de Hägglung e redes neurais MLP com treinamento e algoritmo <i>error backpropagation</i>	Amostras de biomassa, do substrato e do fluxo retiradas da entrada dos reatores após o efluente e do lodo ativado reciclado (<i>recycled activated sludge</i> – RAS)	Deteccão e diagnóstico de alterações nos parâmetros físicos de uma planta de tratamento de esgoto, situado em Manresa, na Espanha	---
WAHAB <i>et al.</i> (1999)	Modelo de regressão linear múltipla	Estudo realizado em 12 transformadores que foram monitorados por um período de 8 anos.	Modelos matemáticos para a tensão de ruptura, acidez total e teor de água em função dos períodos de serviço	---

Quadro 3 – Resumo comparativo dos artigos da seção “2.5.2 Artigos Científicos em Periódicos e Conferências/Congressos”

(continuação)

Referência	Técnica	Dados de entrada do sistema	Saídas do sistema	Observação
BOSWORTH <i>et al.</i> (2001)	Deteção amperométrica pulsada do composto químico furano	Óleos foram examinados ou por pré-extração, ou suspensão direta em medição de solução aquosa, ou por solubilização e medição PAD direta em solventes orgânicos	Nível de furano	Unidades com falha podem ter níveis de furano de até $10\mu\text{gml}^{-1}$
CHEN e LIN (2001)	Metodologias <i>fuzzy</i> entre elas a Takagi-Sugeno	Concentração de gases: H_2 , CH_4 , C_2H_6 , C_2H_4 , C_2H_2 , CO , TCG	Diagnóstico de falha de um transformador de tensão	---
BODZENTA <i>et al.</i> (2002)	---	---	Sensor capaz de detectar gás hidrogênio	---
MACALPINE <i>et al.</i> (2002)	---	---	Bobina de fibra óptica que funciona como um sensor acústico para detectar a localização de descargas parciais	---
YUN <i>et al.</i> (2002)	Equações de regressão para estimativa de carga dos transformadores de poste: equação linear, quadrática, logarítmica e exponencial	Energia elétrica (kWh) e pico de corrente de carga (A) – dados da KEPCO (<i>Korea Electric Power Corporation</i>)	Estimativa de carga de pico de transformadores de poste	---

Quadro 3 – Resumo comparativo dos artigos da seção “2.5.2 Artigos Científicos em Periódicos e Conferências/Congressos”

(continuação)

Referência	Técnica	Dados de entrada do sistema	Saídas do sistema	Observação
BOSWORTH <i>et al.</i> (2003)	Medir o nível de fenol no óleo isolante utilizando dois sensores desenvolvidos pelo autor	Utilização de óleos expostos à variação artificial de corrente/tensão e óleos recuperados de transformadores em serviço	Avaliação dos níveis de fenol no óleo do transformador	---
WANG e HUNG (2003)	<i>Modified grey model – MGM</i>	Proporção de gases: C_2H_2/C_2H_4 , CH_4/H_2 , C_2H_4/C_2H_6	Diagnóstico de falha de um transformador de tensão	Utilizou 46 conjuntos de dados de transformadores de tensão de Taiwan
HUNG e WANG (2004)	Rede neural <i>cerebellar model articulation controller (CMAC)</i>	Proporção dos gases: C_2H_2/C_2H_4 , CH_4/H_2 , C_2H_2/C_2H_6	Diagnóstico de falha de um transformador de tensão	---
KUO <i>et al.</i> (2004)	<i>Symbiotic evolution-based fuzzy-neural transformer diagnostic system – SE-FNTDS</i>	H_2 , CH_4 , C_2H_6 , C_2H_4 e C_2H_2	Diagnóstico de falha de um transformador de tensão	Dados coletados da Taipower (<i>Taiwan Power Company, Taiwan</i>) – 520 amostras de óleo de transformador
CASTRO e MIRANDA (2005)	Rede Neural Artificial	Concentração de gases: CH_4 , C_2H_4 , C_2H_2	Diagnóstico de falha de um transformador de tensão	Esta metodologia extrai ainda regras de inferência tipo Takagi-Sugeno da RNA
GANYUN <i>et al.</i> (2005)	Classificador multicamada SVM	H_2 , CH_4 , C_2H_6 , C_2H_4 e C_2H_2	Diagnóstico de falha de um transformador de tensão	---

Quadro 3 – Resumo comparativo dos artigos da seção “2.5.2 Artigos Científicos em Periódicos e Conferências/Congressos”

(continuação)

Referência	Técnica	Dados de entrada do sistema	Saídas do sistema	Observação
DURAISAMY <i>et al.</i> (2007)	Fuzzy e redes neurais <i>backpropagation</i>	Critérios de IEC/IEEE DGA e valores de concentrações dos gases (H ₂ , CH ₄ , C ₂ H ₆ , C ₂ H ₄ e C ₂ H ₂)	Diagnóstico de falha de um transformador de tensão	Dados coletados da <i>Electricity Board</i> (53 amostras)
SUN <i>et al.</i> (2007)	BP-ALM (BP com <i>adaptive learning rate and momentum coefficient</i>)	H ₂ , CH ₄ , C ₂ H ₆ , C ₂ H ₄ e C ₂ H ₂	Diagnóstico de falha de um transformador de tensão	Metodologia foi comparada com BP convencional e o método refinado de três razões (<i>refined three-ratio method</i> – RTR)
TAN <i>et al.</i> (2007)	Fuzzy ARTMAP (FAM) e <i>rectangular basis function network</i> (RecBFN)	Dados coletados de um sistema de circulação de água de uma estação de geração de energia em Penang, Malasia (12 características que inclui medições de temperatura e pressão em vários pontos na entrada e na saída do condensador)	4 condições de operação do sistema de circulação de água	---
DONG <i>et al.</i> (2008)	<i>Rough set, fuzzy wavelet neural network</i> e algoritmo de fusão ponderado de mínimos quadrados	DGA: H ₂ , CH ₄ , C ₂ H ₆ , C ₂ H ₄ e C ₂ H ₂	Diagnóstico de falha de um transformador de tensão	---

Quadro 3 – Resumo comparativo dos artigos da seção “2.5.2 Artigos Científicos em Periódicos e Conferências/Congressos”

(continuação)

Referência	Técnica	Dados de entrada do sistema	Saídas do sistema	Observação
FEI e SUN (2008)	SVMG – máquinas de vetor de suporte junto com algoritmo genético	Casos obtidos de diversas empresas de energia elétrica da China	Diagnóstico de falha de um transformador de tensão	Metodologia foi comparada com GM
KOUFAKIS <i>et al.</i> (2008)	Previsão do ciclo de vida de um transformador	Medição da resistência de isolamento	Previsão do ciclo de vida de um transformador	---
MIJALOVIC (2008)	Distribuição exponencial, distribuição de Weibull, equações de custo de manutenção preventiva	Potência do transformador, período de funcionamento, pico máximo de carregamento, pico mínimo de carregamento, custos dos componentes do transformador e seus dados de confiabilidade, custos de troca de óleo/filtro, parâmetros de distribuição de Weibull para cada componente, etc.	Custos de diferentes tipos de manutenção preventiva	---
FEI <i>et al.</i> (2009a)	SVMG – máquinas de vetor de suporte junto com algoritmo genético	Dados históricos de proporção dos gases no transformador de diversas companhias de energia elétrica da China	Previsão futura da proporção de gases: C_2H_2/C_2H_4 , CH_4/H_2 , C_2H_4/C_2H_6	---

Quadro 3 – Resumo comparativo dos artigos da seção “2.5.2 Artigos Científicos em Periódicos e Conferências/Congressos”

(continuação)

Referência	Técnica	Dados de entrada do sistema	Saídas do sistema	Observação
FEI <i>et al.</i> (2009b)	PSO-SVM – máquinas de vetor de suporte junto com algoritmo de enxame de partículas	Dados de gases dissolvidos (H ₂ , CH ₄ , C ₂ H ₆ , C ₂ H ₄ e C ₂ H ₂) de companhias de energia elétrica da China	Previsão do teor de gases dissolvidos no óleo do transformador de potência	---
FEI e ZHANG (2009c)	SVMG – máquinas de vetor de suporte junto com algoritmo genético	142 casos obtidos de diversas empresas de energia elétrica da China	Diagnóstico de falha de um transformador de tensão	Metodologia foi comparada com três proporções de gases IEC, SVM e RNA
KIL <i>et al.</i> (2009)	Sistemas de eletrodos e sensores de emissão acústico	---	Identificação de descargas parciais e do posicionamento de sua ocorrência	---
KUO (2009)	Emissão acústica, otimização de enxame de partículas e redes neurais artificiais	Características obtidas no teste de alta tensão: <i>rise time</i> , duração, quantidade, amplitude e energia	Tipos de defeito: - solda inadequada no lado de alta tensão - fio de cobre mole impróprio - alta tensão do painel - bolha imprópria dentro do material isolante em baixa e alta tensão	---

Quadro 3 – Resumo comparativo dos artigos da seção “2.5.2 Artigos Científicos em Periódicos e Conferências/Congressos”

(conclusão)

Referência	Técnica	Dados de entrada do sistema	Saídas do sistema	Observação
LIN <i>et al.</i> (2009)	GCA – <i>grey clustering analysis</i>	Dados da <i>Taiwan Power Company</i> , TPC – concentração de gases de acordo com os critérios padronizados de IEC/IEEE e CIGRE	Diagnóstico de falha de um transformador de tensão. Falhas foram classificadas em: térmicas, elétricas e de degradação do isolamento celulósico	---
KUO (2010)	Método impulso de corrente de descargas parciais, otimização de enxame de partículas e redes neurais artificiais	Sinais de descargas parciais tratados por métodos estatísticos, gerando as seguintes características de <i>input</i> : obliquidade, curtose, correlação cruzada e assimetria	Estágio de envelhecimento do isolamento do transformador	---
JAZEBI <i>et al.</i> (2011)	Máquinas de vetor de suporte (SVM), transformada <i>wavelet</i> , algoritmo de clusterização <i>k-means</i> e técnicas de otimização de enxame de partículas (PSO)	Dois transientes comuns foram considerados: 28.000 casos correntes de magnetização (<i>inrush</i>) e 5.200 casos de falhas internas.	Identificação rápida de transientes, fornecendo um esquema de proteção preciso e confiável	Utilização do software de simulação PSCAD/EMTDC

3 CLASSIFICAÇÃO E RECONHECIMENTO DE PADRÕES

Este capítulo mostra uma visão geral de conceitos relacionados à classificação e reconhecimento de padrões.

Desta forma, o capítulo inicia-se com uma relação de conceitos preliminares pertinentes ao processo de aprendizagem de um algoritmo, tipos de dados que podem ser utilizados na classificação e os tipos de aprendizagem existentes.

Em seguida, é feita uma abordagem mais detalhada sobre o reconhecimento de padrões e as etapas de classificação de dados. Também é apresentada uma metodologia para se verificar a qualidade de um classificador.

Além disso, é feita uma descrição sobre aprendizagem de máquina.

Por fim, são listadas as técnicas escolhidas deste trabalho e o tipo de abordagem utilizada.

3.1 CONCEITOS PRELIMINARES

Tendo como base um conjunto de categorias pré-definidas, a classificação pode ser exposta como a tarefa de designar objetos a cada uma dessas categorias (PAK, 2010).

A partir de um aglomerado de dados que se deseja classificar utilizando algoritmos de classificação, é possível identificar os seguintes conjuntos (BRAGA, 2010):

- **Conjunto de treinamento:** serve de base para algoritmos de aprendizado sendo, portanto, o ponto de partida para a construção de classificadores ou outros modelos (são os dados de entrada do algoritmo). Este conjunto deve ser representativo da distribuição da população dos dados do domínio;
- **Conjunto de teste:** utilizado na avaliação do modelo construído e deve ser utilizado somente na fase de testes do modelo e não na sua fase de construção (idealmente o conjunto de teste deve ser diferente do conjunto de treinamento);

- **Conjunto de validação:** em alguns casos, este conjunto é utilizado no ajuste dos parâmetros do modelo construído pelo algoritmo de aprendizado.

De maneira geral, problemas de aprendizagem de máquina e de classificação de dados podem ser divididos da seguinte forma (LORENA e CARVALHO, 2007; ANDREOLA, 2009; ORMONDE, 2009; BRAGA, 2010):

- **Classificação supervisionada:** o algoritmo em sua fase de treinamento baseia-se em dados previamente classificados por especialistas no assunto, onde cada exemplo está associado a um ou mais rótulos (na forma de entrada-saída). Normalmente esta classificação é utilizada quando existe um número expressivo de exemplos rotulados à disposição;
- **Classificação não supervisionada:** algoritmo utilizado quando não existem exemplos rotulados. Trata-se de uma abordagem utilizada na realização de agrupamento de dados (*data clustering*), principalmente quando existe a necessidade de encontrar padrões ou tendências que auxiliem no entendimento destes dados;
- **Classificação semissupervisionada:** algoritmo utilizado quando existem poucos exemplos rotulados e um número expressivo de exemplos não rotulados sendo, portanto, um meio-termo entre a abordagem supervisionada e a não supervisionada.

Usualmente existem duas abordagens para o desenvolvimento de classificadores (ABE, 2005; BARANOSKI, 2005):

- **Abordagem paramétrica:** que parte do princípio que as classes analisadas possuem uma distribuição de probabilidade com comportamento definido. Neste caso, o conhecimento *a priori* da distribuição dos dados são levados em consideração, exigindo desta forma, uma base de dados de aprendizado para uma correta estimação dos parâmetros;

- **Abordagem não paramétrica:** que parte do princípio que as leis de formação da probabilidade de uma classe são desconhecidas. Neste caso, não se exige nenhum conhecimento *a priori* para a análise.

3.2 RECONHECIMENTO E CLASSIFICAÇÃO DE PADRÕES

O reconhecimento de padrões trata da classificação e da descrição dos objetos. O próprio ser humano faz uso do reconhecimento de padrões ao reconhecer imagens e identificar sons (MELO, 2007).

Um padrão é a descrição do objeto em estudo e pode ser classificado como (CHAVEZ, 2003):

- Concretos:
 - Espaciais: caracteres, imagens, entre outros;
 - Temporais: formas de onda, séries, entre outros;
- Abstratos: raciocínio, soluções de problemas, entre outros.

Pode-se definir o reconhecimento de padrões como o processo pelo qual um padrão/sinal adquirido é referido a uma classe dentre um número pré-determinado de classes/categorias (HAYKIN, 2001).

Em um problema específico de classificação de padrões, um software (também chamado de classificador) é desenvolvido com a finalidade de classificar objetos corretamente. Dentro da classificação de padrões, procura-se atribuir um rótulo de uma classe a um objeto, processo físico ou um evento. Neste caso, no processo de classificação realiza-se um aprendizado entre um conjunto de atributos de entrada x e seu rótulo y . Esta tarefa é sempre baseada em medições que são feitas a partir de um sistema de sensores conforme mostrado na Figura 5 (HEIJDEN *et al.*, 2004; ABE, 2005; PAK, 2010). O Quadro 4 mostra alguns exemplos de aplicação da tarefa de classificação.

Quadro 4 – Alguns campos de aplicação de classificação de padrões

Campo de aplicação	Possíveis medições	Possíveis classes
Classificação de objetos		
Classificação de objetos eletrônicos	Formato, cor	‘Resistor’, ‘capacitor’, ‘transistor’, ‘CI’
Classificação de objetos mecânicos	Formato	‘Anel’, ‘porca’, ‘parafuso’
Leitura de caracteres	Formato	‘A’, ‘B’, ‘C’
Estimativa em um processo físico		
Classificação de manobras de um veículo	Seguir a característica dos pontos em uma sequencia de imagens	‘Seguindo reto’, ‘virando’
Diagnóstico de falha de um motor a combustão	Pressão dos cilindros, temperatura, vibrações, emissões acústicas, ângulo da manivela	‘Funcionamento normal’, ‘defeito no injetor de combustível’, ‘defeito na válvula de entrada de ar’, ‘vazamento na válvula de escape’
Deteção de evento		
Alarme contra roubos	Infravermelho	‘Alarme acionado’, ‘alarme não acionado’
Inspeção de comida	Formato, cor, temperatura, massa, volume	‘OK’, ‘não OK’

Fonte: Adaptado de HEIDEN *et al.*, 2004




Figura 5 – Classificação de padrão
 Fonte: adaptado de HEIDEN *et al.*, 2004

Considera-se que o modelo classificador pode ser utilizado para as finalidades de modelagem descritiva e preditiva. No caso de **modelos descritivos**, procura-se um modelo que possa resumir grande volume de dados, além de esclarecer quais atributos definem cada classificação do conjunto de rótulos. No caso dos **modelos preditivos**, a classificação é utilizada para prever o rótulo de registros desconhecidos (PAK, 2010).

A classificação de padrões nada mais é que a tomada de decisão baseada em informações do ambiente e pode ser utilizado em diversos tipos de aplicações, como no diagnóstico assistido por computador, na visão computacional, em identificação de impressões digitais, reconhecimento de voz e face, entre outros (LIMA, 2009).

Na classificação, procura-se encontrar uma ligação entre os **atributos previsores** e o **atributo meta**.

Conforme descrito por ORMONDE (2009) é possível encontrar os seguintes tipos de classificação:

- **Binária:** onde existem exatamente duas classes, sendo que os rótulos são definidos como $y_i \in \{-1, 1\}$. Exemplo: filtragem de mensagens de SPAM, onde o algoritmo define se uma determinada mensagem é SPAM ($y = 1$) ou não ($y = -1$);
- **Multiclasse:** quando o problema de classificação envolve mais de uma classe, ou seja, quando existam p categorias diferentes. Desta forma, define-se que $y_i \in \{1, \dots, p\}$. Neste caso, as categorias são assumidas como independentes e isso significa que a ordem na qual se

apresentam é arbitrária. Uma maneira usual para se resolver problemas de classificação multiclasse (e também multilabel) é decompor o problema em vários subproblemas de classificação binária;

- **Multilabel:** quando o problema de classificação pertence a mais de uma categoria simultaneamente. Neste caso, para um conjunto de p categorias, os rótulos pertencem ao conjunto das partes deste conjunto de rótulos, assim: $y_i \in 2^{\{1, \dots, p\}}$.

3.3 ETAPAS DA CLASSIFICAÇÃO DE DADOS

Em linhas gerais, pode-se considerar que a classificação de dados é um processo dividido em duas etapas.

Na primeira etapa, tendo como base um conjunto de dados (também chamado de conjunto de treinamento, conforme descrito acima), constrói-se um modelo que descreva este conjunto de dados. Neste caso, é feita uma análise das relações existentes entre os atributos precursores e o atributo preditor (classe). Estas relações são a base para a previsão de classes dos registros do conjunto de treinamento (MITCHELL, 1997).

Na segunda etapa, utiliza-se o conjunto de teste, onde o algoritmo faz a previsão das classes dos registros sem considerar o atributo preditor. Neste caso, após a previsão das classes dos registros do conjunto de teste, essas classes são comparadas com as classes da hipótese definida pelo atributo preditor. Assim, pode-se comparar o número de previsões corretas e incorretas.

3.4 ESTIMAÇÃO DA QUALIDADE DE UM CLASSIFICADOR

Dentro da tarefa de classificação, grande esforço é feito no sentido de encontrar a maior taxa de classificações corretas nos dados de testes. Esta taxa

pode ser definida pela razão entre o número de exemplos classificados corretamente e o número total de amostras do conjunto de teste.

A estimação da qualidade de um classificador é importante, pois serve de base para a comparação de diferentes tipos de técnicas de classificação de dados. Neste caso, pode-se definir o erro de um classificador da seguinte forma:

$$\text{Porcentagem de erro} = \frac{\text{Número de erros}}{\text{Número de casos testados}} \quad (3.1)$$

Define-se o custo de um erro como a penalização imposta ao sistema no caso de uma classificação incorreta.

3.5 APRENDIZAGEM DE MÁQUINA

Ao longo das últimas décadas vem sendo possível observar uma alteração gradual na divisão de tarefas entre homens e máquinas. Atividades que antes eram executadas pelo homem, hoje em dia também podem ser executadas por uma máquina. Devido a esta tendência, vêm eclodindo cada vez mais algoritmos e técnicas que permitem que a máquina “adquira o conhecimento”, de maneira que seja possível o aperfeiçoamento do desempenho da máquina para a realização desta determinada tarefa. Este campo de estudo é chamado de **Aprendizagem de máquina**.

A aprendizagem de máquina pode ser definida como um processo indutivo capaz de construir automaticamente um classificador a partir de um conjunto de dados. Além disso, trata do desenvolvimento de algoritmos que melhoram automaticamente algum aspecto no seu desempenho por meio da experiência. A vantagem deste enfoque é a precisão alcançada pelo classificador comparável à classificação feita por especialistas no assunto. A aplicação destas metodologias pode ser especialmente interessante quando a quantidade de dados disponível é muito grande. Ao utilizar os algoritmos classificadores, evita-se a classificação manual destes dados (SÁ, 2008; BRAGA, 2010; PAK, 2010).

Em aprendizagem de máquina, a classificação é feita baseando-se em dados estatísticos de um conjunto de informações disponíveis ou no conhecimento *a priori* sobre o assunto.

A partir de medições do objeto de estudo, a informação referente ao funcionamento deste sistema precisa ser processada. O bom processamento da medição só é possível se algum conhecimento ou entendimento do ambiente e do sistema de medição estiver disponível. Apesar disso, mesmo com toda a tecnologia à disposição, alguns sistemas só são parcialmente dominados. Neste caso, uma alternativa é a utilização de modelos aproximados. O desenvolvimento de modelos pode envolver os seguintes tópicos (HEIJDEN *et al.*, 2004):

- Classificação: detecção e identificação de objetos, recuperação de dados/informações;
- Estimativa de parâmetros: relacionado à complexidade/incerteza dos dados medidos e da quantidade de medições;
- Estimativa de estado: relacionado à causalidade do processo (onde a ordem dos acontecimentos deve ser levada em consideração).

Em todos os casos, a base de estudo são informações extraídas de um objeto, processo físico ou um evento do mundo real. Estas informações podem ser organizadas por vetores (com dimensão fixa) ou por uma sequência de vetores. Estes vetores devem ser processados para revelar a informação desejada (HEIJDEN *et al.*, 2004).

Dentre as tarefas do aprendizado de máquina destaca-se a classificação de padrões já descrita neste capítulo.

3.6 TÉCNICAS UTILIZADAS NESTE TRABALHO

Com base no conteúdo descrito neste capítulo, este trabalho utilizou a abordagem supervisionada e não paramétrica. Além disso, as técnicas de classificação basearam-se somente nos conjuntos de treinamento e de teste na sua aplicação.

Neste trabalho, serão utilizadas os seguintes algoritmos de classificação para a resolução de problemas de otimização de transformadores de potência:

- i. Classificador Naïve Bayes com seleção de característica seqüencial (FAN *et al.*, 2009)
- ii. LS-SVM (*least squares support vector machines*) (SUYKENS *et al.*, 2002), e
- iii. Rede neural probabilística (SPECHT, 1990).

A descrição dessas metodologias encontra-se no capítulo a seguir.

4 TÉCNICAS DE CLASSIFICAÇÃO

Este capítulo descreve os três classificadores que serão utilizados na resolução de problemas de otimização de transformadores de potência: classificador de Naïve Bayes, LS-SVM e rede neural probabilística.

4.1 CLASSIFICADOR DE NAÏVE BAYES

4.1.1 Teorema de Bayes

Bayes em 1763 demonstrou um procedimento (o teorema de Bayes) que permite calcular a probabilidade de um acontecimento com base em outro evento que tenha acontecido *a priori* (MELLO, 2001). Esta situação é chamada de **probabilidade condicional**.

Segundo definição, sendo A e B dois eventos ocorridos no conjunto C , a representação $P(A)$ significa a probabilidade de acontecer o evento A . Agora, a representação $P(B/A)$ significa a probabilidade condicionada do evento B quando A tiver ocorrido primeiro.

O teorema de Bayes é definido da seguinte forma:

$$P(B|A) = \frac{P(B) * (P(A|B))}{P(A)} \quad (4.1)$$

De forma análoga à equação (4.1), considerando-se um conjunto de treinamento D e a hipótese h , nos problemas de aprendizagem de máquina, o foco é na $P(h/D)$: probabilidade *a posteriori* de h dado o conjunto de treinamento D

$$P(h|D) = \frac{P(D|h) * P(h)}{P(D)} \quad (4.2)$$

Em algumas situações de aprendizagem, considerando-se um conjunto de candidatos de hipóteses H e desejando-se encontrar a mais provável hipótese $h \in H$

a partir dos dados observados D (ou ao menos o mais provável), é possível assumir o seguinte (MITCHELL, 1997):

$$\begin{aligned}
 h &= \arg \max_{h \in H} P(h | D) \\
 &= \arg \max_{h \in H} \frac{P(D | h) * P(h)}{P(D)} \\
 &= \arg \max_{h \in H} P(D | h) * P(h)
 \end{aligned} \tag{4.3}$$

No último passo da equação (4.3), foi retirado o termo $P(D)$ porque este é uma constante independente de h .

Em alguns casos é possível assumir que toda hipótese H é igualmente provável *a priori*. Neste caso, é possível simplificar a equação (4.3) e considerar somente o termo $P(D|h)$ para encontrar a hipótese mais provável (MITCHELL, 1997). Neste caso,

$$h = \arg \max_{h \in H} P(D | h) \tag{4.4}$$

4.1.2 Algoritmo Naïve Bayes

Os métodos Bayesianos baseiam-se em uma abordagem probabilística para dividir as variáveis que serão analisadas em categorias. Parte-se de uma suposição de que os elementos avaliados estão submetidos às distribuições de probabilidade e que as deliberações para a classificação ótima dos dados podem ser adotadas levando-se em conta estas probabilidades.

A utilização da abordagem probabilística é interessante, pois durante o processo de aprendizado, o algoritmo ao invés de simplesmente rejeitar/aceitar uma hipótese tem a possibilidade de aumentar ou diminuir a probabilidade associada a esta hipótese, tornando a metodologia flexível.

O algoritmo Naïve Bayes conhecido como “classificador Bayesiano ingênuo”, é um dos métodos de aprendizagem Bayesiana e, apesar de sua simplicidade, vem ganhando popularidade para resolver problemas de classificação quando

comparado com outros algoritmos, tais como redes neurais e aprendizagem por árvores de decisão.

A base deste classificador consiste em considerar que os diferentes atributos são independentes entre si dentro da mesma classe (FAN, 2009). Esta consideração é conhecida por independência condicional. Isto é adotado para facilitar os cálculos envolvidos.

A vantagem deste classificador deve-se à simplicidade da sua metodologia, que considera a independência entre atributos para atingir a classificação que maximiza o produto da sua fórmula (MITCHELL, 1997).

A fórmula do teorema de Bayes para o classificador de Naïve Bayes é

$$h_{NB} = \arg \max_{h_j \in H} P(h_j) * \prod_i P(a_i | h_j) \quad (4.5)$$

onde h_{NB} (a hipótese de Naïve Bayes) maximiza o valor de um produto entre a probabilidade de ocorrência de uma hipótese h_j (uma entre as possíveis no conjunto de hipóteses H) e um produto de probabilidades das valorações dos i -ésimos atributos dada a hipótese h_j (BORGES, 2006).

Pode-se considerar que as principais características do algoritmo Naïve Bayes são (TAN, 2005; PAK, 2010; AMATRIAIN *et al.*, 2011):

- Robustez para pontos de ruído isolados, pois as probabilidades condicionais são obtidas a partir de uma média;
- Robustez ao lidar com valores inexistentes, pois ignora as instâncias durante os cálculos de estimativa de probabilidade;
- Robustez para lidar com atributos irrelevantes, pois não alteram a distribuição de probabilidade uniforme.

Nos casos de atributos correlacionados a independência da suposição pode não valer. Nestes casos, recomenda-se utilizar outras técnicas como *Bayesian Belief Networks* (BBN). BBN baseia-se em um grafo acíclico para codificar a dependência entre atributos e a probabilidade que associa cada nó com seus pais imediatos. A BBN fornece uma maneira de capturar o conhecimento prévio em um domínio utilizando um modelo gráfico. De modo semelhante aos classificadores Naïve Bayes, a BBN lida com dados incompletos e são bastante robustos para lidar com o sobreajuste.

4.2 SUPPORT VECTOR MACHINES (SVM)

Proposto por VAPNIK (1995), as *Support Vector Machines* (SVM) são consideradas um algoritmo universal de aprendizado e podem ser aplicadas tanto para a regressão quanto para reconhecimento de padrões (VAPNIK, 1995; FONSECA, 2008).

Trata-se de uma ferramenta poderosa utilizada na resolução de problemas de classificação de modelamento. Dentre as principais vantagens da SVM, pode-se listar (FERRÃO, 2007; MARETTO, 2007):

- Elevada capacidade de generalização, evitando o sobreajuste (*overfitting*, situação na qual se obtêm baixos erros no conjunto de treinamento e erros elevados no conjunto de previsão);
- Robustez em grandes dimensões, possibilitando aplicação de SVMs em vetores de características de grandes dimensões;
- Convexidade da função objetivo, a aplicação das SVMs implica na otimização de uma função quadrática, que possui apenas um mínimo;
- Teoria bem estabelecida dentro da matemática e estatística.

VAPNIK (1995) fundamentou a SVM na “teoria da aprendizagem estatística”, que visa estabelecer condições matemáticas para a escolha de um classificador com bom desempenho (GONÇALVES, 2012).

O desempenho do classificador é mensurado pela quantidade de previsões incorretas do classificador f . Desta forma, define-se $R_{emp}(f)$ como sendo o risco empírico para medir a perda entre a resposta desejada e a resposta real. Desta forma:

$$R_{emp}(f) = \frac{1}{n} \sum_{i=1}^n c(f(x_i), y_i) \quad (4.6)$$

onde $c(\cdot)$ é a função de custo relacionada à previsão de $f(x_i)$ com a saída desejada y_i . Este tipo de função de custo é definido pela equação (4.7). Para o processo de busca por uma função f' que represente um menor valor de R_{emp} denomina-se **minimização do risco empírico** (GONÇALVES, 2012).

$$c(f(x_i), y_i) = \begin{cases} 1, & \text{se } y_i f(x_i) < 0 \\ 0, & \text{caso contrário} \end{cases} \quad (4.7)$$

Quando os padrões de treinamento (x_i, y_i) são gerados por uma distribuição de probabilidade $P(x, y)$ em $\mathcal{R}^N \times \{-1, +1\}$ (sendo P desconhecida), denomina-se de **risco funcional** a probabilidade de classificação incorreta do classificador f . Esta probabilidade quantifica a capacidade de generalização, conforme mostra a equação (4.8) (GONÇALVES, 2012):

$$R(f) = \int c(f(x_i), y_i) dP(x_i, y_i) \quad (4.8)$$

Na Figura 6 é possível observar uma classe de funções utilizada para separar padrões linearmente separáveis. Neste caso, determina-se uma função que minimize o R_{emp} (representado na figura como a reta mais escura) (GONÇALVES, 2012).




Figura 6 – Classe de hiperplanos com um hiperplano ótimo
Fonte: GONÇALVES, 2012

Com a teoria de aprendizado estatístico é possível limitar a classe de funções (hiperplanos), prevenindo desta forma a obtenção de modelos que apresentem uma baixa taxa de acerto. Estas limitações são impostas ao risco funcional da função e utiliza o conceito de dimensão VC (Vapnik-Chervonenkis) (GONÇALVES, 2012).

A dimensão VC é uma medida da capacidade de uma família de funções de classificação (LIMA, 2009). Ou seja, a dimensão VC do conjunto de funções de classificação G é o número máximo de exemplos de treinamento que pode ser

aprendido pela máquina sem erro, para todas as rotulações possíveis das funções de classificação (GONÇALVES, 2012).

Desta forma, para funções lineares no $\Re^N$ para $n \geq 2$, a dimensão VC é dada por:

$$VC(n) = n + 1 \quad (4.9)$$

A partir de um hiperplano descrito na equação (4.10), define-se **margem** como a menor distância entre os exemplos do conjunto de treinamento e o hiperplano utilizado para separação destas classes (GONÇALVES, 2012).

$$f(x) = (w \cdot x) + b \quad (4.10)$$

Assim, a margem ρ de um classificador é definida da seguinte forma:

$$\rho = \min_i y_i f(x_i) \quad (4.11)$$

Denominam-se **vetores suporte** aqueles vetores que estão próximo ao hiperplano e que serve de base para a determinação da margem. Os vetores suporte estão destacados na Figura 7 por círculos pontilhados.




Figura 7 – Identificação da margem ρ e dos vetores suporte sobre a linha pontilhada
 Fonte: Adaptado de GONÇALVES, 2012

“A solução para o problema de classificação é representada pelos vetores de suporte, os quais são fundamentais na determinação do hiperplano de separação com margem máxima, onde esta é uma característica especial do SVM” (SOARES, 2008).

Pode-se dizer que a SVM é uma técnica usada para o treinamento de classificadores baseada no conceito da minimização do risco estrutural (*structural risk minimization* – SRM) (BURGES, 1998; SANTOS *et al.*, 2010).

Este princípio de minimização do risco estrutural procura minimizar simultaneamente tanto o risco empírico (que se baseia no conceito de que a taxa de erro de uma máquina de aprendizado no seu conjunto de teste é limitado pela soma dos erros de teste) e a dimensão VC (Vapnik-Chervonenkis), maximizando desta maneira a sua capacidade de generalização (LIMA, 2009; SANTOS *et al.*, 2010).

4.2.1 *Least Squares Support Vector Machines (LS-SVM)*

Em alguns casos, a implementação das SVM pode demandar um tempo computacional elevado. No entanto, Suykens propôs uma extensão da teoria das SVM utilizando o método dos mínimos quadrados (BORIN, 2007).

As máquinas de vetores de suporte por mínimos quadrados (*least squares support vector machines* – LS-SVM) proposta por Suykens é uma modificação das SVMs, que utiliza um sistema de equações lineares, além de utilizar também a função de custo baseada em mínimos quadrados. Não obstante, a LS-SVM utiliza restrições de igualdade ao invés de restrições de desigualdade. Devido à isso tudo, esta técnica diminui a complexidade matemática e o tempo computacional ao ser comparada com a SVM (que utiliza a programação quadrática) sem comprometer a qualidade do resultado obtido (SUYKENS *et al.*, 2002; BORIN, 2007; SANTOS *et al.*, 2010).

A desvantagem desta técnica está no fato de que todos os dados de treinamento são considerados vetores de suporte. A SVM, porém, detecta apenas uma pequena fração do conjunto de vetores de suporte durante a fase de treinamento (BORIN, 2007).

Conforme mostrado na Figura 8, a primeira etapa da LS-SVM é mapear os dados $\mathbf{X}$ do espaço de entrada para um espaço de características de alta dimensão (utilizando $\phi(\bullet)$ – um mapeamento linear ou não linear) (BORIN, 2007).




Figura 8 – Representação do mapeamento realizado no espaço de entrada para o espaço de características n -dimensional
 Fonte: BORIN, 2007

Utiliza-se funções núcleo (*kernel*) para mapear os dados do espaço de entrada para o espaço de características. Existem diferentes tipos de núcleos que caracterizam seu modo de reconhecimento dos padrões, dentre os quais pode-se citar (BORIN, 2007; FERRÃO, 2007):

- **Para dados lineares**
 - Função núcleo linear;
- **Para dados não lineares**
 - Polinomial: manipulação de uma função polinomial cujo grau pode ser definido durante os treinamentos;
 - Gaussiano: corresponde a um espaço de características de dimensão infinita. Neste caso, a SVM apresentará características de uma rede de função de base radial (RBF);
 - Sigmoidal: a SVM apresentará características de uma rede neural.

A Tabela 6 mostra as expressões relacionada a cada função núcleo.

Os resultados obtidos pela SVM possuem forte influência pela definição do núcleo e de seus parâmetros (BORIN, 2007).

Tabela 6 – Funções núcleo para mapeamento dos dados do espaço de entrada para o espaço de características

Núcleo	Expressão	Parâmetros
Linear	$x^T \cdot y$	-
RBF	$\exp\left(-\frac{\ x-y\ ^2}{2\sigma^2}\right)$	σ^2
Polinomial	$(x^T y + a)^b$	a, b
Sigmóide	$\tanh(\beta_0 x^T y + \beta_1)$	β_0, β_1

Fonte: BORIN, 2007

Considerando o seguinte conjunto de treinamento:

$$(x_i, y_i), \dots, (x_n, y_n) \in R^N \times R$$

Utiliza-se a função $\phi(x)$ para mapear o espaço de entrada original R^N para um espaço de características de alta dimensão:

$$\phi(x) = (\phi(x_1), \phi(x_2), \dots, \phi(x_n)) \quad (4.12)$$

A técnica SVM procura ajustar os vetores de suporte definidos em um hiperplano, buscando separar os dados de entrada. Neste espaço de característica de alta dimensão é que ocorrerá a regressão linear baseada na seguinte equação utilizada para aproximar a relação entre entrada e saída:

$$y_i = w\phi(x) + b \quad (4.13)$$

sendo que b é um limiar escalar (*threshold*), w é um coeficiente de ponderação e $\phi(x)$ é uma não linearidade mapeada a partir da entrada (BORIN, 2007; SANTOS *et al.*, 2010).

Os coeficientes w e b são estimados pela minimização da seguinte função de risco, J , dada por:

Minimizar

$$J = \frac{1}{2} \|W\|^2 + \gamma \frac{1}{2} \sum_{i=1}^N \varepsilon(y_i, f(x_i)) \quad (4.14)$$

tal que

$$\varepsilon(y_i, f(x_i)) = \begin{cases} 0, & |y_i, f(x_i)| \leq \varepsilon \\ |y_i, f(x_i)| - \varepsilon, & \text{outros} \end{cases} \quad (4.15)$$

onde W é o vetor de ponderações e γ é um parâmetro de regularização que estabelece um equilíbrio entre a complexidade do modelo e o erro de treinamento (SANTOS *et al.*, 2010).

A função objetivo descrita em (4.14), pode ser dividida em duas partes (BORIN *et al.*, 2007; SANTOS *et al.*, 2010):

- A primeira parte da equação (4.14) pode ser considerada um decaimento utilizado para regularizar os pesos e penalizar aqueles que são elevados. A necessidade deste procedimento deve-se ao fato de que os pesos elevados causam excessiva variância do modelo, deteriorando a capacidade de generalização das LS-SVM (risco de ocorrer sobreajustes);
- A segunda parte da equação (4.14) representa os erros de regressão para todos os dados de treinamento. O parâmetro γ , que fornece o peso relativo desta segunda parte da equação (quando comparado com a primeira parte da mesma), deve ser otimizado pelo usuário.

A definição do erro de regressão está definida na restrição de igualdade descrita em (4.15).

Quando se trata de casos de padrões não linearmente separáveis, pode-se adicionar variáveis ao problema (chamadas de “variáveis soltas”), transformando-se assim a equação (4.14) em uma função objetivo primal (SANTOS *et al.*, 2010):

Minimizar

$$J = \frac{1}{2} \|W\|^2 + \gamma \frac{1}{2} \sum_{i=1}^N (\zeta_i, \zeta_i^*), \quad (4.16)$$

sujeito a

$$y_i - W \cdot \phi(x_i) - b \leq \varepsilon + \zeta_i \quad (4.17)$$

$$W \cdot \phi(x_i) + b - y_i \leq \varepsilon + \zeta_i^* \quad (4.18)$$

onde $i = 1, \dots, N$ e $\zeta_i, \zeta_i^* \geq 0$.

Segundo SUYKENS *et al.* (2002), as formulações de SVM são feitas considerando-se um contexto de uma teoria de otimização convexa.

A vantagem da otimização convexa da função custo deve-se ao fato desta apresentar apenas um mínimo global. Conforme mostrado na figura a seguir, fica evidente a sua conveniência quando comparado com a função complexa que possui diferentes mínimos locais (BORIN, 2007).




Figura 9 – Representação de uma função complexa com presença de mínimos locais e de uma função convexa com um mínimo global

Fonte: BORIN, 2007

Os problemas de otimização do tipo convexo podem ser resolvidos aplicando-se o método dos multiplicadores de Lagrange α_i e α_i^* (também chamados de vetores de suporte), desta forma (LORENA e CARVALHO, 2007; SUYKENS *et al.*, 2002; SANTOS *et al.*, 2010):

$$f(x, \alpha_i, \alpha_i^*) = \sum_{i=1}^N (\alpha_i - \alpha_i^*) \cdot K(x_i, x_j) + b \quad (4.19)$$

onde $K(x_i, x_j)$ é a função núcleo. Os vetores α_i são obtidos resolvendo-se o sistema linear de equações, seguindo as condições de Karush-Kuhn-Tucker.

Como as SVMs são estruturas de natureza linear, para utilizá-la em classificações não lineares, utiliza-se estruturas denominadas núcleos que geram um mapeamento entre o espaço de entrada e um espaço de alta dimensionalidade, chamado espaço de características. Desta forma, no espaço de características é gerado um hiperplano pela SVM que ao ser mapeado de volta ao espaço de entrada, torna-se uma superfície não linear. Consequentemente, o hiperplano de separação neste caso, deixa de ser uma função linear de vetores de entrada e torna-se uma função linear de vetores do espaço de características (LIMA, 2009; SANTOS *et al.*, 2010).

O subterfúgio de utilizar a função núcleo para a substituição de $\phi(x_i)$ e $\phi(x_j)$ tem como objetivo simplificar o cálculo por função aproximada.

Neste caso, $K(x_i, x_j)$ é equivalente ao produto interno de dois vetores x_i e x_j no espaço de características, $\phi(x_i)$ e $\phi(x_j)$, ou seja, $K(x_i, x_j) = \phi(x_i)^T \phi(x_j)$ (SANTOS *et al.*, 2010).

Existem diversas funções de núcleos comuns. Mas no caso deste trabalho, utilizou-se a função de base radial gaussiana (RBF – *radial basis function*), conforme a equação:

$$K(x, y) = \exp\left(-\frac{\|x - y\|^2}{2\sigma^2}\right) \quad (4.20)$$

onde σ é a largura das gaussianas (LIMA, 2009; SANTOS *et al.*, 2010).

4.3 REDE NEURAL PROBABILÍSTICA

As redes neurais artificiais são frequentemente empregadas nas tarefas relacionadas à classificação de padrões, especialmente quando um conjunto de dados está disponível para o aprendizado do algoritmo. Existem à disposição das redes neurais diferentes regras de aprendizado, que basicamente determinam padrões estatísticos a partir de um conjunto de amostras de treinamento para então classificar os novos padrões com base nas informações adquiridas (SPECHT, 1990).

SPECHT (1990) propôs o algoritmo de rede neural probabilística (PNN – *probabilistic neural network*) ao basear-se na rede neural de base radial e na substituição da função ativação de sigmóide para uma função de distribuição de probabilidade. Desta forma, a PNN se aproxima da superfície de decisão ótima de Bayes. Outra vantagem da PNN consiste no fato de necessitar apenas um passo para o seu treinamento.

Dentre as desvantagens, pode-se citar a necessidade de armazenar todas as amostras utilizadas no processo de treinamento para a classificação de novos padrões (MACHADO, 2006).

4.3.1 Estratégia de Bayes na Classificação de Padrões

Considerando-se uma situação onde existam duas categorias para um conjunto de dados θ , onde cada dado pode ser classificado em θ_A ou θ_B . Baseando-se em um conjunto de medições representadas por um vetor n -dimensional $X^t = [X_1 \dots X_i \dots X_n]$, a regra de decisão de Bayes é a seguinte:

$$\begin{aligned} d(X) &= \theta_A \text{ se } h_A l_A f_A(X) > h_B l_B f_B(X) \\ d(X) &= \theta_B \text{ se } h_A l_A f_A(X) < h_B l_B f_B(X) \end{aligned} \quad (4.21)$$

onde $f_A(X)$ e $f_B(X)$ são funções densidade de probabilidade para categorias A e B ; l_A é a função incerteza associada com a decisão $d(X) = \theta_B$ quando $\theta = \theta_A$; l_B é a função incerteza associada com a decisão $d(X) = \theta_A$ quando $\theta = \theta_B$ (quando as

decisões são corretas as perdas são zero); h_A corresponde a probabilidade *a priori* de ocorrência do padrão da categoria A ; $h_B = 1 - h_A$ corresponde a probabilidade *a priori* de que $\theta = \theta_B$.

Portanto a fronteira entre a região onde a decisão de Bayes $d(X) = \theta_A$ e a região onde $d(X) = \theta_B$ é dada pela equação

$$f_A(X) = K f_B(X) \quad (4.22)$$

onde

$$K = \frac{h_B l_B}{h_A l_A} \quad (4.23)$$

De maneira geral, a superfície de decisão entre duas categorias definidas pela equação (4.22) pode ser arbitrariamente complexa, desde que não existam restrições sobre as densidades com exceção às condições cujas funções densidade de probabilidade sejam não negativas, integráveis e que suas integrais sobre todo o espaço sejam iguais à unidade (SPECHT, 1990; MACHADO, 2006).

A possibilidade de se estimar funções densidade de probabilidade baseada em padrões de treinamento é essencial na utilização da equação (4.22). Normalmente probabilidades *a priori* podem ser conhecidas/estimadas, enquanto que as funções de incerteza necessitam de avaliação subjetiva. Contudo, no caso de as densidades de probabilidade dos padrões das classes a serem separadas serem desconhecidas, e ainda, caso esteja somente disponível um conjunto de padrões de treinamento, então, serão esses padrões que fornecerão a única pista para a estimação da densidade de probabilidade desconhecida (SPECHT, 1990; MACHADO, 2006). Neste caso, SPECHT (2010) propõe a utilização do seguinte estimador:

$$f_A(X) = \frac{1}{(2\pi)^{\frac{n}{2}} \sigma^n} \frac{1}{m} \sum_{i=1}^m \exp \left[-\frac{(X - X_{Ai})^T (X - X_{Ai})}{2\sigma^2} \right] \quad (4.24)$$

onde

i é o número padrão;

m é o número total de padrões de treinamento;

X_{Ai} é o i -ésimo padrão de treinamento da categoria θ_{A_i} ;
 σ é o parâmetro de amaciamento;
 n é a dimensionalidade do espaço de medição.

4.3.2 Estrutura da Rede Neural Probabilística

Existe uma notável similaridade entre uma rede que classifica padrões utilizando estimadores de uma função densidade de probabilidade e uma rede neural de base radial utilizada para treinar outros algoritmos (SPECHT, 1990). A Figura 10 mostra a organização da rede neural para classificação de padrões de entrada X em duas categorias.




Figura 10 – Arquitetura básica de rede neural probabilística
 Fonte: Adaptado de SPECHT (1990)

Na Figura 10, a camada de entrada é uma unidade de distribuição que fornece os mesmos valores de entrada para toda a camada de reconhecimento.

Trata-se de uma camada fictícia, pois nesta camada os seus neurônios não realizam nenhuma operação. Já a camada de reconhecimento é constituída de um neurônio para cada caso do conjunto de treinamento. O processo de classificação se inicia com o recebimento da amostra desconhecida para todos os neurônios da camada de reconhecimento. Neste ponto, cada neurônio deve calcular a distância medida entre a amostra de entrada e o conjunto de treinamento ao qual ele pertence, sendo esta distância o argumento da função de ativação do neurônio. Em seguida, cada neurônio da camada de somatório, soma a saída dos neurônios da camada de reconhecimento correspondente à sua classe. O nível de ativação do neurônio somador k é o valor da função densidade de probabilidade estimada da população k . Por fim, o neurônio da camada de saída é um classificador simples que decide qual das entradas proveniente da camada de somatório possui o valor máximo (SPECHT, 1990; MANCUZO, 1999).

5 APLICAÇÃO DAS METODOLOGIAS

Este capítulo apresenta a aplicação das metodologias descritas no capítulo anterior na classificação dos elementos de um banco de dados contendo um histórico da análise cromatográfica de óleo isolante de transformadores de potência de seis usinas termelétricas vinculadas à PETROBRAS, bem como em dados apresentados por DUVAL e dePABLO (2001).

5.1 DADOS UTILIZADOS

A pesquisa baseou-se em um banco de dados contendo um histórico da análise cromatográfica de óleo isolante de transformadores de potência de seis usinas termelétricas vinculadas à PETROBRAS. Neste banco de dados tinha-se à disposição a concentração dos seguintes gases dissolvidos nos transformadores de potência destas usinas: hidrogênio (H_2), metano (CH_4), acetileno (C_2H_2), etileno (C_2H_4), etano (C_2H_6), monóxido de carbono (CO) e dióxido de carbono (CO_2). Além disso, em algumas análises também foi constatado o aparecimento de outros dois gases: o nitrogênio (N_2) e o oxigênio (O_2), além de análises físico-químicas do óleo isolante contido em transformadores de potência.

Além disso, o estudo baseou-se nos dados apresentados por DUVAL e dePABLO (2001). Neste estudo os pesquisadores fizeram a interpretação da norma IEC 60599 para análise de gases dissolvidos em óleo de equipamentos elétricos e examinaram as informações do banco de dados da IEC IC 10. Esta base de dados contém informações da inspeção de equipamentos defeituosos que foram retirados de serviço e foram vistoriados por engenheiros experientes e especialistas em manutenção para encontrar a causa raiz da falha do equipamento.

Neste trabalho, DUVAL e dePABLO (2001) relacionaram as falhas de acordo com as suas características:

- Descargas parciais (PD);
- Descargas de energia:
 - Descarga de baixa energia (D1);

- Descarga de alta energia (D2);
- Falhas térmicas:
 - Falhas térmicas abaixo de 300 °C e entre 300 e 700 °C (T1 e T2);
 - Falhas térmicas acima de 700 °C (T3).

Além disso, o banco de dados IEC TC 10 possui também a concentração de gases considerada normal (o termo utilizado na norma é “valor típico”). Neste caso, se a concentração de gases da análise DGA for menor do que o valor típico significa que a probabilidade de ocorrer a falha é baixa. As tabelas consideram os seguintes casos de “valores típicos”:

- Transformadores de potência sem comunicação OLTC (*On load tap charger* – comutador de derivação em carga);
- Transformadores de potência com comunicação OLTC;
- Valores normais para OLTC;
- Instrumentos de transformadores;
- Dados da influência de parâmetros em transformadores de potência.

5.2 METODOLOGIA

A aplicação da metodologia considerou o aprendizado supervisionado.

Para a aprendizagem, os dados disponíveis foram divididos em duas partes: conjunto de dados para treinamento e para validação do modelo. Neste caso, duas abordagens foram utilizadas para esta divisão:

- Percentagem split: 2/3 dos dados para o conjunto treinamento e 1/3 para o conjunto teste;
- *k-fold cross validation* (validação cruzada ou estimação por camadas): nesta abordagem divide-se as amostras em k subconjuntos e realiza-se diversos testes. Neste caso, testa-se o modelo com todos os subconjuntos, exceto um. Este subconjunto não testado é utilizado na validação do modelo. Este procedimento é repetido para um total de k tentativas, cada vez utilizando um subconjunto diferente para a validação. O desempenho do modelo é avaliado pela média de todos

os erros (HAYKIN, 2001). Desta forma, a análise realizada considerou 10 configurações possíveis (10-fold cross-validation):

- *split* 100% treino / 0% teste;
- *split* 90% treino / 10% teste;
- *split* 80% treino / 20% teste;
- *split* 70% treino / 30% teste;
- *split* 60% treino / 40% teste;
- *split* 50% treino / 50% teste;
- *split* 40% treino / 60% teste;
- *split* 30% treino / 70% teste;
- *split* 20% treino / 80% teste;
- *split* 10% treino / 90% teste.

Para a comparação das metodologias, levou-se em consideração os seguintes critérios:

- grau de acerto ou quantidade de classificações corretas;
- tempo total para a aprendizagem;
- erro médio.

5.3 RESULTADOS

As amostras do banco de dados contendo a concentração dos gases de usinas termelétricas descritas no item 5.1 foram utilizadas como valores de entrada (atributos previsores) dos algoritmos de classificação. Desta forma, os dados de entrada foram os seguintes: hidrogênio (H_2), metano (CH_4), acetileno (C_2H_2), etileno (C_2H_4), etano (C_2H_6), monóxido de carbono (CO) e dióxido de carbono (CO_2).

As metodologias descritas no capítulo 3 realizaram a classificação entre as seguintes classes:

- 0 → sem falha;
- 1 → descarga parcial (PD);
- 2 → descarga de baixa energia (D1);

- 3 → descarga de alta energia (D2);
- 4 → falhas térmicas < 300 e [300,700] °C (T1 e T2);
- 5 → falhas térmicas acima de 700 °C;
- 6 → valores normais para transformadores sem comunicação com OLTC.

A Tabela 7 sintetiza os resultados obtidos pelos classificadores em termos da taxa de acerto (%) acrescido do desvio padrão de acertos (%).

Tabela 7 – Desempenho dos classificadores

Amostras de treinamento / Amostras de teste	Taxa de acerto ± desvio padrão (%)		
	Naïve Bayes	LS-SVM	Rede neural probabilística
split 100% treino / 0% teste	100±0	89,49±2,11	76,61±3,16
split 90% treino / 10% teste	100±0	89,49±2,96	76,61±2,12
split 80% treino / 20% teste	100±0	89,49±3,50	76,61±2,06
split 70% treino / 30% teste	100±0	89,83±3,48	76,61±3,41
split 60% treino / 40% teste	100±0	88,81±2,62	76,61±3,01
split 50% treino / 50% teste	100±0	89,15±3,97	76,61±3,70
split 40% treino / 60% teste	100±0	89,15±4,69	76,61±2,78
split 30% treino / 70% teste	100±0	89,83±2,98	76,61±2,02
split 20% treino / 80% teste	100±0	89,15±2,35	76,61±4,52
split 10% treino / 90% teste	100±0	89,15±2,51	76,61±1,79

Fonte: o autor

Na Tabela 8 consta o tempo médio de execução dos algoritmos de classificação (considerando o tempo gasto com o processo de aprendizagem e a classificação dos dados) testados no caso de *Split* de 100%.

Tabela 8 – Tempo médio de execução (aprendizado + classificação)

Algoritmo de classificação	Tempo (em segundos)
Naïve Bayes	73,1
LS-SVM	14,9
Rede neural probabilística	12,7

Fonte: o autor

6 CONCLUSÃO

Neste trabalho, o foco na tarefa de classificação de dados foi abordado. Neste caso, os algoritmos classificadores atribuíram às amostras de dados diferentes classes podendo indicar a falha no transformador ou não. Em termos de desempenho, pode-se avaliar a precisão da classificação, a qualidade da solução encontrada e o tempo de execução.

Dentre as metodologias abordadas fica evidente a vantagem do algoritmo classificador Naïve Bayes. Este é o mais simples dos classificadores probabilísticos. O modelo construído é na verdade um conjunto de probabilidades.

Em contrapartida, o classificador Naïve Bayes apresentou o maior tempo de execução.

Dentre as outras técnicas aplicadas, pode-se reforçar o fato de que o treinamento da LS-SVM encontra uma solução global, enquanto que a RNA acaba recaindo em mínimos locais. Por este motivo a técnica de LS-SVM tem recebido cada vez mais atenção nos últimos anos.

Os algoritmos de agrupamento e classificação podem ser sensíveis à escala dos dados e à normalização. Portanto, estes fatores podem interferir nos resultados dos algoritmos testados.

Desta forma, quanto melhor a qualidade dos dados, melhores serão os resultados do processo de classificação de suas amostras.

Como sugestão para os próximos passos, com o intuito de obter uma melhor classificação de dados de operação normal e de falhas por meio de dados relativos à análise cromatográfica de óleo isolante em transformadores de potência, pode-se incluir a seleção de atributos através do uso de filtros. Desta forma, ao remover atributos irrelevantes ou redundantes, pode-se reduzir o tamanho do conjunto de dados e facilitar a análise dos resultados no processo de mineração.

REFERÊNCIAS

ABE, S. **Support vector machines for pattern classification**. London: Springer, 2005.

AMATRIAIN, X.; JAIMES, A.; OLIVER, N.; PUJOL, J. M. **Data mining methods for recommender systems**. In: RICCI, F.; ROKACH, L.; SHAPIRA, B.; KANTOR, P. B. **Recommender systems handbook**. Springer Science + Business Media, 39-71, 2011.

ANDREOLA, R. **Support vector machines na classificação de imagens hiperespectrais**, Dissertação de mestrado, Programa de Pós-Graduação em Sensoriamento Remoto, Universidade Federal do Rio Grande do Sul, Porto Alegre, RS, 2009.

Associação Brasileira de Normas Técnicas. Transformador de potência, NBR 5356. Rio de Janeiro, Agosto/1993.

Associação Brasileira de Normas Técnicas. Interpretação da análise dos gases de transformadores em serviço, NBR 7274. Rio de Janeiro, Abril/1983.

ARAGÃO, F. A. P. **Carregamento dinâmico de transformadores a partir de modelos da dinâmica térmica**, Dissertação de mestrado, Programa de Pós-Graduação em Engenharia Elétrica, Universidade Federal do Ceará, Fortaleza, CE, 2009.

ARAÚJO, D. C. P. **Estudo de Metodologia e Técnicas para Execução de Ensaio de Resposta em Frequência em Transformadores de Potência**, Dissertação de mestrado, Programa de Pós-Graduação em Engenharia Elétrica, Universidade Federal de Minas Gerais, Belo Horizonte, MG, 2009.

BARANOSKI, F. L. **Verificação da autoria em documentos manuscritos usando SVM**, Dissertação de mestrado, Programa de Pós-Graduação em Informática Aplicada, Pontifícia Universidade Católica do Paraná, Curitiba, PR, 2005.

BARBOSA, F. R. **Monitoramento on-line e diagnóstico inteligente da qualidade dielétrica do isolamento líquido de transformadores de potência**, Dissertação de mestrado, Programa de Pós-Graduação em Engenharia Elétrica, Universidade Federal do Ceará, Fortaleza, CE, 2007.

BODZENTA, J.; BURAK, B.; GACEK, Z.; JAKUBIK, W.; KOCHOWSKI, S.; URBANCZYK, M. Thin palladium film as a sensor of hydrogen gas dissolved in transformer oil. **Sensors and Actuators B** **87**, 82-87, 2002.

BOOTH, C.; MCDONALD, J. The use of artificial neural networks for condition monitoring of electrical power transformers. **Neurocomputing** **23**, 97-109, 1998.

BOSWORTH, T.; SETFORD, S.; HEYWOOD, R.; SAINI, S. Pulsed amperometric detection of furan compounds in transformer oil. **Analytica Chimica Acta** **450**, 253-261, 2001.

BOSWORTH, T.; SETFORD, S.; HEYWOOD, R.; SAINI, S. Electrochemical sensor for predicting transformer overload by phenol measurement. **Talanta** **59**, 797-807, 2003.

BORGES, H. B. **Redução de dimensionalidade em bases de dados de expressão gênica**, Dissertação de mestrado, Programa de Pós-Graduação em Informática, Pontifícia Universidade Católica do Paraná, Curitiba, PR, 2006.

BORIN, A. **Aplicações de máquina de vetores de suporte por mínimos quadrados (LS-SVM) na quantificação de parâmetros de qualidade de matrizes lácteas**, Tese de doutorado, Instituto de Química, Universidade Estadual de Campinas, SP, 2007.

BRAGA, I. A. **Aprendizado semissupervisionado multidescrição em classificação de textos**, Dissertação de mestrado, Ciências de Computação e Matemática Computacional, ICMC-USP, Universidade de São Paulo, São Carlos, SP, 2010.

BROGINI, A.; SLANZI, D. **Several computational studies about variable selection for probabilistic Bayesian classifiers**. In: PALUMBO, F., *et al.* **Data analysis and classification: studies in classification, data analysis, and knowledge organization**. Springer-Verlag Berlin Heidelberg, 199-207, 2010.

BURGES, C. J. C. A tutorial on support vector machines for pattern recognition. **Data mining and knowledge discovery**, vol. 2, nr. 2, 121-167, 1998.

CASTILLO, E. V. **Aplicação de ontologia e sistema especialista para diagnóstico de falhas em transformadores de potência**, Dissertação de mestrado, Programa de Pós-Graduação em Engenharia Elétrica, Universidade Federal de Santa Catarina, Florianópolis, SC, 2003.

CASTRO, A.; MIRANDA, V. An interpretation of neural networks as inference engines with application to transformer failure diagnosis. **Electrical Power and Energy Systems** **27**, 620-626, 2005.

CHÁVEZ, G. C.; LIANG, Z. Sistema celular para reconhecimento de padrão invariante. **IV Workshop em tratamento de imagens**, NPDI/DCC/ICEx/UFMG, 62-70, 2003.

CHEN, A.; LIN, C. Fuzzy approaches for fault diagnosis of transformers. **Fuzzy Sets and Systems** **118**, 139-151, 2001.

COURY, D. V. **Introdução aos Sistemas Elétricos de Potência. Universidade de São Paulo. Escola de Engenharia de São Carlos.** Departamento de Engenharia Elétrica. SEL 308. Disponível em: <
<http://www.google.com.br/url?sa=t&source=web&cd=1&ved=0CBgQFjAA&url=http%3A%2F%2Fwww.sel.eesc.sc.usp.br%2Fprotecao%2Fapostilasep1.pdf&ei=YHRdTriql8nZgAfSorCMAg&usq=AFQjCNGaDvv779sL1GYOA-rhMZVwOXaqYg>>. Acesso em: 03 ago 2011.

DONG, L.; XIAO, D.; LIANG, Y.; LIU, Y. Rough set and fuzzy wavelet neural network integrated with least square weighted fusion algorithm based fault diagnosis research for power transformers. **Electric Power Systems Research** **78**, 129-136, 2008.

DURASAMY, V.; DEVARAJAN, N.; SOMASUNDARESWARI, D.; VASANTH, A.; SIVANANDAM, S. Neuro fuzzy schemes for fault detection in power transformer. **Applied Soft Computing** **7**, 534-539, 2007.

DUVAL, M.; dePABLO, A. Interpretation of gas-in-oil analysis using new IEC publication 60599 and IEC TC 10 databases, **IEEE Electrical Insulation Magazine**, 17(2): 31-41, 2001.

FAN, L., POH, K. -L., ZHOU, P., A sequential feature extraction approach for Naïve Bayes classification of microarray data. **Expert System with Applications**, 36(6): 9919-9923, 2009.

FARAG, A.; SHEWHDI, M.; JIN, X.; WANG, C.; CHENG, T.; DONG, X.; GAO, S.; JING, W.; WANG, Z. On-line partial discharge calibration and monitoring for power transformers. **Electric Power Systems Research** **50**, 47-54, 1999.

FEI, S.; SUN, Y. Forecasting dissolved gases content in power transformer oil based on support vector machine with genetic algorithm. **Electric Power Systems Research** **78**, 507-514, 2008.

FEI, S.; LIU, C.; MIAO, Y. Support vector machine with genetic algorithm for forecasting of key-gas ratios in oil-immersed transformer. **Expert Systems with Applications** **36**, 6326-6331, 2009a.

FEI, S.; WANG, M.; MIAO, Y.; TU, J.; LIU, C. Particle swarm optimization-based support vector machine for forecasting dissolved gases content in power transformer oil. **Energy Conversion and Management** **50**, 1604-1609, 2009b.

FEI, S.; ZHANG, X. Fault diagnosis of power transformer based on support vector machine with genetic algorithm. **Expert Systems with Applications** **36**, 11352-11357, 2009c.

FERRÃO, M. F.; MELLO, C.; BORIN, A.; MARETTO, D. A.; POPPI, R. J. LS-SVM: uma nova ferramenta quimiométrica para regressão multivariada. Comparação de modelos de regressão LS-SVM e PLS na quantificação de adulterantes em leite em pó empregando NIR. **Quim. Nova**, Vol. 30, nr. 4, 852-859, 2007.

FONSECA, E. S. **Wavelets, predição linear e LS-SVM aplicados na análise e classificação de sinais de vozes patológicas**, Tese de doutorado, Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, SP, 2008.

FUENTE, M.; VEJA, P. Neural networks applied to fault detection of a biotechnological process. **Engineering Applications of Artificial Intelligence** **12**, 569-584, 1999.

GANYUN, L.; HAOZHONG, C.; HAIBAO, Z.; LIXIN, D. Fault diagnosis of power transformer based on multi-layer SVM classifier. **Electric Power Systems Research** **74**, 1-7, 2005.

GONÇALVES, A. R. **Máquina de vetores de suporte**. Disponível em: < <http://www.dca.fee.unicamp.br/~andreric/arquivos/pdfs/svm.pdf> >. Acesso em: 13 mar 2012.

HAYKIN, S., **Redes neurais – princípios e prática**, Ed. Bookman, 2001.

HEIJDEN, F; DUIN, R; RIDDER, D.; TAX, D. **Classification, parameter estimation and state estimation: an engineering approach using MATLAB**. Chichester, Reino Unido: John Wiley & Sons Ltd, 2004.

HUNG, C.; WANG, M. Diagnosis of incipient faults in power transformers using CMAC neural network approach. **Electric Power Systems Research** **71**, 235-244, 2004.

IEC – INTERNATIONAL ELECTROTECHNICAL COMMISSION – 60599. **Mineral oil-impregnated electrical equipment in service**. International Standard, Edition 2.1, 2007-05.

IEEE Std C57.104-1991. **IEEE guide for interpretation of gases generated in oil-immersed transformers**.

JAZEBI, S.; VAHIDI, B.; JANNATI, M. A novel application of wavelet based SVM to transient phenomena identification of power transformers. **Energy Conversion and Management** **52**, 1354-1363, 2011.

JOTA, P.; ISLAM, S.; WU, T.; LEDWICH, G. A class of hybrid intelligent system for fault diagnosis in electric power systems. **Neurocomputing** **23**, 207-224, 1998.

KIL, G.; KIM, I.; PARK, D.; CHOI, S.; PARK, C. Measurements and analysis of the acoustic signals produced by partial discharges in insulation oil. **Current Applied Physics** **9**, 296-300, 2009.

KOUFAKIS, E.; KARAGIANNOPOULOS, C.; BOURKAS, P. Thermal coefficient measurements of the insulation in distribution transformers of a 20 kv network. **Measurement** **41**, 10-19, 2008.

KUO, H.; CHANG, H.; WANG, Y. Symbiotic evolution-based design of *fuzzy*-neural transformer diagnostic system. **Electric Power Systems Research** **72**, 235-244, 2004.

KUO, C. Artificial recognition system for defective types of transformers by acoustic emission. **Expert Systems with Applications** **36**, 10304-10311, 2009.

KUO, C. Artificial identification system for transformer insulation aging. **Expert Systems with Applications** **37**, 4190-4197, 2010.

LIMA, N. H. C. **Comitê de máquinas SVM utilizando reforço adaptativo**, Monografia de conclusão de curso, Engenharia de Computação, Universidade Federal do Rio Grande do Norte, Natal, RN, 2009.

LIMA, S. E. U. **Diagnóstico inteligente de falhas incipientes em transformadores de potência utilizando a análise dos gases dissolvidos em óleo**, Dissertação de mestrado, Programa de Pós-Graduação em Engenharia Elétrica, Universidade Federal do Ceará, Fortaleza, CE, 2005.

LIN, C.; WU, C.; HUANG, P. Grey clustering analysis for incipient fault diagnosis in oil-immersed transformers. **Expert Systems with Applications** **36**, 1371-1379, 2009.

LORENA, A. C. CARVALHO, A. C. P. L. F. Uma introdução às *support vector machines*. **Revista de Informática Aplicada**, Vol. XIX, nr. 2, 43-67, 2007.

MACALPINE, M.; ZHIQIANG, Z.; DEMOKAN, M. Development of a fibre-optic sensor for partial discharges in oil-filled power transformers. **Electric Power Systems Research** **63**, 27-36, 2002.

MACHADO, R. N. M. **Deteção, classificação e quantificação automática de variações de tensão de curta duração para aplicação em análise de pós-operação em sistemas de energia elétrica**, Tese de doutorado, Programa de Pós-

Graduação em Engenharia Elétrica, Universidade Federal do Pará, Belém, PA, 2006.

MANCUZO, M. V. **Deteccção automática de falhas em motores de combustão interna utilizando rede neural**, Dissertação de mestrado, Programa de Pós-Graduação em Engenharia Elétrica, Universidade Federal de Uberlândia, Uberlândia, MG, 1999.

MARETTO, D. A. **Comparação entre máquinas de vetores de suporte por mínimos quadrados (LS-SVM) e métodos lineares para transferência de calibração**, Dissertação de mestrado, Instituto de Química, Universidade Estadual de Campinas, Campinas, SP, 2007.

MELLO, L. C. **Descoberta de conhecimento em banco de dados (mineração de dados) e redes Bayesianas: estado da arte**, Trabalho individual, Instituto de informática, mestrado em Ciência da Computação, Universidade Federal do Rio Grande do Sul, Porto Alegre, RS, 2001.

MELO, L. B. S. **Reconhecimento de padrões textuais para categorização automática de documentos**, Dissertação de mestrado, Programa de Pós-Graduação de Engenharia Elétrica, Universidade Federal do Rio de Janeiro, Rio de Janeiro, RJ, 2007.

MIJAILOVIC, V. Method for effects evaluation of some forms of power transformers preventive maintenance. **Electric Power Systems Research** **78**, 765-776, 2008.

MITCHELL, T. **Machine learning**. McGraw-Hill: New York, NY, USA, 1997.

MORAIS, D. R. **Ferramenta inteligente para detecção de falhas incipientes em transformadores baseada na análise de gases dissolvidos no óleo isolante**, Dissertação de mestrado, Programa de Pós-Graduação em Engenharia Elétrica, Universidade Federal de Santa Catarina, Florianópolis, SC, 2004.

MORAIS, D. R. **Sistema multiagente para diagnóstico integrado de transformadores de potência**, Tese de doutorado, Programa de Pós-Graduação em Engenharia Elétrica, Universidade Federal de Santa Catarina, Florianópolis, SC, 2010.

OSTERMANN, R. **Desenvolvimento de um sistema de gerenciamento de transformadores de potência instalados no sistema de transmissão da companhia estadual de energia elétrica**, Dissertação de mestrado, Programa de Pós-Graduação em Engenharia Elétrica, Pontifícia Universidade Católica do Rio Grande do Sul, Porto Alegre, RS, 2006.

ORMONDE, R. L. R. **Classificação automática de páginas web multi-label via MDL e support vector machines**, Dissertação de mestrado, Departamento de Ciência da Computação, Universidade de Brasília, Brasília, DF, 2009.

PAIXÃO, L. A. **Avaliação da qualidade do óleo isolante em transformadores com o emprego da função discriminante quadrática**, Dissertação de mestrado, Programa de Pós-Graduação em Métodos Numéricos em Engenharia, Universidade Federal do Paraná, Curitiba, PR, 2006.

PAK, A. **Aplicação de técnicas de mineração de texto para categorização de eventos de segurança no CTIR Gov**, Dissertação de mestrado, Programa de Pós-Graduação em Informática, Universidade de Brasília, DF, 2010.

PETROBRÁS – Relatório de Sustentabilidade 2009. Disponível em: < <http://www.petrobras.com.br/rs2009/pt/relatorio-de-sustentabilidade/desempenho-operacional/energia-eletrica/> >. Acesso em: 30 ago 2011.

SÁ, H. R. **Seleção de características para classificação de texto**, Trabalho de graduação, Ciência da Computação, Universidade Federal de Pernambuco, Recife, PE, 2008.

SANTOS, G. S.; LUVIZOTTO, L. G.; MARIANI, V. C; MOURA, L. M; COELHO, L. S. Máquinas de vetores de suporte baseada em mínimos quadrados e evolução diferencial aplicada à identificação de um processo térmico. **XVII Congresso Brasileiro de Automática**, Bonito-MS, 114-121, 2010.

SOARES, H. B. **Análise e classificação de imagens de lesões da pele por atributos de cor, forma e textura utilizando máquinas de vetor de suporte**, Tese de doutorado, Programa de Pós-Graduação em Engenharia Elétrica, Universidade Federal do Rio Grande do Norte, Natal, RN, 2008.

SOUZA, D. C. P. **Falhas e defeitos ocorridos em transformadores de potência do sistema elétrico da Celg, nos últimos 28 anos: um estudo de caso**, Dissertação de mestrado, Programa de Pós-Graduação em Engenharia Elétrica e de Computação, Universidade Federal de Goiás, Goiânia, GO, 2008.

SPECHT, D. F., Probabilistic neural networks. **Neural Networks**, 3(1): 109-118, 1990.

SUYKENS, J. A. K., VAN GESTEL, T., DE BRABANTER, J., DE MOOR, B., VANDEWALLE, J., **Least squares support vector machines**, World Scientific Pub. Co., Singapore, 2002.

SUN, Y.; ZHANG, S.; MIAO, C.; LI, J. Improved BP Neural Network for Transformer Fault Diagnosis. **Journal of China University of Mining & Technology**, Vol.17, No.1, 138-142, 2007.

TAN, P. N.; STEINBACH, M.; KUMAR, V. **Introduction to data mining**. Addison-Wesley Longman Publishing Co., Inc., Boston, MA, USA, 2005.

TAN, S.; LIM, C.; RAO, M. A hybrid neural network model for rule generation and its application to process fault detection and diagnosis. **Engineering Applications of Artificial Intelligence** **20**, 203-213, 2007.

TESSMER, H. **Uma síntese histórica da evolução do consumo de energia pelo homem**. Disponível em: <http://www.google.com.br/url?sa=t&source=web&cd=1&ved=0CBsQFjAA&url=http%3A%2F%2Fwww.liberato.com.br%2Fupload%2Fquivos%2F0131010716090416.pdf&rct=j&q=Uma%20s%C3%ADntese%20hist%C3%B3rica%20da%20evolu%C3%A7%C3%A3o%20do%20consumo%20de%20energia%20pelo%20homem&ei=aQ9eTszOJ-Lf0QHZwICQAw&usq=AFQjCNGuu-bcD7 X Y2kG8Jg-xKNgq6FLQ&cad=rja>. Acessado em: 07 ago 2011.

VAPNIK, V. **The nature of statistical learning theory**. Nova York: Springer-Verlag, 1995.

VAPNIK, V. N., An overview of statistical learning theory, **IEEE Transactions on Neural Networks**, 10(5): 988-999, 1999.

WAHAB, M.; HAMADA, M.; ZEITOUN, A.; ISMAIL, G. Novel modeling for the prediction of aged transformer oil characteristics. **Electric Power Systems Research** **51**, 61-70, 1999.

WANG, M.; HUNG, C. Novel grey model for the prediction of trend of dissolved gases in oil-filled power apparatus. **Electric Power Systems Research** **67**, 53-58, 2003.

YUN, S.; KIM, J.; PARK, C. Peak load estimation of pole-transformer using load regression equation and assumption of cooling load for customer. **Electrical Power and Energy Systems** **24**, 743-749, 2002.

ZIRBES, R. ROLIM, J.; ZÜRN, H. Metodologias para avaliação e diagnóstico do estado de isolamentos de papel impregnado com óleo mineral. **Revista Controle & Automação**. Vol. 16 nr. 3, julho, agosto e setembro 2005.

APÊNDICE A – TABELAS ADAPTADAS DE DUVAL E DEPABLO, 2001

Annex 1. IEC TC 10 Database of Faulty Equipment Inspected in Service

Table 1 – Abbreviations Used for Equipment Type	
Abbr.	Equipment type
P	Power transformer without communicating OLTC
U	Power transformer with communicating OLTC
R	Reactor
I	Instrument transformer
B	Bushing
C	Cable

Table 2 – Fault Identified as Partial Discharges (PD) by Inspection of the Equipment									
Equip.	Inspection	H ₂	CH ₄	C ₂ H ₂	C ₂ H ₄	C ₂ H ₆	CO	CO ₂	Ref.
U	Low energy partial discharges and x-wax formation	32930	2397	-	-	157	313	560	2
I	Corona and x-wax formation	37800	1740	8	8	249	56	197	4
I	X-wax deposition	92600	10200	-	-	-	6400	103151	4
B	Partial discharges inducing displacement of insulation and bolt	8266	1061	-	-	22	107	498	10
I	Partial discharges	9340	995	7	6	60	60	620	15
I	X-wax deposits	36036	4704	10	5	554	6	347	19
I	X-wax deposits	33046	619	-	2	58	51	1	19
I	X-wax deposits	40280	1069	1	1	1060	1	-	19
I	Heavy x-wax deposits	26788	18342	-	27	2111	704	-	19

Table 3 – Fault Identified as Discharges of Low Energy (D1) by Inspection of the Equipment									
Equip.	Inspection	H ₂	CH ₄	C ₂ H ₂	C ₂ H ₄	C ₂ H ₆	CO	CO ₂	Ref.
P	Loosening of potential ring on bushing, with marks of sparking and tracking	78	20	28	13	11		784	2
P	Sparking between HV braided connection and isolated copper tube	305	100	541	161	33	440	3700	3
S	Selector breaking current in selector tank	35	6	482	26	3	200	2240	3
U	Continuous sparking between metal cups and earthed bolts in winding	543	120	1880	411	41	76	2800	3
P	Tracking to HV bushing	1230	163	692	233	27	130	115	4
P	Tracking in bushing	645	86	317	110	13	74	114	4
R	Tracking to the ground in glue of central beam	60	10	4	4	4	780	7600	4
P	Sparking on tank walls to the bushing	95	10	39	11	-	122	467	4
S	500 OLTC normal operations	6870	1028	5500	900	79	29	388	8
S	3600 OLTC normal operations	10092	5399	37565	6500	530	42	413	8
	Poor shielding contact (electrical problem)	650	81	270	51	170	380	2000	10
C	Traces of discharges in paper of cone junction of HV cable	210	22	7	6	6	19	74	13
R	Sparking from bushing to tank	385	60	159	53	8	465	1250	14
R	Sparking from bushing to tank	4230	690	1180	196	5	438	791	14
R	Tracking in paper	7600	1230	1560	836	318	4970	4080	14
P	Low energy arcing on bushing	595	80	244	89	9	524	2100	14
R	Low energy in core	120	25	40	8	1	500	1600	14
S	Contamination from OLTC	8	-	101	43	-	192	4067	14
R	Tracking in insulation	6454	2313	6432	2159	121	3628	225	14
R	Tracking from windings to beam	2177	1049	705	440	207	4571	3923	14
R	Sparking / Tracking in insulation	1790	580	619	336	321	956	4250	14
P	Sparking from core to ground	1330	10	182	66	20	231	1820	14
U	Contamination from OLTC	4	1	52	7	2	93	519	14
U	Defective OLTC operation	1900	285	7730	957	31	681	732	14

Table 3 – Fault Identified as Discharges of Low Energy (D1) by Inspection of the Equipment

Equip.	Inspection	H ₂	CH ₄	C ₂ H ₂	C ₂ H ₄	C ₂ H ₆	CO	CO ₂	Ref.
B	Low energy arcing in bushing	57	24	30	27	2	540	2518	14
B	Low energy discharge in oil, signs of tracking along inner porcelain	1000	500	500	400	1	200	1000	18

Table 4 – Fault Identified as Discharges of High Energy (D2) by Inspection of the Equipment (cont.)

Equip.	Inspection	H ₂	CH ₄	C ₂ H ₂	C ₂ H ₄	C ₂ H ₆	CO	CO ₂	Ref.
P	Flahover from LV to ground, external	440	89	757	304	19	299	1190	4
S	Arc in selector switch	210	43	187	102	12	167	1070	4
U	Short circuit in distribution windings	2850	1115	3675	1987	138	2330	4330	4
U	Short circuit from LV to ground, internal	7020	1850	4410	2960	-	2140	1000	4
P	Short circuit from LV to connector	545	130	239	153	16	660	2850	4
P	Arcing from windings to porcelain	7150	1440	1760	1210	97	608	2260	4
U	Tertiary windings damaged by arcing	620	325	244	181	38	1480	2530	4
R	Arcing in wet cellulose	120	31	94	66	-	48	271	4
P	Short circuit in windings	755	229	460	404	32	845	5580	4
R	Arcing from windings to ground (inadvertent piece leftover)	5100	1430	1010	1140	-	117	197	4
U	Short circuit in windings	13500	6110	4040	4510	212	8690	1460	4
P	Bushing swollen, tank opened	1570	1110	1830	1780	175	135	602	4
P	Arcing to magnetic circuit (ground)	3090	5020	2540	3800	323	270	400	4
P	Short circuit between conductors	1820	405	634	365	35	1010	8610	4
R	Arcing inside windings	535	160	680	305	16	172	338	4

Table 4 – Fault Identified as Discharges of High Energy (D2) by Inspection of the Equipment (cont.)

Equip.	Inspection	H ₂	CH ₄	C ₂ H ₂	C ₂ H ₄	C ₂ H ₆	CO	CO ₂	Ref.
U	Flash-over between dislocated connection and HV bushing turret	13	3	6	3	1	4	51	9
U	Flash-over due to lightning overvoltage with burnt insulation and leads	137	67	104	53	7	196	1678	9
S	Arcing on selector switch ring	1084	188	769	166	8	38	199	9
U	Arcing between connections to tap changer, burnt areas on windings	34	21	56	49	4	95	315	9
I	Arcing in static shield connections	7940	2000	5390	3120	355	1130	285	10
C	Very short HV high energy discharge, followed by tracking	150	130	30	55	9	120	200	13
R	Arcing from bushing to tank	8200	3790	5830	4620	250	31	85	14
P	Arcing in windings	260	215	277	334	35	130	416	14
P	Arcing in windings	75	15	26	14	7	105	322	14
R	Arcing in windings	530	345	250	266	85	3900	20000	14
P	Arcing in oil	60	5	21	21	2	188	2510	14
R	Arcing in windings	90	28	32	31	8	1380	11700	14
R	Arcing in windings	220	77	240	170	22	1800	13800	14
R	Arcing in windings	5900	1500	2300	1200	68	750	335	14
U	Arcing in windings	420	250	800	530	41	300	751	14
R	Arcing from bushing to tank	2800	2800	3600	3500	234	92	718	14
R	Arcing in bushing	99	170	190	200	20	140	1160	14
U	Arcing in oil duct	310	230	760	610	54	150	631	14
U	Arcing in oil duct	800	160	600	260	23	490	690	14
P	Arcing from bushing to tank	1500	395	323	395	28	365	576	14
P	Arcing from windings to core	20000	13000	57000	29000	1850	2600	2430	14
R	Arcing in windings (molten metal)	305	85	130	197	25	813	8380	14
R	Arcing in windings	1900	530	434	383	35	1890	7570	14
R	Arcing in windings	110	62	250	140	90	680	6470	14

Table 4 – Fault Identified as Discharges of High Energy (D2) by Inspection of the Equipment (cont.)

Equip.	Inspection	H ₂	CH ₄	C ₂ H ₂	C ₂ H ₄	C ₂ H ₆	CO	CO ₂	Ref.
P	Arcing in oil (turret)	3700	1690	3270	2810	128	22	86	14
P	Arcing in oil (turret)	2770	660	763	712	54	522	1490	14
R	Arcing from bushing to tank	245	120	167	131	18	829	4250	14
P	Arcing from HV to tank	1170	255	325	312	18	5	1800	14
R	Arcing from bushing to tank	4419	3564	2025	2861	668	909	9082	14
R	Arcing in bushing	810	580	490	570	111	1100	6800	14
R	Arcing in bushing insulation	5000	1200	1100	1000	83	140	265	14
U	Arcing in OLTC and windings	10000	6730	10400	7330	345	1980	3830	14
U	Arcing in oil from copper bus to tank	1570	735	1740	1330	87	711	4240	14

Table 5 – Fault Identified as Thermal Faults<700°C (T1 and T2) by Inspection of the Equipment (cont.)

Equip.	Inspection	H ₂	CH ₄	C ₂ H ₂	C ₂ H ₄	C ₂ H ₆	CO	CO ₂	Ref.
P	High circulating currents between conductors with winding damage	1270	3450	8	1390	520	483	44500	3
P	Circulating currents in LV windings and core	3420	7870	33	6990	1500	573	4640	3
I	Thermal runaway inside thick insulation with puncture / carbonization of paper	360	610	9	260	259	12000	74200	5
I	Thermal runaway in thick paper insulation	1	27	1	4	49	53	254	5
U	Blackened area within windings, interturn fault, open circuit parallel path	3675	6392	5	7691	2500	101	833	9
P	Vertical bar buses burnt out, carbonization of paper strips	48	610	-	10	29	1900	970	10
P	Carbonized windings during heat run tests	12	18	-	4	4	559	1710	12

Table 5 – Fault Identified as Thermal Faults<700°C (T1 and T2) by Inspection of the Equipment (cont.)

Equip.	Inspection	H ₂	CH ₄	C ₂ H ₂	C ₂ H ₄	C ₂ H ₆	CO	CO ₂	Ref.
P	Circulating currents in magnetic tank shunt during heat run tests	66	60	-	7	2	76	90	12
U	Overheating of core to ground and insulation shields (narrow oil ducts)	1450	940	61	322	211	2420	3560	14
B	Hot spot with carbon formation	-	18900	330	540	410	3900	710	14
I	Hot spot in paper	960	4000	6	1560	1290	15800	50300	14
I	Hot spot in paper	24700	61000	1560	42100	26300	14400	30400	14
P	Overheating of conductor<200 °C	14	44	1	7	124	128	2746	16
R	Low temperature overheating of clamping beams of yokes by stray flux	2031	149	-	3	20	556	3008	17
R	Idem, with carbonization of beams	480	1075	-	1132	298	464	1000	17
B	Thermodielectric failure	40000	400	6	600	70	800	218	18

Table 6 – Fault Identified as Thermal Faults > 700 °C (T3) by Inspection of the Equipment									
Equip.	Inspection	H ₂	CH ₄	C ₂ H ₂	C ₂ H ₄	C ₂ H ₆	CO	CO ₂	Ref.
P	Hot spot at connection	8800	64064	-	95650	72128	290	90300	1
P	Circulating currents between yoke clamps and connecting bolts	6709	10500	750	17700	1400	290	1500	3
S	Pyrolitic carbon growth between selector contacts	1100	1600	26	2010	221	-	1430	3
P	Steel lamination eroded	290	966	57	1810	299	72	756	4
P	Circulating currents in clamping bolt	2500	10500	6	13500	4790	530	2310	4
U	Contacts of selector switch burnt	1860	4980	1600	10700	-	158	1300	4
U	Lengthy overheating of tap changer contacts	860	1670	40	2050	30	10	690	6
U	Defects on contacts of tap changer selector	150	22	11	60	9	-	-	7
P	High contact resistance of winding terminal	400	940	24	820	210	390	1700	10
P	Ground wiring burnt and ruptured by circulating current	6	2990	67	26076	29990	6	26	10
U	Burnt copper contacts in change over selector	100	200	11	670	110	100	650	11
P	Bad contact in windings	290	1260	8	820	231	228	826	14
R	Bad contact in defective weld in windings	1550	2740	184	5450	816	1140	9360	14
R	Hot spots in laminations	3910	4290	1230	6040	626	1800	11500	14
R	Hot spot in laminations (molten steel)	12705	23498	5188	34257	6047	4004	8539	14
R	Hot spot on bushing	1	8	6	100	8	300	5130	14
R	High temperature in laminations	300	700	36	1700	280	760	9250	14
P	Burnt lamination during heat run test	107	143	2	222	34	193	1330	14

Table 7 – References in Tables 2 - 6 of Annex 1			
Ref.	Year	Authors	Journal/Report
1	1972	J. Rabaud et al.	Rev. Gen. Elec., 31 (11)
2	1976	J. Rabaud et al.	CIGRE TF 12-06
3	1975	R.R. Rogers	Doble Conf., Sec 10-202
4	1974	M. Duval	IEEE C74-476-8
5	1985	M. Duval et al.	IEEE-EI 20 (2)
6	1986	T. Kawamura et al.	CIGRE TF 12-05
7	1985	M. Markestein	CIGRE TF 15-01
8	1988	M. Carballeira et al.	CIGRE TF 15-01
9	1991	M.R. Caldwell	CIGRE TF 15-01-01
10	1986	C. Sobral Viera	CIGRE Paris
11	1991	G.P. Krikke	CIGRE TF 15-01-01
12	1993	J. Aubin	CIGRE TF 12-09
13	1993	D. Couderc	IREQ Report 93-343
14	1991	R. Daoust et al.	IREQ Report 91-164
15	1973	B. Barraclough et al.	IEE London
16	1997	A. dePablo	WG 13 TC 10
17	1997	M. Wang	EPRI China
18	1995	V. Sokolov	Doble Conf., 3B1-3B13
19	1992		EPRI Workshop on TCs

APÊNDICE B – TABELAS ADAPTADAS DE DUVAL E DEPABLO, 2001

Annex 2. IEC TC 10 Database of Typical (Normal) Values in Service

Table 1 – 90% Typical (Normal) Values for Power Transformers Without a Communicating OLTC, in ppm									
Year	Company	H ₂	CH ₄	C ₂ H ₂	C ₂ H ₄	C ₂ H ₆	CO	CO ₂	Ref.
76	LCIE	134	134	-	45	157	1008	10528	1
80	Alsthom	100	200	20	200	200	1000	10000	2
81	EDF	-	225	3	110	225	785	4500	2
82	Asinel	105	125	10	166	71	2000	18000	2
85	Chili	100	50	15	50	65	500	5000	2
88	Asinel	100	70	10	170	70	1000	10000	2
89	Hydro Quebec (HQ)	150		8	220				3
92	LCIE	-	224	5	112	224	2150	6720	4
92	Vattenfall	200	50	3	200	50	1000	20000	4
93	HQ (electrical)	85		70	35	80			8
93	HQ (thermal)	175		3	375	100			8
93	LCIE / EDF	80		4	100	200	800		4
93	Jeumont Schneider	150	-	15	100	200	1000	10000	4
93	Haefely	125	100	20	150	100	500	6000	4
93	ABB Sweden	200	3	-	200	50	1000	20000	4
93	GEC	50	30	5					4
93	Asinel	100	70	10	170	70	1000	10000	4
95	Enel	95	280	10	150	250	700	8000	4
96	Labelec	60	40	3	60	50	540	5100	9
96	Laborelec (tight OLTC)	84	79	56	166	52	673	8068	9
96	Laborelec (no OLTC)	66	111	15	110	90	865	12670	9
99	60599 (Annex A1)	60-150	40-110	3-50	60-280	50-90	540-900	5100-13000	10

Table 2 – 90% Typical (Normal) Values for Power Transformers with a Communicating OLTC, in ppm

Year	Company	H ₂	CH ₄	C ₂ H ₂	C ₂ H ₄	C ₂ H ₆	CO	CO ₂	Ref.
76	LCIE	235	180	336	145	270	672	4256	1
88	Asinel	250	150	150	250	150	1000	10000	2
89	Hydro Quebec (HQ)	150		150	220				3
92	Vattenfall	200	50	30	200	50	1000	20000	4
92	LCIE	134	224	154	224	550	672	3584	4
93	HQ (electrical)	250		280	150	15			8
93	HQ (thermal)	150		22	320	80			8
93	LCIE / EDF	-	150	150	200	550	800	5000	4
93	Jeumont Schneider	150	-	150	200	200	1000	10000	4
93	Enel	200	100	50	100	100	500	10000	4
93	Asinel	250	190	180	250	180	1000	10000	4
96	Labelec	75	35	80	110	50	400	5300	9
96	Laborelec	151	131	266	250	73	848	11818	9
99	60599 (Annex A1)	75- 150	35- 130	80- 270	110- 250	50- 70	400- 850	5300- 12000	10

Table 3 – 90% Typical (Normal) Values for OLTC, in ppm

Year	Company	H ₂	CH ₄	C ₂ H ₂	C ₂ H ₄	C ₂ H ₆	CO	CO ₂	Ref.
92	LCIE	8288	1120	19712	1344	784	448	5600	4

Table 4 – 90% Typical (Normal) Values for Instrument Transformers, in ppm									
Year	Company	H ₂	CH ₄	C ₂ H ₂	C ₂ H ₄	C ₂ H ₆	CO	CO ₂	Ref.
86	Asinel (CTs)	31	6	1	3	8	260	705	2
86	Asinel (VTs)	22	7	-	5	4	180	650	2
87	Kema (CTs)	80	18	1	-	20			2
87	Kema (VTs)	170	16	1	-	8			2
88	Asinel	50	10	5	10	10	1000	10000	2
89	CIGRE	120		5	10				2
89	Hydro Quebec (HQ)	150		3	8				3
91	HQ (CTs)	85		5	9				7
91	HQ (CCVTs)	70		4	30				7
91	HQ (IVTs)	135		4	30				7
91	HQ (CVTs)	1000		16	20				7
93	Labelec	6	11	1	3	7	250	800	9
93	Milan Vidmar	150	120	1	40	130	1100	4000	9
96	ABB (CT, rubber seal)	20	30	2	4	25	330	900	9
96	ABB (CT, metal seal)	300	30	2	4	25	330	900	9
99	60599 (Annex A1)	6-300	11-120	1-5	3-40	7-130	250-1100	800-4000	10

Table 5 – Influence of Various Parameters on 90% Typical (Normal) Values in Power Transformers, in ppm (Typical Examples)					
Parameter	H ₂	C ₂ H ₂	C ₂ H ₄	C ₂ H ₆	Ref.
Transformer sub-type:					
Sealed	100	35	50		6
Breathing, transmission	150	10	280		
Breathing, generation	100	50	200		
Fault type					
Discharges	85	70	35	8	8
Thermal	175	3	375	100	8
Age, in years					
<2	60	5	5	2	8*
2 – 5	100	100	60	15	8*
10 – 20	200	80	80	20	8*
>20	400	150	100	30	8*
* Case of discharges in power transformers P					

Table 6 – Comparison of 90% and 95% Typical Values with Values Based on Actual Probability of Failure in Service (PFS), in ppm (Typical Examples)					
Base for Calculating Typical Values	H ₂	C ₂ H ₂	C ₂ H ₄	C ₂ H ₆	Ref.
90 % value	85	70	35	8	8*
95 % value	220	170	90	20	8*
PFS value	100	300	100	20	8*
*Case of discharges in power transformers P					

Table 7 – References Used in Annex 2			
Ref.	Year	Authors	Journal/Report
1	76	J. Rabaud et al.	CIGRE Paper 12-06
2	80-89	J. Samat et al.	CIGRE TF 15-01
3	89	M. Duval et al.	Doble Conf., p. 10-4
4	90-94	A. Molmann et al.	CIGRE TF 15-01-01
5	90	M. Duval et al.	CEIDP, p. 325
6	90	IEEE / ANSI	C 57-104
7	91	M. Duval et al.	CEIDP, p. 506
8	93	M. Duval et al.	CIGRE Symp., Paper 110-14
9	93-96		IEC TC 10 WG 13
10	99	M. Duval et al.	IEC 60599