
Rede Bayesiana Aplicada ao Diagnóstico de
Falhas Incipientes em Transformadores de
Potência

Angel Javier Quispe Carita

Rede Bayesiana Aplicada ao Diagnóstico de Falhas Incipientes em Transformadores de Potência

Angel Javier Quispe Carita

Orientadora: *Profa. Dra. Luciana Cambraia Leite*

Dissertação apresentada ao Programa de Pós-graduação em Engenharia Elétrica da Universidade Federal de Mato Grosso do Sul como parte dos requisitos para a obtenção do título de Mestre em Engenharia Elétrica.

UFMS - Campo Grande
Julho 2012

Rede Bayesiana Aplicada ao Diagnóstico de Falhas Incipientes em Transformadores de Potência

Angel Javier Quispe Carita

Dissertação de Mestrado submetida à banca examinadora designada pelo Colegiado do Programa de Mestrado em Engenharia Elétrica (PPGEE) da Universidade Federal de Mato Grosso do Sul, como parte dos requisitos necessários à obtenção do grau de Mestre em Engenharia Elétrica.

Aprovada em 11 de Julho de 2012 por:

Luciana Cambraia Leite - Dra.
Profa. DEL/CCET/UFMS - Orientadora

Banca examinadora:

Ruben Barros Godoy - Dr.
Laboratório de Inteligência Artificial,
Eletrônica de Potência e Eletrônica Industrial
BATLAB - UFMS
Prof. DEL/CCET/UFMS

Leandro Sauer - Dr.
Centro de Ciências Humanas e Sociais (CCHS)
Prof. DEA/CCHS/UFMS

À minha esposa, com amor, admiração e gratidão
pela paciência e apoio durante a realização
deste trabalho.

Aos meus pais, que sempre me deram apoio e
contribuíram para minha formação.

Agradecimentos

A **Deus**, primeiramente, por ter me concedido força para concluir mais essa jornada.

A minha orientadora Dra. Luciana Cambraia Leite pelo aconselhamento apoio constante para o meu desenvolvimento pessoal e acadêmico e pela confiança depositada em mim para a conclusão deste trabalho.

A banca examinadora, Dr. Ruben Barros Godoy e Dr. Leandro Sauer, que contribuíram para o refinamento deste trabalho.

A equipe do professores Dr. Milton Ernesto Romero Romero, Dr. Evandro Mazina Martins, Dr. Vladimir Machado, Selma Hashimoto, que contribuíram na minha formação acadêmica.

Aos meus pais Octavia e Camilo por ter me mostrada a importância da educação, pelo apoio e incentivo incondicional em todos os momentos da minha vida.

A minha amada esposa Edith, por ter permanecido ao meu lado, me incentivando a percorrer este caminho, por compartilhar todos os momentos, estendendo sua mão amiga em momentos difíceis.

A minha família toda, em especial aos meus sogros Elsa e Edilberto, minhas irmãs Vilma, Yudith, Yéssica e Ana por me ensinar, apoiar e acompanhar incondicionalmente no caminho da vida.

Aos colegas do mestrado, pela amizade que desenvolvemos durante o curso.

Aos meus amigos Aarão, Rodrigo, André, Max, José, Fernando, Herbert, Meliton, Mario, Raymundo e pessoal da Alvodara que fizeram agradável a minha permanência no Brasil de forma muito especial a Edgelson e Ana Claudia por tratar a mim e minha esposa como parte da sua família.

A todos aqueles que de uma maneira ou de outra contribuíram para que este percurso pudesse ser concluído.

Por último, agradeço ao CNPq e CAPES pelo financiamento que permitiu todos os passos necessários para a confecção desta pesquisa.

"A maior necessidade do mundo é a de homens - homens que não se compram nem se vendam; homens que no íntimo da alma sejam verdadeiros e honestos; homens que não tenham medo de chamar o erro pelo seu nome; homens, cuja consciência seja tão fiel ao dever como a bússola o é ao pólo; homens que permaneçam firmes pelo que é reto, ainda que aconteça tudo"

Ellen White

Resumo

A importância da energia elétrica nesta sociedade moderna é vital para o seu desenvolvimento; falhas ou anomalias deste recurso podem gerar perdas incalculáveis tanto para concessionária como para o usuário final. O transformador é parte fundamental nos sistemas de transmissão e distribuição de energia elétrica: por isso o interesse de acompanhar o bom funcionamento deste equipamento evitando a presença de falhas incipientes. O presente trabalho descreve a estrutura, aprendizagem e aplicação da Rede Bayesiana destinada ao diagnóstico de falhas incipientes de transformadores mediante a análise de gases dissolvidos (DGA) no óleo. A Rede Bayesiana utiliza as relações de concentração de gases metano/hidrogênio (CH_4/H_2), etano/metano (C_2H_6/CH_4), etileno/etano (C_2H_4/C_2H_6) e acetileno/etileno (C_2H_2/C_2H_4), como elementos causais que ativam o diagnóstico da rede: deterioração normal, falha elétrica e falha térmica. A aprendizagem foi realizada a partir de um banco de dados históricos, no qual a Rede Bayesiana apresentou um acerto de 86.64% e 85.19% nos diagnósticos para os conjuntos de dados avaliados, demonstrando assim a confiabilidade e consistência da Rede Bayesiana.

Abstract

The importance of electricity in the modern society is vital for its development. Failures or malfunctions of this resource can cause incalculable losses for both Power Company and consumer. The transformer is a key part in the transmission and distribution of electricity: hence the interest to follow the proper functioning of this equipment, avoiding incipient faults. This work describes the structure, learning and application of Bayesian Network addressed to the diagnosis of faults in power transformer through the dissolved gases analysis (DGA) in oil. The Bayesian Network uses the concentration ratios of gases methane/hydrogen (CH_4/H_2), ethane / methane (C_2H_6/CH_4), ethylene / ethane (C_2H_4/C_2H_6) and acetylene / ethylene (C_2H_2/C_2H_4) as elements that activate the network diagnosis: normal deterioration, electrical failure and thermal failure. The learning was achieved from historical database, in which the Bayesian Network presented a diagnosis of 86.64% and 85.19% successfully for the evaluated groups of database what shows the reliability and consistency of the Bayesian Network.

Sumário

Resumo	i
Abstract	ii
1 Introdução	1
1.1 Revisão Bibliográfica	2
1.2 Justificativa	7
1.2.1 Objetivos	8
1.3 Estrutura do Trabalho	9
2 Diagnóstico de Transformadores de Potência	10
2.1 Diagnóstico de Falhas Incipientes	10
2.1.1 Falhas de origem Térmico	13
2.1.2 Falhas de origem Elétrico	14
2.2 Análise de Gases Desenvolvidos	14
2.2.1 Método de Gás Chave	15
2.2.2 Método de Rogers	17
2.2.3 Método de Doernenburg	18
2.2.4 Método de Duval	19
2.2.5 Método previsto na NBR 7274	20
3 Redes Bayesianas	21
3.1 Noções Gerais da Teoria de Probabilidade	22
3.1.1 Definição freqüentista de probabilidade (ou definição estatística de probabilidade)	22
3.1.2 Axiomas de Kolmogorov	23
3.1.3 Probabilidade condicional e independência	23
3.1.4 Regra de multiplicação	24
3.1.5 Fórmula da probabilidade total	24
3.1.6 Teorema de Bayes	24
3.2 Redes Bayesianas	25
3.2.1 Condição de Markov	26
3.2.2 Cálculo da Distribuição de Probabilidade Conjunta	27
3.2.3 Inferência em Redes Bayesianas	28
3.2.4 Aprendizagem Bayesiana	29
3.3 Distribuição Qui-Quadrado (χ^2)	31
3.3.1 Cálculo do valor χ^2	32

3.3.2	Hipóteses a serem testados	32
3.3.3	A tomada de decisão	33
3.3.4	Coefficiente de contingência de Pearson (CC)	33
4	Metodologia	35
4.1	Definição dos nós da rede Bayesiana	35
4.2	Estados de cada nó	36
4.3	Definição dos nós de diagnóstico	36
4.3.1	Normal	36
4.3.2	Falha de tipo elétrica	37
4.3.3	Falha de tipo térmica	37
4.4	Histórico de dados	37
4.5	Metodologia para determinação da distribuição de probabilidades de cada nó	37
5	Aplicação da Metodologia e Análise dos Resultados	40
5.1	Histórico de Dados Utilizados	40
5.2	Resultados do Primeiro Histórico de Dados	40
5.3	Resultados do Segundo Histórico de Dados	43
6	Conclusões	47
6.1	Conclusões	47
6.2	Trabalhos Futuros	48
A	Histórico de Dados Utilizados para Elaboração da Rede Bayesiana	50
B	Histórico de Dados Utilizados para Validação da Rede Bayesiana	57
C	Tabela de Distribuição Qui-quadrado (χ^2)	60
	Referências	66

Lista de Figuras

1.1	Topologia da rede neural (Arantes, 2005).	3
1.2	Fluxograma do Método Proposto (Morais, 2004).	4
1.3	Estrutura de diagnóstico do sistema especialista proposto (Lin et al., 1993). . .	5
1.4	Graus de pertinência dos conjuntos fuzzy (Bálint, Szilvia & István, 2009). . . .	6
1.5	Fluxograma de processo de determinação de tipo de falha (Filho, 2012)	7
2.1	Geração de gases no sistema de isolamento do transformador de potência. . . .	12
2.2	Pressões parciais do equilíbrio térmico de Halstead como função da temperatura. .	13
2.3	Concentração típica resultante de sobreaquecimento de óleo - Falha Térmica. . .	15
2.4	Concentração típica resultante de sobreaquecimento da celulose - Falha Térmica. .	16
2.5	Concentração típica resultante de descarga parcial - Falha Elétrica.	16
2.6	Concentração típica resultante de arco elétrico - Falha Elétrica.	17
2.7	Triângulo de Duval.	19
3.1	Estrutura básica de uma Rede Bayesiana.	25
3.2	Exemplo de Rede Bayesiana para Detecção de Problemas de Fraude: F=Fraude; I=Idade; S=Sexo; G=Gasolina; J=Jóias	27
3.3	Tipos de inferência entre variável de consulta (<i>Query</i>) e uma evidência (<i>Evidence</i>)	28
4.1	Estrutura da Rede Bayesiana.	36
4.2	Estados das variáveis da Rede Bayesiana.	36
5.1	Diagnóstico estabelecido no banco de dados.	41
5.2	Diagnóstico dado na Rede Bayesiana proposta.	42
C.1	Distribuição Qui-quadrada.	60

Lista de Tabelas

1.1	Vantagens/Desvantagens Comparativas das Redes Bayesianas.	8
2.1	Gases gerados no sistema de isolamento do transformador de potência.	12
2.2	Definição dos códigos de Rogers	17
2.3	Diagnóstico de falhas baseado nos códigos da Tabela 2.2	18
2.4	Critério de identificação de falha de Doernenburg	18
2.5	Concentração dos gases para validação do método de Doernenburg	19
2.6	Diagnóstico de falhas NBR 7274	20
4.1	Distribuição de probabilidade de R_1	38
4.2	Distribuição de probabilidade de R_2	38
4.3	Distribuição de probabilidade de R_3	38
4.4	Distribuição de probabilidade de R_4	38
4.5	Distribuição de probabilidade de Normal	38
4.6	Distribuição de probabilidade de Falha Elétrica	39
4.7	Distribuição de probabilidade de Falha Térmica	39
5.1	Diagnósticos dados pela RB e o especialista (BD1)	41
5.2	Comparação de casos avaliados da RB com diagnósticos dado no BD1	42
5.3	Cruzamento de dados de diagnóstico do especialista e a rede Bayesiana	43
5.4	Frequências esperadas para o teste Qui-quadrada	43
5.5	Diagnósticos dados pela RB e o especialista (BD2)	45
5.6	Comparação de casos avaliados da RB com diagnósticos dado no BD2	45
5.7	Cruzamento de dados de diagnóstico do especialista e a rede Bayesiana (BD2)	46
5.8	Frequências esperadas para o teste Qui-quadrada (BD2)	46
A.1	Transformador 1	50
A.2	Transformador 2	51
A.3	Transformador 3	51
A.4	Transformador 4	51
A.5	Transformador 5	52
A.6	Transformador 6	52
A.7	Transformador 7	52
A.8	Transformador 8	53
A.9	Transformador 9	53
A.10	Transformador 10	53
A.11	Transformador 11	53
A.12	Transformador 12	54

A.13 Transformador 13	54
A.14 Transformador 14	54
A.15 Transformador 15	54
A.16 Transformador 16	55
A.17 Transformador 17	55
A.18 Transformador 18	55
A.19 Transformador 19	55
A.20 Transformador 20	56
B.1 Conjunto de dados publicados na IEC 60599 (parte 1/2)	58
B.2 Conjunto de dados publicados na IEC 60599 (parte 2/2)	59
C.1 Distribuição Qui-quadrado (χ^2)	61

Introdução

No mundo atual a energia elétrica é um recurso de fundamental importância para o desenvolvimento da sociedade, tornando-se indispensável em todas as atividades modernas passando a ser parte do cotidiano viver. Falhas ou anomalias no fornecimento deste recurso podem deixar importantes cargas inoperantes ocasionando grandes desequilíbrios econômicos, financeiros e de segurança.

O transformador de potência é uma das partes fundamentais nos sistemas de transmissão e distribuição confiável de energia elétrica, que garante a conversão de diferentes níveis de tensão com limites de estabilidade normados, interligando os locais de geração de energia elétrica até os pontos de uso final.

Trata-se de um equipamento de alto custo no contexto de sistemas elétricos de potência. A presença de uma falha pode interferir na transmissão e distribuição de energia elétrica ocasionando perdas catastróficas para a concessionária, pela quantidade de energia e faturação parada no lapso da reposição que em alguns casos pode chegar até os seis meses (Perez et al., 2009).

Neste cenário torna-se fundamental o monitoramento constante do funcionamento e da operação dos transformadores, principalmente os transformadores elevadores das usinas e subestações, buscando evitar-se a ocorrência de superaquecimentos, arcos ou descargas parciais, deterioração acentuada da isolação, formação excessiva de gases, etc., problemas estes derivados de esforços térmicos, mecânicos e elétricos e de reações físico-químicas que ocorrem internamente no transformador. Deve-se ter em conta também que a maioria dos transformadores em operação no Brasil foi instalada há 30, 40 anos atrás, além do que, devido a escassez de energia ocorrida há alguns anos, os transformadores tiveram que operar em constantes sobrecargas o

que só tem agravado o envelhecimento da isolação (Arantes, 2005).

De acordo com estudos realizados sobre os transformadores, o tempo de vida útil razoável deste equipamento varia de 25 a 30 anos (Arantes, 2005). Cabe mencionar que com um monitoramento e cuidado adequados o tempo de vida poderia ser otimizado além do tempo previsto pelo fabricante.

Até o momento numerosas pesquisas no campo da inteligência artificial (Arantes, 2005) (Mamat et al., 2008) (de Aquino et al., 18-23 July 2010) (Morais, 2004) (Németh et al., 2009) (de Medeiros Junior, 2011), como redes neurais, lógica fuzzy, sistemas híbridos, sistemas especialistas, máquinas de estados e outros métodos e teorias estatísticas, foram desenvolvidas para melhorar a eficácia do transformador, propondo distintas ferramentas que permitam detectar as falhas apresentadas neste equipamento.

1.1 Revisão Bibliográfica

Na literatura encontramos várias pesquisas relacionados com o tema desta dissertação, as quais passamos a mencionar:

(Mamat et al., 2008) propuseram uma versão híbrida de uma rede neural artificial de múltiplas camadas (HMLP) que consiste em um sistema de classificação inteligente baseado na análise dos gases dissolvidos (DGA). A camada de entrada da rede possui cinco gases dissolvidos: hidrogênio (H_2), metano (CH_4), etano (C_2H_6), etileno (C_2H_4) e acetileno (C_2H_2); e na saída uma versão híbrida classifica os transformadores em quatro condições: normal, sobreaquecimento, descarga e arco elétrico. A rede foi treinada usando o algoritmo de erro de previsão recursiva modificada (MRPE). Os resultados indicam que a rede neural HMLP com algoritmo de aprendizagem MRPE pode ser treinada mais rápido em comparação com outras três redes neurais artificiais padrões (rede neural de múltiplas camadas (MLP), com algoritmos de aprendizagem: regulação bayesiana (RB), Lavenberg-Marquardt (LM) e gradiente descendente), conseqüentemente, a rede neural HMLP treinada com algoritmo de aprendizagem MRPE produziu o melhor desempenho com precisão de 90%. A segunda maior precisão foi a rede neural MLP treinada com algoritmo LM, que obteve a mesma precisão que a rede neural MLP com algoritmo de aprendizagem RB. Finalmente, a rede neural MLP treinada por gradiente descendente mostrou ser o sistema de pior prognóstico com a menor precisão, de 61,43%.

Em (de Aquino et al., 18-23 July 2010), os autores implementaram um sistema fuzzy para a detecção de falhas incipiente de transformadores de potência através da análise cromatográfica.

fica do óleo isolante. O sistema faz uso das normas de ROGERS e IEC 599, utilizando as três relações de gases contidas nas normas mencionadas (Acetileno/Etileno, Metano/Hidrogênio e Etileno/Etano) e a partir delas utiliza a lógica fuzzy para diagnosticar os prováveis defeitos que podem estar ocorrendo no transformador. Adicionalmente, o sistema é capaz de indicar um provável defeito, mesmo quando as relações dos gases não se encontram tabeladas pelas normas.

(Arantes, 2005) fez uma revisão ampliada sobre os métodos utilizados na análise de gases dissolvidos que se apresentam no óleo isolante, e criou uma rede neural artificial para o diagnóstico de falhas em transformadores de potência baseando-se nos resultados obtidos através da análise de gases dissolvidos (DGA) em óleo isolante ao longo de sua vida útil. A topologia da rede desenvolvida apresentou número de neurônios na camada de entrada igual ao número de neurônios na camada de saída; na entrada da rede foram escolhidos cinco gases considerados como gases chaves precursores de falhas (hidrogênio, metano, etano, etileno e acetileno) e na saída cada neurônio representa uma falha do equipamento (falha térmica ou sobreaquecimento, descargas parciais, arco elétrico, ou ainda falhas não identificadas, além de saída normal).

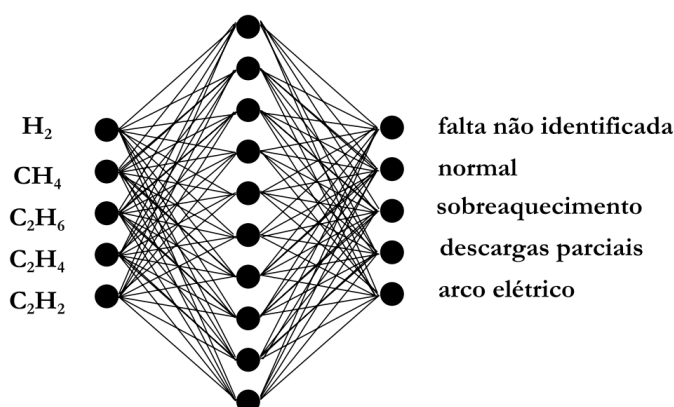


Figura 1.1: Topologia da rede neural (Arantes, 2005).

Concluiu-se que os métodos que utilizam técnicas de Inteligência Artificial são mais precisos e mais rápidos que os métodos tradicionais, trazendo mais segurança ao pessoal de decisão, responsável pela operação e manutenção dos sistemas elétricos de potência.

(Morais, 2004) tentou suprir as deficiências dos métodos convencionais, agrupando em uma mesma ferramenta as normas utilizadas para a análise de gases dissolvidos no óleo (DGA) aliadas às técnicas de redes neurais e lógica fuzzy referenciadas na literatura. Desenvolveu e implementou uma ferramenta de diagnóstico de falhas em transformadores de potência baseada na utilização de forma conjunta: critérios de análise dos gases hidrogênio (H_2), metano (CH_4), etano (C_2H_6), etileno (C_2H_4) e acetileno (C_2H_2) referenciadas em normas de Rogers, Dornenburg e NBR7274, uma rede neural artificial GRNN (General Regression Neural Network)

referenciada na literatura e um sistema de inferência fuzzy. A figura 1.2 apresenta um fluxograma do método proposto.

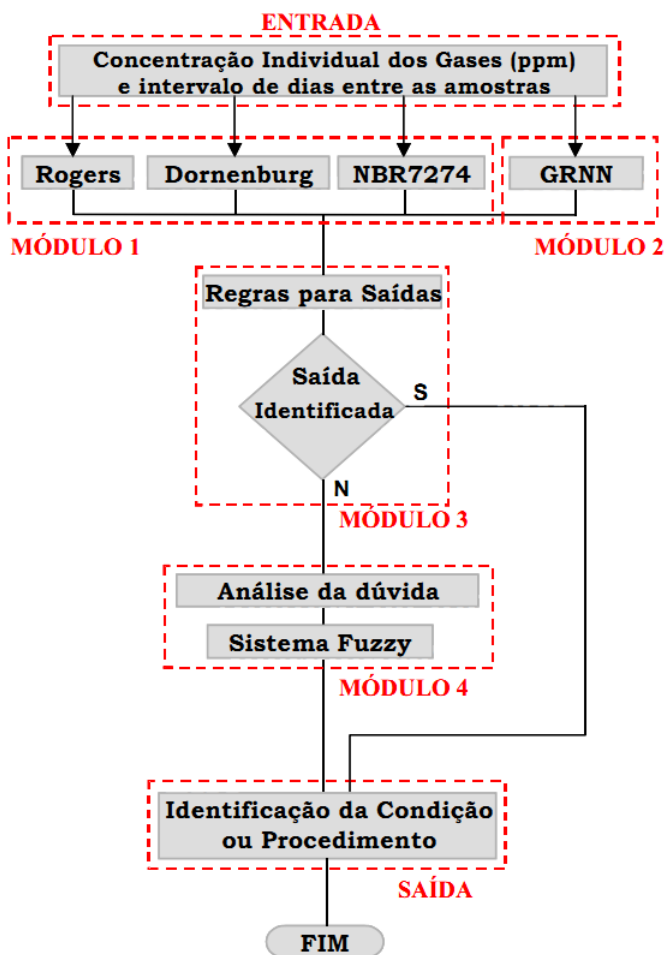


Figura 1.2: Fluxograma do Método Proposto (Morais, 2004).

Na saída dos módulos 1 e 2 a ferramenta apresenta uma classificação entre: "Normal", "Falha elétrica", "Falha térmica", "Reamostragem sugerida" ou "Sem diagnóstico", que são os parâmetros de entrada para o módulo 3, onde foi implementada uma tabela de regras de decisão para fornecer uma resposta; em caso de não estar listada uma possível combinação, deverá passar por uma análise fuzzy dada no módulo 4, que levará em consideração a taxa de geração anormal de gases e o nível de gás gerado em seu processo de decisão. Através deste trabalho se pode constatar que, com a união de uma ou mais técnicas de diagnósticos, pode-se obter resultados de maior confiabilidade, sendo supridas as deficiências individuais de cada método.

Em (Lin et al., 1993), os autores como na maioria das pesquisas apresentadas também utilizou a análise de gases dissolvidos em óleo isolante (DGA), no qual propuseram um sistema especialista de diagnóstico de falhas em transformadores baseados em regras. O sistema especialista foi composto por quatro componentes: memória do trabalho (ou banco de dados), uma

base de conhecimento (regras IF/THEN), máquina de inferência (lógica fuzzy) e uma interface homem-máquina KES (*Knowledge Engineering System*, utilizado em diagnóstico médico). A classificação das falhas do sistema foi: normal, falha térmica e presença de arco elétrico. Os resultados mostraram que o sistema especialista é uma ferramenta confiável e útil para auxiliar especialistas e engenheiros de manutenção.

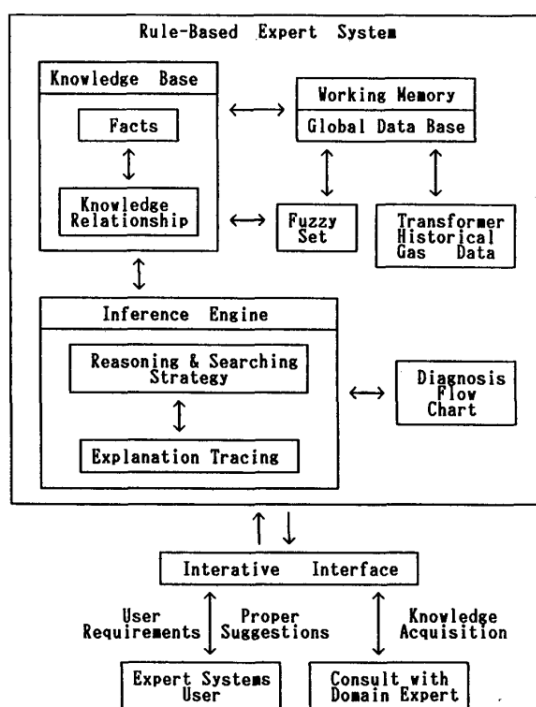


Figura 1.3: Estrutura de diagnóstico do sistema especialista proposto (Lin et al., 1993).

Em (Muhamad et al., 2007), realizaram um estudo comparativo entre os métodos convencionais desenvolvidos para análise e diagnóstico de falhas em transformadores de potência baseados na presença de gases contidos no óleo isolante (DGA). Estes métodos (Gás Chave, Rogers, Doernenburg, Nomógrafo Logarítmica, IEC e Duval) foram avaliados pela precisão e consistência em cada um; verificou-se que os métodos que utilizam códigos específicos (tabelas de classificação de falhas) na sua interpretação são mais precisos na previsão de falha. Isso é devido a que tais métodos serem mais precisos na interpretação dos dados para cada caso referenciado no código. No entanto, sempre que os dados não correspondessem aos códigos disponíveis, estes métodos não foram capazes de dar a sua previsão correta de falha, resultando em uma porcentagem menor na previsão de falha e menos precisa com base em previsão total. Estes resultados foram aplicados aos métodos de Roger e IEC.

(Bálint, Szilvia & István, 2009) em sua pesquisa aproveitaram as vantagens da aplicação de lógica fuzzy: soluciona a presença de incertezas no diagnóstico, devido a valores próximos aos limites do processo de classificação de eventos indesejáveis que ocorrem dentro do transforma-

dor. As relações do método clássico de Rogers (CH_4/H_2 , C_2H_6/CH_4 , C_2H_4/C_2H_6 e C_2H_2/C_2H_4) foram utilizadas de forma eficaz mediante a representação em conjuntos fuzzy, conforme a figura 1.4. (Németh et al., 2009)

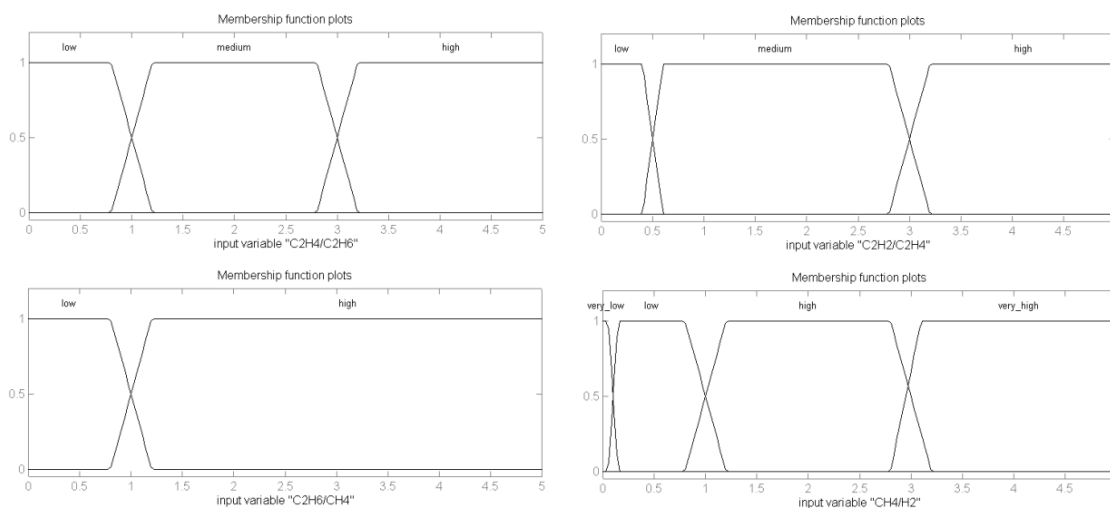


Figura 1.4: Graus de pertinência dos conjuntos fuzzy (Bálint, Szilvia & István, 2009).

(Filho, 2012) ao comparar os métodos convencionais de diagnóstico de falhas em transformadores de potência baseados na análise de gases dissolvidos (DGA) chegou à conclusão que estes podem apresentar erros de até 30% entre si. Propôs uma metodologia de diagnóstico de falhas destes equipamentos em que foi definido três tipos de diagnóstico: falhas térmicas, falhas elétricas e o diagnóstico de normalidade. A metodologia proposta primeiramente verifica a normalidade ou provável anomalia no transformador ponderando os resultados entre os métodos de Rogers original, Rogers CERG, Rogers proposto na NBR, Rogers IEC e o método de Doernenburg, em que se dois ou mais resultados desses métodos forem iguais (elétrica ou térmica), fica identificada então o tipo desta anomalia, caso contrário, ou colhe-se novas amostras e aplicam-se novamente os testes DGA, ou se ainda persistir a dúvida, o caso é considerado indeterminado pelo método cromatográfico e devem-se empregar outros métodos de análise. contribuindo assim para melhorar a manutenção e os procedimentos de análise de gases dissolvidos, mostrando que ela é confiável.

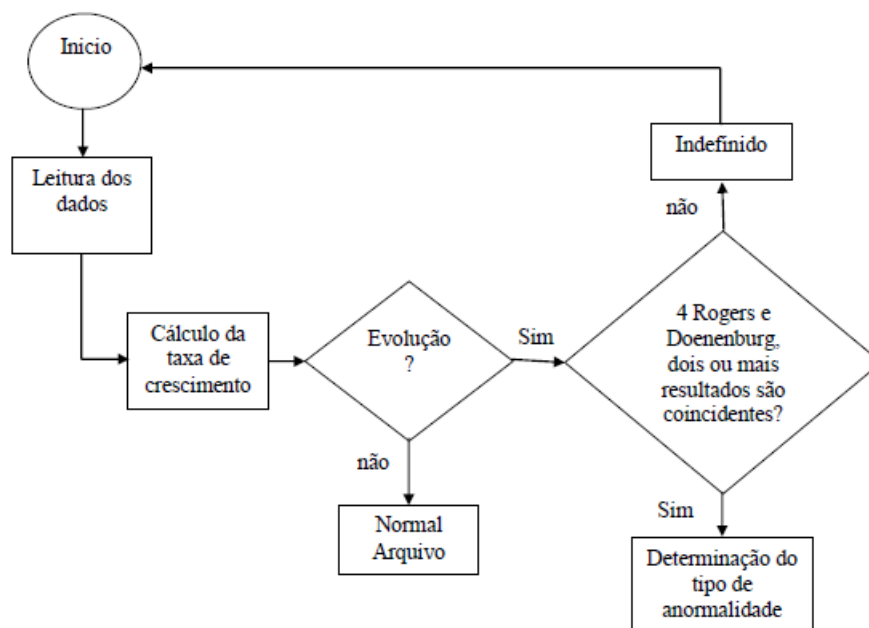


Figura 1.5: Fluxograma de processo de determinação de tipo de falha (Filho, 2012)

1.2 Justificativa

Pela importância do transformador de potência nos sistemas de transmissão e distribuição confiável de energia elétrica (descrito na sessão 1), este trabalho tem o objetivo de proporcionar aos leitores uma ferramenta adicional e confiável na detecção de falhas incipientes no transformador de potência, apresentando resultados coerentes para um ótimo monitoramento e manutenção oportuna do transformador. Como consequência, a minimização de custos e prolongamento da vida útil do transformador estimado pelo fabricante será de grande utilidade para auxiliar especialistas e engenheiros de manutenção em concessionárias de energia.

A ferramenta a ser utilizada para alcançar o objetivo do trabalho é a rede Bayesiana, uma das técnicas da inteligência artificial que atua no campo de raciocínio probabilísticos, ressaltando a vantagem sobre o raciocínio lógico, que é o fato de que agentes podem tomar decisões racionais mesmo quando não existe informação suficiente para se provar que uma ação funcionará (Stuart e Peter, 2002).

Redes Bayesianas permitem analisar grandes quantidades de dados: para extrair conhecimentos úteis em tomada de decisões; controlar ou prever o comportamento de um sistema; diagnosticar as causas de um fenômeno; etc. Utilizadas em vários domínios: saúde (diagnóstico, localização de genes); indústria (controle de autômatos ou de robôs); computação e redes (agentes inteligentes); marketing (mineração de dados, gestão da relação com os clientes); banco e finanças (análise financeira); gestão (tomada de decisões, gestão de conhecimento

e risco). Exemplos de aplicações específicas podem ser encontradas em (Saheki, 2005) (Colossetti, 2009) (Queiroz, 2008) (Mello et al., 2011) (Maturana, 2010) .

Do ponto de vista das aplicações, as vantagens e inconvenientes das redes Bayesianas com relação a algumas técnicas alternativas são apresentadas na Tabela 1.1. Nela (Naim et al., 2004) agruparam as vantagens e inconvenientes baseando-se em três critérios: aquisição, representação e utilização do conhecimento. A representação adotada é a seguinte:

- Cada linha corresponde a uma característica, que pode ser uma vantagem ou a identificação de um problema específico.
- Se a técnica considerada permite lidar com esse problema, ou apresenta vantagem, um sinal + é colocado no caso correspondente.
- Um sinal * indica a melhor técnica, dado o ponto de vista da característica considerada.

Tabela 1.1: Vantagens/Desvantagens Comparativas das Redes Bayesianas.

Conhecimentos	Análise de Dados	Redes Neurais	Árvore de Decisão	Sistemas Especialistas	Redes Bayesianas
AQUISIÇÃO					
Só experiência				*	
Só Dados	+	*	+		+
Misto	+	+	+		*
Incremental		+			*
Generalização	+	*	+		+
Dados incompletos		+			*
REPRESENTAÇÃO					
Incerteza				+	*
Clareza	+		+	+	*
Facilidade		+	*		
Homogeneidade					*
UTILIZAÇÃO					
Requisitos elaborados	+			+	*
Utilidade econômica	+	+			*
Desempenho	+	*			

1.2.1 Objetivos

Objetivo Geral

O presente trabalho tem como principal objetivo, construir uma rede Bayesiana para um diagnóstico eficiente de falhas incipientes em transformadores de potência através da análise de gases dissolvidos no óleo isolante (DGA).

Objetivos Específicos

- Conhecer e descrever as falhas incipientes dadas no sistema de isolamento (papel, óleo) do transformador de potência e os métodos convencionais de diagnóstico de falhas.
- Fundamentar a teoria envolvida na elaboração da rede Bayesiana baseando-se em publicações e artigos científicos.
- Desenvolver a rede Bayesiana, baseado nos gases contidos no óleo isolante do transformador de potência. Serão utilizado dados históricos com amostras de diferentes transformadores e diagnósticos determinados por especialistas citadas no trabalho de dissertação de Diego Morais, "Ferramentas Inteligentes para detecção de falhas incipientes em transformadores baseada na análise de gases dissolvidos no óleo isolante", Florianópolis 2004.

1.3 Estrutura do Trabalho

- Neste capítulo apresentou-se a introdução do contexto do problema com uma breve revisão bibliográfica de pesquisas relacionadas com o tema desta dissertação.
- O capítulo 2 descreve as falhas nos transformadores de potência e os métodos convencionais de diagnóstico baseados na análise de gases dissolvidos no óleo isolante(DGA).
- O capítulo 3 conceitua as noções gerais das probabilidades incluindo o enfoque das redes Bayesianas e suas respectivas características.
- O capítulo 4 apresenta a metodologia proposta para o diagnósticos de falhas incipientes dos transformadores de potência aplicando uma abordagem Bayesiana.
- O capítulo 5 mostra os resultados obtidos da aplicação da rede Bayesiana no banco de dados pertencente a uma grande empresa do setor elétrico brasileiro.
- O capítulo 6 apresenta as conclusões finais desta dissertação e sugestões para os trabalhos futuros.

Diagnóstico de Transformadores de Potência

2.1 Diagnóstico de Falhas Incipientes

O transformador tornou-se um dos equipamentos chaves em sistemas de potência e o seu estado de operação está diretamente relacionado com a confiabilidade e estabilidade dos sistemas de energia (Wensheng et al., 1998). Trata-se de uma máquina elétrica estática, constituída por um núcleo de aço silício, bobinas de fios de cobre revestidas de papel isolante, tanque, estrutura de montagem da parte ativa, além de outros componentes (Portella, 2010). A função básica deste equipamento é a transferência de energia elétrica de um circuito para outro, mantendo a frequência constante, porém, variando os valores de corrente e tensão (Dervos et al., 2006) (Marques, 2004). Desta forma, os transformadores são capazes de reduzir as perdas de energia, utilizando mecanismos de redução da corrente requerida na transmissão de uma determinada potência elétrica (Batista, 2005).

O componente principal de um transformador é seu sistema de isolamento, constituído basicamente, por um líquido isolante (óleo mineral) e uma isolação sólida (papel isolante elétrico). Durante o funcionamento dos transformadores de potência vários processos de desgaste e de envelhecimento ocorrem no sistema de isolamento devido às ocorrências de operação normal do equipamento mas a presença de distúrbios térmicos e elétricos originam efeitos negativos em seu funcionamento, ocasionando as falhas incipientes no transformador de potência.

Nos transformadores de potência utiliza-se uma grande quantidade de óleo mineral isolante que é obtido através da destilação do petróleo natural, da fração de 300 a 400 °C. Este destilado pode ser de origem naftênica, mais usual, mas em vias de escassez (3% do óleo disponível), ou parafínica, tipo de óleo mais comum existente nas jazidas do Brasil e que tem baixo ponto de fluidez o que dificulta seu uso em regiões de inverno rigoroso, mas que tem recebido altos investimentos em pesquisas para obter este tipo de óleo com características mais adequadas para utilização em aparelhos e equipamentos elétricos. Este dois tipos de óleo apresentam características distintas (Myers, 2004). O óleo mineral isolante é uma mistura na qual a maioria das moléculas é constituída basicamente por carbono e hidrogênio (hidrocarbonetos) e, em pequenas quantidades, por compostos que apresentam nitrogênio, enxofre e oxigênio em sua estrutura (Wilson, 1980).

Estes óleos, quando estão novos, são transparentes e de cor amarelo claro, e são processados através de uma rigorosa purificação para retirada de contaminantes, principalmente o enxofre. Eles são estáveis e possuem baixa viscosidade, pois, além de sua função dielétrica de impregnação, atuam também como meio refrigerante para transportar o calor gerado na parte ativa do transformador para a região mais periférica e para os radiadores de calor do mesmo (Oliveira, 2004).

As características ideais para um dielétrico líquido ser utilizado em transformadores de potência decorrem das funções que lhe são exigidas, como elevada rigidez dielétrica, baixo fator de dissipação dielétrica, elevado coeficiente de transmissão térmica, baixa viscosidade, alto ponto de rigidez, elevado ponto de fulgor e baixo custo (Oliveira, 2004).

Durante o processo de funcionamento do transformador o óleo mineral e outros materiais dielétricos ficam submetidos às ações de temperatura e de tensões elétricas, sofrendo processos de decomposição química que resultam na formação de gases. Os gases formados pela decomposição dos materiais isolantes do transformador são dissolvidos, total ou parcialmente, no óleo em temperaturas específicas, como apresentado na figura 2.1, sendo diluídos e transportados por todo seu volume. Esta decomposição é mais intensa quando existem falhas no funcionamento do transformador. A diluição dos gases possibilita obter-se, através da análise de uma amostra, informações a respeito do estado de deterioração dos diversos pontos que estejam em contato com o óleo mineral isolante.

Os gases mais comumente encontrados no óleo de transformadores estão agrupados em: Hidrogênio e Hidrocarbonetos (Hidrogênio, Metano, Etano, Etileno, Acetileno), Óxidos de Carbono (Monóxido de Carbono, Dióxido de Carbono) e gases não oriundo de faltas (Nitrogênio, Oxigênio), como pode ser observado na Tabela 2.1 (IEEE, Std C 57.104-1991).

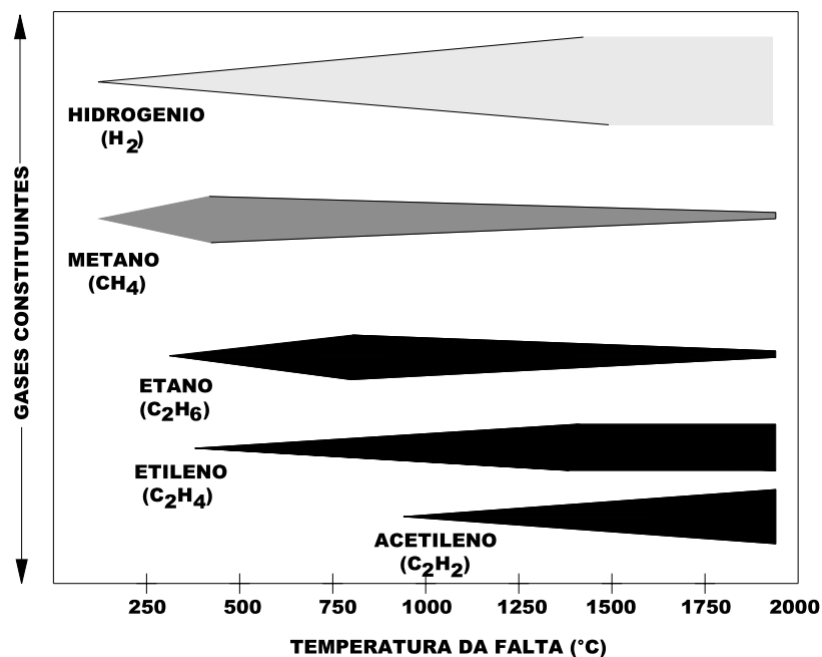


Figura 2.1: Geração de gases no sistema de isolamento do transformador de potência.

Tabela 2.1: Gases gerados no sistema de isolamento do transformador de potência.

Hidrogênio e hidrocarbonetos	
Hidrogênio	H_2
Metano	CH_4
Etano	C_2H_6
Etileno	C_2H_4
Acetileno	C_2H_2
Óxidos de carbono	
Monóxido de carbono	CO
Dióxido de carbono	CO_2
Gases não oriundos de faltas	
Nitrogênio	N_2
Oxigênio	O_2

A estimativa da quantidade de gases formados, bem como a sua evolução, em função da temperatura, pode ser visualizada na figura 2.2, Com base na temperatura de decomposição do óleo, e em função da formação de gases para essa temperatura, supõe-se que uma falha possa estar ocorrendo (IEEE, Std C 57.104-1991).




Figura 2.2: Pressões parciais do equilíbrio térmico de Halstead como função da temperatura.

As duas principais causas de formação de gases dentro de um transformador são distúrbios térmicos e elétricos. A perda do condutor é devido a gases que produzem carregamento de decomposição térmica do óleo associados com o isolamento sólido. Gases também são produzidos a partir da decomposição do óleo e isolamento exposto a temperaturas de arco elétrico. Geralmente, quando os gases são formados, principalmente por bombardeio iônico, há pouco ou nenhum calor associado com baixa energia e descargas parciais (IEEE, Std C 57.104-1991)(Flores et al., 2007).

2.1.1 Falhas de origem Térmico

Fazendo referência à Figura 2.2, em que a decomposição do óleo mineral a partir de 150 ° C a 500 ° C produz quantidades relativamente grandes de gases de baixo peso molecular, tais como o hidrogênio (H₂) e metano (CH₄), e indícios de gases de alto peso molecular mais elevados de etileno (C₂H₄) e etano (C₂H₆). À medida que a temperatura de falha em óleo mineral aumenta a temperaturas moderadas, a concentração de hidrogênio é superior à do metano, mas agora as temperaturas são acompanhados por uma quantidade significativa de gases de alto peso molecular, o qual é um indicador de uma presença de falha de origem térmico (IEEE, Std C 57.104-1991).

2.1.2 Falhas de origem Elétrico

De acordo com (IEEE, Std C 57.104-1991) estas falhas de origem elétrico podem se apresentar das seguintes maneiras:

Falha elétrica - descargas de baixa intensidade

De acordo com a figura 2.2, as descargas de baixa intensidade assim como as descargas parciais e de um arco intermitente de nível baixo produz principalmente o hidrogênio, com quantidades decrescentes de metano e quantidades de acetileno. Como a quantidade das descargas incrementam, as concentrações de acetileno e etano aumentam significativamente.

Falha elétrica - arco de alta intensidade

De acordo com a figura 2.2, como a intensidade da descarga elétrica alcança ao arco ou a proporção da descarga continua produz temperaturas de 700°C até 1800°C, a quantidade de acetileno torna-se pronunciada.

A presença de gases dentro do transformador, gerados no sistema de isolamento (óleo, papel), são dados de crucial importância que permitem detectar a presença de alterações no transformador. Os efeitos de fadiga térmica, química, elétrica e mecânica, tais como, pontos quentes, sobre-aquecimentos, sobre-tensões e vibração são responsáveis por alterações do sistema isolante e devem ser monitorados para garantir a eficiência do equipamento, permitindo intervenções de manutenção preventiva, a fim de evitar paradas de máquina e, conseqüentemente, o aumento de custos (Batista, 2005).

2.2 Análise de Gases Desenvolvidos

Através da análise dos gases dissolvidos (DGA) no óleo isolante é possível avaliar a condição de operação do isolamento do equipamento, com a detecção de eventuais processos de falhas que possam estar ocorrendo. A DGA é a técnica mais utilizada para monitorar o desempenho de transformadores de potência (Couderc et al., 1996)(Yang e Huang, 1998)(Duval, 2002), assim como de outros equipamentos elétricos como reatores, transformadores de corrente, transformadores de potencial, entre outros.

Como métodos convencionais de diagnóstico de falhas através da DGA, podemos citar os métodos que utilizam relações de concentrações de gases, como o método de Rogers, o método de Doernenburg, o método previsto na NBR7274 e o método de Duval, os quais levam em consideração apenas a concentração percentual relativa dos gases.

2.2.1 Método de Gás Chave

É um método bastante conhecido e utilizado, cujo propósito é identificar a presença significativa de algum ou alguns gases para cada tipo de falha este gás ou gases são conhecidos como "gás chave". Nas figuras 2.3, 2.4, 2.5 e 2.6 estão indicadas estes "gases chaves" e a proporção relativa para as principais falhas: térmicas e elétricas, que se apresentam no transformador de potência (IEEE, Std C 57.104-1991).

Sobreaquecimento de Óleo - Térmico

Consiste na decomposição de produtos incluindo etileno e metano, juntos com pequenas quantidades de hidrogênio e etano. Traços de acetileno podem ser formados se o sobreaquecimento é severo ou envolve contatos elétricos. Cujo comportamento típico dos gases é mostrada na figura 2.3, com os respectivos percentagens de cada gás.

Gás chave: etileno.

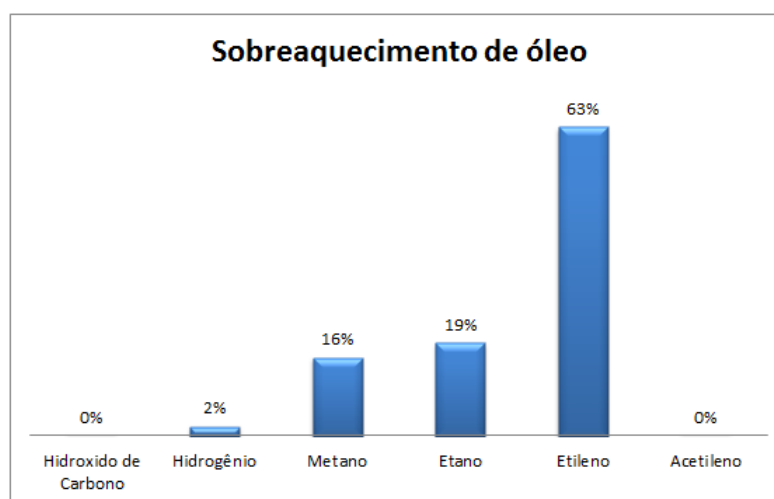


Figura 2.3: Concentração típica resultante de sobreaquecimento de óleo - Falha Térmica.

Sobreaquecimento da Celulose - Térmico

Grandes quantidades de monóxido e dióxido de carbono estão envolvidas no sobreaquecimento da celulose. Gases hidrocarbonetos, tais como o metano e etileno, serão formados se o problema envolver a isolação do enrolamento, normalmente papel isolante impregnado de óleo. Conforme mostrado na figura 2.4.

Gás chave: monóxido de carbono.

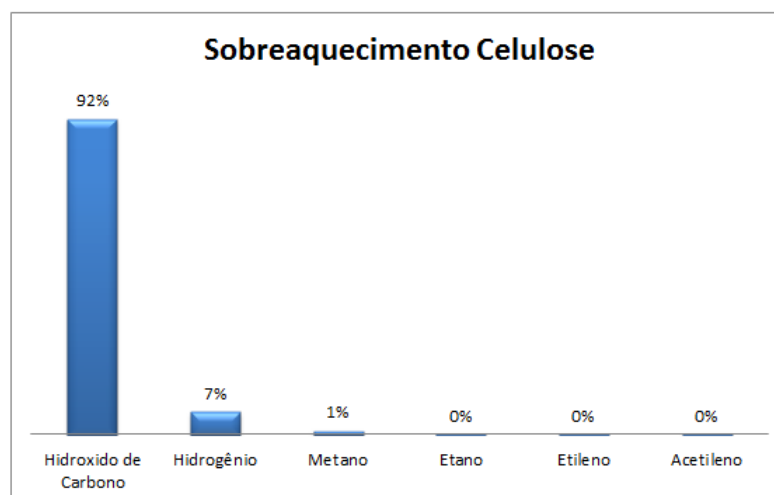


Figura 2.4: Concentração típica resultante de sobreaquecimento da celulose - Falha Térmica.

Descarga Parcial - Elétrico

A ocorrência de descargas elétricas de baixa energia produzem hidrogênio e metano, com pequenas quantidades de etano e etileno. Quantidades significativas de monóxido e dióxido de carbono podem ser devido a descargas na celulose, cujo comportamento típico é observado na figura 2.5.

Gás chave: hidrogênio.




Figura 2.5: Concentração típica resultante de descarga parcial - Falha Elétrica.

Arco Elétrico

Consiste na produção de grandes quantidades de hidrogênio e acetileno e, em menores volumes, de metano e o etileno. Se o arco envolve a celulose, também podem ser formados monóxido e dióxido de carbono. Conforme mostrado na figura 2.6.

Gás chave: acetileno.

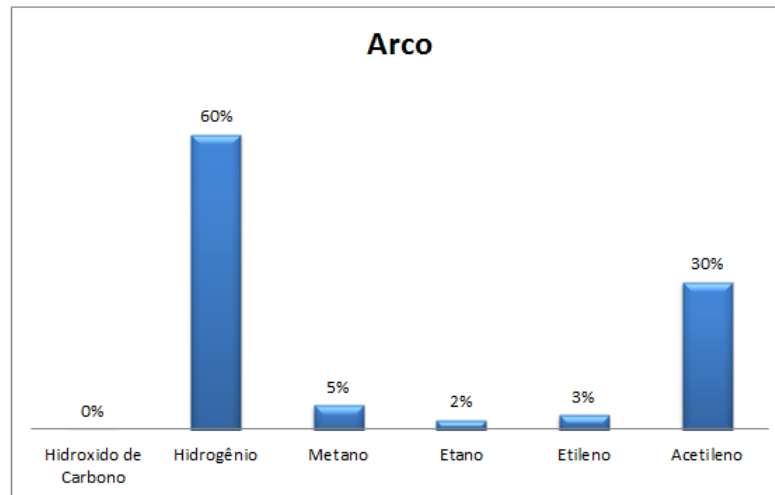


Figura 2.6: Concentração típica resultante de arco elétrico - Falha Elétrica.

2.2.2 Método de Rogers

O método de Rogers utiliza quatro relações de gases: metano/hidrogênio (CH_4/H_2), etano/metano (C_2H_6/CH_4), etileno/etano (C_2H_4/C_2H_6) e acetileno/etileno (C_2H_2/C_2H_4). O diagnóstico de falhas é realizado através de um esquema simples de codificação baseado em intervalos das relações, como pode ser apresentado nas Tabelas 2.2 e 2.3 (Rogers, seção 10-201 1975).

Tabela 2.2: Definição dos códigos de Rogers

Relação de gases	Faixa de variação	Código
$R_1 : CH_4/H_2$	≤ 0.1	5
	$> 0.1, < 1$	0
	$\geq 1, < 3$	1
	≥ 3	2
$R_2 : C_2H_6/CH_4$	< 1	0
	≥ 1	1
$R_3 : C_2H_4/C_2H_6$	< 1	0
	$\geq 1, < 3$	1
	≥ 3	2
$R_4 : C_2H_2/C_2H_4$	< 0.5	0
	$\geq 0.5, < 3$	1
	≥ 3	2

A combinação dos códigos da Tabela 2.2 gera 12 diferentes tipos de falhas no transformador. O tipo de falha está baseado nos códigos apresentados na Tabela 2.3.

Tabela 2.3: Diagnóstico de falhas baseado nos códigos da Tabela 2.2

R_1	R_2	R_3	R_4	Diagnóstico Rogers
0	0	0	0	Deterioração Normal
5	0	0	0	Descargas Parciais
1 ou 2	0	0	0	Sobreaquecimento - abaixo de 150°C
1 ou 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 ou 2	1 ou 2	Arco com alta energia
0	0	2	2	Descarga contínua de baixa potência
5	0	0	1 ou 2	Descarga parcial envolvendo o papel

2.2.3 Método de Doernenburg

O método baseia-se nas relações CH_4/H_2 , C_2H_2/C_2H_4 , C_2H_6/C_2H_2 e C_2H_2/CH_4 . Este critério é capaz de identificar três tipos de falhas: superaquecimento local (pontos quentes), descargas parciais e outros tipos de descargas (falhas elétricas) (IEEE, Std C 57.104-1991). O critério de identificação de falhas do método de Doernenburg está apresentado na Tabela 2.4, cujos valores de relações gasosas classificam o tipo de falha do equipamento.

Tabela 2.4: Critério de identificação de falha de Doernenburg

Tipos de Falha	Relações entre concentrações de gases			
	Relações principais		Relações auxiliares	
	$\frac{CH_4}{H_2}$	$\frac{C_2H_2}{C_2H_4}$	$\frac{C_2H_6}{C_2H_2}$	$\frac{C_2H_2}{CH_4}$
Pontos quentes	>1	<0.75	>0.4	<0.3
Descarga parcial	<0.1	—	>0.4	<0.3
Outros tipos de descarga	>0.1 e <1	>0.75	<0.4	>0.3

Para a validação da aplicação do método de Doernenburg, a Tabela 2.5 apresenta os dados de concentração de gases individualmente. O critério estabelece que, para a utilização da Tabela 2.4, no mínimo um dos gases que compõe as relações principais tenha uma concentração superior ao dobro do valor da Tabela 2.5 e que, para as relações auxiliares, pelo menos um dos gases tenha uma concentração superior àquela apresentada na mesma tabela.

Tabela 2.5: Concentração dos gases para validação do método de Doernenburg

Tipos de gás	H_2	CH_4	C_2H_6	C_2H_4	C_2H_2
Concentração (ppm)	200	50	15	60	15

2.2.4 Método de Duval


O método de Duval analisa a concentração percentual relativa dos gases acetileno (C_2H_2), etileno (C_2H_4) e metano (CH_4). É baseado na visualização da localização da concentração percentual em um mapa triangular, conforme é apresentado na figura 2.7. As coordenadas são estabelecidas pela relação percentual de cada um dos gases em relação ao total de gases gerados. Permite identificar três falhas de origem elétrica e três falhas de origem térmica. As coordenadas são definidas pelas seguintes equações (Duval, 1989):

$$\%C_2H_2 = \frac{100x}{x + y + z} \quad (2.1)$$

$$\%C_2H_4 = \frac{100y}{x + y + z} \quad (2.2)$$

$$\%CH_4 = \frac{100z}{x + y + z} \quad (2.3)$$

em que: $x = C_2H_2$; $y = C_2H_4$; $z = CH_4$

**Figura 2.7:** Triângulo de Duval.

Os códigos apresentados no triângulo representam uma condição de falha;

A: Descargas de alta energia.

B: Descargas de baixa energia.

C: Descargas parciais.

D: Falha térmica, $T < 200$ °C.

E: Falha térmica, $200 < T < 400$ °C.

F: Falha térmica, $T > 400$ °C.

2.2.5 Método previsto na NBR 7274

A norma NBR 7274 foi desenvolvida para transformadores de potência, com enrolamentos de cobre, isolados com papel, papelão ou celulose e imersos em óleo isolante mineral, em serviço em sistemas de potência (NBR7274, 1982.) (baseada na IEC 599/78), considerada como uma extensão ao método de Rogers, variando em algumas faixas das relações e na interpretação para o referido diagnóstico (Zirbes, 2003). Na Tabela 2.6 são apresentados os diagnósticos de falhas baseados nas 3 relações entre os gases.

Tabela 2.6: Diagnóstico de falhas NBR 7274

$\frac{C_2H_2}{C_2H_4}$	$\frac{CH_4}{H_2}$	$\frac{C_2H_4}{C_2H_6}$	Diagnóstico
< 0.1	0.1 a 1.0	< 1.0	Envelhecimento Normal
< 0.1	< 0.1	< 0.1	Descarga parcial baixa energia
0.1 a 3.0	< 0.1	< 0.1	Descarga parcial alta energia
> 0.1	0.1 a 1.0	> 0.1	Arco - descarga baixa energia
0.1 a 3.0	0.1 a 1.0	> 3.0	Arco - descarga alta energia
< 0.1	> 1.0	< 0.1	Sobreaquecimento 150°C < t < 300°C
< 0.1	> 1.0	1.0 a 3.0	Sobreaquecimento 300°C < t < 700°C
< 0.1	> 1.0	> 3.0	Sobreaquecimento t > 700°C

Neste capítulo foram descritos os métodos convencionais de diagnóstico de transformadores de potência baseados na análise de gases dissolvidos no óleo isolante (DGA). O próximo capítulo conceitua as Redes Bayesianas e suas respectivas características.

Redes Bayesianas

Atualmente, estudos em Inteligência Artificial (AI) podem ser divididos em duas grandes áreas: o desenvolvimento de sistemas que agem como humanos (robôs) e o desenvolvimento de sistemas que agem racionalmente. Dentro do contexto dos sistemas que agem racionalmente, duas abordagens principais podem ser utilizadas: raciocínio lógico e raciocínio probabilístico. O raciocínio lógico pondera sobre o conhecimento prévio a respeito do problema e, sobre esta base de conhecimento retira suas conclusões. Esta abordagem, apesar de poderosa, pode não ser útil em situações em que não se conhece previamente todo o escopo do problema, para estes casos, o raciocínio probabilístico surge como uma boa opção (Marques e Dutra, 2003).

Redes Bayesianas oferecem uma abordagem para o raciocínio probabilístico que engloba teoria de grafos, para o estabelecimento das relações entre sentenças e ainda, teoria de probabilidades, para a atribuição de níveis de confiabilidade (Marques e Dutra, 2003).

A principal vantagem de raciocínio probabilístico sobre raciocínio lógico é o fato de que agentes podem tomar decisões racionais mesmo quando não existe informação suficiente para se provar que uma ação funcionará (Stuart e Peter, 2002).

As Redes Bayesianas (RB) foram desenvolvidas no início da década de 80 com o objetivo de facilitar a tarefa de predição em sistema de inteligência artificial para raciocínio com conhecimento incerto (Pearl, 1988). As RB são estruturas gráficas que permitem representar razões ou argumentos no domínio da incerteza (Korb e Nicholson, 2003). Esta ferramenta vem se tornando a metodologia padrão para a construção dos sistemas que confiam no conhecimento probabilístico e entre as principais áreas de aplicação, pode-se destacar: industrial (sistemas de

diagnósticos de falhas e predição), militar (localização automática de alvos) e comercial (recuperação de informações e análise do mercado financeiro) (Pifer e Guedes, 2007).

3.1 Noções Gerais da Teoria de Probabilidade

O cálculo de incertezas utilizadas em Rede Bayesianas (rede probabilística) é baseado na teoria de probabilidade. Assim, as noções de probabilidade e, em particular, a probabilidade condicional desempenha um papel importante. Nesta seção apresentamos alguns conceitos básicos e axiomas que envolvem a teoria da probabilidade Bayesiana.

Um experimento é *aleatório* se, ao ser repetido nas mesmas condições, é impossível prever antecipadamente o resultado. Em contrapartida, um experimento é *determinístico* se, quando repetido nas mesmas condições, conduz ao mesmo resultado. Denominamos espaço amostral o conjunto de todos os resultados possíveis de um experimento aleatório, e o denotamos por Ω (também denotado como: S). Um subconjunto $A \subset \Omega$ é chamado *evento*.

3.1.1 Definição freqüentista de probabilidade (ou definição estatística de probabilidade)

Dada por Richard von Mises (von Mises, 1957), em que \mathcal{E} é definido como um experimento aleatório¹. Sob as mesmas condições teóricas, são realizadas n ensaios independentes do experimento \mathcal{E} , com n suficientemente grande, e em cada ensaio o evento A pode ou não ocorrer. $n(A)$ é definido como o número de ocorrências do evento A . Assim:

$$\lim_{n \rightarrow \infty} \frac{n(A)}{n} \quad (3.1)$$

Em que:

$n(A)$ é o número de vezes que A ocorreu em n ensaios do experimento \mathcal{E} ; n é o número total de repetições (ensaios) de \mathcal{E} ; $\frac{n(A)}{n} = fr(A)$ é a frequência relativa do evento A , em \mathcal{E} .

¹Uma das características de um experimento aleatório é a regularidade estatística, isto é, a propriedade que a frequência relativa tem de se estabilizar. A essência desta propriedade é que se um experimento aleatório for executado um grande número de vezes, a frequência relativa da ocorrência de algum evento A tenderá variar cada vez menos à medida que o número de repetições for aumentada. Nesse sentido é que a frequência relativa converge (em probabilidade) para um número denominado probabilidade do evento A . Essa propriedade de regularidade dos experimentos aleatórios, motivou a formulação de uma importante lei da Estatística: a Lei dos Grandes Números. A Lei dos Grandes números trata da convergência em probabilidade da frequência relativa de um evento para a probabilidade deste evento (Meyer, 1972).

3.1.2 Axiomas de Kolmogorov

Conforme desenvolvida por Kolmogorov (1903 - 1987), a teoria de probabilidades clássica não se preocupa em determinar como seu valor numérico deve ser determinado mas sim com suas propriedades gerais. De forma semelhante à geometria, estabelecem-se propriedades básicas que a medida de probabilidade $P(\cdot)$ deve obedecer. Estas (três) propriedades são conhecidas como os Axiomas de Kolmogorov:

1. $P(A) \geq 0$. A probabilidade é um número não negativo.
2. $P(\Omega) = 1$. O espaço amostral contém todas os possíveis resultados do experimento, assim é um evento certo.
3. $\bigcup_{i=1}^{\infty} P(A_i) = \sum_{i=1}^{\infty} P(A_i)$ se $A_i, A_j \in \mathcal{F}$ e $A_i \cap A_j = \emptyset, i \neq j$. Se dois eventos A_1 e A_2 são mutuamente exclusivos então a probabilidade de A_1 ou A_2 é igual a probabilidade de A_1 somada à probabilidade de A_2 . O mesmo vale para qualquer número de eventos mutuamente exclusivos.

Dos axiomas podem-se extrair várias propriedades importantes, por exemplo:

- $P(\emptyset) = 0$;
- $P(A^c) = 1 - P(A)$, para todo evento A
- Se $A \subseteq B \subseteq \Omega$, então $P(A) \leq P(B)$
- Se $A, B \subseteq \Omega$, então $P(A \cup B) = P(A) + P(B) - P(A \cap B)$
- Se $A \subseteq \Omega$, então $0 \leq P(A) \leq 1$

A tripla (Ω, \mathcal{F}, P) é chamada espaço de probabilidade.

3.1.3 Probabilidade condicional e independência

Seja (Ω, \mathcal{F}, P) um espaço de probabilidade. Para eventos A e B com $P(A) > 0$ e $P(B) > 0$, a *probabilidade condicional* de A dado que B ocorreu é definida por

$$P(A|B) = \frac{P(A \cap B)}{P(B)} \quad (3.2)$$

3.1.4 Regra de multiplicação

Chamada também probabilidade composta. Se A_1, A_2, \dots, A_n são eventos com $P(A_1 \cap \dots \cap A_n) > 0$, então

$$P(A_1 \cap A_2 \cap \dots \cap A_n) = P(A_1)P(A_2|A_1)\dots P(A_n|A_1 \cap \dots \cap A_{n-1})$$

Condicionamento: Se A e B são eventos com $0 < P(B) < 1$, então

$$P(A) = P(A|B)P(B) + P(A|B^c)P(B^c) \quad (3.3)$$

em que B^c é o complemento do evento B .

3.1.5 Fórmula da probabilidade total

Seja B_1, B_2, \dots, B_n uma partição do espaço amostral Ω em eventos de probabilidade positiva, isto é, esses eventos são dois a dois disjuntos, $\Omega = \bigcup_{i=1}^n B_i$ e $P(B_i) > 0$ para todo i . Então, para qualquer evento A ,

$$P(A) = \sum_{i=1}^n P(A|B_i)P(B_i) \quad (3.4)$$

3.1.6 Teorema de Bayes

O fundamento principal das Redes Bayesianas se encontra na fórmula da inversão, também chamada de teorema de Bayes, publicada pelo matemático Thomas Bayes em 1763, é apresentada na equação 3.5.

$$P(H|e) = \frac{P(e|H)P(H)}{P(e)} \quad (3.5)$$

em que:

$P(H)$ é a probabilidade *a priori* do evento H ; $P(e|H)$ é a verossimilhança relativa dada a evidência (e) e dado a hipótese do evento H ; $P(e)$ é um fator de normalização (probabilidade *a priori* do evento e); $P(H|e)$ é a probabilidade *a posteriori* do evento H conhecida a evidência e .

3.2 Redes Bayesianas

As Redes Bayesianas (RB) são Grafos Dirigidos Acíclicos (DAG), representam dependências causais entre variáveis representadas por nós em que se pode atribuir valores conforme o grau de relevância em um modelo probabilístico. Uma RB é um formalismo que mistura a teoria dos grafos e a teoria da probabilidade (Castillo et al., 1997). Nesse sentido, uma RB tem dois componentes principais:

- Uma estrutura, \mathcal{S} , que define relacionamento qualitativo causal entre os nós; e,
- Parâmetros numéricos, Θ , que quantificam a relação probabilística causal entre os nós da estrutura.




Figura 3.1: Estrutura básica de uma Rede Bayesiana.

Na figura 3.1 o nó X_1 (chamado também como pai, ancestral, antecessor, etc.) representa semanticamente uma causa dos nós X_2, X_3, \dots, X_n (filhos).

Uma Rede Bayesiana consiste de:

- Um conjunto de variáveis e um conjunto de arcos ligando as variáveis.
- Cada variável possui um conjunto limitado de estados mutuamente exclusivos.
- As variáveis e arcos formam um grafo dirigido acíclico (DAG).
- Cada variável X_i ou nó possui uma distribuição de probabilidade associada, conforme a equação 3.6.

$$P(U) = P(X_1, X_2, \dots, X_n) = \prod_{i=1}^n P(X_i | Pa_i) \quad (3.6)$$

em que: $P(U)$ é a probabilidade conjunta para a rede e $P(X_i | Pa_i)$ são as probabilidades condicionais de X_i em relação aos seus pais.

Uma RB $\langle \mathcal{S}, \Theta \rangle$, para o conjunto de variáveis $X = \{X_1, X_2, \dots, X_n\}$, tem n famílias (Uma família é formada de uma variável e seus pais) locais $X_i | Pa_i$ (Luna, 2004). Cada X_i tem r_i estados possíveis $x_i^1, x_i^2, \dots, x_i^{r_i}$. A probabilidade de X_i estar no estado x_i^k , dado o j -ésimo estado dos seus pais pa_i e a estrutura \mathcal{S} da RB é expressa por $P(X_i = x_i^k | Pa_i^j, \mathcal{S}) = \theta_{ijk}$.

A quantidade de configurações (q_i) de estados que Pa_i pode assumir é dada pelo produtório da cardinalidade (número de estados possíveis) das variáveis em Pa_i , conforme a equação 3.7.

$$q_i = \prod_{x_k \in Pa_i} r_k \quad (3.7)$$

3.2.1 Condição de Markov

Uma rede Bayesiana é a representação correta de um domínio, caso a condição de Markov seja satisfeita. A condição de Markov é definida por (Neapolitan, 2004)

"Suponha a distribuição de probabilidade conjunta das variáveis aleatórias em um conjunto de nós V em um DAG $G = (V, E)$. Então dizemos que (G, P) satisfazem a condição de Markov se cada variável $X \in V$, X é condicionalmente independente dos nós não descendentes de seus pais". Ou seja, não existe uma relação de dependência direta entre quaisquer dois nós (descendentes do mesmo pai), a não ser que exista um arco entre eles na rede.

De acordo com (Marques e Dutra, 2003), uma vez definida a topologia da rede (distribuição dos nós e os relacionamentos entre as variáveis), é preciso determinar as probabilidades dos nós que participam em dependências diretas e utilizar estas para computar as demais probabilidades desejadas.

Para uma melhor compreensão a figura 3.2 ilustra uma rede Bayesiana que pretende estabelecer a influência causal das variáveis Fraude (cartão fraudado), Idade e Sexo sobre compras de Gasolina e Jóias. O conjunto de variáveis $U = \text{Fraude, Idade, Sexo, gasolina, Joias}$ retrata as variáveis do modelo; os círculos representam tanto os nós da rede quanto as variáveis do conjunto U ; os arcos representam o relacionamento causal entre as variáveis.

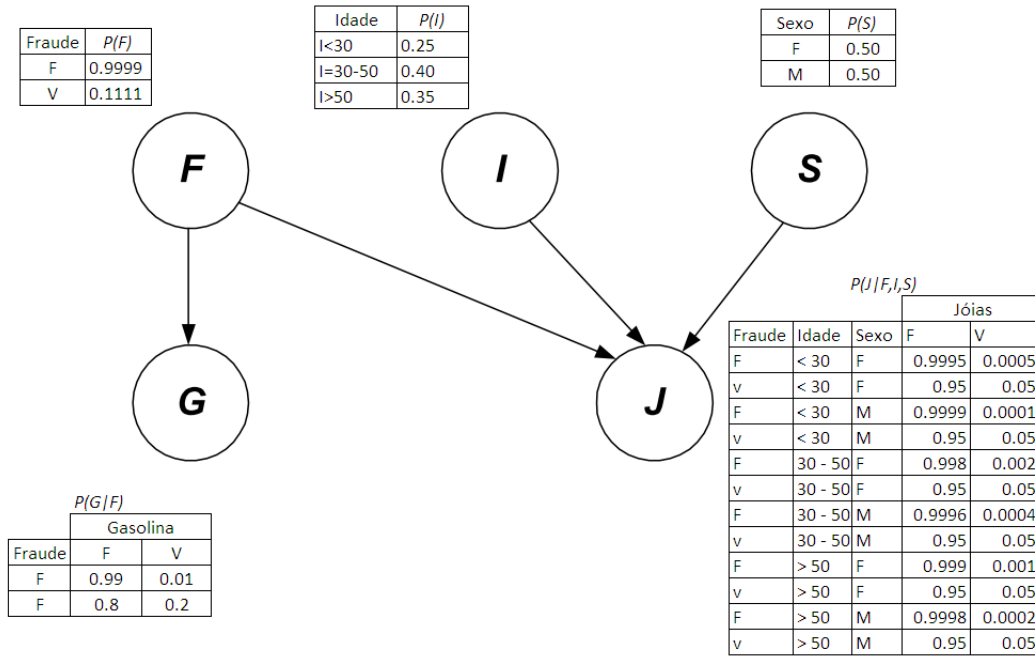


Figura 3.2: Exemplo de Rede Bayesiana para Detecção de Problemas de Fraude: F=Fraude; I=Idade; S=Sexo; G=Gasolina; J=Jóias

Existe uma distribuição de probabilidades associada a cada nó. As redes Bayesianas adotam uma representação compacta, em que são definidas somente as probabilidades condicionais de cada nó em relação aos seus pais.

Observe que, se um nó (por exemplo F) não possui um pai, a tabela de probabilidades é reduzida para uma probabilidade incondicional $P(F)$ (ou seja, probabilidade *a priori*). O nó G tem como seu antecessor (pai) o nó F , então, a tabela de probabilidades associada a G e condicionado a seu antecessor F (probabilidade *a posteriori*) é $P(G|F)$.

Uma vez definida a topologia da rede, basta especificar as probabilidades dos nós que participam em dependências diretas, e utilizar estas para calcular as demais probabilidades que se deseja.

3.2.2 Cálculo da Distribuição de Probabilidade Conjunta

Baseado nas tabelas de probabilidade condicional calculadas podemos obter a distribuição de probabilidade conjunta de todo o domínio.

Considerando que a rede Bayesiana satisfaz a condição de Markov, então sua distribuição de probabilidade conjunta é igual ao produto das probabilidades condicionais de todos os nós dados os valores de seus pais.

$$P(U) = P(A_1, A_2, \dots, A_n) = P(U) = \prod_i^n P(A_i | pa(A_i)) \quad (3.8)$$

em que $P(U)$ é a probabilidade conjunta para a rede, $pa(A_i)$ são os pais do nó A_i e $P(A_i | pa(A_i))$ são as probabilidades condicionais de A_i em relação a seus pais.

Com isso, pode-se concluir que as tabelas de probabilidade condicional constituem uma representação distribuída da tabela de probabilidade conjunta do domínio em questão.

3.2.3 Inferência em Redes Bayesianas

Com a rede Bayesiana definida, pode-se extrair conhecimento nela representado através de um processo de inferência; De acordo com (Júnior, 2003) existem vários métodos para realização de inferência, dentre os métodos tradicionais destacam-se o de propagação em poliarvores (Pearl, 1988) e o de eliminação de variáveis (COZMAN, 2000) com suas variações.

O principal objetivo da inferência Bayesiana é calcular uma distribuição de probabilidade posterior (probabilidade *a posteriori*) para um conjunto de variáveis de consulta (*query variable*), dada uma forte evidência (*hard evidence*), ou seja, calcular a $P(Query/Evidence)$.

(Stuart e Peter, 2002) destacaram que pode-se utilizar quatro maneiras distintas de inferência sobre as Redes Bayesianas:

1. **Diagnóstico:** partindo dos efeitos para as causas;
2. **Causa:** partindo das causas para os efeitos;
3. **Intercausal:** entre causas de um efeito comum;
4. **Mistas:** combinação de dois ou mais tipos descritos acima.




Figura 3.3: Tipos de inferência entre variável de consulta (*Query*) e uma evidência (*Evidence*)

De acordo com (Marques e Dutra, 2003), as Redes Bayesianas também podem ser utilizadas para:

- Tomar decisões baseadas em probabilidades.
- Decidir quais evidências adicionais devem ser observadas a fim de se obter informações úteis do sistema.
- Analisar o sistema a fim de buscar os aspectos do modelo que possuem maior impacto sob as variáveis de consulta.
- Explicar os resultados de uma inferência probabilística ao usuário.

3.2.4 Aprendizagem Bayesiana

O aprendizado em redes de conhecimento pode ser visto como um processo que gera uma representação interna (na máquina) das restrições que definem um dado problema de modo a facilitar a recuperação dos dados, gerando assim, o menor esforço computacional possível para este tipo de representação (Pearl, 1988).

Na aprendizagem Bayesiana, o objetivo é "aprender" as distribuições de probabilidades da rede e identificar sua estrutura, ou seja, identificar as relações de interdependência dadas pelos arcos. Segundo (Castillo et al., 1997) este processo de aprendizagem é dividido em "aprendizagem da estrutura" e "aprendizagem dos parâmetros numéricos".

A *aprendizagem da estrutura* refere-se a alguns aspectos relacionados à estrutura do conhecimento (regras, distribuição de probabilidade, etc), por exemplo, a descoberta de novas causas ou efeitos de uma doença, ou a inclusão de novas regras na base do conhecimento. Já a *aprendizagem dos parâmetros* refere-se a estimar os parâmetros necessários para construir a base do conhecimento, por exemplo, a estimação de frequências ou probabilidades associadas a sintomas ou doenças. Os métodos de aprendizagem variam conforme o conhecimento que se tem dos dados.

Tanto a aprendizagem da estrutura quanto a aprendizagem dos parâmetros podem ser aprendidas através de um especialista, responsável por definir e/ou supervisionar a construção da rede baseado no seu conhecimento. Já a aprendizagem intuitiva utiliza o auxílio de um banco de dados, e partir deste, a rede é construída.

O processo de obtenção dos parâmetros numéricos é, sem dúvida, mais simples que a construção da estrutura da rede. Considerando que se conheça a estrutura da rede, a aprendizagem

dos parâmetros numéricos pode ser estimada por meio das frequências relativas, em caso de existir uma amostra significativa de dados em estudo.

Em geral, os parâmetros da rede são desconhecidos. No processo de estimar os parâmetros da RB o problema se reduz a determinar $P(\Theta|D, \mathcal{S})$, em que D é uma amostra aleatória grande o suficiente para se poder estimar os parâmetros e \mathcal{S} é o DAG determinando as famílias $X_i|Pa_i$ da RB. Dado \mathcal{S} , a distribuição *a priori* de Θ , $P(\Theta|\mathcal{S})$, deve ser estimada para RB como a disponibilidade de uma amostra aleatória D . Deve-se atualizar o conhecimento sobre a distribuição Θ calculando-se *a posteriori* $P(\Theta|D, \mathcal{S})$.

Para estimar a distribuição de probabilidade condicional utiliza-se a equação 3.9 .

$$P(X_i = x_i^k | Pa_i^j, D, \mathcal{S}) = (1 + N_{ijk}) / (r_i + N_{ij}) \quad (3.9)$$

em que: N_{ijk} mede a frequência na amostra D com que a variável X_i tem o k -ésimo estado, condicionada ao j -ésimo estado dos seus pais; r_i é o número de estados da variável X_i ; $N_{ij} = \sum_{k=1}^{r_i} N_{ijk}$.

Existem várias metodologias na literatura para a aprendizagem da estrutura como menciona (Júnior, 2003), na qual cada uma deve ser melhor aplicada em um dado problema específico. Porém, é difícil afirmar qual dos métodos é o mais robusto. Dentre os métodos existentes destacam-se:

- Métodos de Verossimilhança Máxima e "Minimum Cross Entropy" (Herskovits e Cooper, 1990): O método da máxima verossimilhança é utilizado para se definir qual é a melhor estrutura gráfica que representa a distribuição em questão e a seleção é feita com base na verossimilhança dos parâmetros. Já o método da mínima entropia, determina como estrutura ótima, a que possui mínima entropia com os dados (Johnson e Shore, 1983).
- Métodos de Teste de Hipóteses: Este é um modelo básico de seleção de estruturas dado pela estatística clássica. O maior problema desta metodologia, é que ele só trata problemas em que o número de hipóteses não é muito elevado, caso contrário, o método é inviável (Ripley, 1994).
- Métodos de Verossimilhança Estendidos: Na tentativa de otimizar o método da verossimilhança máxima, surgiram várias extensões, como: "verossimilhança penalizada", "critérios de informação AKAIKE" (AIC), "critérios de informação bayesianos" (BIC) e muitos outros (Johnson e Shore, 1983).

- Métodos "Minimum Information Complexity": Este método é bastante utilizado por engenheiros e cientistas da computação, pois são pessoas que possuem um bom embasamento teórico na área de codificação e teoria da informação. Uma das maiores vantagens apontadas pelos defensores deste método é que ele dispensa a existência de conhecimento a priori (Suzuki, 1993).
- Métodos "Resampling": Esta técnica baseia-se na criação de pseudo-amostras a partir da amostra original (Fung e Crawford, 1990). É um método simples e que não possui grande complexidade matemática.
- Métodos Bayesianos: Existem várias versões de métodos bayesianos, e a maioria dos métodos já citados pode ser reproduzida de alguma forma, aplicando-se as técnicas bayesianas (Buntine, 1994). destacando o clássico algoritmo K2.

3.3 Distribuição Qui-Quadrado (χ^2)

Desenvolvido por Karl Pearson em 1899, criada para medir o grau de discrepância entre um conjunto de frequências observadas (o) e o conjunto de frequências esperadas (e) segundo determinada hipótese. É um teste estatístico não paramétrico, ou seja, não depende dos parâmetros populacionais, como a media e variância (Beiguelman, 1994).

Evidentemente, pode-se dizer que dois grupos se comportam de forma semelhante se as diferenças entre as frequências observadas e as esperadas em cada categoria forem muito pequenas, próximas a zero.

Portanto, o teste é utilizado para:

- Verificar se a frequência com que um determinado acontecimento observado em uma amostra se desvia significativamente ou não da frequência com que ele é esperado.
- Comparar a distribuição de diversos acontecimentos em diferentes amostras, a fim de avaliar se as proporções observadas destes eventos mostram ou não diferenças significativas ou se as amostras diferem significativamente quanto às proporções desses acontecimentos.

Para aplicar o teste (χ^2) as seguintes proposições precisam ser satisfeitas:

- Os grupos são independentes.
- Os itens de cada grupo são selecionados aleatoriamente.
- As observações devem ser frequências ou contagens.

- Cada observação pertence a uma e somente uma categoria e
- A amostra deve ser relativamente grande (pelo menos 5 observações em cada célula e, no caso de poucos grupos - pelo menos 10 - Exemplo: em tabelas 2x2).

3.3.1 Cálculo do valor χ^2

Karl Pearson propôs a seguinte fórmula para medir as possíveis discrepâncias entre proporções observadas e esperadas:

$$\chi^2 = \sum_{i=1}^p \sum_{j=1}^q \frac{(o_{ij} - e_{ij})^2}{e_{ij}} \quad (3.10)$$

em que:

o_{ij} é a frequência observada para cada classe e e_{ij} é a frequência esperada para aquela classe. A diferença entre os valores observados e esperados ($o_{ij} - e_{ij}$) dados em uma classe é um desvio (d_{ij}), portanto a fórmula também pode ser escrita como:

$$\chi^2 = \sum_{i=1}^p \sum_{j=1}^q \frac{(d_{ij})^2}{e_{ij}} \quad (3.11)$$

As frequências observadas são obtidas diretamente dos dados das amostras, enquanto que as frequências esperadas são calculadas a partir destas, utilizando a seguinte formula:

$$e_{ij} = (TL * TC) / N \quad (3.12)$$

em que:

TL é a soma total marginal da linha, TC é a soma total marginal da coluna e N é a soma total das frequências observadas.

3.3.2 Hipóteses a serem testados

- Hipótese nula (H_o): As frequências observadas não são diferentes das frequências esperadas. Não existe diferença entre as frequências (contagens) dos grupos. Portanto, não há associação entre os grupos
- Hipótese alternativa (H_a): As frequências observadas são diferentes das frequências esperadas, portanto existe diferença entre as frequências. Portanto, há associação entre os grupos.

No procedimento deste teste é, necessário obter duas estatísticas denominadas: χ_c^2 calculado, o qual é obtido da fórmula apresentada na sessão 3.10 e χ_t^2 tabelado cujo valor é obtido da tabela de distribuição Qui-quadrado (Apêndice C), levando em consideração o número de graus de liberdade e do nível de significância adotado.

3.3.3 A tomada de decisão

É feita comparando os dois valores de χ^2 :

- Se $\chi_c^2 \geq \chi_t^2$: Rejeita-se H_o .
- Se $\chi_c^2 < \chi_t^2$: Aceita-se H_o .

Quando se consulta a tabela de χ^2 observa-se que é determinada uma *probabilidade de ocorrência* daquele acontecimento. Portanto, rejeita-se uma hipótese quando a máxima probabilidade de erro ao rejeitar aquela hipótese for baixa (alfa baixo). Ou, quando a probabilidade dos desvios terem ocorrido pelo simples acaso é baixa.

O nível de significância (alfa) representa a máxima probabilidade de erro que se tem ao rejeitar uma hipótese. O número de graus de liberdade, nesse caso é calculado com a seguinte fórmula:

$$gl = (nl - 1)(nc - 1) \quad (3.13)$$

Em que:

nl é o número linhas e nc é o número de colunas.

E, evidentemente, quanto maior for o valor do χ^2 mais significativa é a relação entre a variável dependente e a variável independente.

3.3.4 Coeficiente de contingência de Pearson (CC)

O coeficiente de contingência quantifica o relacionamento entre duas (ou mais) variáveis de escala nominal. O coeficiente de contingência (CC) calcula-se como:

$$CC = \sqrt{\frac{\chi^2}{\chi^2 + n}} \quad (3.14)$$

Em que n é o tamanho da amostra.

Este coeficiente toma valores entre 0 e 1. Por outro lado, o valor 0 corresponde ao caso em que se tem independência e valores mais elevados correspondem a associação mais forte entre as variáveis.

Após a apresentação dos principais conceitos das probabilidades, as redes Bayesianas incluindo o teste estatístico Qui-quadrado, o próximo capítulo apresenta a metodologia proposta para o diagnóstico de falhas incipientes em transformadores de potência.

Metodologia

Conforme os estudos realizados sobre o comportamento e a presença de falhas incipientes em transformadores de potência, estruturou-se a RB representada por sete nós, classificados em duas categorias baseadas na teoria Bayesiana:

4.1 Definição dos nós da rede Bayesiana

1. Nós causais: ativam o diagnóstico do transformador de potência, composto por quatro nós representados pelas relações dos gases dissolvidos no óleo isolante do transformador, isto é, metano/hidrogênio (CH_4/H_2), etano/metano (C_2H_6/CH_4), etileno/etano (C_2H_4/C_2H_6) e acetileno/etileno (C_2H_2/C_2H_4), referenciadas às relações utilizadas no método de Rogers. Estas relações serão denominadas como R_1 , R_2 , R_3 e R_4 , respectivamente.
2. Nós efeitos: manifestações das falhas incipientes no transformador. São considerados três nós de diagnóstico: Normal (que apresenta uma deterioração normal), Falha Elétrica e Falha Térmica. Os dois últimos nós, conforme as principais falhas, estão referenciados no guia de interpretação de gases em óleo isolante apresentado por IEEE (IEEE, Std C 57.104-1991).

Na figura 4.1 é apresentada a estrutura dessa Rede Bayesiana (RB).




Figura 4.1: Estrutura da Rede Bayesiana.

4.2 Estados de cada nó

Cada variável da RB apresenta estados finitos, mutuamente excludentes, obedecendo a teoria bayesiana. As faixas de variação dos estados de R_1 , R_2 , R_3 e R_4 , foram delimitadas conforme a Tabela 2.2, proposta por Rogers (Rogers, seção 10-201 1975): R_1 (Muito Baixo, Baixo, Alto, Muito Alto), R_2 (Baixo, Alto), R_3 (Baixo, Médio, Alto) e R_4 (Baixo, Médio, Alto); e os estados dos nós de diagnóstico Normal, Falha Elétrica e Falha Térmica possuem dois estados (Sim e Não). Na figura 4.2 são apresentados os estados de cada nó da rede bayesiana escolhida.

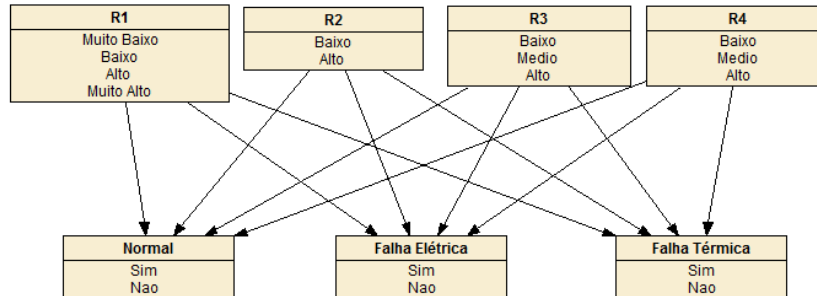


Figura 4.2: Estados das variáveis da Rede Bayesiana.

4.3 Definição dos nós de diagnóstico

Foram definidos três nós de diagnósticos como se descreve nas seções 4.3.1, 4.3.2 e 4.3.3. Estes nós são: o diagnóstico de normalidade, falha de tipo elétrico e falha de tipo térmico, conforme as principais falhas em transformadores de potência, que estão referenciadas no guia de interpretação de gases em óleo isolante apresentado por IEEE (IEEE, Std C 57.104-1991).

4.3.1 Normal

Condição de normalidade, envelhecimento normal, deterioração normal.

4.3.2 Falha de tipo elétrica

Descargas parciais (PD), descargas elétricas de baixa energia (D1), descargas elétricas de alta energia (D2), descarga contínua de baixa potência, arco com alta energia, corrente de circulação entre bobina e tanque, descarga sem fluxo de energia, arco com fluxo de energia, centelhamento contínuo, descargas parciais com monitoramento.

4.3.3 Falha de tipo térmica

Sobreaquecimento, defeitos térmicos com temperaturas menores que 300°C (T1), defeitos térmicos com temperaturas entre 300°C - 700°C (T2), defeitos térmicos com temperaturas maiores que 700°C (T3), leve sobreaquecimento abaixo de 150°C, sobreaquecimento entre 150°C e 200°C, sobreaquecimento entre 200°C e 300°C, sobreaquecimento geral em condutores e conexões, corrente de circulação nos enrolamentos e no núcleo e tanque, pontos quentes.

4.4 Histórico de dados

Os dados utilizados na RB da figura 4.1 foram fornecidos por um banco de dados (BD) pertencente a uma grande empresa do setor elétrico brasileiro referenciado na pesquisa (Morais, 2004), medido no período de 1979 a 1998. O BD constitui-se em dados históricos com amostras de diferentes transformadores e diagnósticos determinados por especialista. São 20 transformadores com dados históricos totalizando 232 amostras, distribuídas em 191 amostras com diagnóstico de condições normais, 13 amostras com diagnóstico de falha elétrica e 28 amostras com diagnóstico de falha térmica. Cada amostra contém gases dissolvidos em óleo isolante hidrogênio (H_2), metano (CH_4), etano (C_2H_6), etileno (C_2H_4) e acetileno (C_2H_2).

4.5 Metodologia para determinação da distribuição de probabilidades de cada nó

Para determinar a distribuição de probabilidade associada a cada nó, foi utilizada a distribuição de frequências relativas para os nós causais (*a priori*), e as distribuições de probabilidades condicionais (*a posteriori*) para os nós de diagnóstico, auxiliados pela equação 3.9, apresentados nas Tabelas 4.1, 4.2, 4.3, 4.4, 4.5, 4.6 e 4.7. Nos nós Normal, Falha Elétrica e Falha Térmica foram apresentadas 72 configurações para cada distribuição de probabilidade (conforme equação 3.7), dados os estados de seus pais R_1 , R_2 , R_3 e R_4 , conforme a estrutura da RB mostrada na figura 4.1.

Tabela 4.1: Distribuição de probabilidade de

R_1	
R_1	$P(R_1)$
Muito Baixo	0.32203
Baixo	0.5339
Alto	0.09746
Muito Alto	0.04661

Tabela 4.2: Distribuição de probabilidade de

R_2	
R_2	$P(R_2)$
Baixo	0.57265
Alto	0.42735

Tabela 4.3: Distribuição de probabilidade de

R_3	
R_3	$P(R_3)$
Baixo	0.32341
Medio	0.36596
Alto	0.31064

Tabela 4.4: Distribuição de probabilidade de

R_4	
R_4	$P(R_4)$
Baixo	0.89362
Medio	0.09787
Alto	0.00851

Tabela 4.5: Distribuição de probabilidade de Normal

#	R_1	R_2	R_3	R_4	Normal	
					Sim	Não
1	Muito Baixo	Baixo	Baixo	Baixo	0.5000	0.5000
2	Muito Baixo	Baixo	Baixo	Médio	0.5000	0.5000
3	Muito Baixo	Baixo	Baixo	Alto	0.5000	0.5000
4	Muito Baixo	Baixo	Médio	Baixo	0.7727	0.2273
5	Muito Baixo	Baixo	Médio	Médio	0.5000	0.5000
6	Muito Baixo	Baixo	Médio	Alto	0.5000	0.5000
7	Muito Baixo	Baixo	Alto	Baixo	0.9231	0.0769
8	Muito Baixo	Baixo	Alto	Médio	0.2500	0.7500
9	Muito Baixo	Baixo	Alto	Alto	0.5000	0.5000
10	Muito Baixo	Alto	Baixo	Baixo	0.8333	0.1667
11	Muito Baixo	Alto	Baixo	Médio	0.5000	0.5000
12	Muito Baixo	Alto	Baixo	Alto	0.5000	0.5000
13	Muito Baixo	Alto	Médio	Baixo	0.8889	0.1111
14	Muito Baixo	Alto	Médio	Médio	0.6667	0.3333
15	Muito Baixo	Alto	Médio	Alto	0.5000	0.5000
16	Muito Baixo	Alto	Alto	Baixo	0.5000	0.5000
17	Muito Baixo	Alto	Alto	Médio	0.5000	0.5000
18	Muito Baixo	Alto	Alto	Alto	0.5000	0.5000
19	Baixo	Baixo	Baixo	Baixo	0.5000	0.5000
20	Baixo	Baixo	Baixo	Médio	0.5000	0.5000
21	Baixo	Baixo	Baixo	Alto	0.5000	0.5000
22	Baixo	Baixo	Médio	Baixo	0.9286	0.0714
23	Baixo	Baixo	Médio	Médio	0.4000	0.6000
24	Baixo	Baixo	Médio	Alto	0.5000	0.5000
25	Baixo	Baixo	Alto	Baixo	0.8605	0.1395
26	Baixo	Baixo	Alto	Médio	0.4286	0.5714
27	Baixo	Baixo	Alto	Alto	0.3333	0.6667
28	Baixo	Alto	Baixo	Baixo	0.9063	0.0938
29	Baixo	Alto	Baixo	Médio	0.8333	0.1667
30	Baixo	Alto	Baixo	Alto	0.5000	0.5000
31	Baixo	Alto	Médio	Baixo	0.9167	0.0833
32	Baixo	Alto	Médio	Médio	0.8571	0.1429
33	Baixo	Alto	Médio	Alto	0.5000	0.5000
34	Baixo	Alto	Alto	Baixo	0.5000	0.5000
35	Baixo	Alto	Alto	Médio	0.5000	0.5000
36	Baixo	Alto	Alto	Alto	0.5000	0.5000
37	Alto	Baixo	Baixo	Baixo	0.5000	0.5000
38	Alto	Baixo	Baixo	Médio	0.5000	0.5000
39	Alto	Baixo	Baixo	Alto	0.5000	0.5000
40	Alto	Baixo	Médio	Baixo	0.5714	0.4286
41	Alto	Baixo	Médio	Médio	0.6667	0.3333
42	Alto	Baixo	Médio	Alto	0.5000	0.5000
43	Alto	Baixo	Alto	Baixo	0.4545	0.5455
44	Alto	Baixo	Alto	Médio	0.5000	0.5000
45	Alto	Baixo	Alto	Alto	0.5000	0.5000
46	Alto	Alto	Baixo	Baixo	0.6250	0.3750
47	Alto	Alto	Baixo	Médio	0.5000	0.5000
48	Alto	Alto	Baixo	Alto	0.5000	0.5000
49	Alto	Alto	Médio	Baixo	0.6667	0.3333
50	Alto	Alto	Médio	Médio	0.5000	0.5000
51	Alto	Alto	Médio	Alto	0.5000	0.5000
52	Alto	Alto	Alto	Baixo	0.5000	0.5000
53	Alto	Alto	Alto	Médio	0.5000	0.5000
54	Alto	Alto	Alto	Alto	0.5000	0.5000
55	Muito Alto	Baixo	Baixo	Baixo	0.5000	0.5000
56	Muito Alto	Baixo	Baixo	Médio	0.5000	0.5000
57	Muito Alto	Baixo	Baixo	Alto	0.5000	0.5000
58	Muito Alto	Baixo	Médio	Baixo	0.3750	0.6250
59	Muito Alto	Baixo	Médio	Médio	0.5000	0.5000
60	Muito Alto	Baixo	Médio	Alto	0.5000	0.5000
61	Muito Alto	Baixo	Alto	Baixo	0.2500	0.7500
62	Muito Alto	Baixo	Alto	Médio	0.3333	0.6667
63	Muito Alto	Baixo	Alto	Alto	0.5000	0.5000
64	Muito Alto	Alto	Baixo	Baixo	0.6667	0.3333
65	Muito Alto	Alto	Baixo	Médio	0.5000	0.5000
66	Muito Alto	Alto	Baixo	Alto	0.5000	0.5000
67	Muito Alto	Alto	Médio	Baixo	0.5000	0.5000
68	Muito Alto	Alto	Médio	Médio	0.5000	0.5000
69	Muito Alto	Alto	Médio	Alto	0.5000	0.5000
70	Muito Alto	Alto	Alto	Baixo	0.5000	0.5000
71	Muito Alto	Alto	Alto	Médio	0.5000	0.5000
72	Muito Alto	Alto	Alto	Alto	0.5000	0.5000

Tabela 4.6: Distribuição de probabilidade de Falha Elétrica

#	R_1	R_2	R_3	R_4	Falha Elétrica	
					Sim	Não
1	Muito Baixo	Baixo	Baixo	Baixo	0.5000	0.5000
2	Muito Baixo	Baixo	Baixo	Médio	0.5000	0.5000
3	Muito Baixo	Baixo	Baixo	Alto	0.5000	0.5000
4	Muito Baixo	Baixo	Médio	Baixo	0.0455	0.9545
5	Muito Baixo	Baixo	Médio	Médio	0.5000	0.5000
6	Muito Baixo	Baixo	Médio	Alto	0.5000	0.5000
7	Muito Baixo	Baixo	Alto	Baixo	0.0769	0.9231
8	Muito Baixo	Baixo	Alto	Médio	0.7500	0.2500
9	Muito Baixo	Baixo	Alto	Alto	0.5000	0.5000
10	Muito Baixo	Alto	Baixo	Baixo	0.0556	0.9444
11	Muito Baixo	Alto	Baixo	Médio	0.5000	0.5000
12	Muito Baixo	Alto	Baixo	Alto	0.5000	0.5000
13	Muito Baixo	Alto	Médio	Baixo	0.1111	0.8889
14	Muito Baixo	Alto	Médio	Médio	0.3333	0.6667
15	Muito Baixo	Alto	Médio	Alto	0.5000	0.5000
16	Muito Baixo	Alto	Alto	Baixo	0.5000	0.5000
17	Muito Baixo	Alto	Alto	Médio	0.5000	0.5000
18	Muito Baixo	Alto	Alto	Alto	0.5000	0.5000
19	Baixo	Baixo	Baixo	Baixo	0.5000	0.5000
20	Baixo	Baixo	Baixo	Médio	0.5000	0.5000
21	Baixo	Baixo	Baixo	Alto	0.5000	0.5000
22	Baixo	Baixo	Médio	Baixo	0.0714	0.9286
23	Baixo	Baixo	Médio	Médio	0.6000	0.4000
24	Baixo	Baixo	Médio	Alto	0.5000	0.5000
25	Baixo	Baixo	Alto	Baixo	0.0465	0.9535
26	Baixo	Baixo	Alto	Médio	0.5714	0.4286
27	Baixo	Baixo	Alto	Alto	0.6667	0.3333
28	Baixo	Alto	Baixo	Baixo	0.0625	0.9375
29	Baixo	Alto	Baixo	Médio	0.1667	0.8333
30	Baixo	Alto	Baixo	Alto	0.5000	0.5000
31	Baixo	Alto	Médio	Baixo	0.0833	0.9167
32	Baixo	Alto	Médio	Médio	0.1429	0.8571
33	Baixo	Alto	Médio	Alto	0.5000	0.5000
34	Baixo	Alto	Alto	Baixo	0.5000	0.5000
35	Baixo	Alto	Alto	Médio	0.5000	0.5000
36	Baixo	Alto	Alto	Alto	0.5000	0.5000
37	Alto	Baixo	Baixo	Baixo	0.5000	0.5000
38	Alto	Baixo	Baixo	Médio	0.5000	0.5000
39	Alto	Baixo	Baixo	Alto	0.5000	0.5000
40	Alto	Baixo	Médio	Baixo	0.1429	0.8571
41	Alto	Baixo	Médio	Médio	0.3333	0.6667
42	Alto	Baixo	Médio	Alto	0.5000	0.5000
43	Alto	Baixo	Alto	Baixo	0.0909	0.9091
44	Alto	Baixo	Alto	Médio	0.5000	0.5000
45	Alto	Baixo	Alto	Alto	0.5000	0.5000
46	Alto	Alto	Baixo	Baixo	0.1250	0.8750
47	Alto	Alto	Baixo	Médio	0.5000	0.5000
48	Alto	Alto	Baixo	Alto	0.5000	0.5000
49	Alto	Alto	Médio	Baixo	0.3333	0.6667
50	Alto	Alto	Médio	Médio	0.5000	0.5000
51	Alto	Alto	Médio	Alto	0.5000	0.5000
52	Alto	Alto	Alto	Baixo	0.5000	0.5000
53	Alto	Alto	Alto	Médio	0.5000	0.5000
54	Alto	Alto	Alto	Alto	0.5000	0.5000
55	Muito Alto	Baixo	Baixo	Baixo	0.5000	0.5000
56	Muito Alto	Baixo	Baixo	Médio	0.5000	0.5000
57	Muito Alto	Baixo	Baixo	Alto	0.5000	0.5000
58	Muito Alto	Baixo	Médio	Baixo	0.2500	0.7500
59	Muito Alto	Baixo	Médio	Médio	0.5000	0.5000
60	Muito Alto	Baixo	Médio	Alto	0.5000	0.5000
61	Muito Alto	Baixo	Alto	Baixo	0.2500	0.7500
62	Muito Alto	Baixo	Alto	Médio	0.3333	0.6667
63	Muito Alto	Baixo	Alto	Alto	0.5000	0.5000
64	Muito Alto	Alto	Baixo	Baixo	0.3333	0.6667
65	Muito Alto	Alto	Baixo	Médio	0.5000	0.5000
66	Muito Alto	Alto	Baixo	Alto	0.5000	0.5000
67	Muito Alto	Alto	Médio	Baixo	0.5000	0.5000
68	Muito Alto	Alto	Médio	Médio	0.5000	0.5000
69	Muito Alto	Alto	Médio	Alto	0.5000	0.5000
70	Muito Alto	Alto	Alto	Baixo	0.5000	0.5000
71	Muito Alto	Alto	Alto	Médio	0.5000	0.5000
72	Muito Alto	Alto	Alto	Alto	0.5000	0.5000

Tabela 4.7: Distribuição de probabilidade de Falha Térmica

#	R_1	R_2	R_3	R_4	Falha Térmica	
					Sim	Não
1	Muito Baixo	Baixo	Baixo	Baixo	0.5000	0.5000
2	Muito Baixo	Baixo	Baixo	Médio	0.5000	0.5000
3	Muito Baixo	Baixo	Baixo	Alto	0.5000	0.5000
4	Muito Baixo	Baixo	Médio	Baixo	0.2273	0.7727
5	Muito Baixo	Baixo	Médio	Médio	0.5000	0.5000
6	Muito Baixo	Baixo	Médio	Alto	0.5000	0.5000
7	Muito Baixo	Baixo	Alto	Baixo	0.0769	0.9231
8	Muito Baixo	Baixo	Alto	Médio	0.2500	0.7500
9	Muito Baixo	Baixo	Alto	Alto	0.5000	0.5000
10	Muito Baixo	Alto	Baixo	Baixo	0.1389	0.8611
11	Muito Baixo	Alto	Baixo	Médio	0.5000	0.5000
12	Muito Baixo	Alto	Baixo	Alto	0.5000	0.5000
13	Muito Baixo	Alto	Médio	Baixo	0.1111	0.8889
14	Muito Baixo	Alto	Médio	Médio	0.3333	0.6667
15	Muito Baixo	Alto	Médio	Alto	0.5000	0.5000
16	Muito Baixo	Alto	Alto	Baixo	0.5000	0.5000
17	Muito Baixo	Alto	Alto	Médio	0.5000	0.5000
18	Muito Baixo	Alto	Alto	Alto	0.5000	0.5000
19	Baixo	Baixo	Baixo	Baixo	0.5000	0.5000
20	Baixo	Baixo	Baixo	Médio	0.5000	0.5000
21	Baixo	Baixo	Baixo	Alto	0.5000	0.5000
22	Baixo	Baixo	Médio	Baixo	0.0357	0.9643
23	Baixo	Baixo	Médio	Médio	0.2000	0.8000
24	Baixo	Baixo	Médio	Alto	0.5000	0.5000
25	Baixo	Baixo	Alto	Baixo	0.1163	0.8837
26	Baixo	Baixo	Alto	Médio	0.1429	0.8571
27	Baixo	Baixo	Alto	Alto	0.3333	0.6667
28	Baixo	Alto	Baixo	Baixo	0.0625	0.9375
29	Baixo	Alto	Baixo	Médio	0.1667	0.8333
30	Baixo	Alto	Baixo	Alto	0.5000	0.5000
31	Baixo	Alto	Médio	Baixo	0.0833	0.9167
32	Baixo	Alto	Médio	Médio	0.1429	0.8571
33	Baixo	Alto	Médio	Alto	0.5000	0.5000
34	Baixo	Alto	Alto	Baixo	0.5000	0.5000
35	Baixo	Alto	Alto	Médio	0.5000	0.5000
36	Baixo	Alto	Alto	Alto	0.5000	0.5000
37	Alto	Baixo	Baixo	Baixo	0.5000	0.5000
38	Alto	Baixo	Baixo	Médio	0.5000	0.5000
39	Alto	Baixo	Baixo	Alto	0.5000	0.5000
40	Alto	Baixo	Médio	Baixo	0.4286	0.5714
41	Alto	Baixo	Médio	Médio	0.3333	0.6667
42	Alto	Baixo	Médio	Alto	0.5000	0.5000
43	Alto	Baixo	Alto	Baixo	0.5455	0.4545
44	Alto	Baixo	Alto	Médio	0.5000	0.5000
45	Alto	Baixo	Alto	Alto	0.5000	0.5000
46	Alto	Alto	Baixo	Baixo	0.3750	0.6250
47	Alto	Alto	Baixo	Médio	0.5000	0.5000
48	Alto	Alto	Baixo	Alto	0.5000	0.5000
49	Alto	Alto	Médio	Baixo	0.3333	0.6667
50	Alto	Alto	Médio	Médio	0.5000	0.5000
51	Alto	Alto	Médio	Alto	0.5000	0.5000
52	Alto	Alto	Alto	Baixo	0.5000	0.5000
53	Alto	Alto	Alto	Médio	0.5000	0.5000
54	Alto	Alto	Alto	Alto	0.5000	0.5000
55	Muito Alto	Baixo	Baixo	Baixo	0.5000	0.5000
56	Muito Alto	Baixo	Baixo	Médio	0.5000	0.5000
57	Muito Alto	Baixo	Baixo	Alto	0.5000	0.5000
58	Muito Alto	Baixo	Médio	Baixo	0.5000	0.5000
59	Muito Alto	Baixo	Médio	Médio	0.5000	0.5000
60	Muito Alto	Baixo	Médio	Alto	0.5000	0.5000
61	Muito Alto	Baixo	Alto	Baixo	0.7500	0.2500
62	Muito Alto	Baixo	Alto	Médio	0.6667	0.3333
63	Muito Alto	Baixo	Alto	Alto	0.5000	0.5000
64	Muito Alto	Alto	Baixo	Baixo	0.3333	0.6667
65	Muito Alto	Alto	Baixo	Médio	0.5000	0.5000
66	Muito Alto	Alto	Baixo	Alto	0.5000	0.5000
67	Muito Alto	Alto	Médio	Baixo	0.5000	0.5000
68	Muito Alto	Alto	Médio	Médio	0.5000	0.5000
69	Muito Alto	Alto	Médio	Alto	0.5000	0.5000
70	Muito Alto	Alto	Alto	Baixo	0.5000	0.5000
71	Muito Alto	Alto	Alto	Médio	0.5000	0.5000
72	Muito Alto	Alto	Alto	Alto	0.5000	0.5000

Aplicação da Metodologia e Análise dos Resultados

Neste capítulo será discutido o emprego da metodologia descrita no capítulo anterior para o diagnóstico de falhas incipientes em transformadores de potência, e serão apresentados os resultados obtidos da aplicação da metodologia.

5.1 Histórico de Dados Utilizados

Nesta etapa de validação da rede Bayesiana e os resultados, foi utilizada dois conjuntos de dados da análise de gases dissolvidos no óleo, como se descreve:

- **Primeiro.**- O banco de dados (Apêndice A) pertencente a uma grande empresa de setor brasileiro, colhidos no período de 1979 a 1998, descrito na seção 4.4, o mesmo que foi utilizado para construção dos parâmetros da rede Bayesiana proposta.
- **Segundo.**- O banco de dados (Apêndice B) composto de 56 casos de anormalidade: 36 de origem elétrica e 20 de origem térmica, publicado na IEC (IEC-60599, 1999). Apresenta as amostras, com as respectivas concentrações dos gases, organizados por tipo de falhas e identificados por equipamento (Duval e dePabla, 2001)

5.2 Resultados do Primeiro Histórico de Dados

O diagnóstico da RB é dado pela presença da maior probabilidade de ocorrência em uma das três variáveis de diagnóstico, por exemplo, no último caso registrado no primeiro banco de

dados observa-se que hidrogênio (H_2) = 12ppm, metano (CH_4) = 5ppm, etileno (C_2H_4) = 5ppm, etano (C_2H_6) = 7ppm e acetileno (C_2H_2) = 0.4ppm. Para aplicar a rede Bayesiana é necessário calcular as relações dos gases (R_1, R_2, R_3 e R_4) conforme as entradas da rede. Neste caso as relações são: $R_1 = 0.416666666666667$ (Baixo), $R_2 = 1.4$ (Alto), $R_3 = 0.714285714$ (Baixo) e $R_4 = 0.08$ (Baixo). Dadas estas relações (evidências), a rede Bayesiana diagnosticou o estado do transformador como "Normal", apresentando uma maior probabilidade de ocorrência (90.62 %), conforme a distribuição de probabilidade dada na tabela 4.5, que coincide com o diagnóstico original do especialista dado no banco de dados (BD).

Uma vez aplicada a rede Bayesiana a todos os casos apresentados no banco de dados, confrontou-se os diagnósticos dados na RB com aqueles registrados no banco de dados fornecidos por especialistas.

A RB apresentou um alto grau de confiabilidade no diagnóstico em comparação aos diagnósticos dados pelo especialista de BD. Como pode ser observado na Tabela 5.1, para o diagnóstico de todos os casos apresentados no BD, a RB concluiu que 87.50% dos casos são normais, 4.74% falha elétrica e 7.76% falha térmica, em comparação ao diagnóstico dado pelo especialista do BD, em que a condição normal foi de 82.33%, falha elétrica 5.60% e falha térmica 12.07%, apresentando uma pequena variação entre os diagnósticos, como também podem ser observadas nas figuras 5.1 e 5.2.

Tabela 5.1: Diagnósticos dados pela RB e o especialista (BD1)

Rede Bayesiana	Especialista (BD)			Total
	Normal	Falha Elétrica	Falha Térmica	
Normal	0.7845	0.0172	0.0733	0.8750
Falha Elétrica	0.0129	0.0345	0.0000	0.0474
Falha Térmica	0.0259	0.0043	0.0474	0.0776
Total	0.8233	0.0560	0.1207	1.0000




Figura 5.1: Diagnóstico estabelecido no banco de dados.




Figura 5.2: Diagnóstico dado na Rede Bayesiana proposta.

Tabela 5.2: Comparação de casos avaliados da RB com diagnósticos dado no BD1

Situação	Diagnósticos			Total	Porcentagem
	Normal	Falha Elétrica	Falha Térmica		
Diagnósticos iguais	182	8	11	201	86.64%
Diagnósticos diferentes	9	5	17	31	13.39%
Total	191	13	28	232	100.00%

Conforme a Tabela 5.2, observa-se que a RB apresenta um 86.64% de casos com o mesmo diagnóstico dado pelo especialista do banco de dados (BD1), confirmando assim a confiabilidade da rede Bayesiana para o diagnóstico de falhas incipientes em transformadores de potência.

A continuação foi aplicada o teste Qui-quadrada para verificar a relação dos diagnósticos tanto do especialista como da rede Bayesiana, no qual as hipóteses a serem testadas foi:

- Hipótese nula (H_o): As frequências observadas não são diferentes das frequências esperadas. Não existe diferença entre as frequências (contagens) dos grupos. Portanto, não há associação entre os grupos
- Hipótese alternativa (H_a): As frequências observadas são diferentes das frequências esperadas, portanto existe diferença entre as frequências. Portanto, há associação entre os grupos.

A tabela de cruzamento de dados de diagnóstico do especialista e a rede Bayesiana está apresentada na tabela 5.3, os quais são as frequências observadas para o teste Qui-quadrada.

A partir desses dados, calcularam-se os valores esperados aplicando a fórmula 3.12 apresentada na seção 3.3.1, cujos resultados é observado na tabela 5.4

Por meio da fórmula 3.10 apresentada na seção 3.3.1, foi obtida que o valor do teste Qui-quadrada é $\chi^2 = \chi_c^2 = 143.35$. Para obter o valor de Qui-quadrada tabelado $\chi_t^2 = \chi_{gl;\alpha}^2$ foi

Tabela 5.3: Cruzamento de dados de diagnóstico do especialista e a rede Bayesiana

Rede Bayesiana	Especialista (BD)			Total
	Normal	Falha Elétrica	Falha Térmica	
Normal	182	4	17	203
Falha Elétrica	3	8	0	11
Falha Térmica	6	1	11	18
Total	191	13	28	232

Tabela 5.4: Frequências esperadas para o teste Qui-quadrada

Rede Bayesiana	Especialista (BD)			Total
	Normal	Falha Elétrica	Falha Térmica	
Normal	167.13	11.38	24.50	203
Falha Elétrica	9.06	0.62	1.33	11
Falha Térmica	14.82	1.01	2.17	18
Total	191	13	28	232

considerado o grau de liberdade $gl = (3 - 1)(3 - 1)$ conforme a formula 3.13 e o nível de significância considerada foi de $\alpha = 0.050$. Sendo então o valor tabelado da distribuição de probabilidade Qui-quadrada $\chi_t^2 = \chi_{4;0.050}^2 = 9.488$ (Apêndice C).

Na tomada de decisão foi rejeitado a H_0 porque ao comparar os valores de Qui-quadrada calculada e tabelado ($\chi_c^2 = 143.35 > \chi_t^2 = 9.488$), encontrou-se que o valor de χ_c^2 é maior que χ_t^2 , indicando que há evidência de associação entre os dois grupos de diagnósticos. Encontrou-se também que existe uma relação de 62.80% nos diagnósticos dados pelo especialista e a rede Bayesiana (para o calculo desta relação aplicou-se a formula 3.14 apresentada na seção 3.3.4). O qual indica e confirma a coerência dos resultados fornecidos pela rede Bayesiana.

5.3 Resultados do Segundo Histórico de Dados

A seguir aplicou-se a rede Bayesiana para todos os casos apresentados no segundo conjunto de dados, em que estes apresentam diagnósticos originais de anomalias: elétricas e térmicas em todos os casos.

Na aplicação da rede Bayesiana observou-se a presença de dois casos especiais, dos transformadores 2 e 37, cujos valores das concentrações dos gases e suas respectivas relações (variáveis de entrada da RB) são: para *primeiro* caso hidrogênio é $(H_2) = 32930ppm$, metano $(CH_4) = 2397ppm$, etileno $(C_2H_4) = 0.4ppm$, etano $(C_2H_6) = 157ppm$ e acetileno $(C_2H_2) = 0.4ppm$, relações $R_1 = 0.072790768$ (Muito Baixo), $R_2 = 392.5$ (Alto),

$R_3 = 0.002547771$ (Baixo) e $R_4 = 1.00$ (Médio) e para *segundo* caso hidrogênio (H_2) = 3090ppm, metano (CH_4) = 5020ppm, etileno (C_2H_4) = 3800ppm, etano (C_2H_6) = 323ppm e acetileno (C_2H_2) = 2540ppm, relações $R_1 = 1.624595469$ (Alto), $R_2 = 0.085$ (Baixo), $R_3 = 11.76470588$ (Alto) e $R_4 = 0.668421053$ (Médio), em que o diagnóstico original para estes dois casos foi de falha elétrica. Porém, o diagnóstico da rede Bayesiana para estes casos observados identificou a mesma probabilidade de ocorrência para os três variáveis de diagnóstico: condição normal, falha elétrica e falha térmica. Estes casos são indeterminados pela rede Bayesiana, e devem-se empregar outros métodos de análise, ou a melhora da RB aprimorando o critério da escolha na hora do diagnóstico, o qual pode ser proposto para trabalhos posteriores.

A presença destes casos indeterminados pela RB pode acontecer pelas seguintes razões:

1° pela ausência de casos sob certas características de concentração de gases, usualmente casos isolados, que não se apresentam no banco de dados, os quais geram uma aprendizagem incompleta dos parâmetros da rede Bayesiana, atribuindo-os a mesma probabilidade de ocorrência em cada variável de diagnóstico. Daí a importância de uma base de conhecimento confiável e coerente, garantida pela quantidade e qualidade de dados a serem analisados.

2° Os diagnósticos originais pertencentes ao banco de dados têm a presença da mesma frequência de casos para condição normal, falha elétrica e falha térmica, sob as mesmas características de concentração de gases no óleo isolante gerando, assim, a mesma probabilidade de ocorrência para cada variável de diagnóstico da rede Bayesiana.

Inicialmente optou-se em adotar o critério utilizado no método de Rogers para auxiliar nestes casos não determinados pela rede Bayesiana. Todavia, este método como os demais também apresentam diagnósticos não determinados.

Foram pois avaliados os 54 casos restantes apresentados no segundo banco de dados. Na Tabela 5.5 mostra os diagnósticos dados pela rede Bayesiana e diagnósticos originais encontrados no banco de dados, em que os diagnósticos da rede Bayesiana foram de 14.82% para condição normal, 62.96% para falha elétrica e 22.22% para falha térmica. Por outro lado, o diagnóstico dado no banco de dados foi de 62.96% para falha elétrica, 37.04% para falha térmica e nenhuma porcentagem para condição normal. Observou-se também que a rede Bayesiana fez um diagnóstico de 100% para os casos de falha elétrica e 60% para os casos de falha térmica.

Tabela 5.5: Diagnósticos dados pela RB e o especialista (BD2)

Rede Bayesiana	Especialista (BD)		Total
	Falha Elétrica	Falha Térmica	
Normal	0.0000	0.1482	0.1482
Falha Elétrica	0.6296	0.0000	0.6296
Falha Térmica	0.0000	0.2222	0.2222
Total	0.6296	0.3704	1.0000

Conforme a Tabela 5.6, observa-se que a RB apresentou uma porcentagem de 85.19% de casos com o mesmo diagnóstico dos 54 casos registrados no banco de dados (BD2), confirmando assim novamente a confiabilidade da rede Bayesiana para o diagnóstico de falhas incipientes em transformadores de potência.

Tabela 5.6: Comparação de casos avaliados da RB com diagnósticos dado no BD2

Situação	Diagnósticos			Porcentagem
	Falha Elétrica	Falha Térmica	Total	
Diagnósticos iguais	34	12	46	85.19%
Diagnósticos diferentes	0	8	8	14.81%
Total	34	20	54	100.00%

A continuação aplicou-se também o teste Qui-quadrada para verificar a relação dos diagnósticos tanto do especialista como da rede Bayesiana para este segundo histórico de dados, no qual as hipóteses a serem testados foi:

- Hipótese nula (H_o): As frequências observadas não são diferentes das frequências esperadas. Não existe diferença entre as frequências (contagens) dos grupos. Portanto, não há associação entre os grupos
- Hipótese alternativa (H_a): As frequências observadas são diferentes da frequências esperadas, portanto existe diferença entre as frequências. Portanto, há associação entre os grupos.

A tabela de cruzamento de dados de diagnóstico do especialista e a rede Bayesiana está apresentada na tabela 5.7, os quais são as frequências observados para o teste Qui-quadrada.

Tabela 5.7: Cruzamento de dados de diagnóstico do especialista e a rede Bayesiana (BD2)

Rede Bayesiana	Especialista (BD)		Total
	Falha Elétrica	Falha Térmica	
Normal	0	8	8
Falha Elétrica	34	0	34
Falha Térmica	0	12	12
Total	34	20	54

A partir desses dados, calcularam-se os valores esperados aplicando a formula 3.12 apresentada na seção 3.3.1, cujos resultados é observado na tabela 5.8.

Tabela 5.8: Frequências esperadas para o teste Qui-quadrada (BD2)

Rede Bayesiana	Especialista (BD)		Total
	Falha Elétrica	Falha Térmica	
Normal	5.04	2.96	8
Falha Elétrica	21.41	12.59	34
Falha Térmica	7.56	4.44	12
Total	34	20	54

Por meio da formula 3.10, foi obtida que o valor do teste Qui-quadrada é $\chi^2 = \chi_c^2 = 364.18$ e sendo o valor de $\chi_t^2 = \chi_{4;0.050}^2 = 5.991$, considerando o mesmo parâmetro de nível de significância $\alpha = 0.050$ e grau de liberdade $gl = (3 - 1)(2 - 1)$.

Na tomada de decisão foi rejeitado mais uma vez a H_o porque ao comparar os valores de Qui-quadrada calculada e tabelado ($\chi_c^2 = 364.18 > \chi_t^2 = 5.991$), encontrou-se que o valor de χ_c^2 é maior que χ_t^2 , indicando que há evidencia de associação entre os dois grupos de diagnósticos. Encontrou-se também que existe uma relação de 93.32% nos diagnósticos dados pelo especialista e a rede Bayesiana. Observou-se neste caso, um alto grau de relação nos diagnósticos apresentados para o segundo histórico de banco de dados.

Em resumo, a rede Bayesiana proposta, apresentou um alto grau de confiabilidade nos resultados de diagnósticos de falhas incipientes no transformadores de potência em comparação aos diagnósticos registrados nos bancos de dados em estudo; apresentando 86.64% e 85.19% de casos como os mesmos resultados dos dois conjuntos de dados analisados, respectivamente.

Conclusões

6.1 Conclusões

O estudo e diagnóstico de falhas incipientes nos transformadores de potência é ainda um dos temas de maior pesquisa no setor elétrico, pela importância funcional e econômica que apresentam estes equipamentos nos sistemas de transmissão e distribuição confiável de energia elétrica, cujo objetivo é a conversão de diferentes níveis de tensão com limites de estabilidade normalizados, interligando os locais de geração de energia elétrica até locais de uso final.

Neste trabalho foi apresentada uma abordagem teórica e prática referente às técnicas de inteligência artificial no campo das redes probabilísticas, que é a rede Bayesiana aplicada ao diagnóstico das falhas incipientes em transformadores de potência através de análise de gases dissolvidos no óleo isolante (DGA).

Durante a construção da rede Bayesiana observou-se a importância da base de conhecimento, como elemento fundamental num sistema para garantir resultados eficientes e coerentes de um problema, bem como um banco de dados adequado para se conseguir um diagnóstico confiável.

A aprendizagem das redes Bayesiana é um fator importante que está diretamente relacionada à construção da base de conhecimento da rede, além de ser necessário considerar o volume de dados para uma aprendizagem eficaz: quanto maior a quantidade de dados, melhor será o resultado e, como consequência, ter-se-á uma grande contribuição no diagnóstico de falhas em

transformadores de potência.

Neste trabalho optou-se por trabalhar com dois conjuntos de dados (bancos de dados), de concessionárias diferentes para a aplicação da rede Bayesiana na solução do problema de falhas incipientes em transformadores de potência. O primeiro conjunto de dados foi utilizado para a construção da rede Bayesiana e validação da mesma, e o segundo conjunto de dados para validação da rede Bayesiana, apresentando resultados satisfatórios.

Nos resultados obtidos na etapa de validação da rede Bayesiana observou-se um acerto de 86.64% e 85.19% nos diagnósticos em comparação com os diagnósticos dados pelos especialistas nos bancos de dados em estudo, confirmando assim um alto grau de confiabilidade da rede Bayesiana proposta para diagnóstico de falhas incipientes em transformadores de potência baseados nos valores de concentração de gases dissolvidos no óleo isolante.

Esta pesquisa gerou um artigo submetido e aceito no Congresso Brasileiro de Automática - CBA, a ser realizado entre os dias 02 e 06 de setembro de 2012 em Campina Grande, PB. Um outro artigo também foi submetido à revista IEEE América Latina e ainda encontra-se em análise.

6.2 Trabalhos Futuros

Uma das maiores vantagens das redes Bayesianas é que são redes dinâmicas, que podem estar em constante atualização, tanto na parte estrutural quanto na parte paramétrica. A medida que se aumenta os casos no banco de dados a aprendizagem estrutural e dos parâmetros da rede serão melhores, influenciarão positivamente nos resultados posteriores, diminuindo assim os erros de diagnósticos e aumentando a confiabilidade da rede Bayesiana.

Como foi mencionado no capítulo anterior, a seção 5.3 apresentou dois casos encontrados no segundo conjunto de dados, em que a probabilidade de ocorrência dada pela rede Bayesiana foi igual para as três variáveis de diagnóstico; ficando assim não determinado o diagnóstico destes casos. Em trabalhos posteriores poderia-se procurar uma ferramenta ou metodologia para escolher o melhor diagnóstico baseado em alguns critérios ou características das concentrações de gases.

Sugere-se que os banco de dados de todas as concessionárias locais, nacionais e estrangeiras sejam uniformizados, indicando as anomalias encontradas em cada caso e certificando o levantamento estatístico adequado dos dados de concentrações dos gases dissolvidos no óleo isolante. Visto que a fidelidade destes dados, armazenados no banco de dados, são de crucial

importância para a elaboração confiável de uma base de conhecimento e, como consequência, os resultados serão coerentes e amplamente satisfatórios de sistemas baseados nesta base de conhecimento.

Propõe-se fazer uma metanálise dos diferentes trabalhos de pesquisa deste tipo, dado que a grande vantagem dos estudos de metanálise é a sua capacidade de síntese de informação. Num só estudo é possível fazer convergir os resultados de muitos trabalhos de investigação. Num tempo em que a investigação avança a um ritmo incessante e se torna, cada vez mais, impossível estar a par de todos os novos avanços da ciência e tecnologia esta é, de facto, uma grande vantagem.

Histórico de Dados Utilizados para Elaboração da Rede Bayesiana

Neste anexo são apresentados os dados que foram utilizados para a elaboração e teste da rede Bayesiana proposta, pertencente a uma grande empresa do setor elétrico brasileiro referenciado na pesquisa (Morais, 2004), medido no período de 1979 a 1998. O banco de dados constitui-se em dados históricos com amostras de diferentes transformadores e diagnósticos determinados por especialista. São 20 transformadores com dados históricos, totalizando 232 amostras, distribuídas em 191 amostras com diagnóstico de condições normais, 13 amostras com diagnóstico de falha elétrica e 28 amostras com diagnóstico de falha térmica. Cada amostra contém gases dissolvidos em óleo isolante hidrogênio (H_2), metano (CH_4), etano (C_2H_6), etileno (C_2H_4) e acetileno (C_2H_2).

Tabela A.1: Transformador 1

Transformador 1	H_2	CH_4	C_2H_4	C_2H_6	C_2H_2	Diagnóstico Especialista	Data da amostra	Procedimento Adotado
Fabricante: SEM	6	17	16	6	***	Normal	28/10/1985	
	10	9	14	10	***	Normal	07/12/1988	
	80	34	19	15	***	Normal	13/10/1989	
	7	75	16	9	***	Normal	18/12/1991	
	49	34	32	18	***	Normal	19/02/1993	
	81	47	27	16	***	Normal	01/03/1994	
	39	41	29	16	2	Normal	05/06/1995	
	73	45	29	23	***	Normal	09/01/1997	
	2800	940	940	100	590	Falha_Eletrica	17/02/1997	
	52	2	15	17	***	Normal	10/04/1997	óleo Trocado 03/97
	46	12	9	2	***	Normal	06/06/1997	

Tabela A.2: Transformador 2

Transformador 2	H ₂	CH ₄	C ₂ H ₄	C ₂ H ₆	C ₂ H ₂	Diagnóstico Especialista	Data da amostra	Procedimento Adotado
Fabricante: Brown Boveri	590	40	16	31	***	Falha_Termica	19/08/1981	
	320	30	19	27	***	Normal	21/12/1981	
	290	16	15	28	***	Falha_Termica	11/11/1982	
	610	17	15	18	***	Normal	23/09/1983	
	230	20	12	17	***	Normal	13/02/1984	
	410	10	10	10	***	Normal	01/07/1986	
	550	9	8	17	***	Normal	09/07/1987	
	64	3	4	4	***	Normal	06/12/1988	óleo Filtrado 08/88
	7	10	19	2	***	Normal	05/12/1995	
	64	7	47	6	***	Normal	25/02/1997	
	39	18	76	6	***	Normal	08/10/1997	
	54	12	88	6	***	Normal	22/06/1998	

Tabela A.3: Transformador 3

Transformador 3	H ₂	CH ₄	C ₂ H ₄	C ₂ H ₆	C ₂ H ₂	Diagnóstico Especialista	Data da amostra	Procedimento Adotado
Fabricante: Brown Boveri	15	110	290	47	13	Falha_Termica	04/05/1979	
	380	100	450	64	20	Falha_Termica	26/10/1979	
	390	90	410	60	28	Falha_Termica	30/10/1979	
	8	2	3	***	***	Normal	06/11/1979	Degasagem 1/11/1979
	89	8	10	8	***	Falha_Termica	29/04/1980	
	51	16	17	11	***	Normal	25/05/1981	
	9	14	10	13	***	Normal	28/07/1982	
	6	4	12	3	***	Normal	20/05/1983	
	3	2	5	5	***	Normal	04/10/1984	
	10	3	6	3	***	Normal	18/09/1985	
	83	3	6	5	***	Normal	26/05/1987	
	9	2	3	3	***	Normal	27/09/1988	
	110	7	3	6	***	Normal	13/09/1989	
	110	13	22	8	***	Normal	18/10/1990	
	39	11	21	8	***	Normal	30/07/1992	
	50	9	15	12	***	Normal	30/09/1993	
	770	16	14	18	***	Normal	05/06/1995	
53	11	8	12	***	Normal	01/04/1996		

Tabela A.4: Transformador 4

Transformador 4	H ₂	CH ₄	C ₂ H ₄	C ₂ H ₆	C ₂ H ₂	Diagnóstico Especialista	Data da amostra	Procedimento Adotado
Fabricante: Desconhecido	42	3	6	***	6	Falha_Eletrica	06/05/1979	
	6	3	5	***	***	Normal	28/05/1979	
	19	3	9	***	***	Normal	16/08/1979	
	33	3	21	***	***	Normal	04/10/1979	
	11	7	19	***	***	Normal	28/04/1980	
	16	32	23	40	***	Falha_Termica	17/02/1981	
	10	7	21	***	***	Normal	03/09/1981	
	12	8	19	***	***	Normal	15/02/1982	
	19	6	9	***	***	Normal	13/05/1982	
	29	2	16	1	***	Normal	11/01/1983	
	27	5	12	2	***	Normal	13/02/1984	
	35	3	3	3	***	Normal	08/06/1989	
	18	3	80	***	***	Falha_Eletrica	08/06/1989	
	18	2	3	5	***	Normal	27/12/1989	
	37	7	8	4	***	Normal	26/11/1992	
	60	5	7	4	***	Normal	02/12/1993	
	16	2	5	1	***	Normal	14/03/1994	
	37	3	2	3	***	Normal	26/06/1995	
	34	4	4	1	***	Normal	10/10/1996	óleo Trocado mar/97
	33	3	6	***	***	Normal	09/12/1997	

Tabela A.5: Transformador 5

Transformador 5	H ₂	CH ₄	C ₂ H ₄	C ₂ H ₆	C ₂ H ₂	Diagnóstico Especialista	Data da amostra	Procedimento Adotado
Fabricante: Itel	220	15	6	26	***	Falha_Termica	17/05/1983	
	84	8	13	4	11	Falha_Eletrica	04/05/1984	
	170	14	7	26	***	Normal	08/06/1984	
	100	10	8	24	***	Normal	27/09/1985	
	190	17	8	28	***	Normal	03/09/1986	
	250	36	19	42	***	Normal	11/03/1988	
	260	13	10	17	***	Normal	20/07/1990	
	320	10	11	11	***	Normal	06/02/1992	
	260	14	12	21	***	Normal	06/04/1993	
	200	8	12	12	***	Normal	01/12/1994	
	17	5	7	3	***	Normal	01/03/1996	óleo regenerado nov/95
	16	0	6	2	***	Normal	07/04/1997	óleo trocado nov/96
	5	7	24	3	***	Normal	20/07/1998	

Tabela A.6: Transformador 6

Transformador 6	H ₂	CH ₄	C ₂ H ₄	C ₂ H ₆	C ₂ H ₂	Diagnóstico Especialista	Data da amostra	Procedimento Adotado
Fabricante: Itel	110	15	5	28	***	Normal	02/01/1983	
	69	18	5	22	***	Normal	29/02/1984	
	140	160	410	84	1	Normal	10/06/1985	
	55	65	300	55	2	Falha_Termica	22/01/1986	óleo filtrado fev/96
	230	23	100	38	***	Normal	03/12/1986	
	210	22	12	17	***	Normal	07/11/1988	
	270	26	9	17	***	Normal	03/07/1990	

Tabela A.7: Transformador 7

Transformador 7	H ₂	CH ₄	C ₂ H ₄	C ₂ H ₆	C ₂ H ₂	Diagnóstico Especialista	Data da amostra	Procedimento Adotado
Fabricante: Itel	29	110	53	290	10	Normal	02/03/1983	
	26	51	52	530	5	Normal	17/08/1984	
	64	180	65	770	5	Normal	10/10/1986	
	620	2200	2000	1100	13	Falha_Termica	05/08/1987	
	790	2400	1900	1100	13	Falha_Termica	05/08/1987	
	410	510	600	150	26	Falha_Termica	14/08/1987	
	350	580	740	180	29	Falha_Termica	14/08/1987	
	460	670	770	200	18	Falha_Termica	27/08/1987	
	350	780	760	260	5	Falha_Termica	21/10/1987	
	2200	890	980	310	490	Normal	05/01/1988	
	13000	2000	3300	950	4600	Falha_Eletrica	19/08/1988	
	180	2700	4200	1600	12	Normal	26/08/1988	
	930	2700	3200	1700	17	Falha_Termica	07/12/1988	
	8600	2200	3100	1300	1100	Falha_Eletrica	15/02/1989	
	480	2200	2700	1600	10	Falha_Termica	31/03/1989	
430	2300	3000	1900	10	Falha_Eletrica	03/07/1989		

Tabela A.8: Transformador 8

Transformador 8	H ₂	CH ₄	C ₂ H ₄	C ₂ H ₆	C ₂ H ₂	Diagnóstico Especialista	Data da amostra	Procedimento Adotado
	13	2	***	***	***	Normal	24/08/1983	
Fabricante: Siemens	15	3	1	1	***	Normal	09/05/1984	óleo tratado 21/7/1986
	14	3	1	1	***	Normal	24/07/1986	
	11	2	3	1	***	Normal	28/01/1987	
	9	5	22	2	1	Normal	15/03/1988	
	11	3	7	3	***	Normal	01/02/1990	
	11	4	8	13	***	Normal	27/02/1991	
	8	3	8	1	2	Normal	11/02/1992	
	10	3	6	1	***	Normal	06/04/1993	
	13	4	8	2	***	Normal	27/01/1994	
	10	4	10	***	***	Normal	01/02/1995	
	7	13	2	1	***	Normal	13/11/1996	

Tabela A.9: Transformador 9

Transformador 9	H ₂	CH ₄	C ₂ H ₄	C ₂ H ₆	C ₂ H ₂	Diagnóstico Especialista	Data da amostra	Procedimento Adotado
	13	2	***	***	***	Normal	24/08/1983	
Fabricante: Siemens	13	2	***	1	***	Normal	09/05/1984	óleo tratado 21/7/1986
	9	4	2	***	***	Normal	24/07/1986	
	11	2	1	1	***	Normal	28/01/1987	
	8	2	5	1	***	Normal	15/03/1988	
	2	1	2	***	***	Normal	27/09/1988	
	4	2	4	8	***	Normal	25/01/1989	
	10	3	7	1	***	Normal	27/02/1991	
	9	4	6	1	***	Normal	11/02/1992	
	13	5	7	15	***	Normal	06/04/1993	
	25	5	8	14	***	Normal	27/01/1994	
	12	6	10	8	***	Normal	01/02/1995	
	11	5	3	1	***	Normal	13/11/1996	

Tabela A.10: Transformador 10

Transformador 10	H ₂	CH ₄	C ₂ H ₄	C ₂ H ₆	C ₂ H ₂	Diagnóstico Especialista	Data da amostra	Procedimento Adotado
	11	2	***	***	***	Normal	24/08/1983	
Fabricante: Siemens	16	3	***	1	***	Normal	09/05/1984	óleo tratado 21/7/1986
	7	2	1	1	***	Normal	24/07/1986	
	10	2	1	1	***	Normal	28/01/1987	
	7	2	5	1	***	Normal	15/03/1988	
	9	3	5	12	***	Normal	25/01/1989	
	9	4	6	6	***	Normal	01/02/1990	
	10	2	9	***	***	Normal	27/02/1991	
	10	4	8	10	***	Normal	11/02/1992	
	12	6	8	13	***	Normal	06/04/1993	
	15	7	8	24	***	Normal	27/01/1994	
	10	4	8	9	***	Normal	01/02/1995	
	6	6	2	2	***	Normal	13/11/1996	

Tabela A.11: Transformador 11

Transformador 11	H ₂	CH ₄	C ₂ H ₄	C ₂ H ₆	C ₂ H ₂	Diagnóstico Especialista	Data da amostra	Procedimento Adotado
Fab.: Asea	71	24	14	6	14	Falha_Eletrica	05/08/1982	óleo tratado jan/82
	200	150	96	160	95	Normal	09/06/1983	
	21	6	38	30	13	Normal	08/05/1985	
	22	8	11	9	***	Normal	28/06/1995	
	130	270	800	160	120	Falha_Termica	22/05/1998	

Tabela A.12: Transformador 12

Transformador 12	H_2	CH_4	C_2H_4	C_2H_6	C_2H_2	Diagnóstico Especialista	Data da amostra	Procedimento Adotado
Fabric.: IteI	64	7	7	8	***	Normal	07/04/1993	
	34	8	11	27	5	Falha_Termica	01/12/1994	
	19	5	5	7	4	Normal	27/04/1995	
	160	14	4	15	***	Normal	04/03/1996	
	25	5	***	***	***	Normal	08/04/1997	
	14	7	8	2	***	Normal	17/07/1998	óleo regenerado dez/95

Tabela A.13: Transformador 13

Transformador 13	H_2	CH_4	C_2H_4	C_2H_6	C_2H_2	Diagnóstico Especialista	Data da amostra	Procedimento Adotado
Fabric.: Toshiba	95	13	5	69	***	Falha_Eletrica	19/08/1983	
	480	37	8	84	***	Falha_Eletrica	15/10/1984	
	330	10	3	26	***	Normal	13/03/1986	
	320	10	5	17	***	Normal	19/08/1987	
	23	5	2	2	***	Normal	31/07/1997	óleo filtrado jun/96
	14	6	7	3	***	Normal	05/11/1997	
	8	5	10	3	***	Normal	24/04/1998	

Tabela A.14: Transformador 14

Transformador 14	H_2	CH_4	C_2H_4	C_2H_6	C_2H_2	Diagnóstico Especialista	Data da amostra	Procedimento Adotado
Fabricante: IteI	19	9	4	17	***	Normal	11/11/1988	
	7	9	7	8	***	Normal	20/07/1990	
	55	11	23	13	***	Normal	06/02/1992	
	26	16	18	12	***	Normal	07/04/1993	
	61	10	17	12	***	Normal	01/12/1994	
	260	8	20	9	***	Normal	04/03/1996	
	370	7	120	8	***	Normal	07/04/1997	óleo regenerado set/96
	17	12	120	7	***	Normal	20/07/1998	

Tabela A.15: Transformador 15

Transformador 15	H_2	CH_4	C_2H_4	C_2H_6	C_2H_2	Diagnóstico Especialista	Data da amostra	Procedimento Adotado
Fabricante: Trafo	64	70	16	230	***	Falha_Termica	17/05/1983	
	130	46	28	160	***	Normal	04/05/1984	
	170	67	10	130	***	Normal	14/12/1984	
	180	22	6	84	***	Normal	27/09/1985	
	180	20	6	64	***	Normal	03/09/1986	
	270	21	8	41	***	Normal	11/03/1988	
	310	9	8	11	***	Normal	10/02/1992	
	290	11	11	8	***	Normal	07/04/1993	
	220	7	10	10	***	Normal	01/12/1994	
	130	8	7	3	***	Normal	04/03/1996	
	5	2	***	***	***	Normal	01/04/1997	
	17	7	8	2	***	Normal	20/07/1998	óleo regenerado nov/97

Tabela A.16: Transformador 16

Transformador 16	H_2	CH_4	C_2H_4	C_2H_6	C_2H_2	Diagnóstico Especialista	Data da amostra	Procedimento Adotado
Fabricante: Trafo	59	37	6	120	***	Normal	17/05/1983	
	140	24	5	65	***	Normal	11/12/1984	
	150	28	10	81	***	Normal	27/09/1985	
	170	18	6	64	***	Normal	03/09/1986	
	240	20	8	39	***	Normal	11/03/1988	
	370	10	10	19	***	Normal	10/02/1992	
	230	7	5	3	***	Normal	06/04/1993	
	280	10	13	6	6	Falha_Termica	01/12/1994	
	310	10	10	3	3	Normal	27/04/1995	
	320	7	10	9	***	Normal	04/03/1996	
	11	***	***	***	***	Normal	09/04/1997	óleo regenerado jan/97
	71	7	6	2	***	Normal	20/07/1998	óleo regenerado nov/97

Tabela A.17: Transformador 17

Transformador 17	H_2	CH_4	C_2H_4	C_2H_6	C_2H_2	Diagnóstico Especialista	Data da amostra	Procedimento Adotado
Fabricante: Weg	190	37	33	2	***	Falha_Termica	08/07/1993	
	120	26	29	6	***	Normal	03/08/1993	
	15	10	19	1	42	Falha_Eletrica	18/11/1993	
	5	1	1	***	2	Normal	14/03/1994	óleo trocado jan/94
	15	2	4	2	1	Normal	08/06/1994	
	14	3	4	2	***	Normal	05/10/1994	
	3	2	4	***	***	Normal	05/12/1995	
	2	5	3	***	***	Normal	09/01/1997	

Tabela A.18: Transformador 18

Transformador 18	H_2	CH_4	C_2H_4	C_2H_6	C_2H_2	Diagnóstico Especialista	Data da amostra	Procedimento Adotado
Fabricante: H. Line	32	11	33	8	***	Normal	21/12/1983	
	100	1200	1300	370	580	Falha_Termica	09/05/1985	
	74	590	1200	300	690	Falha_Termica	13/05/1985	
	9	7	58	22	21	Normal	20/05/1985	
	30	11	68	22	24	Falha_Termica	14/08/1985	
	55	26	87	25	210	Falha_Eletrica	12/11/1985	
	28	14	74	18	130	Normal	10/12/1985	
	1	1	16	6	24	Normal	11/12/1985	
	57	5	12	3	***	Normal	14/01/1986	óleo filtrado dez/85
	23	5	13	5	12	Falha_Eletrica	17/02/1986	
	22	5	9	4	***	Normal	20/05/1987	
	15	4	3	3	***	Normal	27/01/1989	
	110	9	3	2	***	Normal	21/03/1990	

Tabela A.19: Transformador 19

Transformador 19	H_2	CH_4	C_2H_4	C_2H_6	C_2H_2	Diagnóstico Especialista	Data da amostra	Procedimento Adotado
Fabricante: Desconhecido	180	10	1	11	***	Normal	16/05/1983	
	200	13	7	25	***	Normal	14/12/1984	
	140	24	12	20	***	Normal	08/10/1985	
	250	35	6	13	***	Normal	03/09/1986	
	160	7	8	9	***	Normal	10/03/1988	
	210	19	20	14	2	Falha_Termica	19/09/1988	
	110	5	5	7	***	Normal	20/02/1990	
	140	4	6	3	***	Normal	07/02/1992	
	170	5	7	2	***	Normal	07/04/1993	
	80	4	6	5	***	Normal	01/12/1994	
	110	4	3	2	***	Normal	04/03/1996	
	69	5	3	***	***	Normal	08/04/1997	
	17	5	5	2	***	Normal	21/07/1998	óleo regenerado jul/97

Tabela A.20: Transformador 20

Transformador 20	H_2	CH_4	C_2H_4	C_2H_6	C_2H_2	Diagnóstico Especialista	Data da amostra	Procedimento Adotado
Fabricante: Desconhecido	220	12	11	24	***	Falha_Termica	16/05/1983	
	120	11	7	15	***	Normal	11/12/1984	
	310	15	7	12	***	Normal	08/10/1985	
	220	12	6	15	***	Normal	03/09/1986	
	230	12	9	12	***	Normal	11/03/1988	
	340	21	17	10	***	Falha_Termica	05/05/1988	
	210	7	8	7	***	Normal	20/07/1990	
	190	5	7	7	***	Normal	07/02/1992	
	90	4	5	3	***	Normal	06/04/1993	
	170	6	9	5	***	Normal	02/12/1994	
	170	6	6	2	***	Normal	04/03/1996	
	170	6	9	7	***	Normal	09/04/1997	
	12	5	5	7	***	Normal	22/07/1998	óleo regenerado jul/97

*** - Os valores de concentração não detectáveis foram substituídos pelo valor de 0.4 ppm para os cálculos das relações.

Histórico de Dados Utilizados para Validação da Rede Bayesiana

Neste anexo são apresentados os dados utilizados para avaliar a rede Bayesiana proposta, composto de 56 casos de anormalidade: 36 de origem elétrica e 20 de origem térmica, publicado na IEC (IEC-60599, 1999), (Duval e dePabla, 2001). Apresenta as amostras, com as respectivas concentrações dos gases, organizadas por tipo de falhas e identificados por equipamentos. Cabe mencionar que o conjunto de equipamentos escolhidos deste conjunto de dados publicados na IEC é apenas da classe dos transformadores de potência, no qual o tanque principal não tem conexão com comutadores sob carga (Filho, 2012).

Tabela B.1: Conjunto de dados publicados na IEC 60599 (parte 1/2)

Transformador	H_2	CH_4	CO	CO_2	C_2H_4	C_2H_6	C_2H_2	Anomalia	Tipo
1	8800	64064	290	90300	95650	72128	0	Falha térmica > 700	Térmica
2	32930	2397	313	560	0	157	0	Descargas parciais	Elétrica
3	6709	10500	290	1500	17700	1400	750	Falha térmica > 700	Térmica
4	860	1670	10	690	2050	30	40	falha térmica > 700	Térmica
5	150	22	0	0	60	9	11	falha térmica > 700	Térmica
6	13	3	4	51	3	1	6	D. alta energia	Elétrica
7	100	200	100	650	670	110	11	Falha térmica > 700	Térmica
8	12	18	559	1710	4	4	0.1	Falha térmica < 700	Térmica
9	290	1260	228	826	820	231	8	Falha térmica > 700	Térmica
10	14	44	128	2746	7	124	1	Falha térmica < 700	Térmica
11	78	20	0	784	13	11	28	D. baixa energia	Elétrica
12	305	100	440	3700	161	33	541	D. baixa energia	Elétrica
13	543	120	76	2800	411	41	1880	D. baixa energia	Elétrica
14	1270	3450	483	44500	1390	520	8	Falha térmica < 700	Térmica
15	3420	7870	573	4640	6990	1500	33	Falha térmica < 700	Térmica
16	1230	163	130	115	233	27	692	D. baixa energia	Elétrica
17	645	86	74	114	110	13	317	D. baixa energia	Elétrica
18	95	10	122	467	11	0	39	D. alta energia	Elétrica
19	440	89	299	1190	304	19	757	D. baixa energia	Elétrica
20	2850	1115	2330	4330	1987	138	3675	D. alta energia	Elétrica
21	7020	1850	2140	1000	2960	0	4410	Falha elétrica	Elétrica
22	137	67	196	1678	53	7	104	D. alta energia	Elétrica
23	34	21	95	315	49	4	56	Falha elétrica	Elétrica
24	3675	6392	101	833	7691	2500	5	Falha térmica < 700	Térmica
25	48	610	1900	970	10	29	0.1	Falha térmica < 700	Térmica
26	400	940	390	1700	820	210	24	falha térmica > 700	Térmica
27	6	2990	6	26	26076	29990	67	falha térmica > 700	Térmica
28	66	60	76	90	7	2	0.1	Falha térmica < 700	Térmica
29	595	80	524	2100	89	9	244	D. baixa energia	Elétrica
30	107	143	193	1330	222	34	2	Falha térmica > 700	Térmica
31	545	130	660	2850	153	16	239	D. alta energia	Elétrica
32	7150	1440	608	2260	1210	97	1760	D. alta energia	Elétrica
33	620	325	1480	2530	181	38	244	Falha elétrica	Elétrica
34	755	229	845	5580	404	32	460	Falha elétrica	Elétrica
35	13500	6110	8690	1460	4510	212	4040	D. alta energia	Elétrica
36	1570	1110	135	602	1780	175	1830	D. alta energia	Elétrica
37	3090	5020	270	400	3800	323	2540	D. alta energia	Elétrica
38	1820	405	1010	8610	365	35	634	Falha elétrica	Elétrica
39	290	966	72	756	1810	299	57	Falha térmica > 700	Térmica
40	2500	10500	530	2310	13500	4790	6	Falha térmica > 700	Térmica
41	1860	4980	158	1300	10700	0	1600	Falha térmica > 700	Térmica
42	1330	10	231	1820	66	20	182	D. baixa energia	Elétrica
43	260	215	130	416	334	35	277	D. alta energia	Elétrica
44	75	15	105	322	14	7	26	D. alta energia	Elétrica
45	60	5	188	2510	21	2	21	D. alta energia	Elétrica
46	420	250	300	751	530	41	800	D. alta energia	Elétrica

Os valores de concentração iguais a zero, foram substituídos pelo valor de 0.4 ppm para os cálculos das relações.

Tabela B.2: Conjunto de dados publicados na IEC 60599 (parte 2/2)

Transformador	H_2	CH_4	CO	CO_2	C_2H_4	C_2H_6	C_2H_2	Anomalia	Tipo
47	310	230	150	631	610	54	760	D. alta energia	Elétrica
48	800	160	490	690	260	23	600	D. alta energia	Elétrica
49	1500	395	365	576	395	28	323	Falha elétrica	Elétrica
50	20000	13000	2600	2430	29000	1850	57000	Falha elétrica	Elétrica
51	3700	1690	22	86	2810	128	3270	D. alta energia	Elétrica
52	2770	660	522	1490	712	54	763	D. alta energia	Elétrica
53	1170	255	5	1800	312	18	325	D. alta energia	Elétrica
54	10000	6730	1980	3830	7330	345	10400	D. alta energia	Elétrica
55	1570	735	711	4240	1330	87	1740	D. alta energia	Elétrica
56	1450	940	2420	3560	322	211	61	Falha térmica < 700	Térmica

Tabela de Distribuição Qui-quadrado

(χ^2)

Neste anexo é apresentada a tabela de distribuição Qui-quadrado (χ^2) e o gráfico desta distribuição.




Figura C.1: Distribuição Qui-quadrada.

Tabela C.1: Distribuição Qui-quadrado (χ^2)

Graus de Liberdade	Área à direita do valor crítico (alfa)									
	0.995	0.990	0.975	0.950	0.900	0.100	0.050	0.025	0.010	0.005
1	0.000	0.000	0.001	0.004	0.016	2.706	3.841	5.024	6.635	7.879
2	0.010	0.020	0.051	0.103	0.211	4.605	5.991	7.378	9.210	10.597
3	0.072	0.115	0.216	0.352	0.584	6.251	7.815	9.348	11.345	12.838
4	0.207	0.297	0.484	0.711	1.064	7.779	9.488	11.143	13.277	14.860
5	0.412	0.554	0.831	1.145	1.610	9.236	11.070	12.833	15.086	16.750
6	0.676	0.872	1.237	1.635	2.204	10.645	12.592	14.449	16.812	18.548
7	0.989	1.239	1.690	2.167	2.833	12.017	14.067	16.013	18.475	20.278
8	1.344	1.646	2.180	2.733	3.490	13.362	15.507	17.535	20.090	21.955
9	1.735	2.088	2.700	3.325	4.168	14.684	16.919	19.023	21.666	23.589
10	2.156	2.558	3.247	3.940	4.865	15.987	18.307	20.483	23.209	25.188
11	2.603	3.053	3.816	4.575	5.578	17.275	19.675	21.920	24.725	26.757
12	3.074	3.571	4.404	5.226	6.304	18.549	21.026	23.337	26.217	28.300
13	3.565	4.107	5.009	5.892	7.042	19.812	22.362	24.736	27.688	29.819
14	4.075	4.660	5.629	6.571	7.790	21.064	23.685	26.119	29.141	31.319
15	4.601	5.229	6.262	7.261	8.547	22.307	24.996	27.488	30.578	32.801
16	5.142	5.812	6.908	7.962	9.312	23.542	26.296	28.845	32.000	34.267
17	5.697	6.408	7.564	8.672	10.085	24.769	27.587	30.191	33.409	35.718
18	6.265	7.015	8.231	9.390	10.865	25.989	28.869	31.526	34.805	37.156
19	6.844	7.633	8.907	10.117	11.651	27.204	30.144	32.852	36.191	38.582
20	7.434	8.260	9.591	10.851	12.443	28.412	31.410	34.170	37.566	39.997
21	8.034	8.897	10.283	11.591	13.240	29.615	32.671	35.479	38.932	41.401
22	8.643	9.542	10.982	12.338	14.041	30.813	33.924	36.781	40.289	42.796
23	9.260	10.196	11.689	13.091	14.848	32.007	35.172	38.076	41.638	44.181
24	9.886	10.856	12.401	13.848	15.659	33.196	36.415	39.364	42.980	45.559
25	10.520	11.524	13.120	14.611	16.473	34.382	37.652	40.646	44.314	46.928
26	11.160	12.198	13.844	15.379	17.292	35.563	38.885	41.923	45.642	48.290
27	11.808	12.879	14.573	16.151	18.114	36.741	40.113	43.195	46.963	49.645
28	12.461	13.565	15.308	16.928	18.939	37.916	41.337	44.461	48.278	50.993
29	13.121	14.256	16.047	17.708	19.768	39.087	42.557	45.722	49.588	52.336
30	13.787	14.953	16.791	18.493	20.599	40.256	43.773	46.979	50.892	53.672
40	20.707	22.164	24.433	26.509	29.051	51.805	55.758	59.342	63.691	66.766
50	27.991	29.707	32.357	34.764	37.689	63.167	67.505	71.420	76.154	79.490
60	35.534	37.485	40.482	43.188	46.459	74.397	79.082	83.298	88.379	91.952
70	43.275	45.442	48.758	51.739	55.329	85.527	90.531	95.023	100.425	104.215
80	51.172	53.540	57.153	60.391	64.278	96.578	101.879	106.629	112.329	116.321
90	59.196	61.754	65.647	69.126	73.291	107.565	113.145	118.136	124.116	128.299
100	67.328	70.065	74.222	77.929	82.358	118.498	124.342	129.561	135.807	140.169

Referências Bibliográficas

- DE AQUINO, R. R. B.; LIRA, M. M. S.; NETO, O. N.; SILVA, A. M. S.; ASFORA, V. K.; FILGUEIRAS, T.; FERREIRA, H. A fuzzy system for detection of incipient fault in power transformers based on gas-in-oil analysis. *Fuzzy Systems (FUZZ), 2010 IEEE International Conference on*, 18-23 July 2010.
- ARANTES, J. G. *Diagnóstico de falhas em transformadores de potência pela análise de gases dissolvidos em Óleo isolante através de redes neurais*. Dissertação de Mestrado, Universidade Federal de Itajubá. MG - Brasil, 2005.
- BATISTA, D. A. *Desenvolvimento de metodologia colorimétrica para dosagem de compostos furânicos em óleo mineral isolante*. Dissertação de Mestrado, Universidade Federal do Paraná, PR - Brasil, 2005.
- BEIGUELMAN, B. Curso prático de bioestatística. *Sociedade Brasileira de Genética*, p. 244, ribeirão Preto, 1994.
- BUNTINE, W. L. Operations for learning with graphical models. *Journal of Artificial Intelligence Research*, v. 2, p. 159 – 225, 1994.
- CASTILLO, E.; GUTIERREZ, J. M.; HADI, A. S. *Expert systems and probabilistic network models*. Springer, 1997.
- COLOSSETTI, A. P. *Construção de uma rede bayesiana para diagnóstico da doença de alzheimer a partir de neuroimagem, histórico e sintomas*. Dissertação de Mestrado, Centro Universitário da FEI, São Bernardo do Campo, SP - Brasil, 2009.
- COUDERC, D.; BOURASSA, P.; MUIRAS, J.; IREQ, VARENNES, Q. Gas-in-oil criteria for the monitoring of self-contained oil-filled power cables. *Electrical Insulation and Dielectric Phenomena, 1996. IEEE 1996 Annual Report of the Conference on*, 1996.
- DERVOS, C.; PARASKEVAS, C.; SKAFIDAS, P.; STEFANOY, N. Dielectric spectroscopy and gas chromatography methods applied on high-voltage transformer oils. *Dielectrics and Electrical Insulation, IEEE Transactions on*, 2006.

- DUVAL, M. Dissolved gas analysis: It can save your transformer. *IEEE Electrical Insulation Magazine*, 1989.
- DUVAL, M. A review of faults detectable by gas-in-oil analysis in transformers. *Electrical Insulation Magazine, IEEE*, 2002.
- DUVAL, M.; DEPABLA, A. Interpretation of gas-in-oil analysis using new iec publication 60599 and iec tc 10 databases. *Electrical Insulation Magazine, IEEE*, 2001.
- FILHO, G. L. *Comparação entre os critérios de diagnósticos por análise cromatográfica de gases dissolvidos em óleo isolante de transformador de potência*. Dissertação de Mestrado, Universidade de São Paulo, 2012.
- FLORES, W.; MOMBELLO, E.; RATTÁ, G.; JARDINI, J. A. Vida de transformadores de potencia sumergidos en aceite. estado del arte: Estado del arte. parte i. correlación entre la vida y la temperatura. *Latin America Transactions, IEEE (Revista IEEE America Latina)*, 2007.
- FUNG, R. M.; CRAWFORD, S. L. Constructor: A system for the induction of probabilistic models. *Eighth National Conference on Artificial Intelligence, American Association for Artificial Intelligence*, p. 762 – 779, 1990.
- HERSKOVITS, E.; COOPER, G. Kutató: An entropy-driven system for construction of probabilistic expert systems from databases. In: BONISSONE, P. P.; HENRION, M.; KANAL, L.; LEMMER, J. F., eds. *Proceedings of the Sixth Conference on Uncertainty in Artificial Intelligence*, Elsevier, p. 117 – 125, 1990.
- IEC-60599, I. E. C. Mineral oil -impregnated electrical equipment in service - guide to the interpretation of dissolved and free gases analysis. *International Electrotechnical Commission*, 1999.
- IEEE *IEEE guide for the interpretation of gases generated in oil-immersed transformers*. IEEE Power Engineering Society, Std C 57.104-1991.
- JÚNIOR, E. R. H. *Imputação bayesiana no contexto da mineração de dados*. Dissertação de Mestrado, Universidade Federal do Rio de Janeiro, 2003.
- JOHNSON, R. W.; SHORE, J. E. Comments on and correction to 'axiomatic derivation of the principle of maximum entropy and the principle of minimum cross-entropy' (jan 80 26-37). *IEEE Transactions on Information Theory*, v. 29, n. 6, p. 942 – 943, 1983.
- KORB, K.; NICHOLSON, A. *Bayesian artificial intelligence*. Chapman & Hall/CRC, Florida, 2003.

- LIN, C. E.; LING, J. M.; HUANG, C. L. An expert system for transformer fault diagnosis using dissolved gas analysis. *IEEE Transactions on Power Delivery*, 1993.
- LUNA, J. E. O. *Algoritmos em para aprendizagem de redes bayesianas a partir de dados incompletos*. Dissertação de Mestrado, Universidade Federal Mato Grosso do Sul, MS - Brasil, 2004.
- MAMAT, W. M. F. W.; ISA, N. A. M.; ZAMLI, K. Z.; MAMAT, W. M. F. W. Hybrid version of mlp neural network for transformer fault diagnosis system. *Information Technology, 2008. ITSIm 2008. International Symposium on*, 2008.
- MARQUES, A. P. *Eficiência energética e vida Útil de transformadores de distribuição imersos em Óleo mineral isolante*. Dissertação de Mestrado, Universidade Federal de Goiás. GO - Brazil, 2004.
- MARQUES, R. L.; DUTRA, I. Redes bayesianas: o que são, para que servem, algoritmos e exemplos de aplicações. *Coppe Sistemas UFRJ*, 2003.
- MATURANA, M. C. *Aplicação de redes bayesianas na análise da contribuição do erro humano em acidentes de colisão*. Dissertação de Mestrado, Escola Politécnica da Universidade de São Paulo, SP - Brazil, 2010.
- DE MEDEIROS JUNIOR, A. P. P. *Predição de falhas de transformadores de potência em subestações utilizando-se máquinas de estados finitas*. Dissertação de Mestrado, Universidade Federal de Mato Grosso do Sul, 2011.
- MELLO, M. P.; ADAMI, M.; RUDORF, B. F. T.; AGUIAR, D. A. Rede bayesiana aplicada ao monitoramento da moratória da soja. *XV Simpósio Brasileiro de Sensoriamento Remoto - SBSR, Curitiba, PR - Brazil*, 2011.
- MEYER, P. L. *Probabilidade, aplicações à estatística*. Rio de Janeiro: LTC, 1972.
- VON MISES, R. *Probability, statistics, and truth*. London: Allen And Unwin, 1957.
- MORAIS, D. R. *Ferramenta inteligente para detecção de falhas incipientes em transformadores baseado na análise de gases dissolvidos no Óleo isolante*. Dissertação de Mestrado, Universidade Federal Santa Catarina, SC - Brasil, 2004.
- MUHAMAD, N.; PHUNG, B.; BLACKBURN, T.; LAI, K. Comparative study and analysis of dga methods for transformer mineral oil. *Power Tech, IEEE Lausanne*, 2007.
- MYERS, S. *Transformer maintenance guide*. Transformer Maintenance Institute Myers Inc., Akron, Ohio, USA, 3ed, 2004.

- NAIM, P.; WUILLEMIM, P.; LERAY, P.; POURRET, O.; BECKER, A. *Réseaux bayésiens*. Paris Eyrolles, 2004.
- NBR7274 Interpretação da análise dos gases de transformadores em serviço. *Associação Brasileira de Normas Técnicas, RJ - Brazil*, 1982.
- NEAPOLITAN, R. E. *Learning bayesian networks*. Pearson Prentice Hall, 2004.
- NÉMETH, B.; LABONCZ, S.; KISS, I. Condition monitoring of power transformers using dga and fuzzy logic. *IEEE Electrical Insulation Conference, Montreal, QC, Canada*, 2009.
- OLIVEIRA, E. *Cromatografia gasosa como instrumento de manutenção preventiva de transformadores de potência*. Relatório Técnico, Centro Federal de Educação Tecnológica do Estado de Goiás (CEFET/GO), 2004.
- PEARL, J. *Probabilistic reasoning in intelligent systems: Networks of plausible inference*. Morgan Kaufmann, 1988.
- PEREZ, R.; MATOS, E.; FERNANDEZ, S. Identification of the nonlinear model proposed by the mit for power transformers by applying genetic algorithms. *Latin America Transactions, IEEE (Revista IEEE America Latina)*, 2009.
- PIFER, A. C.; GUEDES, L. A. Aprendizagem estrutural de redes bayesianas utilizando métrica mdl modificada. *Latin America Transactions, IEEE (Revista IEEE America Latina)*, 2007.
- PORTELLA, M. D. G. *Avaliação da presença de indicadores de oxidação do papel isolante termoestabilizado em equipamentos de subestação*. Dissertação de Mestrado, Universidade Federal do Paraná, PA - Brazil, 2010.
- QUEIROZ, C. D. N. *Redes bayesianas no gerenciamento e mensuração de riscos operacionais*. Dissertação de Mestrado, Escola Politécnica da Universidade de São Paulo, SP - Brazil, 2008.
- RIPLEY, B. D. *Network methods in statistics. probability, statistics and optimization*. New York: Wiley & Sons, 1994.
- ROGERS, R. R. Experiences in the interpretation of incipient faults in power transformers by dissolved gas-in-oil chromatography analysis (a progress report). *Minutes of Forty- Second International Conference of Double Clients*, seção 10-201 1975.
- SAHEKI, A. H. *Construção de uma rede bayesiana aplicada ao diagnóstico de doenças cardíacas*. Dissertação de Mestrado, Escola Politécnica da Universidade de São Paulo, SP - Brazil, 2005.
- STUART, R. J.; PETER, N. *Artificial intelligence: A modern approach*. Prentice Hall, 2002.

- SUZUKI, J. A construction of bayesian networks from databases based on an mdl scheme. In: MAMDANI, D. H. . A., ed. *Proceedings of the 9th Conference on Uncertainty in Artificial Intelligence*, San Mateo, CA, USA: Morgan Kaufmann Publishers, p. 266 – 273, 1993.
- WENSHENG, G.; ZHENG, Q.; ZHANG, Y. A multi-resolution system approach to power transformer insulation diagnosis. *Electrical Insulating Materials, 1998. Proceedings of 1998 International Symposium on*, 1998.
- WILSON, A. *Insulating liquids: their uses manufacture and properties*. Peter Peregrinus Ltd, 1980.
- YANG, H. T.; HUANG, Y. C. Intelligent decision support for diagnosis of incipient transformer faults using self organizing polynomial networks. *IEEE Transactions on Power Systems*, v. 13, p. 946–952, 1998.
- ZIRBES, R. *Metodologias para avaliação e diagnóstico do estado de isolamentos de papel impregnado com Óleo mineral*. Dissertação de Mestrado, Universidade Federal de Santa Catarina, SC - Brazil, 2003.