



UNIVERSIDADE FEDERAL DO PIAUÍ
CENTRO DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA
MESTRADO ACADÊMICO EM AUTOMAÇÃO INDUSTRIAL

GIELSON VITOR OLIVEIRA VERAS

**DIAGNÓSTICO DA QUALIDADE DO OLEO MINERAL DE TRANSFORMADORES
DE POTÊNCIA ATRAVÉS DAS CONCENTRAÇÕES DOS GASES DISSOLVIDOS
UTILIZANDO REDES NEURAS ARTIFICIAIS**


TERESINA

2018

GIELSON VITOR OLIVEIRA VERAS

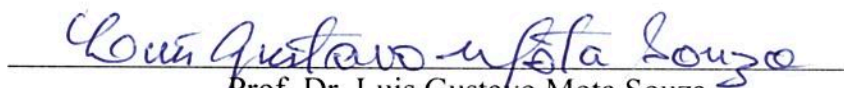
DIAGNÓSTICO DO ÓLEO DE TRANSFORMADOR DE POTÊNCIA ATRAVÉS DA ANÁLISE DE GASES DISSOLVIDOS UTILIZANDO REDES NEURAIS ARTIFICIAIS

Esta Dissertação foi julgada adequada para a obtenção do título de Mestre em Engenharia Elétrica, Área de Concentração Sistemas de Energia Elétrica, e aprovada em sua forma final pelo Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal do Piauí.



Gielson Vitor Oliveira Veras
Pós-Graduando (PPGEE-UFPI)

Banca Examinadora:



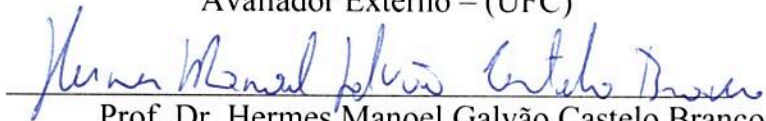
Prof. Dr. Luis Gustavo Mota Souza
Orientador (PPGEE-UFPI).




Prof. Dr. Fábio Rocha Barbosa
Co-Orientador (PPGEE-UFPI).



Prof. Dr. Arthur Plínio de Souza Braga
Avaliador Externo – (UFC)



Prof. Dr. Hermes Manoel Galvão Castelo Branco
Avaliador Interno (PPGEE-UESPI)



Prof. Dr. José Maria Pires de Menezes Junior
Avaliador Interno (PPGEE-UFPI)

Teresina, 17 de outubro de 2018.

AGRADECIMENTOS

A Deus, pelas dádivas e pelos Dons.

Ao Prof. Dr. Luis Gustavo por me orientar em minha dissertação e durante todo o programa.

Ao Prof. Dr. Fabio Rocha, pela coorientação, pela inspiração para o desenvolvimento deste trabalho, desde a graduação até o presente momento.

Aos Membros da Banca, Prof. Dr José Maria Pires de Menezes Junior, Prof. Dr Hermes Manoel Galvão Castelo Branco e José Maria Pires de Menezes Júnior

Aos meus pais, pelo apoio incondicional e pelo alicerce.

À minha família, pelos valores e pela torcida.

À Coordenação do Programa de Pós Graduação em Engenharia Elétrica pela oportunidade.

Aos colegas do PPGEE pelos grupos de estudos e trocas de experiências.

Ao Departamento de Engenharia Elétrica da Universidade Federal do Piauí

RESUMO

Este trabalho tem como objetivo aplicar Redes Neurais Artificiais (RNA) para obter o diagnóstico da qualidade do óleo isolante de transformadores de potência a partir das concentrações de gases dissolvidos neste óleo. Tal diagnóstico é tradicionalmente obtido a partir da análise das propriedades físico-químicas do líquido, enquanto a concentração dos gases é utilizada para detectar as ocorrências de falhas incipientes no transformador. No entanto, existe uma dualidade entre essas duas características. Análises de óleo realizadas por mais de trinta anos em mais de 150 transformadores de potência do Brasil foram usadas para implementar e testar a ferramenta proposta. A consolidação da ferramenta proposta possibilitaria permitir um planejamento correto da manutenção de transformadores com menor custo, uma vez que apenas com a análise dos gases dissolvidos seria possível inferir sobre a qualidade do óleo e a ocorrência de falhas. Quatro RNA são testadas para realizar essa tarefa: Perceptron Multi Camadas, ou *Multilayer Perceptron (MLP)*, Rede Função de Base Radial, ou *Radial Basis Function (RBF)*, Rede Máquina de Aprendizado Extremo, ou *Extreme Learning Machine (ELM)* e Rede Mapa Auto Organizável com K Vencedores, ou *K-Winners Self Organized Map (KSOM)*. O desempenho das RNAs foi analisado e comparado entre elas e entre os métodos tradicionais de diagnósticos de óleo. Os resultados mostraram que a ferramenta proposta foi capaz de diagnosticar a qualidade de óleo com uma taxa de acerto muito maior do que os métodos tradicionais, quando comparado ao diagnóstico realizado por especialistas e com taxas de acerto semelhantes a outros trabalhos que utilizam RNAs para diagnosticar a qualidade do óleo de transformadores utilizando suas propriedades físico-químicas. **Palavras-chave:** Redes Neurais Artificiais. Óleo Mineral

Isolante. Transformadores de Potência. Gases Dissolvidos.

ABSTRACT

This work aims to apply Artificial Neural Networks (ANN) to obtain the diagnosis of the quality of the insulating oil of power transformers from the concentrations of dissolved gases in this oil. Such diagnosis is usually obtained from its physical-chemical analysis, while the dissolved gases concentrations are used to detect the occurrences of faults in the transformer. However, there is a duality between these two characteristics (BARBOSA, 2013). Oil Analysis performed for more than thirty years in more than 150 Power Transformers from Brazil were used to implement and test the proposal tool. The consolidation of the tool would allow a correct maintenance planning of power transformers with lower cost, once with just the dissolved gas analysis it would be possible to infer about both the quality of the oil and the occurrence of faults. Four ANN's were tested to do such task: Multi Layer Perceptron (MLP), Radial Basis Function (RBF), Extreme Learning Machine (ELM) and K Self Organization Map (K-SOM). The performance of the ANNs were analysed and compared between them and between traditional oil diagnosis standards. The results shown that the proposed tool was able to diagnose the quality of the oil with a accuracy rate much better than using traditional methods, when compared to the specialists diagnosis and with accuracy rates similar to works that use ANN to diagnose the transformer quality from its physical-chemical properties.

Keywords: Artificial Neural Networks. Insulating Mineral Oil. Power Transformers. Dissolved Gases.

LISTA DE ILUSTRAÇÕES

Figura 1 – Trabalho de Barbosa (2013)	16
Figura 2 – Proposta desta Dissertação	16
Figura 3 – Cadeias Parafínicas	21
Figura 4 – Cadeia Aromática e Naftênica	21
Figura 5 – Estrutura dos Gases	29
Figura 6 – Formação dos Radicais	29
Figura 7 – Modelo de Halstead	30
Figura 8 – Triângulo de Duval	35
Figura 9 – Acetileno x Teor de Água	36
Figura 10 – Monóxido de Carbono x Teor de Água	37
Figura 11 – Hidrogênio x Acidez	37
Figura 12 – Dióxido de Carbono x Fator de Potência	38
Figura 13 – Neurônio Humano	42
Figura 14 – Modelo McCulloch e Pitts do Neurônio	43
Figura 15 – Rede MLP	44
Figura 16 – Neurônios da Rede ELM: (a)Camada Escondida (b) Camada de Saída	49
Figura 17 – Celulas de Voronoi	51
Figura 18 – Rede Som Bidimensional	54
Figura 19 – Arquitetura do Modelo VQTAM	56
Figura 20 – Diferença entre o treinamento supervisionado e não supervisionado.	57
Figura 21 – Dados Não Balanceados	62
Figura 22 – Dados Balanceados	62
Figura 23 – Comparação entre as classificações através do método da WEG e através da ferramenta proposta utilizando <i>MLP Levenberg Marquardt (LM)</i>	73

LISTA DE TABELAS

Tabela 1 – Composição de Óleo Parafínico e Naftênico	22
Tabela 2 – Fatores de diferenciação entre os óleos	22
Tabela 3 – Padrões de Propriedades Físico-Químicas do Óleo Mineral	26
Tabela 4 – Diagnóstico do Óleo WEG	28
Tabela 5 – Razões entre as concentrações dos gases	32
Tabela 6 – Limites de concentração dos gases para condição de normalidade	32
Tabela 7 – Faixas de Valores das razões para o método de Doenenburg	33
Tabela 8 – Faixas de Valores das razões para diagnóstico através do método de Rogers .	34
Tabela 9 – Limites de aumento de concentração dos gases dissolvidos	35
Tabela 10 – Exemplo de Dado de Coleta	59
Tabela 11 – Distribuição Inicial dos 1034 Dados quanto ao Diagnóstico do Óleo	60
Tabela 12 – Algoritmo <i>One Side Sampling (OSS)</i>	62
Tabela 13 – Dados Balanceados	65
Tabela 14 – Parâmetros das Redes Neurais Artificiais	66
Tabela 15 – Matriz de Confusão para a Classificação Binária do Óleo - Rede MLP-BP .	66
Tabela 16 – Taxas de Acerto para a Classificação Binária do Óleo - Rede MLP-BP . . .	66
Tabela 17 – Matriz de Confusão para a Classificação Binária do Óleo - Rede MLP-LM .	66
Tabela 18 – Taxas de Acerto para a Classificação Binária do Óleo - Rede MLP-LM . . .	67
Tabela 19 – Matriz de Confusão para a Classificação Binária do Óleo - Rede ELM . . .	67
Tabela 20 – Taxas de Acerto para a Classificação Binária do Óleo - Rede ELM	67
Tabela 21 – Matriz de Confusão para a Classificação Binária do Óleo - Rede RBF	67
Tabela 22 – Taxas de Acerto para a Classificação Binária do Óleo - Rede RBF	67
Tabela 23 – Matriz de Confusão para a Classificação Binária do Óleo - Rede KSOM . . .	68
Tabela 24 – Taxas de Acerto para a Classificação Binária do Óleo - Rede K-SOM	68
Tabela 25 – Matriz de Confusão para a Classificação Binária do Óleo - Método WEG . . .	68
Tabela 26 – Matriz de Confusão para a Classificação Não Binária do Óleo - Rede MLP BP	69
Tabela 27 – Taxas de Acerto para a Classificação Não Binária do Óleo - Rede MLP BP .	69
Tabela 28 – Matriz de Confusão para a Classificação Não Binária do Óleo - MLP LM . .	69
Tabela 29 – Taxas de Acerto para a Classificação Não Binária do Óleo - Rede MLP LM	69
Tabela 30 – Matriz de Confusão para a Classificação Não Binária do Óleo - Rede ELM .	69
Tabela 31 – Taxas de Acerto para a Classificação Não Binária do Óleo - Rede ELM . . .	70

Tabela 32 – Matriz de Confusão para a Classificação Não Binária do Óleo - Rede RBF . . .	70
Tabela 33 – Taxas de Acerto para a Classificação Não Binária do Óleo - Rede RBF . . .	70
Tabela 34 – Matriz de Confusão para a Classificação Não Binária do Óleo - Rede KSOM	70
Tabela 35 – Taxas de Acerto para a Classificação Não Binária do Óleo - Rede KSOM . . .	70
Tabela 36 – Matriz de Confusão para a Classificação Não Binária do Óleo - Método WEG	71

LISTA DE ABREVIATURAS

ABNT	Associação Brasileira de Normas Técnicas
BP	<i>Backpropagation</i>
ELM	<i>Extreme Learning Machine</i>
ENN	<i>Edited Nearest Neighbors</i>
OSS	<i>One Side Sampling</i>
DGA	<i>Dissolved Gases Analysis</i>
RNA	Rede Neural Artificial
RBF	<i>Radial Basis Function</i>
SOM	<i>Self Organized Map</i>
MLP	<i>Multi Layer Perceptron</i>
LM	<i>Levenberg Marquart</i>
K-SOM	<i>K-Winners Self Organized Map</i>
DBPC	Diterciário-Butilparacresol
PPM	Partes Por Milhão
PNN	<i>Probabilistic Neural Network</i>
KPCA	<i>Component Analysis by Kernel Principle</i>
FCM	<i>Fuzzy C Means</i>
QPSO	<i>Quantum Behaved Particle Swarm Optimization</i>
MOPSO	<i>Multi Objective Particle Swarm Optimization</i>
FC	<i>Fuzzy Controller</i>
DST	<i>Dempstr-Shafter Theory</i>

LISTA DE SÍMBOLOS

H_2	hidrogênio
CH_4	Metano
C_2H_6	Etano
C_2H_4	Etileno
C_2H_2	Acetileno
CO	Monóxido de Carbono
CO_2	Dióxido de Carbono
u	Campo Local Induzido
φ	Função de Ativação do Neurônio
h	Número de Neurônios da Camada Escondida
α	Taxa de Aprendizagem
μ	Constante de Regularização
σ	Raio da função de Base Radial

SUMÁRIO

1	INTRODUÇÃO	13
1.1	A Análise do Óleo de Transformadores como Ferramenta de Planejamento de sua Manutenção	13
1.2	Proposta do Trabalho	15
1.3	Motivação do Trabalho	17
1.4	Objetivos Geral e Específicos	17
1.5	Resumo dos Capítulos Restantes	18
1.6	Produção Científica	19
2	A ANÁLISE DO ÓLEO MINERAL	20
2.1	Introdução	20
2.2	Decomposição Do Óleo Mineral	22
2.3	Análise Físico-Química	23
2.3.1	<i>Testes físico-químicos</i>	24
2.4	Análise de Gases Dissolvidos	28
2.4.1	<i>Método do Gás Chave</i>	31
2.4.2	<i>Método das Razões de Doernenburg</i>	32
2.4.3	<i>Método das Razões de Rogers</i>	33
2.4.4	<i>O Triângulo de Duval</i>	34
2.5	Relação Entre as Propriedades Físico-Químicas e os Gases Dissolvidos no Óleo Mineral	36
2.6	Métodos Computacionais de Análise de Óleo	38
2.7	Conclusão	40
3	REDES NEURAIS ARTIFICIAIS	41
3.1	Introdução	41
3.2	O modelo do Neurônio Artificial	41
3.3	A Rede MLP	43
3.3.1	<i>O Algoritmo Backpropagation</i>	45
3.3.1.1	<i>Sentido Direto</i>	46
3.3.1.2	<i>Sentido Inverso</i>	47
3.3.2	<i>O Algoritmo Levenberg-Marquardt</i>	47

3.4	A Rede ELM	48
3.5	A Rede RBF	50
3.5.1	<i>O Algoritmo WTA</i>	51
3.5.2	<i>O Algoritmo K-Médias</i>	52
3.5.3	<i>Projeto da Camada de Saída</i>	52
3.6	A Rede SOM	53
3.6.1	<i>Competição</i>	54
3.6.2	<i>Cooperação</i>	54
3.6.3	<i>Adaptação</i>	55
3.7	Rede K-SOM	55
3.8	Conclusão	58
4	METODOLOGIA	59
4.1	O Balanceamento dos Dados	60
4.2	Treino e Teste das RNAs	63
4.3	Estudo de Caso	64
5	RESULTADOS E DISCUSSÕES	65
5.1	Dados Balanceados	65
5.2	Treino e Teste das Redes	65
5.2.1	<i>Classificação Binária</i>	65
5.2.2	<i>Classificação Não Binária</i>	68
5.2.3	<i>Análise do Desempenho das Redes e Comparação com Trabalhos Seme-</i> <i>lhantes</i>	71
5.3	Estudo de Caso	73
6	CONCLUSÕES E TRABALHOS FUTUROS	75
6.1	Trabalhos Futuros	76
	REFERÊNCIAS	77
	APÊNDICES	82
	APÊNDICE A – APÊNDICE A: Parâmetros das Redes Neurais	82
A.1	Critério de Parada	82
A.2	Função de Ativação	82
A.3	Normalização das Entradas	83
A.4	Taxa de Aprendizado	83

A.5	Inicialização dos Pesos	84
	ANEXOS	84
	ANEXO A – Dados Utilizados	85
	ANEXO B – Dados para Estudo de Caso	86

1 INTRODUÇÃO

Neste Capítulo, a problemática em questão nesta pesquisa será contextualizada e discutida. As principais técnicas de análises do óleo mineral de transformadores de potência serão apresentadas, bem como pesquisas recentes que foram desenvolvidas na área. Na Seção 1.1 serão apresentados as técnicas de análise de óleo mais amplamente utilizadas como ferramenta para o planejamento de manutenção de transformadores, bem como pesquisas recentes envolvendo o tema. Na Seção 1.2 a proposta desta pesquisa será apresentada e discutida. Na Seção 1.3 a relevância da pesquisa é explicitada. Na Seção 1.4 os objetivos gerais e específicos que foram traçados para atingir o que foi proposto, são apresentados. Na Seção 1.5 os outros capítulos deste documento serão brevemente apresentados e na Seção 1.6 a produção técnica gerada a partir da pesquisa desenvolvida é listada.

1.1 A Análise do Óleo de Transformadores como Ferramenta de Planejamento de sua Manutenção

O setor elétrico é um dos pilares base da economia de um país e está diretamente relacionado com o aumento da sua produção industrial, do seu consumo interno e do seu desenvolvimento econômico. Um dos principais elementos estratégicos para um setor elétrico baseado em corrente alternada, como o Sistema Elétrico de Potência Brasileiro, é o transformador. Este equipamento está presente desde a geração, até a transmissão e distribuição de energia elétrica (BARBOSA, 2013).

Os transformadores de potência, em especial, são aqueles cuja potência elétrica é acima de 500 kVA e possuem importância estratégica ainda maior, por serem equipamentos caros e suprirem um grande número de consumidores, muitos dos quais com cargas para as quais a continuidade de fornecimento é estratégica, como indústrias e hospitais. O bom funcionamento desses equipamentos é, portanto, crucial para garantir a continuidade e qualidade do fornecimento de energia elétrica (VERAS *et al.*, 2017). Além do mais, falhas de transformadores de potência em serviço representam perigo aos operadores, uma vez que podem causar explosões, incêndios e sérios danos ao meio ambiente devido ao derramamento de óleo (PANDEY, 2012).

Portanto, muitos esforços têm sido feitos no intuito de diagnosticar a condição de transformadores de potência em operação. Busca-se, com o diagnóstico, embasar a tomada de decisões a curto prazo em termos de operação e manutenção, possibilitando a diminuição da

incidência de falhas (HYDROELECTRIC RESEARCH; UNITED STATES, 2003).

O uso de sensores na estrutura do aparato, possibilita um monitoramento de praticamente todos os parâmetros do transformador, no entanto a correta estratégia de escolha e alocação de sensores, bem como o alto custo empregado frente ao porte do equipamento e ao grande número de transformadores no sistema elétrico, representa um empecilho para o uso de sensores em larga escala (BARBOSA, 2013).

Uma variedade de técnicas de diagnóstico das condições de operação de transformadores estão disponíveis na literatura, tal como visto em Milasch (1984), STANDARTS (1999) e IEEE (2008). Entre elas, as análises do óleo mineral do tanque dos transformadores consistem nos testes mais comuns, utilizados para avaliar os equipamentos sem a necessidade de tirá-los da operação (WANG; VANDEMAAR; SRIVASTAVA, 2002).

O óleo mineral tem sido amplamente utilizado em transformadores desde o início do século 20 e tem função dual para o seu bom funcionamento: a isolamento elétrica entre partes com diferentes tensões e o seu resfriamento através do movimento de convecção (PANDEY, 2012; PALMER *et al.*, 2000).

Dois Análises do óleo mineral de transformadores são amplamente utilizadas como ferramenta para seu planejamento de manutenção, são elas: a Análise dos Gases Dissolvidos no Óleo, ou do inglês *Dissolved Gases Analysis* (DGA) e a análise de suas propriedades físico-químicas. A primeira, possibilita identificar falhas incipientes na operação do transformador, a segunda, permite inferir quanto à qualidade do óleo mineral em desempenhar bem suas funções (BARBOSA *et al.*, 2012; IEEE, 2008; WANG; VANDEMAAR; SRIVASTAVA, 2002). Técnicas envolvendo inteligência computacional vêm sendo amplamente utilizadas como ferramentas para contribuir com o planejamento de manutenção preventiva de transformadores de potência nas últimas décadas (HUANG; ZHU; ZIEW, 2006). Destacam-se o uso das Redes Neurais Artificiais (RNAs), da Lógica Fuzzy e de Algoritmos Evolutivos. Tais técnicas computacionais podem, de maneira satisfatória, inferir sobre condições de falhas e diagnósticos de maneira mais eficiente que certas técnicas tradicionais ou promover conclusões mais profundas em determinadas análises (ZHANG, 1996).

Podem ser citadas pesquisas como as de Mokhnache (2002), Antonio, Ivan e Andre (2002), Barbosa (2008), Barbosa *et al.* (2012), Bacha, S. e Gossa (2012), Ming e Yu (2014), Chenxi, Liu e Cui (2014), Ghanizadeh e Gharehpetian (2014), Meng *et al.* (2010), Peimankara *et al.* (2017), Zarković e Stojović (2017) e Tusongjiang *et al.* (2018).

A busca constante por novas metodologias de diagnóstico do óleo faz-se necessária frente à importância da aplicação, em uma tentativa de auferir maneiras cada vez mais acessíveis e eficazes de analisar as condições de operação de um transformador de potência, otimizando sua manutenção preventiva. Muitas das práticas utilizadas tradicionalmente são, para determinadas situações, inconclusivas, portanto, muitas vezes há a necessidade de um especialista com alto grau de experiência para a obtenção de conclusões precisas.

1.2 Proposta do Trabalho

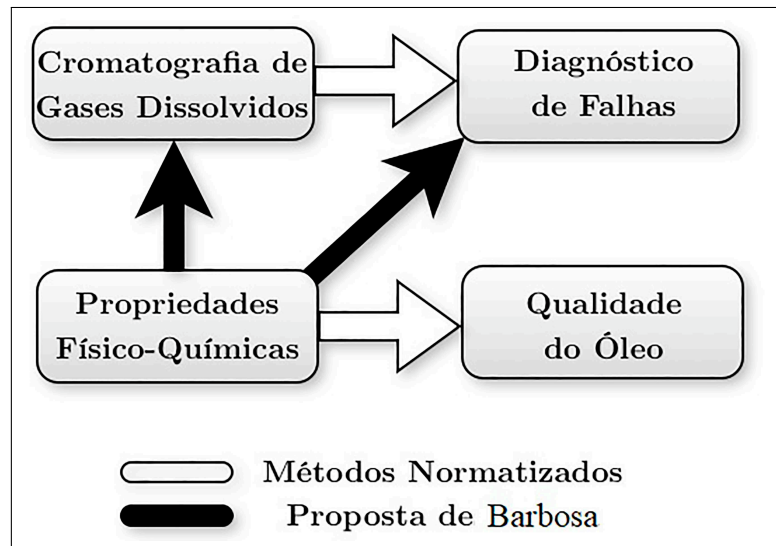
Pesquisas foram desenvolvidas no sentido de associar as características dielétricas (físicas) do óleo do transformador com o aparecimento de falhas internas, como em (SETAYESH-MEHR *et al.*, 2008; DERVOS *et al.*, 2005; FERGUSON; LOBEIRAS; SABOU, 2002; ABDI; BOUBAKEUR; HADDAD, 2008; IEEE, 2008). Baseado nestas, Barbosa *et al.* (2012) foram capazes de, utilizando Redes Neurais Artificiais, estimar as concentrações de gases dissolvidos no óleo mineral de transformadores de potência, a partir das propriedades físico-químicas deste óleo com sucesso. Em adição, o autor foi capaz de inferir quanto às falhas incipientes de transformadores de potência em operação, utilizando como base as propriedades físico-químicas do óleo mineral. O autor propôs, portanto, técnica inovadora de diagnóstico de falhas incipientes de transformadores de potência, pois como discutido, tradicionalmente tais falhas são obtidas através da análise das concentrações de gases no óleo, e não de sua análise físico-química. Na Figura 1, uma síntese do trabalho de Barbosa *et al.* (2012) é apresentada.

De maneira semelhante ao desenvolvido por Barbosa *et al.* (2012), esta pesquisa propõe explorar a dualidade entre as características físico-químicas do óleo mineral e as concentrações de gases dissolvidos neste óleo para propor nova técnica de diagnóstico do óleo utilizando RNAs. É proposto aqui, utilizar RNAs para inferir quanto à qualidade do óleo isolante de transformadores de potência, a partir das concentrações dos gases dissolvidos nesse óleo. Como supra exposto, tradicionalmente a informação das concentrações dos gases dissolvidos é utilizada para identificar a ocorrência de falhas incipientes no transformador, enquanto a qualidade deste óleo é diagnosticada através da análise das propriedades físico-químicas do mesmo. A Figura 2 apresenta uma síntese da ferramenta proposta.

As Redes Neurais Artificiais: *MLP*, *RBF*, *ELM* e *KSOM* são utilizados como ferramentas para obtenção dos resultados desejados.

A capacidade de generalização em tarefas de classificação de padrões complexos com

Figura 1 – Trabalho de Barbosa (2013)



Fonte – Modificado de Barbosa (2013).

Figura 2 – Proposta desta Dissertação



Fonte – Modificado de (BARBOSA, 2013).

características não-lineares das RNA's e suas características de aprendizado com a apresentação a pares de dados de entrada e saída são propriedades desejadas.

Mais de 500 dados das coletas de análises de óleo realizados em mais de 150 transformadores de potência no Brasil, durante mais de 30 anos são utilizados na implementação

da ferramenta proposta. Os dados apresentam os resultados das análises físico-químicas e DGA do óleo desses transformadores, bem como as conclusões obtidas pelos operadores especialistas após a análise dos dados.

A base de dados foi utilizada para treinamento e teste das RNAs utilizadas. Outros Métodos de diagnóstico da qualidade do óleo de transformadores foram também utilizados para fins de comparação, como os métodos tradicionais propostos pela fabricante de transformadores WEG (2004) e os métodos propostos por Mokhnache (2002) e Barbosa (2008).

1.3 Motivação do Trabalho

A pesquisa desenvolvida apresenta uma metodologia alternativa ao diagnóstico da qualidade do óleo de transformadores, utilizando como base as concentrações de gases dissolvidos neste óleo, obtidos através de cromatografia, utilizando Redes Neurais.

O diagnóstico tradicional, obtido através da análise físico-química do óleo requer a implementação de numerosas análises laboratoriais, regidas por diferentes normatizações. Tal diagnóstico é realizado seguindo recomendações que, muitas vezes, não apresentam conclusões evidentes, o que torna necessário o conhecimento de um especialista experiente para a obtenção de diagnósticos precisos.

Através do uso da ferramenta proposta, é possível reduzir a necessidade da análise físico-química do óleo em laboratório, acarretando na redução do custo do planejamento de manutenção de transformadores de potência, uma vez que as concentrações dos gases através de cromatografia já são utilizadas para a identificação de falhas incipientes no equipamento.

Devido à característica de aprendizado das RNAs, a ferramenta apresenta intrinsecamente o conhecimento dos especialistas, o que possibilitaria o diagnóstico do óleo mesmo por um operador inexperiente de maneira mais eficiente do que seguindo as recomendações dos vários normativos vigentes.

1.4 Objetivos Geral e Específicos

O objetivo principal desta dissertação é propor uma metodologia alternativa de diagnóstico da qualidade do óleo de transformadores de Potência, baseada nas concentrações de gases dissolvidos nesse óleo através de Redes Neurais Artificiais. Os objetivos específicos da mesma, podem ser listados a seguir:

- Analisar a composição do óleo de transformadores, seu processo de decomposição em equipamentos em operação, bem como as principais técnicas de análise desse óleo, suas vantagens e limitações.
- Analisar a relação entre o aumento na concentração de gases dissolvidos no óleo de transformadores com o processo de degradação físico-química do óleo de transformadores que o tornam inapto a desempenhar suas funções.
- Analisar as características das RNAs *MLP*, *RBF*, *ELM* e *KSOM*, utilizadas no presente trabalho, bem como suas peculiaridades e seus algoritmos de treinamento.
- Analisar os dados obtidos através de análises do óleo de transformadores em operação e tratá-los com o objetivo de treinar as RNAs com eficiência.
- Treinar e testar as RNAs para a tarefa de diagnosticar a qualidade do óleo a partir das concentrações de gases dissolvidos.
- Comparar o desempenho de cada RNA utilizada entre si e entre outras técnicas utilizadas no mercado e na academia de análise da qualidade de óleo.
- Realizar um estudo de caso com um conjunto relevante dos dados através da aplicação da ferramenta proposta e de outros métodos de diagnóstico e avaliar seus desempenhos.

1.5 Resumo dos Capítulos Restantes

Esta dissertação está organizada em cinco capítulos. Além deste capítulo, de introdução ao documento, segue uma breve descrição dos capítulos restantes:

- Capítulo 2: é introduzido por uma abordagem acerca da composição do óleo, sua fabricação, bem como dos seus processos deterioração e recuperação. Aborda as técnicas de análise do óleo mineral do transformador, consolidadas pela literatura especializada, além de estudos recentes que se propõem a desenvolver técnicas otimizadas de análise de óleo utilizando inteligência computacional e por fim apresenta estudos que relacionam os processos de decomposição do óleo mineral com o aumento da concentração dos gases dissolvidos nesse óleo.
- Capítulo 3: explora a base histórica, teórica e matemática das Redes Neurais Artificiais, além de expor as formulações matemáticas das redes utilizadas no presente trabalho.
- Capítulo 4: caracteriza os dados utilizados e apresenta os resultados obtidos e discussão sobre os mesmos.
- Capítulo 5: apresenta as conclusões finais, bem como sugestões para trabalhos futuros.

Por fim, o Apêndice A apresenta algumas formulações matemáticas necessárias para o completo entendimento da metodologia aplicada e o Anexo A apresenta os dados utilizados no treino e teste das redes neurais.

1.6 Produção Científica

A pesquisa em torno do tema desta dissertação gerou a seguinte produção científica:

- Veras, G.V.O; Souza, L.G.M; Barbosa, F.R; Almeida, O.M; Freitas, A.A.C. Diagnóstico da Qualidade do Óleo Isolante de Transformadores de Potência a Partir da Concentração de Gases Dissolvidos. XIII Simpósio Brasileiro de Automação Inteligente, Porto Alegre-RS, 1 a 4 de Outubro de 2017

2 A ANÁLISE DO ÓLEO MINERAL

Neste capítulo será abordado o óleo mineral isolante de transformadores, na seção 2.1 a utilização e função do óleo será abordada, bem como sua composição química, na seção 2.2 será abordado o processo de decomposição do mesmo, na seção 2.3 será abordada a análise das propriedades físico-químicas do óleo como método tradicional de diagnóstico de sua qualidade, na seção 2.4 será brevemente exposto os métodos tradicionais de análises de gases dissolvidos como técnica de detecção de falhas incipientes, na seção 2.5 serão apontados estudos que relacionam as análises físico-químicas e cromatográficas, na seção 2.6 serão expostos estudos recentes envolvendo técnicas de inteligência computacional utilizadas nas análises de óleo de transformadores e por fim, na seção 2.7 serão feitos comentários de conclusão do capítulo.

2.1 Introdução

O óleo mineral tem sido amplamente utilizado em transformadores desde o começo do século XX (PALMER *et al.*, 2000) e têm duas funções cruciais para o bom funcionamento do equipamento: (i) a isolamento elétrica de partes energizadas com diferença de potencial considerável e (ii) o resfriamento do equipamento em operação através do movimento de convecção dentro do tanque (PANDEY, 2012).

Devido à ampla disponibilidade e ao custo x benefício do seu uso, o óleo mineral é, provavelmente, o líquido isolante mais utilizado no mundo hoje e tem sido desde o início do século passado (DOBLE, 1993), embora pesquisas envolvendo óleos vegetais e sintéticos alternativos venham evoluindo nos últimos anos (MARIPRASATH; KIRUBAKARAN, 2016; FEIL *et al.*, 2017; FOFANA *et al.*, 2002).


O óleo isolante de transformadores é subproduto do refino do petróleo. Sua composição e características dependem da natureza do petróleo do qual foi extraído e do processo empregado em sua preparação. O óleo parafínico é originado do petróleo parafínico e o óleo naftênico do petróleo naftênico (MILASCH, 1984).

O óleo mineral isolante é constituído de uma mistura de hidrocarbonetos, em sua maioria, e de heterocompostos em pequena proporção. Cerca de 2900 é o número aproximado de compostos existentes, dos quais cerca de 90 % ainda não foram identificados. Uma pesquisa dispendiosa seria necessária para identificar todos eles e uma vez que o comportamento e as características principais para o desempenho das funções do óleo são conhecidos, bem como os

produtos de sua deterioração, uma análise dessa natureza não é necessária (MILASCH, 1984).


Os principais componentes conhecidos são: hidrocarbonetos parafínicos, cuja composição química é representada na Figura 3, hidrocarbonetos naftênicos, cuja composição é representada na Figura 4, hidrocarbonetos saturados, hidrocarbonetos aromáticos mononucleares, dinucleares, trinucleares e tetranucleares, e heterocompostos, que são elementos compostos de oxigênio, de nitrogênio e enxofre.

Figura 3 – Cadeias Parafínicas



Fonte – Modificado de (LUIZ; RUTH, 2006).

Figura 4 – Cadeia Aromática e Naftênica



Fonte – Modificado de(LUIZ; RUTH, 2006).

Os óleos parafínicos têm em sua composição, maior proporção de hidrocarbonetos

parafínicos (Figura 3), com fórmula geral: $H_3C - (CH_2)_n - CH_3$ (n varia de 2 a 27). Os óleos Naftênicos, por sua vez possuem maior proporção de hidrocarbonetos naftênicos (Figura 4), cujas moléculas têm cinco e seis anéis naftênicos e cadeias laterais parafínicas e alifáticas. A identificação do óleo como Naftênico ou Parafínico pode ser realizada através das relações de composições expostas na Tabela 1.

Tabela 1 – Composição de Óleo Parafínico e Naftênico

Tipo de Óleo Isolante	Compostos Aromáticos (%)	Compostos Naftênicos (%)	Compostos Parafínicos (%)
Naftênico	11	47	42
Parafínico	8	29	63

Fonte – (MILASCH, 1984)

Algumas características típicas são apresentadas na Tabela 2, a seguir para cada um dos tipos de óleo. No Brasil, a maioria do óleo utilizado é Parafínico.

Tabela 2 – Fatores de diferenciação entre os óleos

Fatores	Óleo tipo B (Parafínico)	Óleo Tipo A (Naftênico)
Densidade a 20 °C	0,855 (max)	0,880 (max)
Ponto de Fluidez (°C)	-15	-40
Ponto de Anilina (°C)	+88	+72
Índice de Refração a 20 °C	1,4750	1,4880

Fonte – (MILASCH, 1984)

2.2 Decomposição Do Óleo Mineral

Logo que o transformador é enchido com o óleo na fábrica, o processo de deterioração e contaminação do líquido se inicia, sendo estes acentuados com a operação do equipamento. A contaminação do óleo ocorre com a mistura de água e outras substâncias estranhas com o mesmo. A deterioração ocorre através do surgimento de substâncias resultantes de sua oxidação (MILASCH, 1984).

O processo de oxidação do óleo tem início quando o oxigênio entra em combinação com os hidrocarbonetos instáveis, na presença de catalisadores como o cobre, o ferro, a água, entre outros (ASTM, 1991). Este é o fator predominante no processo de envelhecimento do líquido (LIPSCHTEIN; SHAIKHOVICH, 1970). A oxidação ocorre em cadeia, da seguinte maneira (MILASCH, 1984): os hidrocarbonetos reagem com o oxigênio, formando hidroperóxidos, estes, se dissociam em dois radicais livres instáveis que por sua vez reagem com as moléculas de

hidrocarbonetos formando outros radicais reativos. Os radicais reagem com o oxigênio formando novos radicais, que em consequência reagem com os hidrocarbonetos formando novos radicais e assim por diante de maneira desencadeada. Os hidroperóxidos também podem se decompor e formar aldeídos e cetonas, que podem ser oxidados e formar ácidos e éteres.

Inibidores do óleo são substâncias que retardam a oxidação. O óleo possui inibidores naturais orgânicos compostos de enxofre, no entanto, inibidores sintéticos como o Diterciário-Butilparacresol (DBPC) são muito utilizados por operadores e fabricantes para prolongar a vida útil do isolante. Os inibidores agem interrompendo as reações da primeira fase de oxidação do óleo e os hidrocarbonetos deixam de reagir até que se esgote todo o inibidor.

Agem como aceleradores do processo de oxidação, o calor, comum na operação de transformadores em serviço, os catalisadores presentes no próprio equipamento ou provenientes de contaminação, como a água e ácidos produzidos do próprio processo de oxidação, além do campo elétrico, também proveniente da operação do equipamento (ZIRBES; ROLIM; ZURN, 2005).

O avanço desses processos, compromete consideravelmente as propriedades do óleo, sua capacidade de agir como isolante e resfriador e, conseqüentemente, a vida útil do transformador. Em transformadores, 70% das falhas são devidas a problemas com a isolação líquida (MARIPRASATH; KIRUBAKARAN, 2016). No entanto, um transformador cuja manutenção e condições de operação sejam adequadas, pode operar de maneira satisfatória por até cinquenta anos (MILASCH, 1984).

Faz-se necessário, portanto, monitorar a qualidade do óleo para possibilitar o planejamento de manutenção e garantir boas condições de operação do equipamento.

No intuito de inferir se o óleo é capaz de realizar as suas funções de forma eficiente, a análise físico-química do líquido desempenha importante papel. Através da análise de gases dissolvidos, obtida através de cromatografia, é possível inferir sobre as condições de operação do transformador. Juntas, a DGA e a análise físico-química do óleo são os dois testes mais comumente realizados em Transformadores de Potência (BARBOSA, 2013).

2.3 Análise Físico-Química

Uma vez que o óleo está em contato constante com todas as partes ativas internas do transformador, alterações no regime de operação do equipamento refletem nas características do líquido e no seu comportamento (BARBOSA, 2013). As altas temperaturas, provenientes

do regime normal do equipamento ou de sobrecargas e surtos de tensão, o estresse físico, bem como a contaminação com água e resíduos sólidos aceleram o processo de degradação normal do líquido isolante e modificam suas características físicas e químicas, podendo comprometer suas funções de isolamento e resfriamento (MILASCH, 1984).

A análise em laboratório das principais características físicas e químicas do óleo podem, portanto, indicar o grau da contaminação e deterioração do mesmo, sua capacidade de desempenho das funções vitais ao equipamento, e o processo de recuperação que pode ser realizado para a restauração das suas características nominais (WEG, 2004).

2.3.1 Testes físico-químicos

Uma série de indicadores físicos e químicos são citados pela literatura especializada como indicadores da qualidade de operação do óleo mineral (HYDROELECTRIC RESEARCH; UNITED STATES, 2003; PARRISH; KELLY; MYERS, 1981; WEG, 2004): a cor, a densidade, a viscosidade, a tensão interfacial, a umidade, a acidez, a rigidez dielétrica e o fator de potência são os principais:

- **Inspecção Visual:** observar as condições visíveis do óleo mineral em campo pode ser um indicador inicial de suas condições. Através da verificação da cor do óleo e da existência de partículas sólidas e gotículas de água em suspensão. Os métodos *American Society for Testing Materials (ASTM) D1524 69/79* e *ASTM D 1500* podem ser utilizado com tal propósito. Um disco comparador de cores é utilizado para comparar a cor do óleo com uma graduação padrão e classificar sua cor de 0 a 8. Um feixe de luz também é utilizado em um ambiente escuro para identificar sedimentos e água em suspensão, que refletem a luz, tornando-se visíveis. Um óleo em boas condições, deve se apresentar claro, límpido e transparente. Conforme o óleo se degrada, seu aspecto torna-se mais escuro e turvo.
- **Densidade:** pode ser determinada pelo método *ASTM (D1298)80*. A densidade relativa é a relação entre a massa de determinado volume de óleo e a massa de igual volume de água pura na temperatura de 15°C e é determinada com um densímetro de vidro a temperatura controlada e comparada com valores padrões (0,9 para o óleo tipo A). Valores diferentes do padronizado podem indicar contaminação por líquidos estranhos.
- **Viscosidade:** é a resistência que o óleo oferece ao escoamento contínuo sem turbulência, inércia ou outras forças. A quantidade de calor que o óleo é capaz de transferir, por hora, do transformador para o meio ambiente depende desta propriedade. Sua medição e valores

padrões são descritos na Norma Brasileira (NBR) 7148 e Associação Brasileira de Normas Técnicas (ABNT)-MB-293 (BARBOSA, 2008).

- **Tensão Interfacial:** mede a força de atração entre as moléculas de óleo e água em dina/cm ou milinewton/metro. Óleos novos tem a Tensão Interfacial elevada (40 dina/cm). O valor da tensão interfacial indica com bastante antecedência o início da deterioração do óleo, pois uma vez contaminado por produtos provenientes de oxidação, a tensão enfraquece. Os métodos recomendados para medição e análise são: ASTM (D971)50/77 e ASTM (D2285) 60/78.
- **Rigidez Dielétrica:** a capacidade dielétrica do óleo mineral é essencial para sua função de isolante. O teste de rigidez dielétrica expõe sob qual tensão aplicada ocorre ruptura dielétrica no óleo, o que acarreta na formação de um arco elétrico de grande energia sobre o líquido, através da ionização das moléculas do mesmo. A ruptura dielétrica se dá principalmente da combinação de excesso de umidade, oxigênio e calor no óleo. Este teste por si só, no entanto, não é conclusivo, visto que esta combinação provavelmente provocará quebra das moléculas do papel isolante muito antes de o teste indicar má qualidade do óleo.
- **Umidade:** água dissolvida no óleo do transformador pode ser altamente perigosa para o equipamento. Além de diminuir a rigidez dielétrica do líquido, facilitando a ocorrência de curtos, a umidade, juntamente com oxigênio e acidez, acelera bruscamente a decomposição do papel isolante do transformador. Para analisar a quantidade segura de umidade no óleo do transformador, utiliza-se da relação entre água e material seco no óleo (W/DM) (do inglês: *Water over Dry Material*). De acordo com *Reference Book on Insulating Liquids and Gases RBIL-391* (DOBLE, 1993) valores acima de 2% nunca devem ser alcançados para garantir o bem estar do equipamento.
- **Acidez:** um óleo com boa qualidade apresenta praticamente nenhuma acidez. Com o seu envelhecimento, a oxidação do próprio óleo e da celulose formam compostos ácidos capazes de corroer as partes metálicas do transformador e ainda acelerar a degradação dos isolantes. O teste de acidez aponta a quantidade de Hidróxido de Potássio necessário para neutralizar 1 g de óleo (HYDROELECTRIC RESEARCH; UNITED STATES, 2003) . Recomenda-se que o óleo seja regenerado se o teste resulta em, no mínimo, cerca de 0,20 mg KOH/g (PARRISH; KELLY; MYERS, 1981) .
- **Fator de Potência:** é igual ao cosseno do ângulo de fase entre a tensão senoidal aplicada

no mesmo e a corrente medida. O fator de potência aumenta com o grau de deterioração do óleo (MCWHINTER; TEAGUE, 1952).

A Tabela 3 fornecida pela fabricante de transformadores WEG, apresenta os principais indicadores físico-químicos do estado do óleo isolante de transformadores, com os respectivos valores típicos para diferentes condições do óleo.

Tabela 3 – Padrões de Propriedades Físico-Químicas do Óleo Mineral

Análise	Satisfatório	Recondicionar	Regenerar	Métodos de Teste
Rigidez	>35	25 - 35	-	ASTM D-877
Dielétrica	>70	50 - 70	-	NBR-6869
(kV)	>27	20 - 27	-	ASTM D-1816 (004'')
	>54	40 - 54	-	ASTM D-1816 (008'')
Umidade (ppm)	<15	15-40	>40	Método Karl Fischer - ASTM D-1533 e PMB-818
Acidez (mgKOH/g de óleo)	<0.1	-	>0.4	ASTM D-974 MB-101 ASTM D-664 MB-494
Tensão Interfacial (N/m)	>0.025	0.02-0.025	>0.020	ASTMD-971 NBR 6234 ASTM D-2285
Fator de Potência (%)	0.5	0.5-1.5	>1.5	20°C ASTM D-974 25°C ASTM D-974 100°C ASTM D-974 90°C VDE-370

Fonte – (MILASCH, 1984)

Como é exposto na tabela, uma série de normativos nacionais e internacionais são utilizados para reger os testes e as conclusões de suas análises. Tais normativos, criados por organizações de reconhecimento internacional como a ABNT são utilizadas em manutenção de transformadores de potência no mundo todo.

Com o auxílio da realização periódica dos testes e ensaios citados, pode-se aquilatar as condições de deterioração da isolação e a adoção de medidas para tratar o óleo isolante antes que falhas ocorram devido à problemas na isolação. A recuperação do óleo é o tratamento utilizado para o líquido deteriorado com a finalidade de eliminar os produtos da oxidação, contaminantes ácidos e em estado coloidal por meios químicos e de adsorção (MILASCH, 1984). De acordo com o grau de contaminação e deterioração do óleo mineral, técnicas distintas podem ser aplicadas para que este recupere suas características físicas e químicas e conseqüentemente sua capacidade isolante e refrigeradora. Quanto à sua deterioração, o óleo pode ser classificado em 4 grupos:

- grupo 1: óleo Satisfatório;

- grupo 2: óleo para Recondicionamento, i.e. eliminação por centrifugação, filtração e desidratação à vácuo da umidade e partículas sólidas em suspensão;
- grupo 3: óleo para Tratamento Químico (Regeneração), i.e. adsorção para remover os produtos da oxidação e os contaminantes ácidos e coloidais;
- grupo 4: óleo para descarte, uma vez que é técnica ou economicamente inviável recuperar o óleo;

Os principais métodos de recondicionamento e regeneração são brevemente descritos a seguir (MILASCH, 1984).

Filtração: neste processo, remove-se água não dissolvida e partículas sólidas em suspensão através da utilização de um filtro prensa. O óleo é bombeado por placas e quadros de ferro fundido, entre os quais são prensadas folhas de papel de filtro. Testes de rigidez e umidade são realizados ao longo do processo para acompanhar o avanço da filtragem.

Centrifugação: separa mecanicamente a água em suspensão e partículas de sedimentos do óleo através de separadoras centrífugas que possuem um tambor girando a alta velocidade. Desidratadores a vácuo retiram a água, gases e ácidos voláteis do óleo. É utilizado quando o óleo apresenta alto grau de contaminação.

Regeneração por Ácido Sulfúrico: o óleo é adicionado a ácido sulfúrico em seguida a silicato de sódio e então a Terra Fúler. O óleo é então filtrado para retirada da acidez e melhora da rigidez dielétrica.

Regeneração por Trifosfato de Sódio e Terra Fúler Ativada: o óleo é misturado à solução de Trifosfato de Sódio, depois é lavado e passa por separação centrífuga, logo após é depositado em um tanque com Terra Fúler ativada. Por fim é novamente lavado, centrifugado e filtrado. É utilizado para grandes quantidades de óleo muito deteriorado.

Carvão Ativado e Silicato de Sódio: o óleo é misturado com carvão e agitado a 85 °C, logo após, é filtrado e misturado com Silicato de Sódio, em seguida é centrifugado e adicionado a Terra Fúler, por fim é novamente centrifugado e filtrado.

A Tabela 4 apresenta recomendações da fabricante WEG para o diagnóstico da qualidade do óleo e a medida a ser tomada para recuperação do mesmo, se necessário, baseado em suas propriedades físico-químicas:

A tarefa de diagnosticar o óleo isolante de transformadores com base em suas propriedades físico-químicas é complexa, uma vez que demanda a realização de vários testes e a análise de várias faixas de valores e fatores de influência, muitas vezes, sendo necessário um

Tabela 4 – Diagnóstico do Óleo WEG

Fator de Potência	Rigidez Dielétrica	Umidade	Acidez	Tensão Interfacial	Diagnóstico	
Atende	Atende	Atende	Atende	Atende	Satisfatório	
				Não Atende	Regeneração	
			Não Atende	—	Regeneração	
	Não Atende	Atende	Atende	Atende	Atende	Recondicionar
				Não Atende	—	Regeneração
		Não Atende	Atende	Atende	Atende	Regeneração
				Não Atende	—	Recondicionar
			Não Atende	—	Regeneração	
	Não Atende	—	—	—	—	Regeneração

Fonte – (WEG, 2004)

operador experiente para o diagnóstico correto e seguro (MOKHNACHE, 2002; BARBOSA *et al.*, 2012).

Juntamente com a análise das físico-química do óleo, a DGA também constitui ferramenta crucial no planejamento de manutenção de transformadores de potência, pois possibilita a identificação de falhas incipientes no interior do transformador, antes que as mesmas possam vir a acarretar faltas de prejuízo maior. Uma descrição sobre o fenômeno de formação de gases dissolvidos no óleo, bem como as principais técnicas de DGA são apresentadas a seguir.

2.4 Análise de Gases Dissolvidos

Em operação normal, um transformador está sujeito a esforços físicos, elétricos e térmicos. Tais esforços, que em demasia acarretam na ocorrência de falhas incipientes, podem potencializar a decomposição dos seus materiais isolantes através de processos químicos com produção de gases característicos. Sobreaquecimento, efeito corona e formação de arcos são falhas que estão normalmente associadas à formação de gases (ZHANG, 1996).


A energia gerada por essas falhas causam a quebra das ligações químicas entre Carbono-Hidrogênio (H-C) ou Carbono-Carbono (C-C), a oxidação do óleo catalisada pelos metais presentes, como o cobre também contribuem para a quebra. Com o avanço desses

processos em altas temperaturas, ácidos e água são formados, mudando as características físico-químicas do óleo, como efeito colateral, os radicais livres presentes se recombina formando os gases.

Todo esse processo de decomposição pode ainda ser acentuado pela presença de um campo elétrico influenciando nas reações químicas (ZIRBES; ROLIM; ZURN, 2005).


Os principais gases resultantes da decomposição dos isolantes em transformadores são o hidrogênio (H_2), o metano (CH_4), o etano (C_2H_6), o etileno (C_2H_4), o acetileno (C_2H_2); estes relacionados à decomposição do óleo mineral; além do monóxido de carbono (CO) e dióxido de carbono (CO_2); relacionados principalmente à decomposição da celulose.

Figura 5 – Estrutura dos Gases



Fonte – Modificada de (MILASCH, 1984).

Figura 6 – Formação dos Radicais



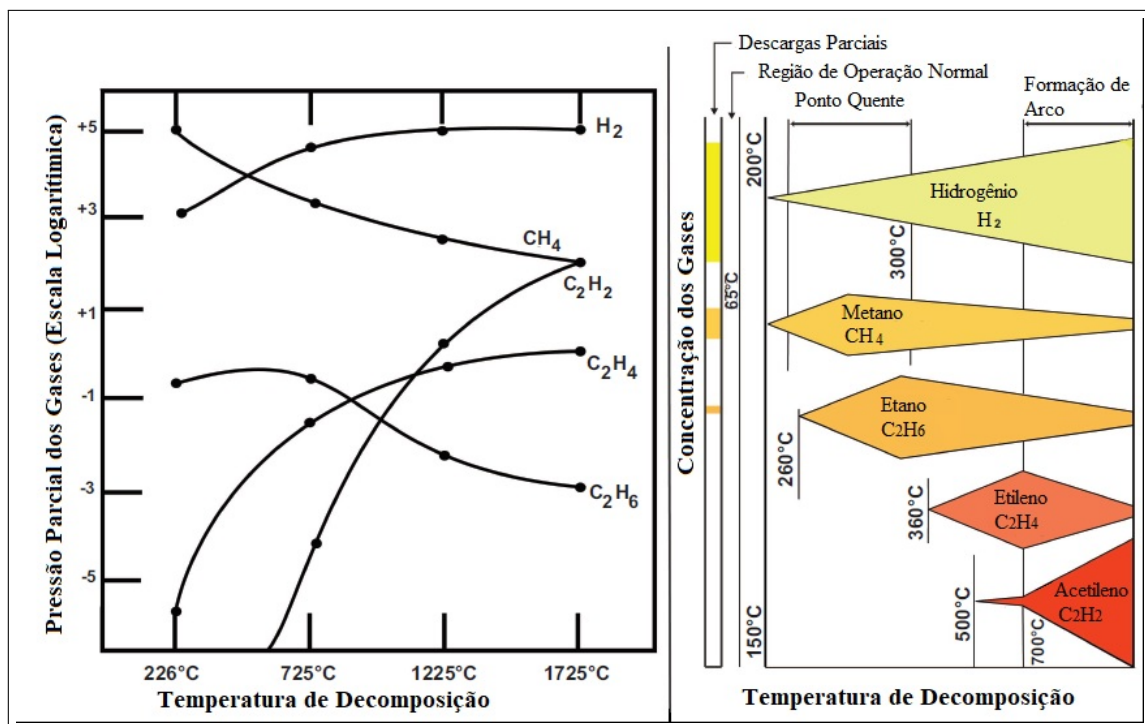
Fonte – Modificada de (MILASCH, 1984).

Esses gases, inicialmente, se dissolvem no óleo e não podem ser vistos a olho nu. Conforme o volume de gases gerados aumenta, mais desses gases se dissolvem no óleo, até que um ponto de saturação é atingido, a partir do qual, a geração continuada de gases por

decomposição dos materiais isolantes do transformador resulta em gases livres no tanque do mesmo (PANDEY, 2012).

Halstead (1973) propôs um modelo termodinâmico no qual, através de algumas suposições de condições ideais aceitáveis, relaciona a pressão parcial dos gases formados no óleo presente no interior do tanque do transformador em função da temperatura de regime.

Figura 7 – Modelo de Halstead



Fonte – (BARBOSA *et al.*, 2012).

A essas faixas de temperaturas, estão também empiricamente associados os principais tipos de falha ocorrentes nos transformadores. Dessa forma, uma vez dispondo das concentrações dos principais gases dissolvidos no óleo de um transformador, é possível inferir sobre o funcionamento do equipamento, se em regime normal ou se há ocorrência de falhas e qual a falha. Os métodos de Análise de Gases Dissolvidos, se baseiam no proposto por Halstead. As concentrações dos gases podem ser obtidos através da análise cromatográfica do óleo, feita com equipamento cromatográfico em laboratório especializado.

Na Figura 7 são apresentados, o aumento das concentrações dos gases dissolvidos no óleo mineral com o aumento da temperatura e as falhas incipientes empiricamente associadas a cada faixa de temperatura.

Recorrendo à Figura 7, percebe-se que a decomposição do óleo em temperaturas

entre 200 e 500 graus produz gases de baixo peso molecular como hidrogênio e metano e baixas quantidades de etileno e etano, atribui-se, portanto, a presença desses gases à falhas de menor energia. Com o aumento da temperatura, ocorre por consequência o aumento da concentração de hidrogênio, mas principalmente de gases com maior peso molecular como o etano e etileno, e finalmente, faltas relacionadas à temperaturas maiores e a maior desprendimento de energia promovem a formação de grandes quantidades de acetileno. Por esse motivo atribui-se normalmente a presença desse gás à formação de arcos no interior do tanque do transformador. A literatura apresenta alguns métodos de Análise de Gases Dissolvidos, (BARBOSA, 2013; IEEE, 2008; HYDROELECTRIC RESEARCH; UNITED STATES, 2003; PANDEY, 2012). Os principais deles são: o método do gás chave, das razões de Dornenburg, de Rogers, e do triângulo de Durval. Como já exposto, as concentrações dos gases foram utilizadas no presente trabalho de maneira inovadora para diagnosticar a qualidade do óleo isolante e não para detectar falhas incipientes como tradicionalmente é feito. Os principais métodos de identificação de falhas incipientes serão, portanto, apenas brevemente descritos.

2.4.1 Método do Gás Chave

Uma análise periódica dos gases dissolvidos no óleo do transformador é aconselhável para identificar traços de falhas na operação do equipamento no início da incidência dessa. Desta forma, pode-se diminuir os danos causados e a possibilidade da ocorrência de um efeito cascata, acarretando em uma falha mais severa e danosa. Um exemplo pode ocorrer com um transformador atuando em sobrecarga. Um diagnóstico correto e prematuro da condição pode alertar o operador para a necessidade de uma medida corretiva. No entanto, a permanência da condição de sobrecarga pode comprometer a isolação interna do equipamento e acarretar em um curto circuito que provavelmente irá demandar a troca do transformador.

Ações que devem ser tomadas uma vez identificada a falha, variam desde o aumento na periodicidade da análise, replanejamento do carregamento, até a troca do equipamento, dependendo dos valores encontrados e do método utilizado (IEEE, 2008).

O método do gás chave relaciona a formação de gases típicos, com certas falhas incipientes com base no modelo proposto por Halstead (1973), conforme exposto na sessão anterior e por constatações empíricas. Esses gases típicos são chamados de gases chave. A seguir esses gases são apresentados para cada falha identificável pelo método:

- decomposição térmica do óleo: o gás chave é o etileno, que se forma em maior quantidade,

mas juntamente com menores quantidades de metano, etano e hidrogênio;

- decomposição térmica da celulose: O gás chave é o monóxido de carbono, mas concentrações consideráveis de dióxido de carbono também são observáveis;
- descarga elétrica parcial: O gás hidrogênio é o chave, mas concentrações menores de metano e etileno podem ser observadas devido ao efeito térmico sobre o óleo, e de monóxido de carbono e dióxido de carbono se o papel isolante tiver sido prejudicado;
- arco elétrico: O gás chave é o acetileno, que só é observável na ocorrência de arco, mas grandes volumes de gás hidrogênio também são formados.

Tal método representa uma alternativa para se obter um diagnóstico simples e rápido, sem a necessidade de cálculos mais complexos. No entanto, o método do gás chave pode levar a conclusões confusas quando há a ocorrência de mais de uma falha, ou de um efeito cascata como o previamente descrito.

2.4.2 Método das Razões de Doernenburg

Os métodos que utilizam razões das concentrações de certos gases dissolvidos no óleo são baseados em constatações empíricas provenientes da análise de grande quantidade de transformadores de diferentes modelos, atribui-se tal metodologia inicialmente a Doernenburg, através da análise de grande número de equipamentos dos Estados Unidos da América, e posteriormente, a Rogers, com a análise de equipamentos de países da Europa (IEEE, 2008). As razões utilizadas nos métodos, podem ser visualizadas na Tabela 5.

Certos limites inferiores de concentração dos gases utilizados devem ser observados, no entanto, pois para valores abaixo desses gases, os resultados do método são incertos e imprecisos. Tais valores são expostos na Tabela 6:

Tabela 5 – Razões entre as concentrações dos gases

Razão	CH_4/H_2	C_2H_2/H_2	C_2H_2/CH_4	C_2H_6/C_2H_2	C_2H_4/C_2H_6
Notação	R1	R2	R3	R4	R5

Fonte – (IEEE, 2008)

Tabela 6 – Limites de concentração dos gases para condição de normalidade

Gás	H_2	CH_4	C_2H_2	C_2H_4	C_2H_6	CO	CO_2
Limite L1(ppm)	100	120	1	50	65	350	2500

Fonte – (IEEE, 2008)

Para a realização do método de Doernenburg, em particular, faz-se uso das razões R1, R2, R3 e R4, possibilitando diagnosticar 3 tipos de falha: decomposição térmica, descarga parcial e formação de arcos. A norma IEEE, Guia Para a Interpretação de Gases Gerados em Transformadores Imersos em Óleo (IEEE, 2008) sugere os seguintes passos para a realização do método das razões de Doernenburg:

- passo 1: obter das concentrações gasosas dissolvidas no óleo através de análise cromatográfica;
- passo 2: analisar as concentrações obtidas dos gases H_2 , CH_4 , C_2H_2 , e C_2H_4 , se uma delas exceder qualquer um dos valores L1 duas vezes, e outra exceder o valor L1, a unidade é considerada em condição de anormalidade;
- passo 3: validar a análise ao observar se pelo menos um dos gases presentes nas razões R1 a R4 excede os limites de L1, do contrário, o método não levará a conclusões confiáveis e a unidade deve ser reanalisada ou diagnosticada por outros métodos;
- passo 4: se a análise for considerada válida, todas as razões devem ser comparadas com os valores da Tabela 7;
- passo 5: se todos os gases estiverem nos valores da Tabela 7 para o diagnóstico correspondente, tal diagnóstico é considerado o correto (IEEE, 2008).

Tabela 7 – Faixas de Valores das razões para o método de Doernenburg

Diagnóstico Sugerido	R1	R2	R3	R4
Decomposição Térmica	>1,0	<0,75	<0,3	>0,4
Descarga Parcial	<0,1	Irrelevante	<0,3	>0,4
Formação de Arco	>0,1 e <1,0	>0,75	>0,3	<0,4

Fonte – (IEEE, 2008)

2.4.3 Método das Razões de Rogers

O método de Rogers é baseado tanto nas análises termodinâmicas sumarizadas anteriormente, como em constatações empíricas, no entanto, através de um número muito maior de diagnósticos de equipamentos do que o de Doernenburg. Os cálculos são mais simples, visto que as razões utilizadas são somente R1, R2 e R5 e levam a uma gama maior de condições de operação. A saber, condição normal, arco de baixa intensidade, arco de alta intensidade, falha térmica de baixa temperatura, falha térmica de menos que 700°C e falha térmica de mais que 700°C. O método, assim como o antecessor, leva a faixas de razões com resultados

inconclusivos, os quais demandam algumas vezes na aplicação de outros métodos. Na Tabela 8, são apresentadas as faixas de valores de razões referentes a cada tipo de falha.

Tabela 8 – Faixas de Valores das razões para diagnóstico através do método de Rogers

Caso	R2	R1	R5	Diagnóstico Sugerido
0	<0,1	>0,1 e <1,0	<1,0	Unidade Normal
1	<0,1	<0,1	<1,0	Descarga de Baixa Intensidade
2	>0,1 e <3,0	>0,1 e <1,0	>3,0	Arco-Descarga de Alta Intensidade
3	<0,1	>0,1 e <1,0	>1,0 e <3,0	Falha Térmica de Baixa Temperatura
4	<0,1	>1,0	>1,0 e <3,0	Falha Térmica < 700 °C
5	<0,1	>1,0	>3,0	Falha Térmica > 700 °C

Fonte – (IEEE, 2008)

O procedimento de realização do método é bastante semelhante ao de Doernenburg, um esquemático mais didático é disponível em IEEE (2008).

2.4.4 O Triângulo de Duval

Este método foi criado por Michel Duval na década de 1960 através da análise de um banco de dados de milhares de DGA's. O método é considerado preciso e têm sido bastante difundido entre os especialistas. O triângulo de Duval, porém, não pode ser utilizado para descobrir se um transformador de potência apresenta ou não falha incipiente, pois mesmo se os dados de um transformador em operação normal forem utilizados, o método apontará alguma falha. Por tal motivo, outro método deve ser utilizado para observar se o equipamento em questão se apresenta em condição normal de operação (HYDROELECTRIC RESEARCH; UNITED STATES, 2003). Recomenda-se que sejam observados, além dos limites L1, demonstrados na Tabela 6, os valores G1 e G2, dos valores de concentração empartes por milhão (ppm) de certos gases obtidos em análises consecutivas no intervalo de um mês, conforme a Tabela 9.

As Regiões marcadas no triângulo exposto na Figura 8 representam as seguintes falhas, de acordo com suas respectivas cores e siglas:

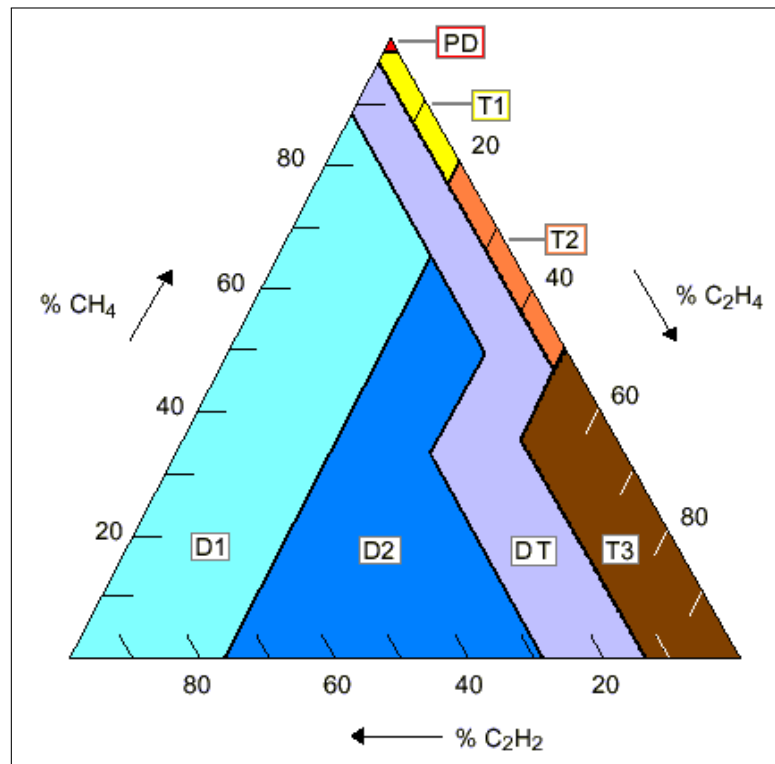
- vermelho (PD): descarga parcial;
- azul claro (D1): descarga de baixa energia(Corona);
- azul escuro (D2): descarga de alta energia (Arco);
- roxo (DT): ocorrência de descarga elétrica e estresse Térmico;
- amarelo (T1): estresse térmico menor que 300°C;
- laranja (T2): estresse térmico entre 300 e 700°C;

Tabela 9 – Limites de aumento de concentração dos gases dissolvidos

Gás	G1	G2
H_2	10	50
CH_4	8	38
C_2H_2	3	3
C_2H_4	8	38
C_2H_6	8	38
CO	70	350
CO ₂	700	3505

Fonte – (HYDROELECTRIC RESEARCH; UNITED STATES, 2003)

Figura 8 – Triângulo de Duval



Fonte – (HYDROELECTRIC RESEARCH; UNITED STATES, 2003).

- marrom (T3): estresse térmico maior que 700°C.

Para a correta identificação de falhas incipientes em transformadores, há a necessidade de um especialista na área para emissão de laudo técnico. Experiência é necessária e mais de uma técnica de DGA deve ser utilizada, já que muitas vezes uma única técnica pode não levar a uma conclusão confiável. Situações em que mais de uma falha podem estar ocorrendo simultaneamente em um equipamento são ainda complicadores de um diagnóstico correto (BARBOSA, 2013).


2.5 Relação Entre as Propriedades Físico-Químicas e os Gases Dissolvidos no Óleo Mineral

As duas principais análises de óleo mineral de transformadores de potência são: a análise das propriedades físico-químicas do óleo e a análise dos gases dissolvidos neste óleo. Como visto, as propriedades físico-químicas do óleo são indicadores da qualidade do mesmo em desempenhar sua função isolante e dielétrica, enquanto as concentrações de gases dissolvidos são utilizadas para identificar falhas incipientes internas do transformador.

Pesquisas procuram relacionar as características dielétricas anormais do óleo ao aparecimento de falhas internas de um transformador (SETAYESHMEHR *et al.*, 2008; FERGUSON; LOBEIRAS; SABOU, 2002; ABDI; BOUBAKEUR; HADDAD, 2008; IEEE, 2008; DERVOS *et al.*, 2005).

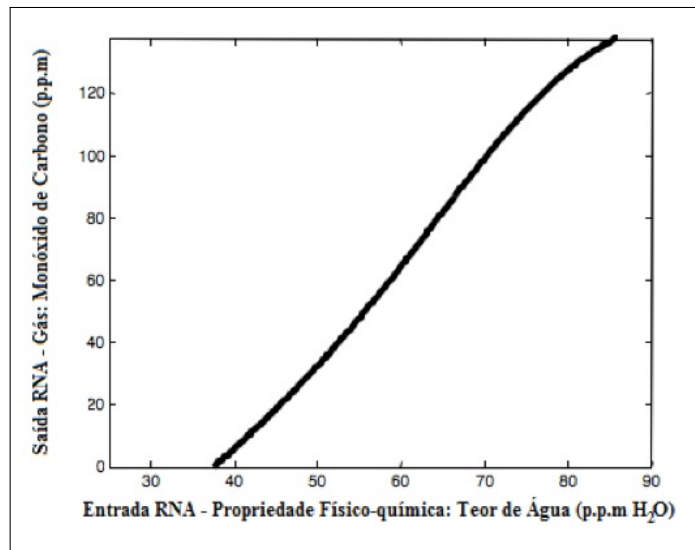
Barbosa *et al.* (2012) constatou que há relação direta entre as grandezas, ao passo que utilizou Redes Neurais Artificiais para, a partir dos valores das principais propriedades físico-químicas que influenciam na qualidade do óleo isolante, estimar as concentrações de gases dissolvidos nesse óleo. A RNA *MLP* foi utilizada devido à sua característica de aproximador universal de funções e de aprendizado por meio de exemplos. Baseado na estimativa realizada pelas Redes Neurais, Barbosa obteve graficamente a relação entre os principais atributos físico-químicos do óleo mineral e os gases dissolvidos neste óleo. Alguns desses gráficos são expostos nas Figuras 9, 10, 11 e 12.

Figura 9 – Acetileno x Teor de Água



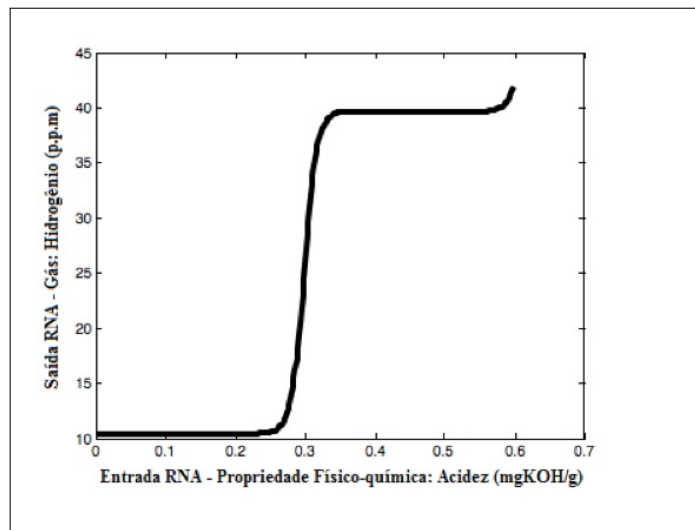
Fonte – (BARBOSA, 2013).

Figura 10 – Monóxido de Carbono x Teor de Água



Fonte – (BARBOSA, 2013).

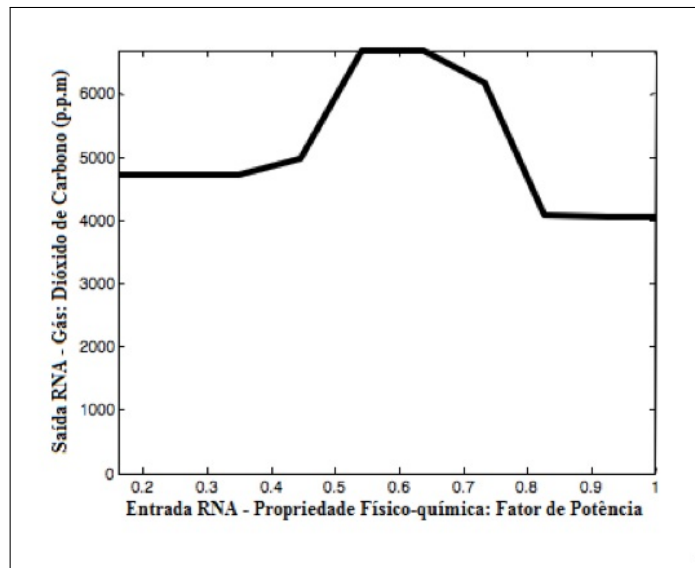
Figura 11 – Hidrogênio x Acidez



Fonte – (BARBOSA, 2013).

Como descrito na seção 2.2, o processo de degradação do óleo, responsável pela alteração de suas propriedades físico-químicas e consequente diminuição de sua qualidade como isolante e refrigerador, tem como efeito químico colateral a produção de radicais livres, que nas condições de operação de um transformador se recombina formando os gases que se dissolvem no óleo. Essas reações são ainda acentuadas na presença de condições como altas temperaturas, umidade e acidez. Portanto, os processos de degradação do óleo e formação de gases estão de alguma forma relacionados, como provado por Barbosa (2013).

Figura 12 – Dióxido de Carbono x Fator de Potência



Fonte – (BARBOSA, 2013).

Com base no exposto, a proposta do presente trabalho foi desenvolvida: utilizar Redes Neurais para, de maneira inovadora, inferir quanto à qualidade do óleo mineral de transformadores em desempenhar suas funções de dielétrico e refrigerante a partir das concentrações de gases dissolvidos neste óleo.

2.6 Métodos Computacionais de Análise de Óleo

A análise das propriedades físico-químicas do óleo e a DGA, juntas, são indispensáveis para o correto planejamento de manutenção de transformadores em operação (TANEJA; PANDEY; SEHWART, 2016; PANDEY, 2012). Devido à sua importância, e as limitações de técnicas tradicionais citadas nas seções 2.3 e 2.4, muitos estudos têm sido feitos na tentativa de desenvolver técnicas cada vez mais eficientes e diretas de análise do óleo, diminuindo a necessidade de especialistas experientes.

Destacam-se o uso de ferramentas de inteligência computacional como Lógica Fuzzy, Redes Neurais Artificiais, Algoritmos Evolutivos entre outros (MENG *et al.*, 2010). Mokhnache (2002) comparou diferentes algoritmos de *Backpropagation* (BP) para treinar redes MLP para diagnosticar a qualidade do óleo de Transformadores. Barbosa (2008) propôs um algoritmo inteligente, baseado em Redes Neurais, para diagnóstico da qualidade dielétrica do líquido isolante através das grandezas físico-químicas. Barbosa *et al.* (2012) utilizaram o MLP para prever falhas incipientes em Transformadores de Potência utilizando como entrada os

resultados dos testes físico-químicos do seu óleo. Bacha, S. e Gossa (2012) usaram Support Vector Machines (SVM) em DGA e comparou seus resultados com a aplicação da Logica *Fuzzy*, da rede MLP e da Rede Função de Base Radial (RBF) obtendo resultados ligeiramente melhores.

Ming e Yu (2014) combinaram um modelo de regressão logística multinomial e Redes Neurais com algoritmo de retropropagação do erro (do inglês *error backpropagation*), para determinar o tipo de falha de um transformador de potência analisando os gases dissolvidos. Chenxi, Liu e Cui (2014) combinaram Rede Neural Probabilística, ou do inglês *Probabilistic Neural Network (PNN)* e análise de componentes de princípio de Kernel, ou do inglês *Component Analysis by Kernel Principle (KPCA)* com o mesmo propósito. Ghanizadeh e Gharehpetian (2014) usaram MLP treinado com o algoritmo Levenberg Marquardt para detectar e localizar defeitos de curto-circuito entre discos, defeitos de deformação radiais e de deslocamento axial nos enrolamentos de Transformadores de Potência Imersos em Óleo.

Meng *et al.* (2010) propuseram um classificador de rede neural Rede de Função Basial auto-adaptativo para análise de falhas de transformadores usando FCM (*Fuzzy C-Means*) e otimização de enxame de partículas inspiradas em Otimização de enxame com comportamento de Partículas Quantum, do inglês *Quantum Behaved Particle Swarm Optimization (QPSO)*, para configurar automaticamente as estruturas da Rede e treinou-as para diagnosticar falhas de transformadores com DGA.

Peimankara *et al.* (2017) usaram uma versão binária do Algoritmo de Otimização de Enxame de Partículas Múltiplas, do inglês *Multi Objective Particle Swarm Optimization (MOPSO)* para selecionar os melhores recursos do DGA usados em diferentes classificadores para melhorar a precisão do análise de gases dissolvidos de Transformadores de Potência.

Zarković e Stojović (2017) usaram a idade, a temperatura de sobreaquecimento do ponto quente do óleo, a análise de resposta em frequência, temperatura de isolamento, DGA, $\text{tg } \delta$ e o índice de polarização como entradas de um Controlador *Fuzzy* (FC) para caracterizar a condição operacional e determinar a urgência da intervenção com a possibilidade de indicar a probabilidade de um tipo específico de falha em um Transformador de Potência.

Tusongjiang *et al.* (2018) usaram sistema de inferência Neuro-*Fuzzy* adaptativa (ANFIS) e Teoria de Dempster-Shafter (DST) para melhorar a precisão da DGA em comparação com os métodos tradicionais.

O uso de técnicas de inteligência computacional como as citadas, apresentam alternativas para os diagnósticos tradicionais, muitas vezes com uma assertividade maior e com a

internalização do conhecimento de especialistas, possibilitando a operadores inexperientes uma tomada de decisão mais embasada no planejamento da manutenção dos transformadores.

As Rede Neurais Artificiais foram utilizadas no presente trabalho, devido à sua capacidade de aprendizado com dados de entrada e saída, de generalização do conhecimento adquirido, da internalização do conhecimento de especialistas (HAYKIN, 2001) e da eficiência em aplicações semelhantes desta pesquisa como as citadas anteriormente.

2.7 Conclusão

Neste capítulo, o óleo mineral de transformadores de potência foi abordado. Foram explorados: sua composição química, seu processo de degradação e as principais técnicas de análises do líquido que possibilitam uma otimização no planejamento de manutenção dos transformadores: a análise das propriedades físico-químicas do óleo e a análise de gases dissolvidos. Foram também brevemente descritas várias técnicas modernas que utilizam ferramentas de inteligência computacionais para aprofundar as análises do óleo e contribuir promovendo conclusões mais precisas, mais diretas ou métodos alternativos de análises. Neste trabalho também foi utilizada uma ferramenta de inteligência computacional para o desenvolvimento da proposta: as Redes Neurais Artificiais. No capítulo seguinte, essas ferramentas serão abordadas. As RNAs serão descritas de uma maneira geral e aquelas redes em particular que foram utilizadas no desenvolvimento da pesquisa, serão aprofundadas.

3 REDES NEURAIAS ARTIFICIAIS

O escopo deste capítulo são as Redes Neurais Artificiais, na seção 3.1 uma breve conceituação e histórico do desenvolvimento das redes serão apresentados, na seção 3.2 o modelo do neurônio artificial será apresentado e nas seções seguintes as redes neurais que foram utilizadas neste trabalho serão discutidas em termos de arquitetura e algoritmos de aprendizagem: na seção 3.3 a rede MLP, na seção 3.5 a rede RBF, na seção 3.6 a rede SOM e na seção 3.7 a rede K-SOM e por fim comentários conclusivos do capítulos serão apresentados na seção 3.8.

3.1 Introdução

As Redes Neurais Artificiais (RNAs) constituem uma ferramenta de inteligência computacional, tal como os algoritmos evolutivos e a lógica *fuzzy*. Usualmente atribui-se o surgimento das Redes Neurais com os estudos de Mcculloch e Pitts (1943) sobre o modelo do neurônio artificial na década de 50, destaca-se ainda os trabalhos de Rosenblatt (1959), com o *perceptron* de Widrow e Hoff (1960), com o Adaline e a regra Delta, ainda utilizadas até hoje.

O desenvolvimento das RNAs visa lançar mão de características desejáveis no sistema nervoso natural, em especial a aprendizagem, adaptação a estímulos e internalização de informações através da experiência. Haykin (2001) definiu as RNAs da seguinte maneira:

“Uma rede neural é um processador maciça e paralelamente distribuído constituído de unidades de processamento simples, que têm a propensão natural para armazenar conhecimento experimental e torna-lo disponível para uso”

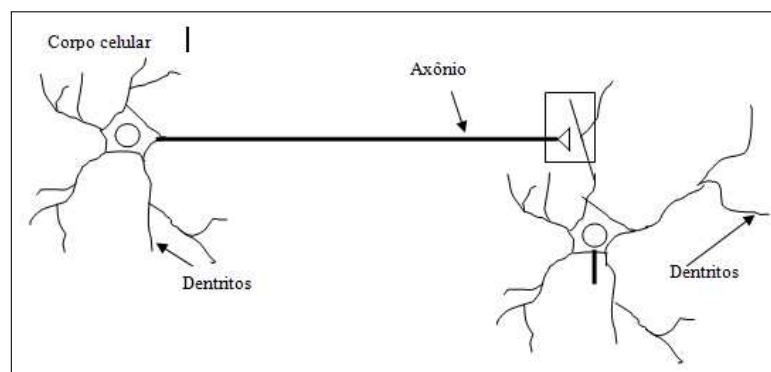
As características de não linearidade, complexidade, aprendizado com a exposição a dados de entrada e saída e capacidade de generalização das RNAs as tornam ferramentas poderosas no trato de fenômenos não lineares. Destacam-se aplicações que vão desde controle, telecomunicação, matemática financeira, previsão do tempo, análises de séries temporais e reconhecimento de padrões. Muitos estudos vêm sendo realizados nos últimos anos aplicando RNAs como ferramentas para otimizar o planejamento de manutenção, como os trabalhos citados na seção 2.6.

3.2 O modelo do Neurônio Artificial

As peculiares características de processamento e aprendizagem do sistema nervoso humano devem-se às suas características físicas e biológicas. Portanto, é relevante discutir tais características para entender a modelagem e aplicação do neurônio artificial.

O neurônio é uma célula especial capaz de processar e transmitir informações. Sua estrutura é composta basicamente do corpo celular, que contém um núcleo responsável por manter informações hereditárias e um citoplasma, que mantém nutrientes necessários para seu sustento biológico; além de terminais conhecidos como dendritos e axônios. A informação transita através dos neurônios na forma de impulsos nervosos, que ao longo do corpo da célula é transmitida através de pulsos elétricos de curta duração, e entre uma célula e outra é transmitida por reações químicas, através dos dendritos, que agem como receptores, e dos axônios que agem como transmissores. Essas transmissões são conhecidas como sinapses, e a maneira como ela ocorre varia com a característica dos próprios sinais. Sabe-se que a alteração das sinapses de acordo com o sinal transmitido, está relacionada com a capacidade de aprendizado com a experiência e é associada à memória dos sistemas nervosos (JAIN; JIANCHANG; MOHIUDDIN, 1996).

Figura 13 – Neurônio Humano




Fonte – (HAYKIN, 2001).

O Cérebro humano é composto por cerca de 10^{11} neurônios, cada um deles está um número entre 10^3 e 10^4 outros neurônios, totalizando de 10^{13} a 10^{14} ligações. O processamento de informações entre os neurônios no sistema nervoso se dá de maneira complexa, não linear e altamente paralela, através de sinais de poucos bits transmitidos de maneira distribuída (ANTONIO; IVAN; ANDRE, 2002).

Atribui-se aos pesquisadores McCulloch e Pitts o primeiro modelo matemático de um neurônio. Tal modelo é representado pelo diagrama de blocos da Figura 14. Trata-se de um modelo relativamente simples, mas que é eficientemente utilizado como a base para o projeto de redes neurais artificiais até hoje (ZHANG, 1996; MCCULLOCH; PITTS, 1943).

O modelo de Mccluooh e Pitts é constituído por três elementos básicos (Haykin,2001):

Figura 14 – Modelo McCulloch e Pitts do Neurônio



Fonte – (SOUZA, 2012).

- um conjunto de sinapses, cada um caracterizado pelo sinal de entrada x_j , multiplicado pelo peso correspondente w_{ij}
- um elemento somador dos sinais de entrada ponderados
- uma função de ativação φ , responsável por suavizar e limitar a saída do neurônio.

O componente x_0 , também citado na literatura como θ corresponde ao Limiar ou Bias. Matematicamente, o modelo do neurônio acima descrito pode ser representado pelas equações 3.1 e 3.2:

$$u_i = \sum_{j=0}^p x_j w_{ij}, \quad (3.1)$$

$$y_i = \varphi(u_i) \quad (3.2)$$

Em que u é conhecido pela literatura como campo local induzido e y é a saída do neurônio.

O Neurônio artificial é utilizado, organizado, ativado e treinado de diferentes maneiras, formando diferentes topologias de redes e algoritmos de treinamento, como já citado, as redes utilizadas no presente trabalho são: MLP, ELM, RBF e KSOM, detalhadas a seguir.

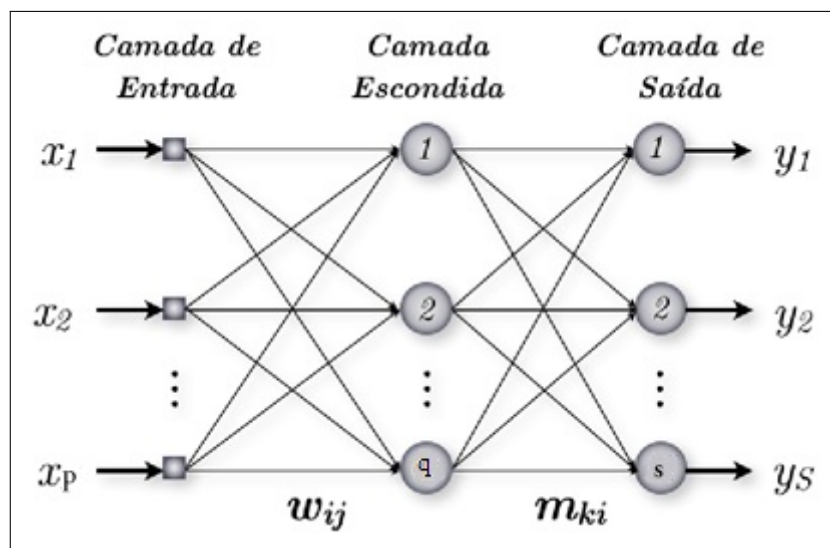
3.3 A Rede MLP

A rede MLP consiste em uma arquitetura formada por um conjunto de unidades sensoriais, que constituem a camada de entrada, uma ou mais camadas ocultas e uma camada

de saída. Cada camada é formada pelos neurônios artificiais conectados entre si de maneira multi-paralela. A Figura 15 mostra arquitetura de uma rede MLP com uma camada oculta. Na rede, cada neurônio é conectado a todos os neurônios da camada seguinte, e o sinal se propaga de maneira direta, da esquerda para a direita (*feedforward*) (HAYKIN, 2001).

Os estudos de Hornik, Stinchcombe e White (1989) e de Cao, Xie e Xu (2008) comprovam a utilização de Redes Neurais de uma camada como aproximador universal de funções contínuas arbitrárias. Baseado nestes estudos no uso de redes com apenas uma camada escondida com sucesso em trabalhos com aplicações semelhantes ao desta pesquisa, como em Barbosa (2013), Antonio, Ivan e Andre (2002), Mokhnache (2002), apenas redes com uma camada oculta foram utilizadas no presente trabalho.

Figura 15 – Rede MLP



Fonte – Modificado de (BARBOSA, 2013).

Na rede, x_1, x_2, \dots, x_p são as componentes do vetor de entrada \mathbf{x} o qual deve ser acrescido do bias $x_0 = -1$. Pode se organizar as entradas em um vetor de dimensão $p + 1$:

$$\mathbf{x}(t) = \begin{pmatrix} -1 \\ x_1(t) \\ x_2(t) \\ \vdots \\ x_p(t) \end{pmatrix}. \quad (3.3)$$

Define-se a Matriz $\mathbf{X} \in \mathbb{R}^{(p+1) \times N}$ reunindo todos os vetores coluna para as N amostras do

conjunto de dados utilizado na etapa de treinamento como:

$$\mathbf{X} = [\mathbf{x}(1) \mid \mathbf{x}(2) \mid \dots \mid \mathbf{x}(N)]. \quad (3.4)$$

Na Figura 15, q ($2 \leq q < \infty$) representa o número de neurônios da camada oculta. Os mesmos não possuem conexão direta com o vetor de entradas ou de saídas da rede. Esses neurônios são, no entanto, cruciais para a eficiência da rede, a eles é atribuído a capacidade de internalizar as características não-lineares do fenômeno em estudo, conforme o processo de aprendizado progredir (HAYKIN, 2001). A matriz $\mathbf{W} \in \mathbb{R}^{h \times (p+1)}$ é formada por todas as conexões sinápticas (ou pesos) entre as unidades de entrada e os neurônios da camada oculta. Portanto, cada elemento w_{ij} de \mathbf{W} na Figura 15 representa a conexão sináptica entre a j -ésima entrada e o i -ésimo neurônio da camada oculta. A matriz \mathbf{W} pode então ser representada por:

$$\mathbf{W} = \begin{bmatrix} \mathbf{w}_1^T \\ \mathbf{w}_2^T \\ \vdots \\ \mathbf{w}_q^T \end{bmatrix}. \quad (3.5)$$

De maneira semelhante, define-se a matriz $\mathbf{M} \in \mathbb{R}^{s \times (h+1)}$ formado pelos pesos entre os neurônios ocultos e os s neurônios da camada de saída:

$$\mathbf{M} = \begin{bmatrix} m_1^T \\ m_2^T \\ \vdots \\ m_s^T \end{bmatrix}. \quad (3.6)$$

O algoritmo de aprendizagem da rede MLP propicia que a rede neural organize sua estrutura interna de forma a desenvolver uma tarefa em particular de maneira apropriada (RUMMELHART; HINTON, 1986). No presente trabalho, dois algoritmos foram utilizados, o Backpropagation e o Levenberg-Marquardt. Esses serão detalhados nas seções a seguir.

3.3.1 O Algoritmo Backpropagation

O algoritmo backpropagation, desenvolvido inicialmente por Rumelhart e Hinton (1986) e utilizado em muitos trabalhos recentes envolvendo manutenção de transformadores (VERAS *et al.*, 2017; BARBOSA *et al.*, 2012; MOKHNACHE, 2002), consiste em dois passos. Um passo com sentido direto, ou propagação para frente dos sinais de entrada e outro com

propagação no sentido inverso, ou retro propagação do erro. Na primeira etapa, com sentido direto, as informações de entrada da rede excitam os nós sensoriais (neurônios da camada de entrada) e são propagados para a camada ou camadas escondidas e em seguida para a camada de saída.

Os sinais são ponderados nas sinapses, somados nos neurônios e processados pelas suas respectivas funções de ativação até gerar a saída da rede, esta por sua vez é comparada com uma referência, o que origina um sinal de erro. Este sinal quantifica a diferença entre a saída da rede e um sinal alvo desejado.

O passo seguinte é a propagação no sentido inverso, ou retro propagação do erro calculado. Conforme a esta ocorre, os pesos das sinapses são alterados obedecendo a uma regra de correção de erro, de maneira a diminuir gradativamente o erro calculado. Estes passos são repetidos por um número suficiente de iterações até chegar a um erro mínimo admissível. Os passos descritos são matematicamente detalhados a seguir, segundo Haykin (2001).

3.3.1.1 Sentido Direto

Inicialmente, os dados de entrada são apresentados à rede e processados pelos neurônios da camada escondida. Cada neurônio "i" apresenta processamento conforme a equação 3.7 para a iteração t:

$$u_i(t) = \sum_{j=0}^p x_j w_{ij}, i = 1, \dots, h. \quad (3.7)$$

Em que p indica o número de sinais de entrada da rede e h indica o número de neurônios da camada escondida. Logo em seguida as saídas dos neurônios ocultos $z_i(t)$ são geradas a partir das funções de ativação (Vide Anexo A):

$$z_i(t) = \varphi[u_i(t)] = \varphi\left[\sum_{j=0}^p x_j w_{ij}\right], i = 1, \dots, h. \quad (3.8)$$

As Equações 3.7 e 3.8 podem ser escritas matricialmente envolvendo os vetores de entrada e de pesos da rede:

$$\mathbf{Z} = \varphi(\mathbf{W}^T(t) * \mathbf{X}(t)). \quad (3.9)$$

A seguir, de maneira semelhante, as saídas dos neurônios da camada escondida são propagados para os neurônios da camada de saída:

$$\mathbf{Y} = \varphi(\mathbf{M}^T(t) * \mathbf{Z}(t)). \quad (3.10)$$

3.3.1.2 Sentido Inverso

Nesta etapa do algoritmo, comumente chamada de retropropagação do erro, a informação do erro da saída da rede é transmitida no sentido inverso, isto é, da camada de saída para as camadas escondidas e por sua vez para a camada de entrada. Ela consiste basicamente no cálculo dos gradientes locais e no ajuste dos pesos dos neurônios.

Inicialmente calcula-se os gradientes locais dos k neurônios da camada de saída:

$$\delta_k(t) = e_k(t) \varphi'(u_k(t)) \quad k = 1, \dots, M, \quad (3.11)$$

em que e_k é a diferença entre o sinal de referência d_k e a saída da rede y_k :

$$e_k(t) = d_k(t) - y_k(t) \quad k = 1, \dots, M, \quad (3.12)$$

e $\varphi'(u_k(t))'$ é a derivada da função de ativação do neurônio. De maneira semelhante, o gradiente local dos neurônios da camada escondida é dado por:

$$\delta_i(t) = \varphi'(u_i(t))' \sum_{k=1}^S m_{ki} \delta_k \quad i = 1, \dots, M. \quad (3.13)$$

Uma vez calculados os gradientes locais dos neurônios, os pesos dos mesmos são atualizados de maneira a gerarem um vetor de saídas \mathbf{Y} que minimize os erros e_k :

$$w_{ij}(t+1) = w_{ij}(t) + \alpha \delta_i(t) x_j(t), \quad i = 1, \dots, h. \quad (3.14)$$

Em que α é a taxa de aprendizagem, fator importante para a convergência do algoritmo. Por fim, os pesos da camada de saída são atualizados:

$$m_{ki}(t+1) = m_{ki}(t) + \alpha \delta_k(t) z_i(t), \quad i = 1, \dots, h. \quad (3.15)$$

O algoritmo é repetido em sua totalidade até que seja atingido um critério de parada previamente estabelecido, alguns critérios de parada são apresentados no Apêndice A.

3.3.2 O Algoritmo Levenberg-Marquardt

O algoritmo Levenberg-Marquardt (JAIN; JIANCHANG; MOHIUDDIN, 1944; MARQUARDT, 1963) envolve a derivada segunda da função a ser minimizada acelerando a convergência (BARBOSA, 2013). O método consiste em um aperfeiçoamento do método de otimização de Newton. Este, usa a informação da derivada parcial de segunda ordem do índice

de desempenho utilizado para corrigir os pesos permitindo que, além da informação do gradiente, também, informações da curvatura do erro sejam usadas (RANGANATHAN, 2004). Este método é custoso devido à necessidade da computação da matriz hessiana, formada pelas derivadas segundas da função. No método de Levenberg-Marquardt a matriz Hessiana é aproximada utilizando Equação 3.16:

$$\mathbf{H}(w) = \mathbf{J}^T(w)\mathbf{J}(w)e(w), \quad (3.16)$$

onde w é a matriz dos pesos e limiares, \mathbf{J} é a matriz Jacobiana formada pelas primeiras derivadas dos erros da rede com relação aos pesos. O gradiente é obtido através da equação:

$$\delta(w) = \mathbf{J}^T(w)\mathbf{e}(w). \quad (3.17)$$

Uma vez que a matriz Hessiana, calculada na equação 3.16 pode não ter inversa, na atualização dos pesos, é adicionado a parcela μI , onde μ é um escalar, conhecido como constante de regularização e I é a matriz Identidade. Os pesos, então, são atualizados através da equação:

$$w(t+1) = w(t) - [\mathbf{J}^T(w)\mathbf{J}(w) + I\mu]^{-1} \mathbf{J}^T(w)\mathbf{e}(w). \quad (3.18)$$

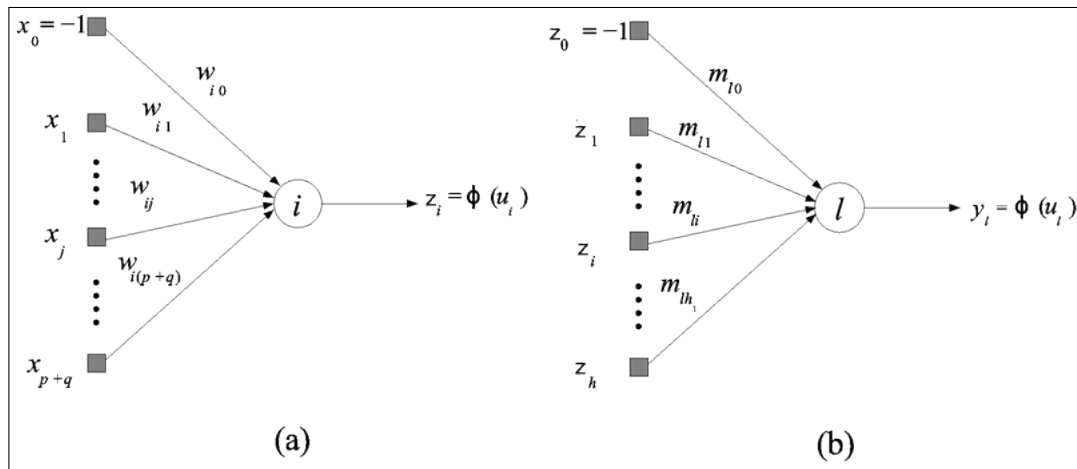
O escalar μ no algoritmo de treinamento é um fator de grande relevância. Quando este tem valor muito baixo, o método LM se comporta como o método de Newton. Quando este assume valores elevados, o algoritmo é semelhante ao *Back-Propagation*. O método de Newton é mais eficaz onde o erro é pequeno, e o método BP é mais eficaz para causar variações maiores. Portanto, no algoritmo, μ é decrementado a cada época em que há a diminuição do valor do erro e incrementado quando há um aumento deste.

3.4 A Rede ELM

A rede Extreme Learning Machine (ELM) (HUANG; ZHU; ZIEW, 2006) é uma RNA *feedforward* que tem a mesma arquitetura de uma MLP de uma camada escondida, mas com uma etapa de treinamento muito mais rápida, que a torna uma ferramenta interessante para aplicações em que menos esforço computacional é necessário. A figura 16 representa a topologia da rede.

Onde i é um neurônio da camada escondida, l é um neurônio da camada de saída. A entrada da rede, bem como os pesos da camada escondida e da camada de saída são organizados matricialmente da mesma maneira que na seção 3.3, formando as matrizes \mathbf{X} , \mathbf{W} e \mathbf{M} respectivamente. O algoritmo de treinamento da rede é descrito a seguir:

Figura 16 – Neurônios da Rede ELM: (a) Camada Escondida (b) Camada de Saída



Fonte – (SOUZA, 2012).

Os pesos da matriz \mathbf{W} são iniciados aleatoriamente. A matriz de entradas é então apresentada a rede em uma iteração t e a saída dos neurônios é calculado por:

$$\mathbf{U}(t) = \mathbf{W}\mathbf{X}(t), \quad (3.19)$$

$$\mathbf{Z}(t) = \varphi(\mathbf{U}(t)) = \varphi(\mathbf{W}\mathbf{X}(t)). \quad (3.20)$$

A matriz \mathbf{Y} é formada pela saída correspondente para cada vetor de entradas na iteração t , a ela deve ser adicionada uma linha de valores -1 como limiar ou bias da camada de saída.

Os pesos da camada de saída são então calculados, através de um mapeamento linear entre a camada escondida e a camada de saída. Para tal propósito, define-se um vetor com a saída desejada $d(t)$ para cada entrada de treino. Deseja-se um vetor que melhor represente a transformação linear:

$$\mathbf{D}(t) = \mathbf{M}^T \mathbf{Y}(t). \quad (3.21)$$

O Método da Pseudo-Inversa pode ser utilizado com essa finalidade (PRINCIPE; EULIANO; LEFEBVRE, 2000):

$$\mathbf{M} = (\mathbf{Y}\mathbf{Y}^T)^{-1} \mathbf{Y}\mathbf{D}. \quad (3.22)$$

. Uma vez treinada, a rede ELM deve ser capaz de generalizar o conhecimento adquirido a um novo dado de entradas desconhecidas e gerar a saída correta. O processo das novas entradas, uma

vez que os neurônios de saída são lineares, são calculados de acordo com as equações(SOUZA, 2012):

$$\hat{u}(t) = \mathbf{m}^T \mathbf{Z}(t), \quad (3.23)$$

em que o vetor de saídas dos neurônios ocultos, $\mathbf{Z}(t)$, é calculado por:

$$\mathbf{Z}(t) = \begin{bmatrix} -1 \\ \varphi(\mathbf{W}\mathbf{x}(t)) \end{bmatrix}, \quad (3.24)$$

3.5 A Rede RBF

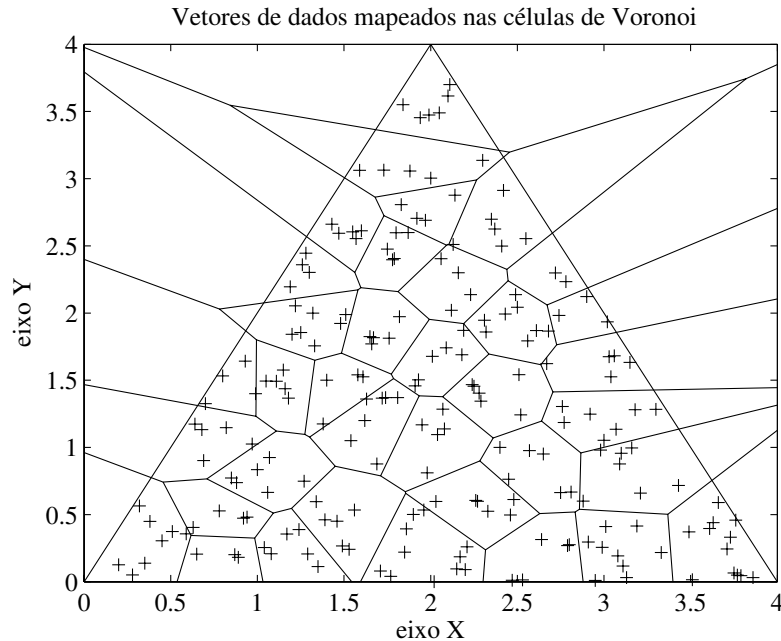
O projeto de uma rede neural pode ser executado de várias formas, neste tipo de topologia de rede, a arquitetura trata o aprendizado como um problema de ajuste de curvas (MOODY; DARKEN, 1989). O aprendizado, nesse enfoque, corresponde a encontrar uma superfície em um espaço multidimensional que melhor ajuste os dados de treinamento conforme suas características. Uma vez treinada, a capacidade de generalização da rede a possibilita utilizar essa superfície para classificar ou interpolar de maneira adequada dados ainda não conhecidos (dados de teste) (HAYKIN, 2001).

A rede RBF é também uma rede multicamadas com aplicações semelhantes à MLP, com um enfoque maior para classificação de padrões. Sua estrutura consiste, necessariamente por uma camada de entrada, uma camada de saída e apenas uma camada oculta. A peculiaridade desta rede está na camada oculta, em que seus neurônios são ativados por Funções de Base Radial, diferente das utilizadas (Vide Anexo A) na MLP. As funções de Base Radial possuem duas características intrínsecas, o centro e o raio de abertura. A ativação dos neurônios da camada oculta se dá em função da distância entre o vetor de entrada e os pesos, que no caso das RBF's são os centros de base. Os ajustes desses centros são determinantes para a formação da superfície de classificação.

As regiões de classificação ou agrupamento, também chamadas de clusteres, são conhecidos pela literatura como células de Voronoi (SOUZA, 2012). Na Figura 17, são representadas as células de Voronoi em uma aplicação de agrupamento de dados.

O algoritmo de treinamento da rede RBF, consiste também de duas etapas. Na primeira, os neurônios da camada escondida são calculados em termo de seus parâmetros principais: o centro e o raio de base. A segunda etapa do treinamento da rede RBF consiste na atualização dos pesos da camada de saída, de maneira semelhante ao visto na Seção 3.3.

Figura 17 – Celulas de Voronoi



Fonte – (SOUZA, 2012).

Os raios dos neurônios da camada escondida σ , no presente trabalho, possuem o mesmo valor para todos os neurônios e são uma função da maior distância entre os centros de todos os neurônios e o número de neurônios na camada escondida q (BARRETO; SOUZA, 2010):

$$\sigma = \frac{d_{\max}(c_i, c_j)}{\sqrt{2 * h}} \quad (3.25)$$

Através de um algoritmo de quantização vetorial, os centros de base dos neurônios podem ser calculados. Os algoritmos *Winner Takes All* (WTA), o algoritmo K-Médias e a rede SOM são comumente utilizados. Os dois primeiros, são abordados nas subseções 3.5.1 3.5.2. A Rede SOM, utilizada neste trabalho como algoritmo de quantização vetorial para a rede RBF, será abordada na seção 3.6 por ser uma ferramenta mais complexa e uma rede neural com arquitetura e algoritmo de treinamento particulares.

3.5.1 O Algoritmo WTA

Neste algoritmo de treinamento, inicia-se os centros de base, que podem ser entendidos como os pesos dos neurônios, de maneira aleatória (DARKEN; MOODY, 1990). Para cada entrada de treino, apenas um neurônio é escolhido para ser atualizado, o neurônio vencedor,

escolhido de acordo com o seguinte critério:

$$i^*(t) = \operatorname{argmin} \|x(t) - c_i(t)\|. \quad (3.26)$$

Em que $i^*(t)$ é o índice associado ao neurônio vencedor, $x(t)$ é o dado de entrada da rede na iteração t e $c_i(t)$ é o peso associado ao neurônio vencedor (SOUZA, 2012).

Observa-se que o neurônio vencedor é escolhido em função da distância euclidiana entre o dado de entrada e o centro de base do neurônio da camada escondida.

Uma vez escolhido o neurônio vencedor, o centro do mesmo é atualizado segundo a seguinte equação:

$$c_i(t+1) = c_i(t) + \|x(t) - c_i(t)\| + \alpha[x(t) - c_i(t)] \quad (3.27)$$

3.5.2 O Algoritmo K-Médias

O algoritmo K-médias (MACQUEEN, 1967), por sua vez, visa encontrar um conjunto de g protótipos (pesos dos neurônios da camada escondida) que particione os dados de entrada em g grupos distintos. A região de influência de determinado protótipo é chamada de partição de Voronoi daquele protótipo (SOUZA, 2012) e é definida como:

$$V_i = \{x \in \mathcal{R}^p \mid \|x - w_i\| < \|x - w_j\|, \forall j \neq i\}, \quad (3.28)$$

em que $\|\cdot\|$ denota a norma euclidiana. Assim com g protótipos é possível particionar o espaço de entradas em g regiões de Voronoi V_i . Os vetores protótipos são iniciados aleatoriamente, e o conjunto de dados é inicialmente separado nas g regiões de Voronoi. Os protótipos são recalculados como as médias aritméticas (centróides) dos dados alocados a cada região de Voronoi:

$$w_i = \frac{1}{N_i} \sum_{x \in V_i} x_i, \quad (3.29)$$

Em que N_i é o número de vetores pertencentes à célula de Voronoi do i -ésimo protótipo.

3.5.3 Projeto da Camada de Saída

Uma vez determinados os centros dos neurônios através do algoritmo de quantização e os raios dos mesmos, o sinal de entrada pode ser propagado de maneira direta através da rede RBF. A saída dos $z_i(t)$ neurônios da camada oculta são calculadas através das equações:

$$u_i(t) = \|x(t) - c_i(t)\|, \quad (3.30)$$

$$z_i(t) = \varphi[u_i(t)] = \exp\left(-\frac{u_i^2(t)}{2\sigma_i^2}\right), i = 1, \dots, h. \quad (3.31)$$

O cálculo dos pesos da camada de saída, podem então ser calculados. Para tanto utiliza-se procedimento semelhante com o descrito na Seção 3.3, através da regra Delta, sumarizada nas seguintes equações:

$$\mathbf{Y}_k = \varphi(\mathbf{Z}(t) * \mathbf{M}^T(t)). \quad (3.32)$$

Utilizando conotação matricial conforme em 3.3, em que \mathbf{M} é a matriz de pesos da camada de saída inicializada aleatoriamente.

Os pesos dos neurônios de saída são então atualizados pela regra delta:

$$m_{ki}(t+1) = m_{ki}(t) + y_i(t) \varphi'_k e_k \alpha \quad (3.33)$$

Em que α é a taxa de aprendizagem, φ'_k é a derivada da função de ativação (Vide Anexo A) e e_k é o erro relacionado à k-ésima saída.

3.6 A Rede SOM

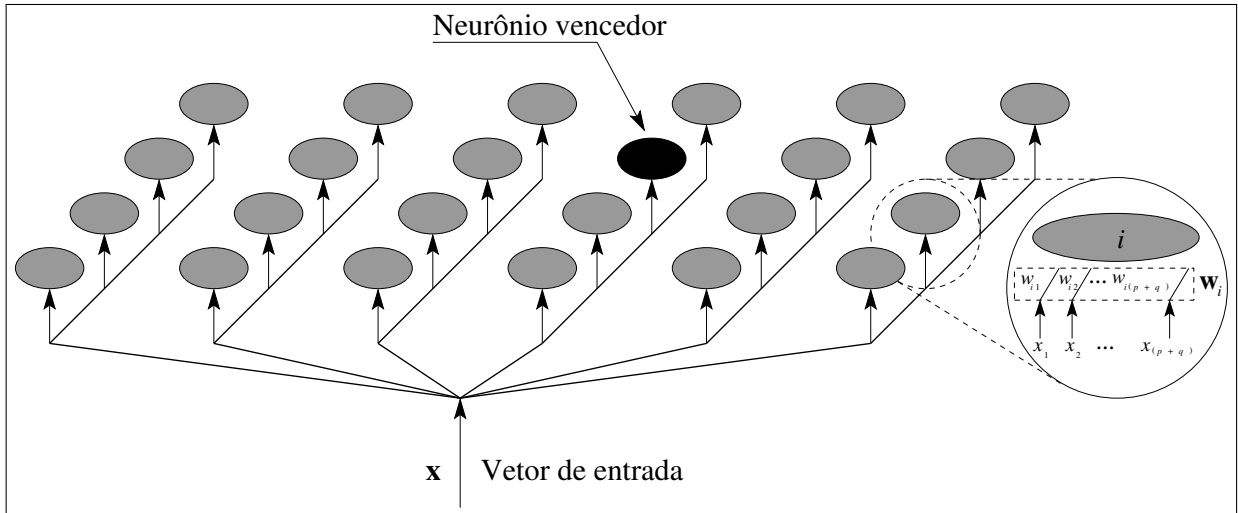
A rede SOM, do inglês *Self Organized Map* (Mapa Auto-Organizável) foi proposta por Kohonen (1982) e tem como objetivo principal transformar um sinal de entrada de dimensão qualquer em um arranjo discreto de unidades de processamento (SOUZA, 2012). Seja um conjunto finito de vetores \mathbf{x} pertencentes a um espaço χ e seja um espaço de saída A definido pelo arranjo geométrico de um conjunto de neurônios i . Φ é a transformação não-linear ou mapeamento de características, que leva do espaço de entrada ao espaço de saída:

$$\Phi: \chi \rightarrow A. \quad (3.34)$$

A Figura 18 mostra um esquema de um arranjo de neurônios retangular (de duas dimensões) usado como espaço discreto de saída. Cada neurônio i é conectado às p unidades do vetor de entrada o por meio dos pesos w_{ij} , agrupados no vetor \mathbf{w}_i .

A implementação da Rede SOM inicia-se com a atribuição de valores iniciais aleatórios aos pesos da rede. Em seguida, três etapas distintas completam a formação da rede: A competição, a cooperação e a adaptação.

Figura 18 – Rede Som Bidimensional



Fonte – (SOUZA, 2012).

3.6.1 Competição

Nesta etapa, para cada vetor de entrada, são calculados, para cada neurônio da rede, o valor de determinada função discriminante, aquele que apresenta o menor valor desta função, é o neurônio vencedor. A função utilizada no presente trabalho é a distância euclidiana entre os vetores de pesos dos neurônios e o vetor de entrada. O neurônio vencedor é então escolhido através da equação:

$$i^*(\mathbf{x}(t)) = \underset{i \in \mathcal{S}}{\operatorname{arg\,min}} \|\mathbf{x}(t) - \mathbf{w}_i(t)\|, \quad (3.35)$$

em que $i^*(\mathbf{x}(t))$ é o índice que representa o neurônio vencedor para o padrão de entrada $\mathbf{x}(t)$. A norma euclidiana $\|\cdot\|$ é definida como

$$\|\mathbf{x}(t) - \mathbf{w}_i(t)\| = \sqrt{[\mathbf{x}(t) - \mathbf{w}_i(t)]^T [\mathbf{x}(t) - \mathbf{w}_i(t)]} = \sqrt{\sum_{j=1}^{p+q} [x_j(t) - w_{ij}(t)]^2}. \quad (3.36)$$

3.6.2 Cooperação

O neurônio vencedor interage com seus vizinhos de maneira proporcional a proximidade dos neurônios ao neurônio vencedor. Define-se uma função vizinhança $h(i^*, i; t)$ que relaciona a intensidade da relação entre o neurônio vencedor i^* e os outros neurônios da rede. Duas funções comumente utilizadas são a função Gaussiana:

$$h(i^*, i; t) = \exp\left(-\frac{\|\mathbf{r}_{i^*} - \mathbf{r}_i\|^2}{2\sigma^2(t)}\right), \quad (3.37)$$

e a função Retangular:

$$h(i^*, i; t) = \begin{cases} 1, & \text{se } i \in K_{i^*}(t) \\ 0, & \text{caso contrário,} \end{cases} \quad (3.38)$$

em que $K_{i^*}(t)$, chamado de conjunto vizinhança, contém os neurônios vizinhos de $i^*(t)$.

3.6.3 Adaptação

Nessa etapa, ocorre o processo de ajuste dos pesos, a atualização destes, que foram iniciados aleatoriamente, baseia-se nos estudos de Hebb (1949), em uma tentativa de relacionar a alteração estrutural de sinapses reais com a memória e, conseqüentemente, com aprendizagem ou experiência. Assim, uma abstração matemática destas suposições foi proposta por Kohonen como uma regra recursiva para ajuste dos pesos (KOHONEN, 1982):

$$\mathbf{w}_i(t+1) = \mathbf{w}_i(t) + \alpha(t)h(i^*, i; t)[\mathbf{x}(t) - \mathbf{w}_i(t)], \quad (3.39)$$

Os pesos são atualizados iterativamente até ser alcançado um critério de parada pré-estabelecido, no processo de quantização vetorial da Rede RBF, eles constituem os centros de base dos neurônios da camada escondida de rede RBF.

3.7 Rede K-SOM

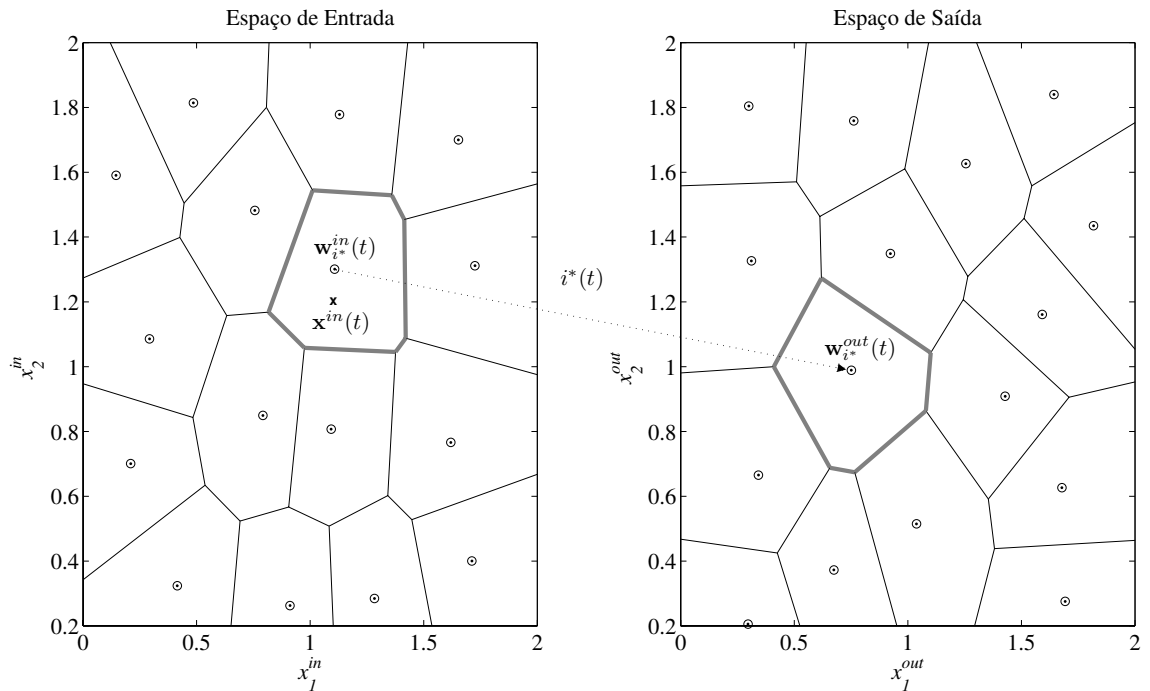
Essa Rede é constituída a partir do modelo VQTAM, do inglês *Vector-Quantized Temporal Associative Memory* (Memória Associativa de Quantização Vetorial) (BARRETO; SOUZA, 2010), que usa a rede SOM para quantizar simultaneamente os espaços de entrada e saída a partir dos pares entrada-saída disponíveis para treino (SOUZA, 2012). Dado um vetor de entrada e um vetor de peso, ambos compostos por duas partes:

$$\mathbf{x}(t) = \begin{pmatrix} \mathbf{x}^{in}(t) \\ \mathbf{x}^{out}(t) \end{pmatrix} \quad \text{e} \quad \mathbf{w}_i(t) = \begin{pmatrix} \mathbf{w}_i^{in}(t) \\ \mathbf{w}_i^{out}(t) \end{pmatrix}. \quad (3.40)$$

No qual $\mathbf{x}^{in}(t)$ corresponde aos padrões dos dados e $\mathbf{x}^{out}(t)$ é a classificação dos dados, para uma aplicação de reconhecimento de padrões; $\mathbf{w}_i^{in}(t)$ e \mathbf{w}_i são os pesos associados ao i -ésimo neurônio da rede.

O treinamento da rede VQTAM consiste em associar um vetor de pesos de um neurônio vencedor que forma um espaço de entradas com os pesos do espaço de saída quantizados. A Figura 19 apresenta a arquitetura do modelo:

Figura 19 – Arquitetura do Modelo VQTAM



Fonte – (SOUZA, 2012).

O algoritmo de treinamento consiste em selecionar um neurônio vencedor conforme as entradas são apresentadas à rede através da equação:

$$i^*(t) = \arg \min_i \{ \|\mathbf{x}^{in}(t) - \mathbf{w}_i^{in}(t)\| \}. \quad (3.41)$$

Os pesos são então iterativamente atualizados:

$$\mathbf{w}_i^{in}(t) = \mathbf{w}_i^{in}(t) + \alpha(t)h(i^*, i; t)[\mathbf{x}^{in}(t) - \mathbf{w}_i^{in}(t)], \quad (3.42)$$


$$\mathbf{w}_i^{out}(t) = \mathbf{w}_i^{out}(t) + \alpha(t)h(i^*, i; t)[\mathbf{x}^{out}(t) - \mathbf{w}_i^{out}(t)], \quad (3.43)$$

Em que $0 < \alpha(t) < 1$ é a taxa de aprendizagem e $h(i^*, i; t)$ é a função de vizinhança dada pela Equação 3.37 ou 3.38.

Há uma diferença conceitual importante entre a estratégia associativa do modelo VQTAM com relação ao comumente utilizado em redes com treinamento supervisionados como MLP e RBF, conforme mostrado no diagrama de blocos da Figura 20.

Na estratégia supervisionada, o vetor $\mathbf{x}^{in}(t)$ seria utilizado na entrada da rede, enquanto $\mathbf{x}^{out}(t)$ seria utilizado na saída da rede, para calcular o erro utilizado para guiar as atualizações dos pesos da rede. Por outro lado, na estratégia não supervisionada, $\mathbf{x}^{out}(t)$ é também apresentado como entrada da rede, sem o cálculo explícito de um erro de aproximação.

Figura 20 – Diferença entre o treinamento supervisionado e não supervisionado.



Fonte – (SOUZA, 2012).

Depois do treino do modelo VQTAM, um conjunto de K protótipos (neurônios) mais próximos ao vetor de entrada atual $\mathbf{x}^{in}(t)$ é determinado:

$$\begin{aligned} i_1^*(t) &= \arg \min_i \{ \|\mathbf{x}^{in}(t) - \mathbf{w}_i^{in}(t)\| \} \\ i_2^*(t) &= \arg \min_{i \neq i_1^*} \{ \|\mathbf{x}^{in}(t) - \mathbf{w}_i^{in}(t)\| \} \\ &\vdots \\ i_K^*(t) &= \arg \min_{i \neq i_1^*, i_2^*, \dots, i_{K-1}^*} \{ \|\mathbf{x}^{in}(t) - \mathbf{w}_i^{in}(t)\| \}. \end{aligned} \quad (3.44)$$

A idéia em que o modelo KSOM se baseia é utilizar os pares protótipos $\{\mathbf{w}_{i_k^*}^{in}(t), w_{i_k^*}^{out}(t)\}_{k=1}^K$ dos k neurônios vencedores na iteração t para coonstruir uma aproximação local de funções. Uma alternativa é determinar um vetor de parâmetros que satisfaça as seguintes relações lineares (SOUZA, 2012):

$$w_{i_k^*}^{out}(t) = \mathbf{a}^T(t) \mathbf{w}_{i_k^*}^{in}(t), \quad k = 1, \dots, K. \quad (3.45)$$

Em que $\mathbf{a}(t) = [a_1(t), \dots, a_p(t), b_1(t), \dots, b_q(t)]^T$ é um vetor de coeficientes em t . A Equação 3.46 pode ser escrita de matricialmente:

$$\mathbf{p}(t) = \mathbf{R}(t) \mathbf{a}(t), \quad (3.46)$$

onde o vetor \mathbf{p} chamado vetor de predição e a matriz \mathbf{R} matriz de regressão são dados por:

$$\mathbf{p}(t) = [w_{i_1^*}^{out}(t) \ w_{i_2^*}^{out}(t) \ \dots \ w_{i_K^*}^{out}(t)]^T, \quad (3.47)$$

e

$$\mathbf{R}(t) = \begin{pmatrix} w_{i_1^*,1}^{in}(t) & w_{i_1^*,2}^{in}(t) & \dots & w_{i_1^*,p+q}^{in}(t) \\ w_{i_2^*,1}^{in}(t) & w_{i_2^*,2}^{in}(t) & \dots & w_{i_2^*,p+q}^{in}(t) \\ \vdots & \vdots & \vdots & \vdots \\ w_{i_K^*,1}^{in}(t) & w_{i_K^*,2}^{in}(t) & \dots & w_{i_K^*,p+q}^{in}(t) \end{pmatrix}_{K \times (p+q)}. \quad (3.48)$$

Para resolver as equações, o Método da Pseudo-Inversa pode ser utilizado (AGUIRRE, 2007; PRINCIPE; EULIANO; LEFEBVRE, 2000). Logo $\mathbf{a}(t)$ pode ser determinado por:

$$\mathbf{a}(t) = (\mathbf{R}^T(t)\mathbf{R}(t) + \lambda\mathbf{I})^{-1} \mathbf{R}^T(t)\mathbf{p}(t), \quad (3.49)$$

em que \mathbf{I} é a matriz identidade com ordem $p + q$ e $\lambda > 0$ é uma constante positiva com valor pequeno. Uma vez que o vetor $\mathbf{a}(t)$ é calculado, através da equação (3.49) a saída do mapeamento não linear pode ser aproximado por:

$$\hat{u}(t) = \sum_{l=1}^p a_l(t)y(t-l) + \sum_{k=1}^q b_k(t)u(t-k) = \mathbf{a}^T(t)\mathbf{x}^{in}(t) \quad (3.50)$$

3.8 Conclusão

Neste capítulo, as Redes Neurais Artificiais de maneira geral, bem como as Redes que foram utilizadas como ferramenta para o desenvolvimento da proposta desta pesquisa, foram abordadas. Foram descritas suas topologias, formulações matemáticas e algoritmos de treinamento. A seguir, a metodologia utilizada para o treinamento e teste das redes utilizando os dados disponíveis, bem como o tratamento destes dados para uma otimização do treinamento das redes será abordado.

4 METODOLOGIA

O desenvolvimento do presente trabalho utiliza dados colhidos pela Companhia Hidrelétrica do São Francisco (CHESF), através de análises de óleo em 158 transformadores cujas potências variam de 230 a 500 kV em operação. Os equipamentos foram fabricados entre 1961 e 2008 e os testes foram realizados entre 1982 e 2009. A base de dados é composta pelos resultados de Cromatografia e de Análises Físico-Químicas que eram realizados rotineiramente.

As análises foram feitas por empresa prestadora de serviços especializada em análises de óleo. Os dados são formados pelas informações das coletas cromatográficas e físico-químicas e dos resultados obtidos pela empresa baseada na aplicação dos métodos de análise de óleo apresentados no capítulo 2 e, principalmente, na experiência de especialistas.

A Tabela 10 apresenta um dado de uma coleta de um transformador a título de exemplo:

Tabela 10 – Exemplo de Dado de Coleta

SE	TSA
N. Série	568687
Coleta	08/04/2009
Fabricação	1979
Energização	Dez/1981
H₂	0,3
O₂	16348
N₂	53329
CH₄	1
CO	8
CO₂	157
C₂H₄	1
C₂H₆	0,2
C₂H₂	1
R1	3,33
R2	1
R3	1
R4	0,2
R5	5
Acidez	0
Rig. Dielétrica	87,2
Umidade	13
Tens. Interf.	0
Densid.	0
Fat. Pot.	1.86
Diagnóstico	Satisfatório

O dado apresenta, respectivamente: a subestação a qual o transformador pertence (SE), o número de série do mesmo, a data da coleta, a data da fabricação do transformador, a data de energização do mesmo; os dados de concentração dos gases em ppm: hidrogênio (H_2), oxigênio (O_2), nitrogênio (N_2), metano (CH_4), monóxido de carbono (CO), dióxido de carbono (CO_2), etileno(C_2H_6), etano(C_2H_6) e o acetileno (C_2H_2); as razões das concentrações dos gases para DGA R1, R2, R3, R4 e R5 (Tabela 5); os resultados das análises físico-químicas: Acidez, Rigidez Dielétrica, Umidade, Tensão Interfacial, Densidade, Fator de Potência e o Diagnóstico da qualidade do óleo.

4.1 O Balanceamento dos Dados

A base de dados original apresenta mais de 30 mil coletas. No entanto, para este trabalho, foram utilizados somente as coletas de cromatografia e análises físico-químicas que foram realizados na mesma data. Esse cuidado é importante para manter a relação intrínseca entre as duas análises para um transformador com as mesmas condições de operação, uma vez que análises realizadas em dias diferentes, podem ter sido influenciadas por eventos majoritários que ocorreram no intervalo entre as coletas, como por um curto-circuito ou condição de sobrecarga.

Essa seleção resultou num conjunto de 1034 dados. Destes dados, as Concentrações dos Gases obtidos por Cromatografia foram utilizados como entradas das RNAs e o diagnóstico da qualidade do óleo obtido foram as saídas desejadas das redes. Na Tabela 11 é apresentada a distribuição original dos dados quanto ao diagnóstico da qualidade do óleo:

Tabela 11 – Distribuição Inicial dos 1034 Dados quanto ao Diagnóstico do Óleo

Satisfatório	878	85%
Regenerar	131	13%
Recondicionar	16	2%
Aditivar	8	1%

Uma vez que os transformadores analisados são sujeitos a manutenção periódica, a maioria dos dados apresenta óleo satisfatório, conforme pode ser visto na Tabela 11. A configuração dos dados é, portanto, caracterizada como uma base de dados desbalanceada, na qual há muito mais dados de uma das classes do que das outras (STEFANOWSKI, 2013).

Muitos estudos lidam com os efeitos de utilizar dados desbalanceados no treinamento de ferramentas de aprendizado de máquina, como no caso das RNAs (SOBHANI; VIKTOR; MATWIN, 2014; CASSIMIRO, 2016; KUBAT; MATWIN S.AND HOLTE, 1997). Os resultados

apontam para treinos ineficientes nesses casos, uma vez que a rede tende a classificar todos os dados como pertencentes à classe com maior quantidade de dados.

Uma alternativa para o problema do desbalanceamento consiste em tratar os dados de maneira a obter um subconjunto de dados consistente, isto é, um conjunto que contenha a informação suficiente e necessária para o treinamento, com características mais balanceadas.

As técnicas de balanceamento de dados são divididas em duas: *Oversampling* e *Undersampling* (CASSIMIRO, 2016). As primeiras consistem em aumentar a quantidade de amostras das classe minoritárias, isto é, com menos quantidades de amostras. As segundas consistem em diminuir a quantidade de dados das classes majoritárias, isto é, com mais quantidades de amostras.

Os dados utilizados no presente trabalho foram balanceados com o objetivo de otimizar o treinamento das RNAs. As amostras das classes minoritárias passaram por um processo de *Oversampling*, enquanto as amostras da classe majoritária passaram por um processo de *Undersampling*.

A técnica utilizada para os dados minoritários foi o *Random Oversampling* (GARCIA; HAIBO, 2012) em que os exemplares da classe minoritárias são replicados aleatoriamente.

Quanto à técnica de *Undersampling*, se faz necessário utilizar de artifícios mais rebuscados para evitar a perda de dados crucias para o treinamento eficiente das RNAs e de sua capacidade de generalização. Com este objetivo, a técnica utilizada foi o *OSS*. Esta técnica foi criada por Kubat e Matwin S. and Holte (1997) e teve a sua eficiência para o balanceamento de dados utilizados para o treinamento de RNAs provadas por (CASSIMIRO, 2016).


O método *OSS* visa reduzir a quantidade de dados da classe majoritária excluindo os dados redundantes, os ruidosos e os limítrofes. As amostras ruidosas, são oriundas de erros na coleta dos dados, enquanto as amostras limítrofes apresentam características muito próximas de amostras de outras classes e, portanto, podem levar a um treinamento ineficiente das redes. Os dados redundantes são aqueles que apresentam características muito semelhantes, de maneira que podem ser desconsiderados em sua maioria, sem que haja prejuízo no aprendizado (KUBAT; MATWIN S. AND HOLTE, 1997; SOBHANI; VIKTOR; MATWIN, 2014). O pseudo algoritmo na tabela 12 resume o método de undersampling *OSS*.

Ligações Tomek são definidas a seguir: deixe e_i e e_j serem duas amostras de classes diferentes. Deixe d ser uma função distância entre os dois exemplos. Um par de amostras (e_i, e_j) é uma ligação Tomek se não existe um exemplo e_k em que $d(e_k, e_i) < d(e_i, e_j)$ ou $d(e_k, e_j)$

$< d(e_i, e_j)$. Ligações Tomek são conhecidamente amostras próximas a curvas de decisão ou amostras ruidosas (KUBAT; MATWIN S.AND HOLTE, 1997).


As figuras 21 e 22 apresentam uma base de dados com duas classificações, sendo uma minoritária(+) e uma majoritária (.). A figura 21 apresenta a base de dados completa, enquanto a figura 22 apresenta a base de dados após o tratamento:

Figura 21 – Dados Não Balanceados



Fonte – (CASSIMIRO, 2016).

Figura 22 – Dados Balanceados



Fonte – (CASSIMIRO, 2016).

Tabela 12 – Algoritmo OSS.

Algoritmo OSS

- 1. Deixe S ser a base de dados original**
 - 2. Inicialmente, um subconjunto C contém todas as amostras minoritárias de S e uma amostra majoritária aleatoriamente escolhida**
 - 3. Classifique S com a regra do 1º Vizinho mais Próximo usando as amostras em C e compare as classificações com as classes corretas.
Mova todas as amostras classificadas erroneamente para C.**
 - 4. Remova de C todos os exemplos majoritários que representem ligações Tomek. Isso remove todas as amostras teoricamente ruidosas e limítrofes.
Todas as amostras minoritárias são mantidas.
O subconjunto T deve ser utilizado para treinamento.**
-
-

A Base de dados resultante da aplicação dos algoritmos é exposta no Capítulo 5.

4.2 Treino e Teste das RNAs

Os dados balanceados foram usados para treinar e testar as RNAs. As concentrações dos gases em ppm foram utilizadas como entradas das redes: hidrogênio (H_2), oxigênio (O_2), nitrogênio (N_2), metano (CH_4), monóxido de carbono (CO), dióxido de carbono (CO_2), etileno (C_2H_4), etano (C_2H_6) e o acetileno (C_2H_2), totalizando nove entradas. Como em Wang, Vandemaar e Srivastava (2002), uma classificação em duas etapas foi realizada.

Primeiramente, os dados foram expostos a uma rede binária que classifica a amostra como um óleo satisfatório ou não satisfatório. Em seguida, o óleo não satisfatório foi exposto a uma rede que aponta a ação a ser tomada para a recuperação do óleo: Regenerar, Recondicionar ou Aditivar. Todos os diagnósticos foram baseados nas conclusões das análises fornecidas pela empresa especialista, que serviram como referências para o treino da rede.

Os dados foram utilizados para treinar e testar as Redes MLP com algoritmo *Back-propagation* (MLP-BP), MLP com algoritmo *Levenberg-Marquardt* (MLP-LM), RBF, ELM e KSOM. As amostras do óleo foram também diagnosticadas de acordo com o método tradicional, que utiliza as propriedades físico-químicas, sintetizada por WEG (2004) através das Tabelas 3 e 4, expostas na seção 2.3 para fins de comparação.

Antes do treinamento das redes, os dados foram embaralhados e divididos em 70% para treino e 30% para teste. Esse processo foi repetido 30 vezes, em uma tentativa de expor o maior número possível dos dados à rede na etapa de teste.

Os parâmetros das redes foram testados heurísticamente, elas foram treinadas e testadas com diferentes configurações em termos de quantidades de neurônios na camada escondida, funções de ativação, número de épocas de treinamento e normalização das entradas. Os parâmetros que levaram às melhores classificações foram utilizados.

As redes e suas diferentes configurações foram analisadas em termos da acurácia das classificações na etapa de testes, de acordo com a Equação 4.1 e das Matrizes de Confusão.

$$Acerto = \frac{Nc}{Nt} \quad (4.1)$$

Em que Nc é o número de dados classificados corretamente e Nt é o número total de dados com aquela classificação.

Uma vez que o processo de treino e teste de cada rede foi realizado trinta vezes, a média das matrizes de confusão foi analisada, bem como o valor máximo, mínimo, médio e o desvio padrão das taxas de acerto.

As Matrizes de Confusão foram organizadas de maneira que as classificações corretas estão dispostas nas linhas da matriz e as classificações realizadas pelas redes, nas colunas da mesma. Os valores da matriz são porcentagens em relação ao valor total de dados utilizados no teste, 160 casos para a classificação binária e 81 dados para a classificação não binária. Para o caso da Rede Binária, que divide o óleo satisfatório do óleo não satisfatório, foi levada em consideração para a avaliação da rede, além da acurácia a porcentagem de falsos positivos e falsos negativos, ambas são classificações erradas da RNA. A primeira, classifica um óleo não satisfatório, como satisfatório. A segunda classifica um óleo satisfatório como não satisfatório. É importante perceber, que o primeiro erro é mais grave, visto que sugere ao operador que um óleo está em plenas condições de desempenhar suas funções, quando na verdade o mesmo necessita de tratamento. Esta sugestão é perigosa, visto que manter o óleo ruim em um transformador em operação pode causar a evolução de falhas internas no transformador podendo desencadear faltas como curto circuito ou formação de arcos internos ao equipamento.

4.3 Estudo de Caso

Para analisar mais a fundo a classificação realizada pelas RNAs, uma série de 160 dados (30% da base de dados total) foi submetida à RNA com melhor desempenho, previamente treinada com outros dados. Os dados foram comparados um a um, em termos do diagnóstico realizado pela rede, pelo especialista e pela recomendação da WEG. A quantidade de dados em que os diagnósticos foram os mesmos e a quantidade de dados em que os diagnósticos foram distintos, foi então analisada.

5 RESULTADOS E DISCUSSÕES

Os resultados dos processos de balanceamento dos dados, de treino e teste das redes neurais e do estudo de caso são expostos e discutidos a seguir, nas Seções 5.1, 5.2 e 5.3.

5.1 Dados Balanceados

Após a aplicação dos algoritmo OSS e ENN, e da replicação aleatória dos dados das classes minoritárias, o resultado foi uma base de dados com 534 amostras, classificados como mostra a Tabela 13.

Tabela 13 – Dados Balanceados

Satisfatório	275	51%
Regenerar	133	24%
Recondicionar	51	14%
Aditivar	76	9%

Percebe-se que há uma distribuição dos dados balanceada, com relação à classificação binária: 51 % dos dados Satisfatórios e 49% dos dados não satisfatórios; e que há uma quantidade mais representativa das classes minoritárias, em relação à quantidade total de amostras, na classificação não binária das amostras não satisfatórias.

Esta base de dados foi utilizada para o treino e teste das RNAs e a eficiência do balanceamento será observada mediante a eficiência no treinamento das redes e em sua consequente capacidade de classificar corretamente os dados na etapa de teste.

5.2 Treino e Teste das Redes

A Tabela 14 apresenta os parâmetros para cada rede, que levaram às melhores taxas de acerto (ou acurácia). Detalhes sobre todos os parâmetros testados são dados no Apêndice A. Em todas as redes, 20 neurônios foram utilizados na camada escondida.

5.2.1 Classificação Binária

A classificação das amostras entre óleo satisfatório e não satisfatório foi realizada inicialmente. As taxas de acerto para cada RNA na etapa de teste, bem como as Matrizes de Confusão para cada classificação são analisadas a seguir.

Tabela 14 – Parâmetros das Redes Neurais Artificiais

	Normalização das Entradas	K	Função de Ativação	Épocas de Treino
MLP-BP	Linear	-	Logística	3000
ML-LM	Linear	-	Logística	500
ELM	Linear	-	Tangente Hiperbólica	-
RBF	Linear	-	-	3000
K-SOM	Estatística	3	-	300

A Tabela 15 apresenta a média das 30 matrizes de confusão obtidas para a Rede MLP treinada com o algoritmo *BP*, enquanto a Tabela 16 apresenta os dados estatísticos relacionados às taxas de acerto obtidas.

Tabela 15 – Matriz de Confusão para a Classificação Binária do Óleo - Rede MLP-BP

	Satisfatório	Não Satisfatório
Satisfatório	30%	22%
Não Satisfatório	11%	37%

Tabela 16 – Taxas de Acerto para a Classificação Binária do Óleo - Rede MLP-BP

Taxas de Acerto	
Média	67%
Máxima	74%
Mínima	60%
Desvio Padrão	3,82%

Observa-se que a taxa de acerto médio para as 30 realizações é de 67%. Destaca-se ainda que houveram 11% das amostras, em média, foram classificadas como falsos negativos.

A Tabela 17 apresenta a média das 30 matrizes de confusão obtidas com a aplicação da Rede MLP treinada com LM, enquanto a tabela 18 apresenta os dados de taxa de acerto.

Tabela 17 – Matriz de Confusão para a Classificação Binária do Óleo - Rede MLP-LM

	Satisfatório	Não Satisfatório
Satisfatório	38%	14%
Não Satisfatório	10%	38%

Observa-se que a taxa de acerto médio para as 30 realizações é de 76%. Destaca-se ainda que houveram 10% de classificação de falsos negativos.

A Tabela 19 apresenta a média das 30 matrizes de confusão obtidas com a rede ELM, enquanto a Tabela 20 apresenta as taxas de acerto para a classificação utilizando esta rede.

Tabela 18 – Taxas de Acerto para a Classificação Binária do Óleo - Rede MLP-LM

Taxas de Acerto	
Média	76%
Máxima	83%
Mínima	67%
Desvio Padrão	5,08%

Tabela 19 – Matriz de Confusão para a Classificação Binária do Óleo - Rede ELM

	Satisfatório	Não Satisfatório
Satisfatório	38%	16%
Não Satisfatório	15%	31%

Tabela 20 – Taxas de Acerto para a Classificação Binária do Óleo - Rede ELM

Taxas de Acerto	
Média	69%
Máxima	75%
Mínima	64%
Desvio Padrão	4,01%

Destacam-se um acerto médio de 69% e uma classificação de falsos negativos de 15% dos dados.

A Tabela 21 apresenta a média das 30 matrizes de confusão obtidas com a utilização da rede *RBF*, enquanto a tabela 22 apresenta as taxas de acerto para a classificação utilizando esta rede.

Tabela 21 – Matriz de Confusão para a Classificação Binária do Óleo - Rede RBF

	Satisfatório	Não Satisfatório
Satisfatório	39 %	14%
Não Satisfatório	12%	34%

Tabela 22 – Taxas de Acerto para a Classificação Binária do Óleo - Rede RBF

Taxas de Acerto	
Média	73%
Máxima	82%
Mínima	60%
Desvio Padrão	4,31%

Observa-se que em média 73% dos dados foram classificados corretamente e que 12% dos dados foram classificados como falsos negativos.

A Tabela 23 apresenta a média das 30 matrizes de confusão obtidas para a classificação binária utilizando a rede *KSOM*, enquanto a Tabela 24 apresenta as taxas de acerto.

Tabela 23 – Matriz de Confusão para a Classificação Binária do Óleo - Rede KSOM

	Satisfatório	Não Satisfatório
Satisfatório	31%	21%
Não Satisfatório	20%	27%

Tabela 24 – Taxas de Acerto para a Classificação Binária do Óleo - Rede K-SOM

Taxas de Acerto	
Média	58%
Máxima	68%
Mínima	47%
Desvio Padrão	5,46%

Conforme exposto, a média de acerto é de 58% para a rede KSOM e 20% dos dados são falsos positivos.

A Tabela 25 apresenta a matriz de confusão da aplicação do método WEG para diagnóstico da qualidade do óleo descrito na Seção 2.3 e resumido pelas Tabelas 3 e 4. Uma vez que não há etapa de treino no método, o mesmo foi aplicado em todos os dados, em apenas uma realização, logo não há cálculos de máximo, mínimo, média e desvio padrão das taxas de acerto.

Tabela 25 – Matriz de Confusão para a Classificação Binária do Óleo - Método WEG

	Satisfatório	Não Satisfatório	Inconclusivo
Satisfatório	12%	21%	19%
Não Satisfatório	2%	17%	30%

Da matriz de confusão é possível calcular a taxa de acertos, que foi igual a 29%. Percebe-se ainda que para muitos dados, 49%, a aplicação direta do método WEG não levou a nenhuma classificação. Destaca-se ainda o percentual de falsos negativos: 2%.

5.2.2 Classificação Não Binária

Posteriormente as RNAs foram treinadas para classificar o óleo não satisfatório quanto à medida a ser tomada para torná-lo apto novamente a desempenhar suas funções: Regenerar, Recondicionar e Aditivar.

A Tabela 26 apresenta a média das matrizes de confusão geradas durante as 30 realizações para a rede MLP BP e a Tabela 27 apresenta as taxas de acerto.

A taxa de acerto médio para a classificação utilizando MLP BP foi de 92% e a taxa máxima foi de 99%.

A Tabela 28 apresenta a média das matrizes de confusão geradas durante as 30

Tabela 26 – Matriz de Confusão para a Classificação Não Binária do Óleo - Rede MLP BP

	Regenerar	Recondicionar	Aditivar
Regenerar	44%	4%	3%
Recondicionar	3%	16%	0%
Aditivar	0%	0%	30%

Tabela 27 – Taxas de Acerto para a Classificação Não Binária do Óleo - Rede MLP BP

Taxas de Acerto	
Média	92%
Máxima	99%
Mínima	85%
Desvio Padrão	3,4%

realizações para a rede MLP treinada com o algoritmo LM e a Tabela 29 apresenta as taxas de acerto.

Tabela 28 – Matriz de Confusão para a Classificação Não Binária do Óleo - MLP LM

	Regenerar	Recondicionar	Aditivar
Regenerar	47%	2%	2%
Recondicionar	4%	17%	0%
Aditivar	0%	0%	29%

Tabela 29 – Taxas de Acerto para a Classificação Não Binária do Óleo - Rede MLP LM

Taxas de Acerto	
Média	94%
Máxima	97%
Mínima	90%
Desvio Padrão	2,5%

A taxa de acerto médio para a classificação utilizando MLP LM foi de 94% e a taxa máxima foi de 97%. Destaca-se o desvio padrão : 2,5%

A Tabela 30 apresenta a média das matrizes de confusão geradas durante as 30 realizações para a rede ELM e a Tabela 31 apresenta as taxas de acerto.

Tabela 30 – Matriz de Confusão para a Classificação Não Binária do Óleo - Rede ELM

	Regenerar	Recondicionar	Aditivar
Regenerar	44%	3%	4%
Recondicionar	6%	15%	0%
Aditivar	4%	0%	25%

A taxa de acerto médio para a classificação utilizando a rede ELM foi de 85% e a taxa máxima foi de 89%. Destaca-se o baixo desvio padrão: 2%

Tabela 31 – Taxas de Acerto para a Classificação Não Binária do Óleo - Rede ELM

Taxas de Acerto	
Média	85%
Máxima	89%
Mínima	82%
Desvio Padrão	2%

A Tabela 32 apresenta a média das matrizes de confusão geradas durante as 30 realizações para a rede RBF e a Tabela 33 apresenta as taxas de acerto.

Tabela 32 – Matriz de Confusão para a Classificação Não Binária do Óleo - Rede RBF

	Regenerar	Recondicionar	Aditivar
Regenerar	48%	3%	1%
Recondicionar	5%	14%	0%
Aditivar	0%	0%	29%

Tabela 33 – Taxas de Acerto para a Classificação Não Binária do Óleo - Rede RBF

Taxas de Acerto	
Média	91%
Máxima	97%
Mínima	86%
Desvio Padrão	2,3%

A taxa de acerto médio para a classificação utilizando a rede RBF foi de 91% e a taxa máxima foi de 97%. Destaca-se o baixo desvio padrão: 2,3%

A Tabela 34 apresenta a média das matrizes de confusão geradas durante as 30 realizações para a rede KSOM e a Tabela 35 apresenta as taxas de acerto.

Tabela 34 – Matriz de Confusão para a Classificação Não Binária do Óleo - Rede KSOM

	Regenerar	Recondicionar	Aditivar
Regenerar	38%	8%	6%
Recondicionar	4%	8%	0%
Aditivar	9%	4%	23%

Tabela 35 – Taxas de Acerto para a Classificação Não Binária do Óleo - Rede KSOM

Taxas de Acerto	
Média	70%
Máxima	83%
Mínima	53%
Desvio Padrão	6,74%

A taxa de acerto médio para a classificação utilizando a rede KSOM foi de 70% e a taxa máxima foi de 84%.

Para fins de comparação, o método WEG foi aplicado para a classificação não binária do óleo não satisfatório. Uma vez que o método não exige treinamento, uma única realização foi necessária para classificar todos os dados, a matriz de confusão obtida está exposta na Tabela 36.

Tabela 36 – Matriz de Confusão para a Classificação Não Binária do Óleo - Método WEG

	Regenerar	Recondicionar	Aditivar	Inconclusivo
Regenerar	14%	0%	0%	39%
Recondicionar	12%	0%	0%	9%
Aditivar	10%	0%	0%	16%

A taxa de acerto da classificação não binária utilizando o método WEG foi de apenas 14% quando comparada ao diagnóstico realizado por especialistas. Destaca-se ainda, a grande quantidade de dados em que, aplicar diretamente as recomendações do método não leva a nenhuma conclusão: 64%.

5.2.3 *Análise do Desempenho das Redes e Comparação com Trabalhos Semelhantes*

Todas as redes neurais foram analisadas em termos de suas matrizes de confusão e de suas taxas de acerto. As Matrizes de confusão foram organizadas em porcentagens com relação ao número total de amostras utilizadas para teste: 160 amostras para a classificação Binária e 81 amostras para a classificação não Binária.

Convém comparar o desempenho das redes, entre si e com os métodos tradicionais de análise de óleo baseados nas propriedades físico-químicas e ainda, comparar com resultados de outras pesquisas envolvendo Redes Neurais utilizadas para diagnóstico da qualidade do óleo mineral. Nos trabalhos de Mokhnache (2002) e Barbosa (2008), a qualidade do óleo foi diagnosticada a partir de suas propriedades físico-químicas utilizando RNAs, os resultados dessas pesquisas também serão citados aqui para fim de comparação.

Para a classificação binária, as RNAs que obtiveram média de taxa de acerto, para as 30 realizações foram a Rede MLP com BP, RBF e MLP com LM: 67%, 73% 76%, respectivamente. Estas obtiveram também as menores taxas de classificação de falsos positivos: 11%, 12% e 10% respectivamente.

Ao aplicar diretamente o método tradicional, resumido pela fabricante de transformadores WEG (2004) obteve-se uma taxa de acerto de 29%, uma taxa menor que a metade da

acurácia obtida com as RNAs citadas. Observa-se ainda a alta taxa de amostras em que o método não chegou a nenhuma conclusão, 49% dos dados, o que evidencia a necessidade da presença de um especialista para aplicação do método, que utilizando de outras informações e de sua experiência, possa chegar a conclusões mais precisas.

A aplicação do método resulta em uma taxa baixa de falsos positivos, 2%, o que diminui bastante a possibilidade de manter um óleo ruim em transformadores em operação, no entanto, observa-se que em 40 % dos casos o óleo satisfatório foi classificado como não satisfatório ou inconclusivo. Frente a provável cautela de um especialista, que recomendaria o tratamento do óleo em caso de não conclusão, para não correr o risco da ocorrência de falta no equipamento, devido a um diagnóstico falso positivo, o custo de manutenção seria aumentado consideravelmente.

Para a Classificação não Binária, novamente as redes MLP com BP, RBF e MLP com LM obtiveram as maiores taxas de acerto médias: 92%, 91% e 94% respectivamente. O método tradicional recomendado pela WEG, obteve uma taxa de acerto de 14% e uma taxa de não conclusão de 64%. Destaca-se que as Redes tiveram taxas de acerto mais de seis vezes maiores. Ao analisar a matriz de confusão, percebe-se ainda que há uma tendência do método WEG em recomendar o óleo para Regeneração Química, que como explicado na seção 2.3 é o processo mais complexo e caro, o que sugere excesso de cautela implícito no diagnóstico do método.

O método proposto por Mokhnache (2002) consiste em fornecer como entrada para uma RNA MLP os dados físico-químicos cor, viscosidade, acidez, rigidez dielétrica, tangente de perdas e teor de água e treiná-la de maneira que a saída seja o diagnóstico da qualidade do óleo, entre: Descartar, Regenerar, Recondicionar e Manter (óleo satisfatório).

Em seus melhores resultados, Mokhnache diagnosticou corretamente 100 por cento dos dados utilizados para teste. No entanto, foram utilizados apenas 5 amostras para treino e 5 amostras para teste, um número da ordem de 1% do número de amostras utilizadas no presente trabalho.

Barbosa (2008) diagnosticou a qualidade de 102 amostras de óleo através de redes MLP e RBF utilizando 5 parâmetros físico químicos com entradas das redes: a acidez, a rigidez dielétrica, a densidade e o fator de potência. Os diagnósticos obtidos nas saídas das redes foram: regenerar, recondicionar, reamostrar imediatamente, reamostrar em um ano. Os melhores resultados obtidos por Barbosa (2008) são um acerto de 100% para a rede MLP LM e 95% para

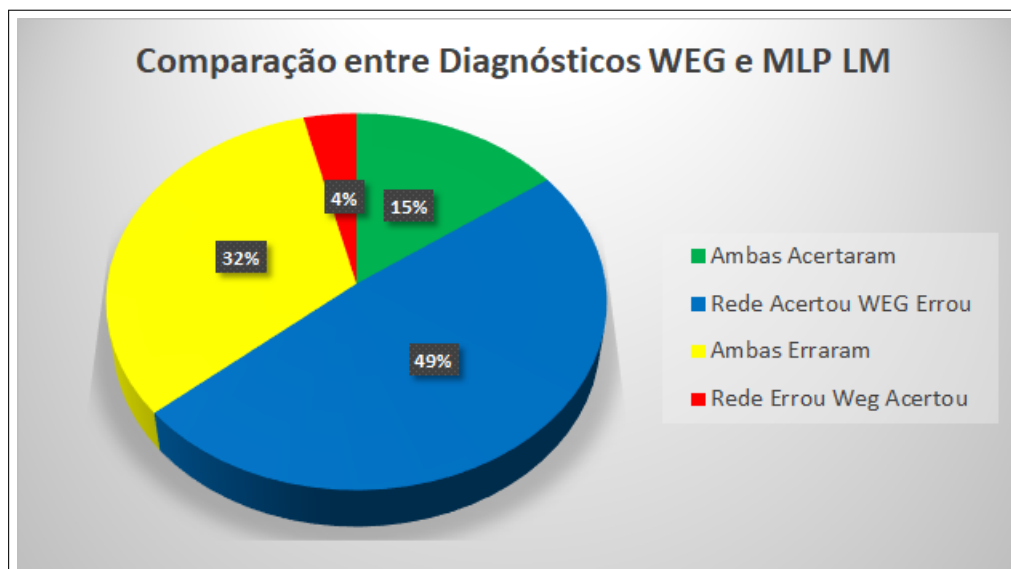
a rede RBF, resultados ligeiramente melhores dos obtidos neste trabalho.

É pertinente salientar, que diferentemente dos trabalhos de Mokhnache e Barbosa, através da ferramenta proposta nesta pesquisa, o diagnóstico da qualidade do óleo é obtido, de maneira inovadora, através das concentrações dos gases obtidos por cromatografia, que são tradicionalmente utilizados para a identificação de falhas incipientes em transformadores.

5.3 Estudo de Caso

Dos 534 dados utilizados no trabalho, 160 foram escolhidos aleatoriamente para que fossem classificados tanto pelas recomendações da WEG, quanto pela ferramenta proposta. A rede que teve melhor desempenho na etapa de treino e teste, descrita anteriormente foi escolhida para a comparação. Como observado na seção anterior, a rede *MLP* treinada com *LM* teve um desempenho ligeiramente maior que a rede RBF e *MLP* treinada com *BP*, que foram as três redes com melhor desempenho. A rede foi treinada com os outros 374 dados que não foram utilizados para a análise. A figura 23 apresenta a distribuição dos dados quanto as classificações de cada método.

Figura 23 – Comparação entre as classificações através do método da WEG e através da ferramenta proposta utilizando *MLP LM*



Fonte – Autor

A rede foi utilizada tanto para classificar como satisfatório ou não satisfatório e quanto à medida a ser tomada para o óleo não satisfatório, se regeneração, recondicionamento

ou aditivação. A composição da saída das duas classificações foi utilizada para completar o diagnóstico de cada amostra. O Anexo B apresenta os dados e as classificações obtidas para a aplicação de cada método. Ao analisar a figura, percebe-se que, em 49% dos dados ou seja 79 dados a Rede *MLP LM* classificou corretamente a qualidade da amostra de óleo, enquanto a aplicação do método WEG levou a um diagnóstico diferente do correto, dado pelo especialista. Em 15 % dos dados, totalizando 24 dados, ambas as classificações levaram ao diagnóstico correto. Em 32% dos dados (51 dados), ambas as classificações foram diferentes da classificação dada pelo especialista. Apenas em 4% dos dados, ou seja, 7 dados, a classificação da WEG foi correta, enquanto a classificação da rede foi diferente daquela dada pelo especialista.

É possível inferir portanto, que o método proposto classificou corretamente 64% dos casos, destes em sua maioria (77%), a aplicação direta do método tradicional de diagnóstico levou a um diagnóstico errado. Destaca-se também que para os 36% das amostras em que o método proposto levou a uma classificação errada,, na maioria (88%) dos casos a aplicação dos métodos tradicionais também levou a um diagnóstico errado.

6 CONCLUSÕES E TRABALHOS FUTUROS

O presente trabalho visou utilizar diferentes Redes Neurais Artificiais para diagnosticar a qualidade do óleo mineral isolante de Transformadores de Potência a partir das concentrações de gases dissolvidos neste óleo em uma classificação de dois passos. Primeiramente, um classificação utilizando RNA foi utilizada para separar o óleo satisfatório do óleo não satisfatório. Em seguida, o óleo não satisfatório foi classificado quanto à medida a ser tomada para torná-lo utilizável novamente: regeneração química, recondicionamento ou aditivação.

Tradicionalmente, o diagnóstico do óleo é realizado a partir da análise das propriedades físico-químicas do mesmo. Esse processo no entanto, demanda a realização de vários testes distintos em laboratório e a análise de grande quantidade de normativos, que em certas situações, levam a resultados inconclusivos. O método proposto visa constituir-se em uma alternativa a estes métodos tradicionais, possibilitando a obtenção do diagnóstico, a partir das concentrações dos gases dissolvidos, que já são utilizadas tradicionalmente para outros propósitos.

A utilização da técnica proposta visa diminuir o custo da manutenção de Transformadores de Potência, uma vez que diminuiria a necessidade de testes físico-químicos em laboratório, além de promover conclusões mais precisas devido à internalização do conhecimento de especialistas inerentes aos dados utilizados para o treino das redes neurais.

Uma base de dados contendo as concentrações de gases e as propriedades físico-químicas de mais de 150 Transformadores de Potência em Operação no sistema elétrico brasileiro, colhidos ao longo de mais de 30 anos foi utilizada.

As Redes *MLP* treinadas com *Backpropagation* e com *Levenberg-Marquardt*, a Rede *RBF* com a rede SOM como algoritmo de quantização, a rede ELM e a rede K-SOM foram testadas para desenvolver a tarefa proposta. As taxas de acerto na classificação do óleo, em relação ao diagnóstico feito por especialistas, foi utilizado para testar as redes e compará-las com a eficiência do diagnóstico utilizando os métodos tradicionais.

Todas as redes apresentaram taxa de acerto maior do que a taxa obtida com a utilização de métodos tradicionais. As redes, MLP-BP, RBF-SOM MLP-LM e apresentaram maior taxa de acerto, 67% ,73% e 76%, respectivamente para uma rede que separa o óleo satisfatório do óleo não-satisfatório e 92%, 91% 94% para uma rede que recomenda ações para tornar o óleo utilizável novamente. Os métodos tradicionais em contra-partida apresentaram taxas de acerto de 29% para a rede binária e 14% para a rede não-binária, o que evidencia a ineficiência do procedimento em comparação com o diagnóstico de especialistas.

Um estudo de caso com 160 amostras foi realizado comparando o desempenho da rede *MLP* treinada com *LM* com a metodologia proposta por esta pesquisa e da aplicação de métodos tradicionais no diagnóstico do óleo. Os resultados obtidos foram relevantes: Em 49% das amostras a rede acertou o diagnóstico enquanto os métodos tradicionais levaram a um diagnóstico errado. Em 15% dos casos ambas acertaram, em 32% ambas erraram e em apenas 4% a rede *MLP* errou o diagnóstico enquanto os métodos tradicionais levaram ao diagnóstico correto. Esses resultados demonstram, que na maioria dos casos a rede teve melhor desempenho que os métodos tradicionais e que na maioria dos casos em que a rede errou o diagnóstico, a aplicação dos métodos tradicionais também levou ao erro.

Os resultados apontam para a relevância e para uma característica promissora do método proposto. O mesmo pode servir como uma alternativa aos métodos tradicionais ou mesmo servir como mais uma ferramenta que propicie a tomada de decisão embasada dos operadores, em adição aos métodos tradicionais.

6.1 Trabalhos Futuros

Algumas sugestões de trabalhos futuros são fornecidos para o desenvolvimento do presente trabalho e consolidação da ferramenta proposta:

- A aplicação de comitês de classificadores, com o objetivo de obter melhores taxas de acerto e soluções mais conservadoras.
- A aplicação do método em transformadores que utilizam óleos isolantes com fontes alternativas, como os óleos vegetais e óleos a base de Éster
- A aplicação de técnicas híbridas de inteligência computacional, como algoritmos evolutivos e lógica fuzzy em adição às Redes Neurais para aumentar as taxas de acerto obtidas.

REFERÊNCIAS

- ABDI, S.; BOUBAKEUR, A.; HADDAD, A. Influence of thermal ageing on transformer oil properties. *IEEE International Conference on Dielectric Liquids*, p. 1–4, 2008.
- AGUIRRE, L. A. **Introduction to Systems Identification: Linear and Nonlinear Techniques applied to real systems**. [S.l.]: Publisher of UFMG, 2007.
- AMERICAN SOCIETY FOR TESTING AND MATERIAL. **ASTM D-971-91**: Standard test method for interfacial tension of oil against water by the ring method. [S.l.], 1991.
- ANTONIO, A. C. F.; IVAN, N. d. S.; ANDRE, N. d. S. Aplicação de redes neurais na estimação da temperatura interna de transformadores de distribuição imersos em óleo. **Sba Controle E Automação**, v. 13, n. 3, 2002.
- BACHA, K.; S.; GOSSA, M. Power transformer fault diagnosis based on dissolved gas analysis by support vector machine. **Power Systems Research**, v. 83, p. 73–79, 2012.
- BARBOSA, F. **Monitoramento Online e Diagnóstico Inteligente da qualidade dielétrica do óleo de Transformadores de Potência**. Dissertação (Mestrado) — Universidade Federal do Ceará, Fortaleza, 2008.
- BARBOSA, F. *et al.* Application of an artificial neural network in the use of physicochemical properties as a low cost proxy of power transformers dga data. **IEEE Transactions on Dielectrics and Electrical Insulation**, IEEE, v. 16, n. 1, p. 239–246, 2012.
- BARBOSA, F. R. **Diagnóstico de Falhas Incipientes a partir das Propriedades Físico-Químicas do Óleo Isolante de Transformadores de Potência Como uma Alternativa a Análise de Gases Dissolvidos**. Tese (Doutorado) — Universidade Federal do Ceará, Fortaleza, 2013.
- BARRETO, G.; SOUZA, L. On building local models for inverse system identification with vector quantization algorithms. **Neurocomputing**, v. 73, n. 10-12, p. 1993–2005, 2010.
- CAO, F.; XIE, t.; XU, Z. The estimate for approximation error of neural networks: A constructive approach. **Neurocomputing**, v. 71, n. 4-6, p. 626–630, 2008.
- CASSIMIRO, J. C. **Investigation of the Effects of Class Imbalance on the Learning of Regulation of Health Plans**. Dissertação (Mestrado) — Universidade Federal do Piauí, 2016.
- CHENXI, D.; LIU, Z.; CUI, Y. The transformer fault diagnosis combing kpca with pnn. In: INTERNATIONAL JOINT CONFERENCE ON NEURAL NETWORKS (IJCNN). The address of the publisher, 2014.
- DARKEN, C.; MOODY, J. Fast adaptive k-means clustering: Some empirical results. **Proceedings of the International Joint Conference on Neural Network (IJCNN'90)**, v. 2, p. 233–238, 1990.
- DERVOS, C. T. *et al.* Characterization of power transformer oils as a diagnostic life prediction method. **IEEE Electrical Insulation Magazine**, v. 21, n. 1, p. 11–19, 2005.
- DOBLE, E. C. **Reference Book on Insulating Liquids and Gases**. [S.l.: s.n.], 1993.

- FEIL, D. *et al.* Development of an efficient distribution transformer using amorphous core and vegetable insulating oil. **Electric Power Systems Research**, v. 144, p. 268–275, 2017.
- FERGUSON, R.; LOBEIRAS, A.; SABOU, J. Suspended particles in the liquid insulation of aging power transformers. **IEEE Electrical Insulation Magazine**, v. 18, n. 4, p. 17–23, 2002.
- FOFANA, I. *et al.* Challenge of mixed insulating liquids for use in high-voltage transformers, part 1: Investigation of mixed liquids. **IEEE Electrical Insulation Magazine**, v. 18, n. 3, p. 18–37, 2002.
- GARCIA, E. A.; HAIBO, H. A review on ensembles for the class imbalance problem: Bagging-, boosting-, and hybrid-based approaches. **IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews)**, v. 42, n. 4, p. 463–484, 2012.
- GHANIZADEH, A. J.; GHAREHPETIAN, G. Nn and cross-correlation based features for discrimination between electrical and mechanical defects and their localization in transformer winding. **IEEE Transactions on Dielectrics and Electrical Insulation**, v. 21, n. 5, p. 2374–2382, 2014.
- HALSTEAD, W. A. Thermodynamic assessment of the formation of gaseous hydrocarbons in faulty transformers. **Journal Institute of Petroleum**, v. 59, n. 9, p. 239–241, 1973.
- HAYKIN, S. **Neural Nets, Principle and Practice**. 2. ed. Porto Alegre: Ed. Bookman, 2001.
- HEBB, D. O. **The Organization of Behavior**. New York, NY: John Wiley,, 1949.
- HORNIK, K.; STINCHCOMBE, M.; WHITE, H. Multilayer feedforward networks are universal approximators. **Neural Networks**, v. 359-369, p. 359–368, 1989.
- HUANG, G. B.; ZHU, Q. Y.; ZIEW, C. K. Extreme learning machine: Theory and applications. **Neurocomputing**, v. 1-3, n. 70, p. 489–501, 2006.
- HYDROELECTRIC RESEARCH, T. S. G.; UNITED STATES, D. O. T. I. B. O. R. **Transformer Diagnostics, Facilities Instructions, Standards, And Techniques**. [S.l.: s.n.], 2003.
- INSTITUTE OF ELECTRICAL AND ELECTRONICS ENGINEERING. **IEEE C57.104-1991**: Ieee guide for the interpretation of gases generated in oil-immersed transformers. [S.l.], 2008.
- JAIN, A.; JIANCHANG, M.; MOHIUDDIN, K. Method for the solution of certain non-linear problems in least squares. **Quarterly of Applied Mathematics**, v. 2, n. 2, 1944.
- JAIN, A.; JIANCHANG, M.; MOHIUDDIN, K. Artificial neural networks: a tutorial. **Computer**, v. 29, 1996.
- KOHONEN, T. Clustering, taxonomy and topological maps of patterns. In: PROCEEDINGS OF THE 6TH INTERNATIONAL CONFERENCE ON PATTERN RECOGNITION. **IEEE Computer Soc. Press**. Washington DC:, 1982. p. 114–128.
- KUBAT, M.; MATWIN S.AND HOLTE, R. Learning when negative examples abounds. In: 9TH EUROPEAN CONFERENCE ON MACHINE LEARNING, ECML. Prague, Czech Republic, 1997. v. 1224, p. 146–153.

- LIPSHTEIN, R. A.; SHAICHNOVICH, M. I. **Transformer Oil**. 2. ed. Jerusalém Israel: Program, for Scientific Translations, 2, 1970.
- LUIZ, E. F.; RUTH, M. C. S. Propriedades de óleos isolantes de transformadores e a proteção do meio ambiente. In: . Porto Alegre, RS: [s.n.], 2006.
- MACQUEEN, J. Some methods for classification and analysis of multivariate observations. In: UNIVERSITY OF CALIFORNIA). **Proceedings of the Fifth Berkeley Symposium on Mathematical Statistics and Probability**. Berkeley, CA, 1967. p. 281–297.
- MARIPRASATH, T.; KIRUBAKARAN, V. A critical review on the characteristics of alternating liquid dielectrics and feasibility study on pongamiapinnata oil as liquid dielectrics. **Renewable and Sustainable Energy Reviews**, v. 65, 2016.
- MARQUARDT, D. W. An algorithm for least-squares estimation of nonlinear parameters. **SIAM Journal on Applied Mathematics**, v. 11, n. 12, p. 431–441, 1963.
- MCCULLOCH, W. S.; PITTS, W. A logical calculus of the ideas immanent in nervous activity,. 1943.
- MCWHINTER, J. H.; TEAGUE, W. L. Dielectric measurements on new power transformer insulation. **AIEE Transformers Committee and approved by the AIEE Technical Program Committee for presentation at the AIEE Summer General Meeting, Minneapolis**, 1952.
- MENEZES, J. **Contribuições ao Problema de Predição Recursiva de Séries Temporais Univariadas Usando Redes Neurais Recorrentes**. Tese (Doutorado) — Universidade Federal do Ceará, Fortaleza, 2012.
- MENG, K. *et al.* A self-adaptive rbf neural network classifier for transformer fault analysis. **IEEE TRANSACTIONS ON POWER SYSTEMS**, v. 25, n. 3, 2010.
- MILASCH, M. **Maintenance of Insulating Liquid Transformers**. 6. ed. São Paulo SP: Edgar Blücher, 1984.
- MING, J.; YU, C. A pragmatic approach to diagnose on transformer's insulating oil with gas pattern. **International Symposium on Computer, Consumer and Control**, 2014.
- MOKHNACHE, L. Comparison of different back-propagation algorithms used in the diagnosis of transformer oil. **Annual Report Conference on Electrical Insulation and Dielectric Phenomena**, 2002.
- MOODY, J. E.; DARKEN, C. Fast learning in networks of locally-tuned processing units. **Neural Computation**, v. 1, p. 281–294, 1989.
- PALMER, J. A. *et al.* Effect of aging on the spectral response of transformer oil. **Conference Record of the 2000 IEEE International Symposium on Electrical Insulation**, Anaheim, CA USA, 2000.
- PANDEY, D. R. M. T. Dissolved gas analysis (dga) of mineral oil used in transformer. **International Journal of Application or Innovation in Engineering And Management (IJAEM)**, v. 1, p. 208–212, 2012.
- PARRISH, R.; KELLY, J.; MYERS, S. **A Guide to Transformers Maintenance**. [S.l.]: Transformer Maintenance Institute, 1981.

PEIMANKARA, A. *et al.* Evolutionary multi-objective fault diagnosis of power transformers. **Swarm and Evolutionary Computation**, p. 62–75, 2017.

PRINCIPE, J. C.; EULIANO, N. R.; LEFEBVRE, W. C. **Neural Adaptive Systems: Fundamentals Through Simulations**. New York NY: John Wiley And Sons, 2000.

RANGANATHAN, A. The levenberg-marquardt algorithm. 2004.

ROSENBLATT, F. Two theorems of statistical separability on the perceptron. proceedings of a symposium on the mechanisation of thought processes. **Her Majesty's Stationary Office**, p. 421–456, 1959.

RUMMELHART, D.; HINTON, W. Learning internal representations by error propagation. **Parallel Distributed Processing**, 1986.

SETAYESHMEHR, A. *et al.* Dielectric spectroscopic measurements on transformer oil-paper insulation under controlled laboratory conditions. **IEEE Transactions on Dielectrics and Electrical Insulation**, v. 15, n. 4, p. 1100–1111, 2008.

SOBHANI, P.; VIKTOR, H.; MATWIN, S. Learning from imbalanced data using ensemble methods and cluster-based undersampling. In: SPRINGER INTERNATIONAL PUBLISHING, (LECTURE NOTES IN COMPUTER SCIENCE). **New Frontiers in Mining Complex Patterns**. Washington, DC:, 2014. p. 69–83.

SOUZA, L. **Moldelos Locais Lineares Para Identificação de Sistemas Utilizando Redes Neurais Competitivas**. Tese (Doutorado) — Universidade Federal do Ceará, Fortaleza, 2012.

STANDARTS, I. **IEC 60599: Mineral Oil-Impregnated Electrical Equipment in Service - Guide to the Interpretation of Dissolved and Free Gases Analysis**. 2. ed. Geneva, Switzerland: IEC, 1999.

STEFANOWSKI, J. Overlapping rare examples and class decomposition in learning classifiers from imbalanced data. **Emerging Paradigms in Machine Learning**. [S.l.]: Springer Berlin Heidelberg, (Smart Innovation, Systems and Technologies), p. 277–306, 2013.

TANEJA, M. S.; PANDEY, K.; SEHWAT, S. A. Review on prognosis and diagnosis of transformer oil quality using intelligent techniques based on dissolved gas analysis. In: 7TH INDIA INTERNATIONAL CONFERENCE ON POWER ELECTRONICS (IICPE). **New Frontiers in Mining Complex Patterns**. [S.l.], 2016.

TUSONGJIANG, K. *et al.* An integrated method of anfis and dempster-shafer theory for fault diagnosis of power transformer. **IEEE Transactions on Dielectrics and Electrical Insulation**, v. 25, n. 1, 2018.

VERAS, G. V. O. *et al.* Diagnóstico da qualidade do Óleo isolante de transformadores de potencial a partir da concentração de gases dissolvidos. **XIII Simpósio Brasileiro de Automação Inteligente**, Porto Alegre, 2017.

WANG, M.; VANDEMAAR, A. J.; SRIVASTAVA, K. D. Review of condition, assessment of power transformers in service. **IEEE Electrical Insulation Magazine**, v. 18, n. 6, p. 12–25, 2002.

WEG. **Manual de Instalação e Manutenção de Transformadores**. Rio de Janeiro, 2004.

WIDROW, B.; HOFF, M. E. **Adaptive Switching Circuits**. [S.l.], 1960.

ZARKOVIĆ, M.; STOJOVIĆ, Z. Analysis of artificial intelligence expert systems for powertransformer condition monitoring and diagnostics. **Electric Power Systems Research**, v. 149, p. 125–135, 2017.

ZHANG, Y. **An Artificial Neural Network Approach to Transformer Fault Diagnosis**. Tese (Doutorado) — Virginia Tech, Virginia, Blacksburg, USA, 1996.

ZIRBES, R.; ROLIM, J. G.; ZURN, H. H. Methodologies for assessment and diagnosis of state of paper insulation impregnated with mineral oil. **SBA Control And Automation**, v. 16, n. 3, p. 318–331, 2005.

APÊNDICE A – APÊNDICE A: PARÂMETROS DAS REDES NEURAIAS

No Projeto de uma Rede neural, alguns fatores são relevantes na velocidade convergência do algoritmo de aprendizagem, na capacidade de generalização e na eficiência da utilização da rede de um modo geral. A variação desses parâmetros foi realizada no presente trabalho de maneira heurística, diferentes estratégias foram utilizadas na busca daquelas que acarretavam nas melhores taxas de acerto, até que um conjunto de parâmetros ideal fosse utilizado. Os principais parâmetros utilizados no presente trabalho no projeto das redes neurais serão discutidos a seguir.

A.1 Critério de Parada

O término do treinamento da rede neural é, em geral avaliado com base no valor da média do erro quadrático, calculado ao final de cada época de treinamento. Uma época de treinamento, consiste em uma vez em que todos os pares de vetores entrada-saída do conjunto de treinamento da rede foram expostos a mesma. O erro quadrático médio ϵ_{med} pode ser obtido pela equação A.1:

$$\epsilon_{med} = \frac{1}{N} \sum_{t=1}^N \epsilon(n) = \frac{1}{2N} \sum_{t=1}^N e_k^2(n) \quad (A.1)$$

Em que N é o número de Par de Vetores de Treino e k é o número de saídas da rede e e_k é o erro de aproximação da rede dado pela equação 3.12. Neste trabalho, a rede neural é treinada por várias épocas até que um número máximo de épocas permitido seja alcançado.

A.2 Função de Ativação

Para as redes MLP e ELM, as funções utilizadas para a ativação dos neurônios podem ser as Funções Logística, dada pela equação A.2:

$$\varphi(\mu_n) = \frac{1}{1 + \exp(-\mu(n))} \quad (A.2)$$

e Tangente Hiperbólica:

$$\varphi(\mu_n) = \frac{1 - \exp(-\mu(n))}{1 + \exp(-\mu(n))} \quad (A.3)$$

A.3 Normalização das Entradas

Antes de apresentar os dados de treinamento à RNA, é comum mudar a escala original dos componentes dos vetores de entrada e de saída para as escalas das funções de ativação logística (0 e 1) ou da tangente hiperbólica (-1 e 1)(MENEZES, 2012). As transformações mais comumente utilizadas na literatura são as seguintes(HAYKIN, 2001):

- Transformação Linear [0,1]:

$$x_t^* = \frac{x_t - x_{min}}{x_{max} - x_{min}} \quad (\text{A.4})$$

- Normalização estatística:

$$x_t^* = \frac{x_t - \bar{x}}{s} \quad (\text{A.5})$$

em que \bar{x} é a média dos atributos do vetor e s é o desvio padrão dos valores do atributo.

- Transformação Linear Simples [0,1]:

$$x_t^* = \frac{x_t}{x_{max}} \quad (\text{A.6})$$

- Transformação Linear [a,b]:

$$x_t^* = (b - a) \cdot \frac{x_t - x_{min}}{x_{max} - x_{min}} + a \quad (\text{A.7})$$

- Transformação para um caso particular do anterior, quando $a = -1$ e $b = +1$:

$$x_t^* = 2 \cdot \frac{x_t - x_{min}}{x_{max} - x_{min}} - 1 \quad (\text{A.8})$$

A.4 Taxa de Aprendizagem

Como dito no Capítulo 3, a taxa de aprendizagem utilizada na atualização dos pesos dos neurônios é um fator importante para a convergência do algoritmo de treinamento das RNA's. Uma taxa muito alta, pode levar a divergência do valor dos pesos, uma taxa muito baixa causa pouca variação na atualização dos pesos o que torna a atualização muito lenta ou mesmo impede os pesos de chegarem ao valor ideal que cause o mínimo global da função de custo. Valores entre 0,01 e 0,1 são comumente utilizados (HAYKIN, 2001).

Uma taxa de aprendizagem que decaia com o tempo, muitas vezes é o ideal, na impossibilidade de encontrar o valor ideal no intervalo citado. Um decaimento linear pode ser utilizado:

$$\alpha(t) = \alpha_0 \left(1 - \frac{t}{1 + \exp(-t_{max})} \right) \quad (\text{A.9})$$

em que α_0 é o valor inicial da taxa de aprendizagem e t_{max} é o número máximo de iterações, dado por:

$$t_{max} = NXn_{epocas} \quad (\text{A.10})$$

e, que n_{epocas} é o número máximo de épocas. Um decaimento exponencial também pode ser utilizado:

$$\alpha(t) = \frac{\alpha_0}{1+t} \quad (\text{A.11})$$

A.5 Inicialização dos Pesos

Os pesos das camadas escondida w_{ij} e da camada de saída m_{ki} de uma RNA devem ser iniciados de maneira aleatória. Existem duas maneiras comumente utilizadas para iniciá-los, uma uniformemente distribuída no intervalo (a,b):

$$w_{ij} = U(a,b) \quad (\text{A.12})$$

e outra normalmente distribuída com média μ e variância σ^2 :

$$w_{ij} = N(a,b) \quad (\text{A.13})$$

Dados									Classificação Não Binária				Classificação Binária	
H2	O2	N2	CH4	CO	CO2	C2H4	C2H6	C2H2	Satisfatório	Regenerar	Recondicionar	Adicionar	Satisfatório	Não Satisfatório
0,8	1657	11596	0,7	6	58	0,4	0,1	0,1	1	0	0	0	1	0
1	3398	11497	1	12	34	0,2	0,3	0,7	1	0	0	0	1	0
1	4268	6986	0,7	1	23	0,8	0,8	0,4	1	0	0	0	1	0
1	2367	7424	1	31	228	0,2	0,2	5	1	0	0	0	1	0
1	22410	68459	2	111	2234	33	2	11	1	0	0	0	1	0
2	1316	78257	133	209	4580	23	198	0,3	1	0	0	0	1	0
3	12519	57337	5	30	262	0,6	10	0,3	1	0	0	0	1	0
3	3582	16592	8	40	508	1	12	0,2	0	0	1	0	0	1
3	1375	5502	2	21	106	1	0,2	1	1	0	0	0	1	0
3	12519	57337	5	30	262	0,6	10	0,3	1	0	0	0	1	0
4	13120	67288	6	243	2204	30	3	14	1	0	0	0	1	0
4	1231	1901	4	12	28	1	4	0,2	0	0	1	0	0	1
4	5900	84709	16	894	4549	178	12	4	1	0	0	0	1	0
4	4880	33142	2	105	600	0,9	0,6	0,9	1	0	0	0	1	0
5	1796	15410	6	51	745	2	11	0,3	1	0	0	0	1	0
5	3023	57400	64	146	2036	4	93	0,1	1	0	0	0	1	0
6	1629	13235	5	27	325	0,5	5	0,1	1	0	0	0	1	0
6	6185	78767	10	462	3469	41	4	0,8	1	0	0	0	1	0
6	7111	25448	4	24	222	0,5	0,2	0,5	1	0	0	0	1	0
6	1250	54659	13	226	3018	12	6	0,5	1	0	0	0	1	0
6	8688	66690	12	401	2128	85	6	0,9	1	0	0	0	1	0
6	3505	12332	7	35	197	0,8	10	0,2	1	0	0	0	1	0
7	2137	75177	11	288	1962	11	4	2	1	0	0	0	1	0
7	16174	60211	2	387	3148	79	2	1	1	0	0	0	1	0
8	3835	17156	2	190	1026	0,4	0,4	0,1	1	0	0	0	1	0
8	11272	42026	4	76	1225	46	2	26	1	0	0	0	1	0
8	2322	62406	136	271	2040	16	332	0,1	1	0	0	0	1	0
8	1583	84931	107	99	2525	8	304	0,5	1	0	0	0	1	0
8	18755	71827	15	477	4138	127	6	27	1	0	0	0	1	0
8	5343	86204	14	471	4268	18	3	6	1	0	0	0	1	0
8	7470	62367	63	175	867	17	32	1	1	0	0	0	1	0
8	16714	62699	8	586	3938	65	2	19	1	0	0	0	1	0
8	908	71341	10	467	2504	23	3	4	1	0	0	0	1	0
8	13220	72660	2	286	2114	12	0,5	1	1	0	0	0	1	0
8	2237	76881	27	398	3728	37	8	11	1	0	0	0	1	0
8	2839	11407	6	26	370	0,5	10	0,4	1	0	0	0	1	0
9	3301	16797	8	53	373	0,9	10	0,5	1	0	0	0	1	0
9	3043	77532	6	550	4379	53	2	4	1	0	0	0	1	0
9	2044	72498	12	550	3043	36	3	4	1	0	0	0	1	0

9	3696	24621	15	73	1005	3	13	0,2	1	0	0	0	1	0
9	2874	5541	8	21	140	1	10	0,2	1	0	0	0	1	0
9	3113	76178	12	576	2613	32	4	0,2	1	0	0	0	1	0
9	18802	109642	5	430	3733	30	0,8	9	1	0	0	0	1	0
9	11320	71853	9	418	4287	36	4	0,5	1	0	0	0	1	0
9	2044	72498	12	550	3043	36	3	4	1	0	0	0	1	0
10	6253	82583	48	73	867	10	133	2	1	0	0	0	1	0
10	19036	59042	4	657	2840	45	2	14	1	0	0	0	1	0
10	2171	13691	6	48	1097	1	3	0,1	1	0	0	0	1	0
10	36195	144061	2	40	378	26	4	44	0	0	1	0	0	1
10	3594	75489	64	411	2151	9	86	0,4	1	0	0	0	1	0
11	4376	41129	34	47	1566	4	60	0,1	1	0	0	0	1	0
11	4636	82384	23	388	3487	14	12	0,3	1	0	0	0	1	0
11	4868	61884	27	670	3596	122	11	1	1	0	0	0	1	0
11	13492	61958	6	345	2957	27	2	0,3	1	0	0	0	1	0
11	13040	75967	16	465	2386	84	6	0,9	1	0	0	0	1	0
12	1110	11156	13	64	538	0,6	14	0,1	1	0	0	0	1	0
12	4131	77221	52	405	1160	31	56	0,1	0	1	0	0	0	1
12	9929	97737	16	302	5699	56	4	1	1	0	0	0	1	0
12	700	15653	14	77	804	2	10	0,1	1	0	0	0	1	0
12	9029	79743	17	388	2425	18	10	3	1	0	0	0	1	0
12	25020	65007	4	280	3738	69	4	20	1	0	0	0	1	0
12	23272	74034	6	626	4878	61	4	17	1	0	0	0	1	0
13	8707	64617	8	434	1764	56	2	0,3	1	0	0	0	1	0
13	9206	79596	22	102	1488	7	56	0,3	1	0	0	0	1	0
13	15038	102953	35	830	4668	175	16	1	1	0	0	0	1	0
13	2607	79709	10	548	4661	58	3	2	1	0	0	0	1	0
13	2783	87058	15	383	4093	11	4	2	1	0	0	0	1	0
13	24776	72793	5	227	2455	40	10	11	1	0	0	0	1	0
13	6074	83485	14	474	4078	18	4	9	1	0	0	0	1	0
13	21592	58276	2	138	1199	19	0,4	0,7	1	0	0	0	1	0
14	2855	39698	14	56	648	4	26	2	1	0	0	0	1	0
14	7963	85926	28	476	2928	26	15	10	0	1	0	0	0	1
14	2161	26856	16	80	550	0,6	19	0,1	1	0	0	0	1	0
14	5650	78253	11	671	3597	58	2	1	1	0	0	0	1	0
14	2957	73828	49	494	2886	32	30	7	0	1	0	0	0	1
14	21008	79195	2	118	788	13	2	5	0	1	0	0	0	1
14	3504	86879	23	92	895	2	53	1	0	0	1	0	0	1
15	1764	73821	16	524	3803	26	3	0,1	1	0	0	0	1	0
15	18420	71695	2	147	954	9	0,9	4	0	1	0	0	0	1
15	2487	27433	34	104	783	2	54	0,1	0	0	1	0	0	1
15	4765	28931	7	185	645	3	1	32	0	1	0	0	0	1
15	37180	1237	21	70	1007	2	26	0,3	0	0	1	0	0	1
16	13348	100878	18	909	3864	125	11	0,5	1	0	0	0	1	0
16	9456	57158	9	365	3445	112	6	14	1	0	0	0	1	0
16	6261	39317	7	530	1368	0,5	9	0,1	1	0	0	0	1	0
16	5804	53406	6	368	3571	32	2	16	1	0	0	0	1	0
16	4001	43357	49	201	2666	13	24	0,3	1	0	0	0	1	0
16	22380	72996	8	466	3802	108	6	15	1	0	0	0	1	0
16	3750	26406	19	66	1196	2	23	0,4	1	0	0	0	1	0

17	17358	77064	20	376	1867	58	5	0,3	1	0	0	0	1	0
17	1463	31117	21	121	1601	3	33	0,1	1	0	0	0	1	0
17	2246	42059	33	150	1550	4	29	0,3	1	0	0	0	1	0
18	6799	78212	11	312	2585	13	3	2	1	0	0	0	1	0
18	3286	15639	1	192	1268	1	0,9	0,1	1	0	0	0	1	0
18	16734	51047	20	144	1212	69	8	8	1	0	0	0	1	0
18	15331	61511	3	354	5280	32	4	0,6	1	0	0	0	1	0
18	4239	35082	10	33	487	4	19	2	1	0	0	0	1	0
18	7270	51099	33	99	978	0,6	55	1	1	0	0	0	1	0
19	23514	71056	6	457	5797	84	3	35	1	0	0	0	1	0
19	19544	67489	4	441	3753	115	3	3	1	0	0	0	1	0
19	18275	65812	6	530	3415	83	5	28	1	0	0	0	1	0
19	3088	16557	20	184	1106	1	14	0,8	1	0	0	0	1	0
19	3685	30309	28	132	2004	2	30	0,5	1	0	0	0	1	0
19	3030	53289	58	259	3347	6	69	0,1	0	1	0	0	0	1
19	3158	66050	63	164	2261	26	63	0,2	1	0	0	0	1	0
19	4809	21337	22	43	523	2	24	0,4	1	0	0	0	1	0
19	5123	28995	10	75	695	1	10	0,2	1	0	0	0	1	0
20	4716	69664	13	422	3155	52	4	0,2	1	0	0	0	1	0
20	18082	61298	5	202	1885	15	6	27	1	0	0	0	1	0
20	4666	69621	54	438	1693	12	54	0,9	0	1	0	0	0	1
20	4564	82221	23	840	5388	128	5	1	1	0	0	0	1	0
21	3249	18130	19	109	380	2	45	0,5	1	0	0	0	1	0
21	1491	47251	32	162	1286	5	24	0,2	1	0	0	0	1	0
21	3742	16417	6	38	280	0,5	11	0,3	1	0	0	0	1	0
21	2872	27582	22	77	1303	3	30	0,2	1	0	0	0	1	0
21	1444	53526	14	393	3812	22	4	11	1	0	0	0	1	0
21	3742	16417	6	38	280	0,5	11	0,3	1	0	0	0	1	0
22	6065	82148	46	370	1069	17	59	0,1	0	1	0	0	0	1
22	2039	67444	50	441	1239	35	83	0,1	0	1	0	0	0	1
22	1642	82236	50	108	11533	8	97	1	1	0	0	0	1	0
22	7990	77205	66	765	4293	134	22	2	1	0	0	0	1	0
22	7967	55407	3	339	3438	16	4	1	1	0	0	0	1	0
22	20302	72978	7	499	4222	42	2	0,1	1	0	0	0	1	0
23	7426	75892	11	496	4091	28	5	0,3	1	0	0	0	1	0
23	13766	43041	3	333	2512	35	2	8	1	0	0	0	1	0
23	13023	63596	7	278	2316	16	1	36	1	0	0	0	1	0
24	2470	76127	46	775	7965	62	12	0,2	1	0	0	0	1	0
24	15984	69236	2	195	1199	9	2	5	0	1	0	0	0	1
24	5797	16567	14	61	249	5	1	2	1	0	0	0	1	0
24	11485	104609	122	129	4255	18	232	0,3	1	0	0	0	1	0
25	3879	14152	9	37	233	4	5	2	1	0	0	0	1	0
25	1533	26312	20	67	698	1	13	0,4	1	0	0	0	1	0
25	9792	70206	16	989	5781	71	9	0,5	1	0	0	0	1	0
25	4821	76414	44	131	1446	20	88	5	1	0	0	0	1	0
26	7205	33439	5	338	1800	1	2	0,2	1	0	0	0	1	0
26	11356	68955	31	79	2257	2	38	0,8	1	0	0	0	1	0
26	14053	84887	21	479	6089	116	8	21	1	0	0	0	1	0
26	1576	7172	2	89	496	0,3	2	0,3	1	0	0	0	1	0
26	6281	30735	7	55	682	1	6	0,1	1	0	0	0	1	0

26	16572	69962	8	648	2682	51	3	1	1	0	0	0	1	0
26	12644	96392	20	354	1929	24	14	24	0	1	0	0	0	1
26	8330	77934	14	663	2135	46	6	0,2	1	0	0	0	1	0
27	3118	71484	30	402	3736	34	10	8	1	0	0	0	1	0
27	5175	34624	25	64	981	5	64	0,5	1	0	0	0	1	0
27	5951	71140	43	544	2333	9	22	0,4	0	1	0	0	0	1
27	8647	87525	58	1003	2476	13	32	29	0	1	0	0	0	1
27	4980	29375	15	85	1245	4	17	0,2	1	0	0	0	1	0
27	1486	48168	53	113	3486	6	82	0,1	1	0	0	0	1	0
27	4836	73514	11	728	5253	49	4	0,8	1	0	0	0	1	0
28	14212	68060	6	287	2638	10	1	6	1	0	0	0	1	0
28	3888	62334	37	485	2006	8	29	0,3	0	1	0	0	0	1
28	23849	78995	16	306	3895	55	8	23	0	1	0	0	0	1
28	2150	15070	26	220	1050	2	15	0,6	1	0	0	0	1	0
28	2656	60661	24	460	1269	7	6	23	0	1	0	0	0	1
29	17947	70623	5	318	3516	31	6	8	0	1	0	0	0	1
29	2591	13042	2	116	708	0,4	0,4	0,4	1	0	0	0	1	0
29	7458	58507	5	344	3093	23	1	3	1	0	0	0	1	0
29	7921	48571	9	19	743	2	13	0,6	1	0	0	0	1	0
29	2607	54501	52	104	2771	4	74	0,2	1	0	0	0	1	0
29	6870	59259	23	177	1105	3	16	0,5	1	0	0	0	1	0
29	2622	75703	112	666	6254	184	29	3	1	0	0	0	1	0
29	2129	66528	51	168	1963	26	44	0,3	1	0	0	0	1	0
29	13504	68472	6	734	4270	78	4	0,5	1	0	0	0	1	0
30	24672	81091	8	467	4202	81	5	32	1	0	0	0	1	0
30	5030	90616	33	455	2333	27	26	9	0	1	0	0	0	1
30	6255	41068	12	562	3471	6	2	0,1	1	0	0	0	1	0
30	3585	51956	14	105	603	2	33	0,6	1	0	0	0	1	0
30	4332	52879	51	235	1991	12	42	0,2	1	0	0	0	1	0
30	2260	51595	79	146	2617	3	180	0,6	1	0	0	0	1	0
31	3466	21439	21	86	1170	3	14	0,7	1	0	0	0	1	0
32	26063	89988	12	552	4663	141	8	82	1	0	0	0	1	0
32	20862	66596	7	258	2401	72	33	11	1	0	0	0	1	0
32	3398	37368	59	98	2830	17	64	0,5	1	0	0	0	1	0
32	16829	69628	2	619	2997	36	0,4	36	0	1	0	0	0	1
33	16126	69123	4	514	2740	31	0,9	3	1	0	0	0	1	0
33	8789	98856	16	877	2457	20	3	0,1	1	0	0	0	1	0
33	5736	62516	46	399	2246	13	68	0,5	0	1	0	0	0	1
33	3316	41046	10	664	2754	5	2	0,4	1	0	0	0	1	0
34	2663	68499	43	519	2107	11	65	0,3	0	1	0	0	0	1
34	24051	75292	9	272	3414	69	9	22	0	1	0	0	0	1
34	4078	88910	26	534	5498	102	7	0,9	1	0	0	0	1	0
34	7559	55850	7	83	576	3	5	0,2	1	0	0	0	1	0
34	4764	70249	40	604	2613	13	52	0,7	0	1	0	0	0	1
35	6644	34767	54	272	983	9	12	0,3	1	0	0	0	1	0
35	11271	67626	5	496	1355	2	1	0,4	1	0	0	0	1	0
35	5589	89139	130	460	1510	15	87	2	0	1	0	0	0	1
36	4771	64225	23	555	3441	23	10	32	0	1	0	0	0	1
36	9384	31193	31	99	591	56	7	7	1	0	0	0	1	0
37	1806	21553	17	56	859	3	13	0,4	1	0	0	0	1	0

37	3065	71146	53	67	792	28	156	1	1	0	0	0	1	0
37	3063	29274	32	124	828	3	68	0,1	0	0	1	0	0	1
37	6390	88838	115	871	6819	178	36	6	0	0	1	0	0	1
38	5655	64284	58	557	1963	20	36	74	0	1	0	0	0	1
38	23783	73093	7	331	3920	55	8	24	0	1	0	0	0	1
38	4296	60329	13	277	1245	9	12	0,1	1	0	0	0	1	0
39	5706	114460	32	180	6813	9	72	1	1	0	0	0	1	0
39	2890	19321	22	59	475	10	14	0,9	1	0	0	0	1	0
39	3103	48253	47	173	1517	9	45	2	1	0	0	0	1	0
39	23232	88314	9	435	5052	55	8	37	0	1	0	0	0	1
39	4647	90534	31	122	10260	8	69	0,7	1	0	0	0	1	0
39	4090	39004	13	63	382	6	13	0,4	0	0	1	0	0	1
40	11053	53270	5	448	3970	47	3	15	1	0	0	0	1	0
40	4868	67412	65	269	2205	15	48	1	1	0	0	0	1	0
40	12586	49041	3	610	3898	63	3	24	1	0	0	0	1	0
41	3118	46620	70	375	8337	9	72	0,6	1	0	0	0	1	0
41	2314	84583	110	397	2434	36	121	8	0	1	0	0	0	1
42	6754	75958	28	522	3151	39	17	44	0	1	0	0	0	1
42	17198	68179	6	352	2599	22	1	6	1	0	0	0	1	0
42	3819	71263	70	359	2399	22	62	2	1	0	0	0	1	0
42	1200	46004	68	264	2214	17	50	5	1	0	0	0	1	0
42	8217	82750	54	689	1823	14	24	42	0	1	0	0	0	1
46	3852	70762	27	896	5103	145	9	37	1	0	0	0	1	0
46	20163	71681	7	405	4423	52	6	28	0	1	0	0	0	1
47	2033	37864	39	472	2786	15	12	1	1	0	0	0	1	0
47	6563	83153	32	708	2395	7	10	0,5	0	1	0	0	0	1
48	4371	70202	21	155	1285	5	48	1	1	0	0	0	1	0
48	2255	92167	28	124	12116	3	60	1	1	0	0	0	1	0
48	12689	53639	8	601	2942	48	3	19	1	0	0	0	1	0
49	24166	140516	40	410	3990	74	10	35	1	0	0	0	1	0
49	17422	72430	5	735	3652	56	1	85	1	0	0	0	1	0
50	33889	133695	7	380	4082	14	3	35	0	1	0	0	0	1
51	8044	94646	142	144	2894	60	156	8	1	0	0	0	1	0
51	22778	82487	4	537	4521	35	2	0,3	1	0	0	0	1	0
52	3117	74611	48	774	3689	10	11	0,4	1	0	0	0	1	0
54	3990	53591	25	568	5933	4	5	0,3	1	0	0	0	1	0
54	2803	82284	85	343	2467	14	104	1	1	0	0	0	1	0
54	2479	53666	60	524	1194	27	37	111	0	1	0	0	0	1
55	3706	42057	48	82	1524	2	113	0,6	1	0	0	0	1	0
55	3780	69760	8	544	3118	8	2	0,4	1	0	0	0	1	0
56	5096	55426	22	80	745	6	41	1	1	0	0	0	1	0
56	1718	63388	117	719	3838	116	25	0,6	1	0	0	0	1	0
57	3335	63004	74	263	1184	20	82	71	0	1	0	0	0	1
57	3645	61964	114	346	1252	12	191	15	1	0	0	0	1	0
57	11497	67547	8	436	4754	58	13	80	0	1	0	0	0	1
58	25609	135939	91	317	2965	17	62	2	1	0	0	0	1	0
58	16512	90617	5	656	3914	60	3	10	1	0	0	0	1	0
59	15021	67313	5	276	1511	5	6	2	1	0	0	0	1	0
59	6288	73629	14	425	3626	39	22	15	0	1	0	0	0	1
60	7334	71186	57	660	3095	8	41	0,6	0	1	0	0	0	1

60	17895	55664	32	176	1276	42	7	12	1	0	0	0	1	0
60	21842	68148	12	328	4602	61	10	32	0	1	0	0	0	1
61	17704	79673	5	661	6022	108	12	24	0	1	0	0	0	1
61	4836	69735	27	91	562	8	39	1	1	0	0	0	1	0
61	7190	97777	32	63	712	13	48	5	1	0	0	0	1	0
62	9095	53117	11	160	917	14	7	0,6	1	0	0	0	1	0
63	2541	74334	19	276	2816	21	5	0,8	1	0	0	0	1	0
63	17901	71679	7	486	3300	71	2	24	1	0	0	0	1	0
64	20749	147311	92	408	2368	12	108	0,9	0	1	0	0	0	1
64	3759	73232	173	183	4641	16	289	0,9	1	0	0	0	1	0
65	6134	87896	50	756	4696	220	12	39	1	0	0	0	1	0
65	3328	81866	152	171	4747	21	248	1	1	0	0	0	1	0
68	4264	70562	34	117	680	6	79	3	1	0	0	0	1	0
69	6788	26597	0,5	84	371	0,1	0,1	0,1	1	0	0	0	1	0
70	13679	70098	8	476	4079	66	4	11	1	0	0	0	1	0
72	1256	26028	129	231	2149	115	85	0,1	1	0	0	0	1	0
73	19484	70513	15	559	4158	72	2	156	1	0	0	0	1	0
74	11606	94738	14	348	3210	24	9	16	1	0	0	0	1	0
74	14360	53752	4	466	2750	38	2	54	1	0	0	0	1	0
75	5433	76124	70	375	1766	16	88	6	0	1	0	0	0	1
75	15542	71388	16	615	3328	139	21	35	0	1	0	0	0	1
75	3935	66209	24	161	855	4	94	0,4	1	0	0	0	1	0
76	2486	61115	29	57	2026	4	46	0,7	1	0	0	0	1	0
76	2492	79435	8	1376	3363	10	3	0,4	1	0	0	0	1	0
77	1586	78756	55	1032	12027	114	12	0,9	1	0	0	0	1	0
78	18691	75849	14	375	3477	115	22	145	0	1	0	0	0	1
78	26975	102850	281	344	2743	345	155	15	1	0	0	0	1	0
79	7601	73228	21	495	3520	49	16	31	0	1	0	0	0	1
80	11146	86134	64	329	2211	13	118	4	0	1	0	0	0	1
80	4419	74218	17	276	1571	3	38	0,8	1	0	0	0	1	0
80	17743	67236	4	167	878	2	3	3	1	0	0	0	1	0
81	22993	88927	226	504	3780	292	124	27	1	0	0	0	1	0
82	2220	44807	11	516	3708	2	2	0,5	1	0	0	0	1	0
82	11622	53560	15	376	1051	4	0,9	0,9	1	0	0	0	1	0
82	5242	79614	43	139	741	8	92	8	1	0	0	0	1	0
83	6501	62258	104	379	3724	17	235	0,5	0	1	0	0	0	1
83	4105	70234	37	342	3334	60	27	51	0	1	0	0	0	1
84	4436	75528	26	667	3729	31	14	41	0	1	0	0	0	1
84	9488	65882	15	470	4146	73	13	91	0	1	0	0	0	1
84	4732	27145	30	146	1001	15	22	0,2	1	0	0	0	1	0
85	7588	71828	28	813	8087	114	18	12	0	1	0	0	0	1
86	7382	69066	24	802	2269	14	3	23	0	0	1	0	0	1
88	2649	52673	106	287	1126	10	140	0,8	1	0	0	0	1	0
88	6492	67190	41	405	1835	49	28	201	0	1	0	0	0	1
88	1618	54498	76	95	1016	66	88	0,6	1	0	0	0	1	0
88	6669	73183	21	441	2551	49	20	24	0	1	0	0	0	1
88	4170	99797	55	756	1844	49	42	8	1	0	0	0	1	0
90	7159	75400	27	429	2849	59	23	32	0	1	0	0	0	1
90	2471	33691	49	62	1173	69	51	0,2	1	0	0	0	1	0
91	3981	63154	17	82	482	6	31	6	1	0	0	0	1	0

91	9611	73866	11	654	4105	64	15	29	0	1	0	0	0	1
92	1243	74631	44	1004	10302	94	12	0,5	1	0	0	0	1	0
92	2479	85314	185	163	4818	57	363	0,1	1	0	0	0	1	0
95	4069	9246	80	545	1701	10	98	4	0	1	0	0	0	1
95	3727	70070	55	469	2237	12	100	0,3	1	0	0	0	1	0
95	5367	64662	54	103	2253	15	57	0,6	1	0	0	0	1	0
96	5021	86488	47	66	751	51	52	4	1	0	0	0	1	0
96	17781	73028	18	402	3819	135	20	41	0	1	0	0	0	1
97	8326	35001	0,8	134	944	0,6	1	0,1	1	0	0	0	1	0
98	3729	65940	135	471	3903	19	241	0,5	0	1	0	0	0	1
98	23021	144251	80	616	5982	27	84	3	0	1	0	0	0	1
99	3858	73293	16	62	403	8	25	8	1	0	0	0	1	0
99	9439	67531	13	390	4360	17	10	17	0	1	0	0	0	1
100	8623	92584	33	551	3637	44	27	25	0	1	0	0	0	1
101	9977	71737	9	435	3156	7	5	18	1	0	0	0	1	0
103	5100	60808	24	359	1925	6	17	0,2	1	0	0	0	1	0
105	4861	72174	86	118	3228	27	124	2	1	0	0	0	1	0
105	2478	44180	49	86	976	4	72	2	1	0	0	0	1	0
106	5456	72112	21	683	3915	51	23	26	0	1	0	0	0	1
107	2466	74023	80	979	5464	13	48	0,4	0	1	0	0	0	1
107	12104	69028	25	309	2650	151	23	202	0	1	0	0	0	1
107	4498	75476	34	510	3332	55	23	50	0	1	0	0	0	1
108	7499	71239	90	408	1859	17	109	30	0	1	0	0	0	1
109	4649	67995	46	446	1896	47	38	139	0	1	0	0	0	1
110	7274	71359	18	549	3622	53	16	22	0	1	0	0	0	1
110	10555	63186	20	394	2947	125	24	142	0	1	0	0	0	1
112	8402	63684	25	408	4917	205	34	228	0	1	0	0	0	1
112	6031	59600	80	320	1655	16	101	29	0	1	0	0	0	1
113	5861	77967	42	550	3712	64	27	58	0	1	0	0	0	1
115	4209	63878	73	576	1615	8	37	10	1	0	0	0	1	0
115	3847	83623	16	573	3537	38	14	36	0	1	0	0	0	1
116	5436	65870	99	654	2262	9	55	3	0	1	0	0	0	1
117	12528	60552	22	288	2432	123	21	135	0	1	0	0	0	1
117	8004	87771	41	578	5249	60	37	65	0	1	0	0	0	1
119	4442	73494	54	571	1797	46	34	185	0	1	0	0	0	1
122	13475	95539	21	427	6229	154	32	33	0	1	0	0	0	1
122	14837	70282	22	454	4322	160	28	190	0	1	0	0	0	1
124	3973	82450	47	505	3547	64	10	2	1	0	0	0	1	0
125	3030	64632	67	427	1808	7	121	1	0	1	0	0	0	1
125	6344	92696	115	539	3106	16	191	0,5	0	1	0	0	0	1
127	4231	82506	22	528	3365	53	18	39	0	1	0	0	0	1
127	3493	72874	41	500	4342	48	29	62	0	1	0	0	0	1
129	9267	78617	24	457	3561	25	15	23	0	1	0	0	0	1
129	2424	20872	70	166	1524	58	17	20	1	0	0	0	1	0
129	5946	70226	140	608	2793	220	160	0,6	0	1	0	0	0	1
129	6450	67859	57	450	2450	73	65	29	0	1	0	0	0	1
129	5290	65874	50	436	2216	66	69	54	0	1	0	0	0	1
131	8234	77218	65	552	3135	72	73	37	0	1	0	0	0	1
131	12571	73628	82	575	3641	64	54	0,2	1	0	0	0	1	0
132	14038	66138	26	353	3647	160	28	169	0	1	0	0	0	1

133	6425	82983	21	525	3029	47	23	32	0	1	0	0	0	1
134	5766	68936	23	540	4025	30	11	37	0	1	0	0	0	1
136	7942	91333	18	493	4359	20	13	24	0	1	0	0	0	1
139	3515	66492	57	535	1738	50	34	213	0	1	0	0	0	1
139	5271	69566	71	514	3122	71	79	50	0	1	0	0	0	1
140	4458	21887	140	141	864	98	45	0,3	1	0	0	0	1	0
140	3769	64590	76	484	2514	40	71	47	0	1	0	0	0	1
141	3419	61954	36	385	2099	5	28	0,8	1	0	0	0	1	0
141	17765	78228	28	384	3464	163	29	195	0	1	0	0	0	1
141	17765	78228	28	384	3464	163	29	195	0	1	0	0	0	1
142	3569	73749	83	84	956	128	86	2	1	0	0	0	1	0
142	5648	62427	20	696	4382	112	5	243	1	0	0	0	1	0
143	3394	59062	136	259	1215	60	294	70	1	0	0	0	1	0
144	1460	59195	62	452	5603	46	11	19	1	0	0	0	1	0
146	3820	67174	20	437	3278	42	32	15	0	1	0	0	0	1
146	3935	54454	66	180	1601	18	21	2	1	0	0	0	1	0
147	14968	73031	27	423	5931	250	39	301	0	1	0	0	0	1
147	3076	61518	116	359	1074	34	208	45	1	0	0	0	1	0
149	7252	73320	98	544	3695	62	103	46	0	1	0	0	0	1
150	7858	73499	27	540	2398	35	25	23	0	1	0	0	0	1
150	6904	81347	12	453	3342	23	12	17	0	1	0	0	0	1
151	9185	78168	14	432	4585	26	12	22	0	1	0	0	0	1
151	3533	76380	80	457	2236	10	148	2	0	1	0	0	0	1
153	5947	67607	30	698	3612	42	21	10	0	1	0	0	0	1
154	4462	71716	32	574	4584	170	38	8	0	1	0	0	0	1
156	10337	65836	39	219	2184	8	37	0,7	1	0	0	0	1	0
158	3102	73488	73	533	2614	49	76	75	0	1	0	0	0	1
158	3743	78483	24	552	4619	20	16	26	0	1	0	0	0	1
160	7109	81148	99	597	3502	75	104	41	0	1	0	0	0	1
160	7934	84427	38	571	3179	43	43	29	0	1	0	0	0	1
160	3493	63007	144	292	2361	57	433	119	1	0	0	0	1	0
163	3811	66009	27	421	1705	19	12	63	1	0	0	0	1	0
164	2602	60682	45	217	1354	15	21	0,6	1	0	0	0	1	0
164	5938	78850	40	670	2768	39	40	21	0	1	0	0	0	1
165	2201	55389	44	310	1808	6	26	10	1	0	0	0	1	0
167	4818	69685	84	191	2087	23	36	0,5	1	0	0	0	1	0
167	6319	71348	149	473	1750	168	228	105	0	0	1	0	0	1
168	4160	22972	69	175	947	46	11	17	1	0	0	0	1	0
170	6351	67930	30	722	4179	42	20	18	0	1	0	0	0	1
173	5973	70916	23	564	3332	35	15	9	0	1	0	0	0	1
175	7610	112370	76	661	8217	35	108	1	0	1	0	0	0	1
176	3642	62541	117	335	1544	139	237	102	1	0	0	0	1	0
178	5316	74263	18	509	4849	52	24	20	0	1	0	0	0	1
184	4158	56330	98	329	2739	12	184	2	0	1	0	0	0	1
185	4290	69971	158	421	2000	244	278	53	1	0	0	0	1	0
186	4825	63078	149	230	3356	69	71	2	1	0	0	0	1	0
188	4458	64898	20	481	3497	95	18	25	0	1	0	0	0	1
203	5206	83981	85	384	2013	118	138	33	1	0	0	0	1	0
204	5367	79079	143	370	1793	414	268	478	1	0	0	0	1	0
209	2533	62590	28	479	3418	68	24	19	0	1	0	0	0	1

211	5311	56133	107	410	1986	32	77	59	0	0	1	0	0	1
211	4786	74551	22	458	6261	87	25	40	0	1	0	0	0	1
213	3996	72908	242	629	2780	316	162	6	0	1	0	0	0	1
214	4906	67524	127	348	1764	291	230	401	0	0	1	0	0	1
215	4856	70262	51	374	2224	75	47	131	1	0	0	0	1	0
216	2761	59943	336	629	2205	423	61	2	1	0	0	0	1	0
218	4827	67532	110	335	2084	345	241	309	1	0	0	0	1	0
222	6651	81750	33	610	4269	64	22	23	0	1	0	0	0	1
225	5798	70021	25	508	6166	69	28	42	0	1	0	0	0	1
226	4413	67914	124	409	1768	143	251	46	0	0	1	0	0	1
229	1640	62904	503	679	2202	632	102	2	1	0	0	0	1	0
235	3015	70228	95	355	1525	113	153	202	1	0	0	0	1	0
241	5618	81007	169	496	2348	225	337	83	0	0	1	0	0	1
245	4523	93650	196	673	2895	248	324	94	0	1	0	0	0	1
251	1217	19953	112	255	1412	85	18	62	1	0	0	0	1	0
253	1312	74896	524	761	3133	724	116	2	1	0	0	0	1	0
255	4129	69399	132	408	1891	151	294	48	0	0	1	0	0	1
257	9404	99194	270	851	2620	425	162	5	0	1	0	0	0	1
259	4615	85005	14	496	3739	7	8	0,2	0	1	0	0	0	1
270	5548	92795	121	830	6839	23	47	0,7	1	0	0	0	1	0
275	4596	63760	79	358	1361	87	105	29	1	0	0	0	1	0
277	5343	65245	131	349	1806	253	214	454	1	0	0	0	1	0
290	5986	69094	181	235	1706	269	396	457	1	0	0	0	1	0
298	6146	76974	129	407	1897	202	203	353	1	0	0	0	1	0
309	4610	78696	228	417	3061	236	539	386	1	0	0	0	1	0
312	2260	17852	360	178	890	358	191	0,2	1	0	0	0	1	0
331	2248	56074	306	260	3820	473	417	0,5	1	0	0	0	1	0
335	14207	102430	14	525	3682	47	12	24	0	1	0	0	0	1
360	3097	67985	210	573	2614	269	140	6	0	1	0	0	0	1
430	4663	27848	23	28	2130	4	24	3	1	0	0	0	1	0
904	4360	40390	30	53	2853	8	32	7	0	0	1	0	0	1
950	4860	84954	18	576	4496	80	22	32	0	1	0	0	0	1
1289	9565	78353	22	551	4691	29	12	30	0	1	0	0	0	1
1321	4912	41300	36	53	3036	4	36	3	1	0	0	0	1	0
1932	5039	68489	28	643	5643	40	18	31	0	1	0	0	0	1
7	25827	126664	6	701	4753	83	2	0,7	0	0	0	1	0	1
13	4572	25998	3	356	1194	0,3	0,6	0,1	0	0	0	1	0	1
20	12811	73030	5	295	3604	33	1	28	0	0	0	1	0	1
22	11351	71693	4	993	3259	82	3	0,7	0	0	0	1	0	1
28	4955	21986	2	146	720	0,2	0,2	0,7	0	0	0	1	0	1
34	11170	39876	2	239	983	0,7	0,7	0,2	0	0	0	1	0	1
47	2560	74930	8	725	5827	118	3	0,6	0	0	0	1	0	1
28	4955	21986	2	146	720	0,2	0,2	0,7	0	0	0	1	0	1
13	4572	25998	3	356	1194	0,3	0,6	0,1	0	0	0	1	0	1
22	11351	71693	4	993	3259	82	3	0,7	0	0	0	1	0	1
7	25827	126664	6	701	4753	83	2	0,7	0	0	0	1	0	1
47	2560	74930	8	725	5827	118	3	0,6	0	0	0	1	0	1
20	12811	73030	5	295	3604	33	1	28	0	0	0	1	0	1
34	11170	39876	2	239	983	0,7	0,7	0,2	0	0	0	1	0	1
28	4955	21986	2	146	720	0,2	0,2	0,7	0	0	0	1	0	1

13	4572	25998	3	356	1194	0,3	0,6	0,1	0	0	0	1	0	1
22	11351	71693	4	993	3259	82	3	0,7	0	0	0	1	0	1
7	25827	126664	6	701	4753	83	2	0,7	0	0	0	1	0	1
47	2560	74930	8	725	5827	118	3	0,6	0	0	0	1	0	1
20	12811	73030	5	295	3604	33	1	28	0	0	0	1	0	1
34	11170	39876	2	239	983	0,7	0,7	0,2	0	0	0	1	0	1
7	25827	126664	6	701	4753	83	2	0,7	0	0	0	1	0	1
13	4572	25998	3	356	1194	0,3	0,6	0,1	0	0	0	1	0	1
20	12811	73030	5	295	3604	33	1	28	0	0	0	1	0	1
22	11351	71693	4	993	3259	82	3	0,7	0	0	0	1	0	1
28	4955	21986	2	146	720	0,2	0,2	0,7	0	0	0	1	0	1
34	11170	39876	2	239	983	0,7	0,7	0,2	0	0	0	1	0	1
47	2560	74930	8	725	5827	118	3	0,6	0	0	0	1	0	1
28	4955	21986	2	146	720	0,2	0,2	0,7	0	0	0	1	0	1
13	4572	25998	3	356	1194	0,3	0,6	0,1	0	0	0	1	0	1
22	11351	71693	4	993	3259	82	3	0,7	0	0	0	1	0	1
7	25827	126664	6	701	4753	83	2	0,7	0	0	0	1	0	1
47	2560	74930	8	725	5827	118	3	0,6	0	0	0	1	0	1
20	12811	73030	5	295	3604	33	1	28	0	0	0	1	0	1
34	11170	39876	2	239	983	0,7	0,7	0,2	0	0	0	1	0	1
28	4955	21986	2	146	720	0,2	0,2	0,7	0	0	0	1	0	1
13	4572	25998	3	356	1194	0,3	0,6	0,1	0	0	0	1	0	1
22	11351	71693	4	993	3259	82	3	0,7	0	0	0	1	0	1
15	37180	1237	21	70	1007	2	26	0,3	0	0	1	0	0	1
4	1231	1901	4	12	28	1	4	0,2	0	0	1	0	0	1
15	2487	27433	34	104	783	2	54	0,1	0	0	1	0	0	1
37	3063	29274	32	124	828	3	68	0,1	0	0	1	0	0	1
14	3504	86879	23	92	895	2	53	1	0	0	1	0	0	1
39	4090	39004	13	63	382	6	13	0,4	0	0	1	0	0	1
3	3582	16592	8	40	508	1	12	0,2	0	0	1	0	0	1
904	4360	40390	30	53	2853	8	32	7	0	0	1	0	0	1
167	6319	71348	149	473	1750	168	228	105	0	0	1	0	0	1
37	6390	88838	115	871	6819	178	36	6	0	0	1	0	0	1
241	5618	81007	169	496	2348	225	337	83	0	0	1	0	0	1
214	4906	67524	127	348	1764	291	230	401	0	0	1	0	0	1
86	7382	69066	24	802	2269	14	3	23	0	0	1	0	0	1
10	36195	144061	2	40	378	26	4	44	0	0	1	0	0	1
226	4413	67914	124	409	1768	143	251	46	0	0	1	0	0	1
255	4129	69399	132	408	1891	151	294	48	0	0	1	0	0	1
211	5311	56133	107	410	1986	32	77	59	0	0	1	0	0	1
15	37180	1237	21	70	1007	2	26	0,3	0	0	1	0	0	1
4	1231	1901	4	12	28	1	4	0,2	0	0	1	0	0	1
15	2487	27433	34	104	783	2	54	0,1	0	0	1	0	0	1
37	3063	29274	32	124	828	3	68	0,1	0	0	1	0	0	1
14	3504	86879	23	92	895	2	53	1	0	0	1	0	0	1
39	4090	39004	13	63	382	6	13	0,4	0	0	1	0	0	1
3	3582	16592	8	40	508	1	12	0,2	0	0	1	0	0	1
904	4360	40390	30	53	2853	8	32	7	0	0	1	0	0	1
167	6319	71348	149	473	1750	168	228	105	0	0	1	0	0	1
37	6390	88838	115	871	6819	178	36	6	0	0	1	0	0	1

241	5618	81007	169	496	2348	225	337	83	0	0	1	0	0	1
214	4906	67524	127	348	1764	291	230	401	0	0	1	0	0	1
86	7382	69066	24	802	2269	14	3	23	0	0	1	0	0	1
10	36195	144061	2	40	378	26	4	44	0	0	1	0	0	1
226	4413	67914	124	409	1768	143	251	46	0	0	1	0	0	1
255	4129	69399	132	408	1891	151	294	48	0	0	1	0	0	1
211	5311	56133	107	410	1986	32	77	59	0	0	1	0	0	1
7	25827	126664	6	701	4753	83	2	0,7	0	0	0	1	0	1
13	4572	25998	3	356	1194	0,3	0,6	0,1	0	0	0	1	0	1
20	12811	73030	5	295	3604	33	1	28	0	0	0	1	0	1
22	11351	71693	4	993	3259	82	3	0,7	0	0	0	1	0	1
28	4955	21986	2	146	720	0,2	0,2	0,7	0	0	0	1	0	1
34	11170	39876	2	239	983	0,7	0,7	0,2	0	0	0	1	0	1
47	2560	74930	8	725	5827	118	3	0,6	0	0	0	1	0	1
28	4955	21986	2	146	720	0,2	0,2	0,7	0	0	0	1	0	1
13	4572	25998	3	356	1194	0,3	0,6	0,1	0	0	0	1	0	1
22	11351	71693	4	993	3259	82	3	0,7	0	0	0	1	0	1
7	25827	126664	6	701	4753	83	2	0,7	0	0	0	1	0	1
47	2560	74930	8	725	5827	118	3	0,6	0	0	0	1	0	1
20	12811	73030	5	295	3604	33	1	28	0	0	0	1	0	1
34	11170	39876	2	239	983	0,7	0,7	0,2	0	0	0	1	0	1
28	4955	21986	2	146	720	0,2	0,2	0,7	0	0	0	1	0	1
13	4572	25998	3	356	1194	0,3	0,6	0,1	0	0	0	1	0	1
22	11351	71693	4	993	3259	82	3	0,7	0	0	0	1	0	1
7	25827	126664	6	701	4753	83	2	0,7	0	0	0	1	0	1
47	2560	74930	8	725	5827	118	3	0,6	0	0	0	1	0	1
20	12811	73030	5	295	3604	33	1	28	0	0	0	1	0	1
34	11170	39876	2	239	983	0,7	0,7	0,2	0	0	0	1	0	1
7	25827	126664	6	701	4753	83	2	0,7	0	0	0	1	0	1
13	4572	25998	3	356	1194	0,3	0,6	0,1	0	0	0	1	0	1
20	12811	73030	5	295	3604	33	1	28	0	0	0	1	0	1
22	11351	71693	4	993	3259	82	3	0,7	0	0	0	1	0	1
28	4955	21986	2	146	720	0,2	0,2	0,7	0	0	0	1	0	1
34	11170	39876	2	239	983	0,7	0,7	0,2	0	0	0	1	0	1
47	2560	74930	8	725	5827	118	3	0,6	0	0	0	1	0	1
28	4955	21986	2	146	720	0,2	0,2	0,7	0	0	0	1	0	1
13	4572	25998	3	356	1194	0,3	0,6	0,1	0	0	0	1	0	1
22	11351	71693	4	993	3259	82	3	0,7	0	0	0	1	0	1
7	25827	126664	6	701	4753	83	2	0,7	0	0	0	1	0	1
47	2560	74930	8	725	5827	118	3	0,6	0	0	0	1	0	1
20	12811	73030	5	295	3604	33	1	28	0	0	0	1	0	1
34	11170	39876	2	239	983	0,7	0,7	0,2	0	0	0	1	0	1
28	4955	21986	2	146	720	0,2	0,2	0,7	0	0	0	1	0	1
13	4572	25998	3	356	1194	0,3	0,6	0,1	0	0	0	1	0	1
22	11351	71693	4	993	3259	82	3	0,7	0	0	0	1	0	1

ANEXO B - DATOS ESTUDO DE CASO

98

H2	O2	N2	CH4	CO	CO2	C2H6	C2H4	C2H2	Acidez	Rig.	Teor Agua	T.I.	Dens.	F.P.	Especia.	WEG	MLP_LM
37	6390	88838	115	871	6819	178	36	6	0	30,7	29	0	0	0	RECOND	REG	SAT
29	6870	59259	23	177	1105	3	16	0,5	0	92	12	0	0	0	SAT	REG	SAT
158	3102	73488	73	533	2614	49	76	75	0,086	62,8	20	23	0,8814	0	REG	INCONCLU	REG
25	9792	70206	16	989	5781	71	9	0,5	0,04	95	9	31,3	0,8816	1,96	SAT	REG	SAT
88	6492	67190	41	405	1835	49	28	201	0,045	78,4	24	27,6	0,8868	16,6	REG	INCONCLU	REG
83	4105	70234	37	342	3334	60	27	51	0	81	17	0	0	0	REG	INCONCLU	REG
275	4596	63760	79	358	1361	87	105	29	0,04	0	16	26,9	0,8916	0	SAT	REG	SAT
22	7990	77205	66	765	4293	134	22	2	0,038	56,1	26	33,5	0,8876	1,91	SAT	INCONCLU	SAT
165	2201	55389	44	310	1808	6	26	10	0	63	27	0	0	0	SAT	INCONCLU	SAT
185	4290	69971	158	421	2000	244	278	53	0	88,3	15	0	0	0	SAT	INCONCLU	SAT
60	17895	55664	32	176	1276	42	7	12	0,012	73,9	18	45,9	0,8906	0,17	SAT	INCONCLU	SAT
23	13023	63596	7	278	2316	16	1	36	0	76,1	19	0	0	1,59	SAT	INCONCLU	SAT
14	21008	79195	2	118	788	13	2	5	0,064	72,4	21	21,1	0,8751	0	REG	INCONCLU	SAT
13	2607	79709	10	548	4661	58	3	2	0,012	81,9	13	34,8	0,8831	1,85	SAT	REG	SAT
19	3030	53289	58	259	3347	6	69	0,1	0	71,2	11	27,3	0,8858	4,32	REG	REG	SAT
55	3706	42057	48	82	1524	2	113	0,6	0	78,8	10	0	0	0,32	SAT	SAT	SAT
56	5096	55426	22	80	745	6	41	1	0,007	80,4	7	40,1	0,8836	0,42	SAT	REG	SAT
241	5618	81007	169	496	2348	225	337	83	0	21,6	43	0	0	0	RECOND	REG	RECOND
22	11351	71693	4	993	3259	82	3	0,7	0,031	72,7	8	32	0,8826	1,16	ADIT	REG	SAT
7	2137	75177	11	288	1962	11	4	2	0	92,4	15	35,9	0,8826	1,44	SAT	INCONCLU	SAT
79	7601	73228	21	495	3520	49	16	31	0,081	84,6	17	23,3	0,8834	5,94	REG	INCONCLU	SAT
49	17422	72430	5	735	3652	56	1	85	0	77,2	12	0	0	6,18	SAT	SAT	SAT
15	2487	27433	34	104	783	2	54	0,1	0	43,7	24	0	0	0	RECOND	INCONCLU	RECOND
39	23232	88314	9	435	5052	55	8	37	0,066	61,4	25	23,9	0,8669	0	REG	INCONCLU	SAT
42	3819	71263	70	359	2399	22	62	2	0,009	74,2	8	38	0,8851	0,99	SAT	REG	REG
32	16829	69628	2	619	2997	36	0,4	36	0,113	98,5	14	24,6	0,8806	8,8	REG	REG	SAT
96	5021	86488	47	66	751	51	52	4	0,008	80,3	9	41,4	0,8835	0,87	SAT	REG	RECOND
88	2649	52673	106	287	1126	10	140	0,8	0,046	73,9	17	27,5	0,8834	3,98	SAT	INCONCLU	SAT

34	11170	39876	2	239	983	0,7	0,7	0,2	0,001	70,3	20	37,7	0,8886	1,56	ADIT	INCONCLU	SAT
13	4572	25998	3	356	1194	0,3	0,6	0,1	0	74,7	8	0	0	0,25	ADIT	SAT	SAT
290	5986	69094	181	235	1706	269	396	457	0,073	87,1	23	26,2	0,8883	4,73	SAT	INCONCLU	SAT
78	26975	102850	281	344	2743	345	155	15	0,024	67,2	16	31,5	0,8832	1,78	SAT	INCONCLU	RECOND
1932	5039	68489	28	643	5643	40	18	31	0	62,2	22	21	0,8809	0	REG	INCONCLU	REG
22	11351	71693	4	993	3259	82	3	0,7	0,031	72,7	8	32	0,8826	1,16	ADIT	REG	SAT
11	13492	61958	6	345	2957	27	2	0,3	0	64,5	17	0	0	1,28	SAT	INCONCLU	SAT
4	1231	1901	4	12	28	1	4	0,2	0	55,4	20	0	0	0	RECOND	INCONCLU	SAT
20	12811	73030	5	295	3604	33	1	28	0,002	63,4	19	36,1	0,8816	1,46	ADIT	INCONCLU	ADIT
225	5798	70021	25	508	6166	69	28	42	0,148	16	94	19,3	0,8818	0	REG	REG	REG
163	3811	66009	27	421	1705	19	12	63	0	90,2	16	0	0	0	SAT	INCONCLU	REG
3	12519	57337	5	30	262	0,6	10	0,3	0	83,4	13	0	0	0	SAT	REG	SAT
61	17704	79673	5	661	6022	108	12	24	0,213	39,9	26	24,7	0,8841	11,92	REG	INCONCLU	SAT
26	6281	30735	7	55	682	1	6	0,1	0,012	89,6	14	39	0,8816	0,48	SAT	REG	SAT
15	37180	1237	21	70	1007	2	26	0,3	0	54	25	0	0	0	RECOND	INCONCLU	SAT
47	2560	74930	8	725	5827	118	3	0,6	0,041	46,1	20	32,5	0,883	2,17	ADIT	INCONCLU	SAT
50	33889	133695	7	380	4082	14	3	35	0,086	68,8	25	22,1	0,8791	7,39	REG	INCONCLU	REG
107	2466	74023	80	979	5464	13	48	0,4	0,168	78,2	20	21,2	0,8905	18,5	REG	INCONCLU	SAT
15	2487	27433	34	104	783	2	54	0,1	0	43,7	24	0	0	0	RECOND	INCONCLU	RECOND
164	2602	60682	45	217	1354	15	21	0,6	0,011	88,6	16	36,6	0,8844	1,85	SAT	INCONCLU	SAT
22	11351	71693	4	993	3259	82	3	0,7	0,031	72,7	8	32	0,8826	1,16	ADIT	REG	SAT
64	3759	73232	173	183	4641	16	289	0,9	0,005	72,4	10	36,3	0,885	1,55	SAT	REG	REG
41	3118	46620	70	375	8337	9	72	0,6	0	79,4	8	0	0	0,46	SAT	SAT	SAT
11	4868	61884	27	670	3596	122	11	1	0,023	84,4	22	33,6	0,8825	3,87	SAT	INCONCLU	SAT
105	2478	44180	49	86	976	4	72	2	0,007	80,7	10	36,9	0,887	1,34	SAT	REG	SAT
32	3398	37368	59	98	2830	17	64	0,5	0	84	12	0	0	0	SAT	REG	SAT
96	17781	73028	18	402	3819	135	20	41	0,111	46,7	22	20,2	0,8754	7,25	REG	INCONCLU	ADIT
26	1576	7172	2	89	496	0,3	2	0,3	0,002	81,9	10	43,7	0,8902	0,63	SAT	REG	SAT
62	9095	53117	11	160	917	14	7	0,6	0	81,5	14	0	0	10,09	SAT	SAT	SAT
253	1312	74896	524	761	3133	724	116	2	0	77	7	38,7	0,8836	0,95	SAT	REG	REG
142	5648	62427	20	696	4382	112	5	243	0,06	80,9	14	27	0,8801	3,44	SAT	REG	REG
7	25827	126664	6	701	4753	83	2	0,7	0,039	60,3	22	31,1	0,8827	1,94	ADIT	INCONCLU	ADIT
90	7159	75400	27	429	2849	59	23	32	0,087	55,2	27	22,7	0,8822	6,24	REG	INCONCLU	REG

8	16714	62699	8	586	3938	65	2	19	0	80,7	9	0	0	3,23	SAT	SAT	SAT
58	16512	90617	5	656	3914	60	3	10	0	0	13	0	0	0	SAT	REG	REG
88	4170	99797	55	756	1844	49	42	8	0	55,4	21	0	0	2,96	SAT	INCONCLU	REG
33	3316	41046	10	664	2754	5	2	0,4	0	80,5	8	0	0	1,09	SAT	SAT	SAT
34	11170	39876	2	239	983	0,7	0,7	0,2	0,001	70,3	20	37,7	0,8886	1,56	ADIT	INCONCLU	SAT
10	36195	144061	2	40	378	26	4	44	0	19,8	65	0	0	0	RECOND	REG	RECOND
360	3097	67985	210	573	2614	269	140	6	0	13,9	69	0	0	0	REG	REG	RECOND
13	4572	25998	3	356	1194	0,3	0,6	0,1	0	74,7	8	0	0	0,25	ADIT	SAT	SAT
20	4666	69621	54	438	1693	12	54	0,9	0,053	79,8	17	26,5	0,8851	30,15	REG	INCONCLU	REG
86	7382	69066	24	802	2269	14	3	23	0,011	82,3	9	39,5	0,8709	3,94	RECOND	REG	SAT
23	7426	75892	11	496	4091	28	5	0,3	0,029	80,3	23	36,8	0,8885	1,86	SAT	INCONCLU	SAT
10	19036	59042	4	657	2840	45	2	14	0,034	84,9	16	32,5	0,8816	3,96	SAT	INCONCLU	SAT
18	4239	35082	10	33	487	4	19	2	0	60,6	7	0	0	0,54	SAT	SAT	REG
150	7858	73499	27	540	2398	35	25	23	0,193	25,9	48	20,6	0,8824	7,68	REG	REG	REG
255	4129	69399	132	408	1891	151	294	48	0	26,8	55	0	0	0	RECOND	REG	RECOND
19	3685	30309	28	132	2004	2	30	0,5	0,011	69,4	7	38,6	0,8867	0,76	SAT	REG	SAT
15	37180	1237	21	70	1007	2	26	0,3	0	54	25	0	0	0	RECOND	INCONCLU	SAT
9	3301	16797	8	53	373	0,9	10	0,5	0	37,9	13	0	0	0	SAT	REG	SAT
7	25827	126664	6	701	4753	83	2	0,7	0,039	60,3	22	31,1	0,8827	1,94	ADIT	INCONCLU	ADIT
76	2486	61115	29	57	2026	4	46	0,7	0	64	17	0	0	1,83	SAT	INCONCLU	SAT
213	3996	72908	242	629	2780	316	162	6	0,114	18,8	73	23,9	0,8908	8,1	REG	REG	RECOND
14	7963	85926	28	476	2928	26	15	10	0,028	40,2	210	27	0,8868	0,11	REG	INCONCLU	SAT
52	3117	74611	48	774	3689	10	11	0,4	0	69,5	9	0	0	1,22	SAT	SAT	SAT
9	2874	5541	8	21	140	1	10	0,2	0	0	13	0	0	2,5	SAT	RECOND	SAT
10	36195	144061	2	40	378	26	4	44	0	19,8	65	0	0	0	RECOND	REG	RECOND
47	2560	74930	8	725	5827	118	3	0,6	0,041	46,1	20	32,5	0,883	2,17	ADIT	INCONCLU	SAT
950	4860	84954	18	576	4496	80	22	32	0,102	33,2	22	21,4	0,8802	0	REG	REG	REG
36	4771	64225	23	555	3441	23	10	32	0,075	59	20	24,4	0,8841	11,85	REG	INCONCLU	SAT
13	4572	25998	3	356	1194	0,3	0,6	0,1	0	74,7	8	0	0	0,25	ADIT	SAT	SAT
78	18691	75849	14	375	3477	115	22	145	0,056	33,1	44	22,4	0,8796	0	REG	REG	REG
142	3569	73749	83	84	956	128	86	2	0,015	72,9	6	40,3	0,8836	0,57	SAT	REG	SAT
59	15021	67313	5	276	1511	5	6	2	0	89,6	8	0	0	0,16	SAT	SAT	SAT
3	1375	5502	2	21	106	1	0,2	1	0	81,8	8	0	0	1,76	SAT	SAT	SAT

14	3504	86879	23	92	895	2	53	1	0	66	20	0	0	0	RECOND	INCONCLU	RECOND
55	3780	69760	8	544	3118	8	2	0,4	0,009	66	16	36,8	0,8881	2,56	SAT	INCONCLU	SAT
112	8402	63684	25	408	4917	205	34	228	0,066	27,7	68	24,8	0,8799	3,16	REG	REG	REG
216	2761	59943	336	629	2205	423	61	2	0	0	4	0	0	0	SAT	REG	RECOND
9	3113	76178	12	576	2613	32	4	0,2	0	91,8	5	0	0	1,08	SAT	SAT	SAT
20	12811	73030	5	295	3604	33	1	28	0,002	63,4	19	36,1	0,8816	1,46	ADIT	INCONCLU	ADIT
188	4458	64898	20	481	3497	95	18	25	0	66,8	21	21,5	0,8801	0	REG	INCONCLU	REG
29	7921	48571	9	19	743	2	13	0,6	0	77,5	6	0	0	0,51	SAT	SAT	SAT
39	4090	39004	13	63	382	6	13	0,4	0,009	43,5	24	37,7	0,8727	0	RECOND	INCONCLU	SAT
15	37180	1237	21	70	1007	2	26	0,3	0	54	25	0	0	0	RECOND	INCONCLU	SAT
141	17765	78228	28	384	3464	163	29	195	0	62,6	21	24,8	0,8788	0	REG	INCONCLU	REG
37	3063	29274	32	124	828	3	68	0,1	0	51,5	30	0	0	0	RECOND	INCONCLU	RECOND
7	25827	126664	6	701	4753	83	2	0,7	0,039	60,3	22	31,1	0,8827	1,94	ADIT	INCONCLU	ADIT
72	1256	26028	129	231	2149	115	85	0,1	0,016	81,7	8	31,2	0,8766	1,39	SAT	REG	SAT
61	4836	69735	27	91	562	8	39	1	0	65,3	10	0	0	0,45	SAT	SAT	SAT
59	6288	73629	14	425	3626	39	22	15	0	76,3	24	0	0	0	REG	INCONCLU	REG
125	6344	92696	115	539	3106	16	191	0,5	0,174	25,8	56	20,2	0,882	7,3	REG	REG	REG
21	3249	18130	19	109	380	2	45	0,5	0	33	10	0	0	0	SAT	REG	REG
16	3750	26406	19	66	1196	2	23	0,4	0	84,9	11	0	0	0,94	SAT	SAT	SAT
16	9456	57158	9	365	3445	112	6	14	0	82,1	11	0	0	2,69	SAT	SAT	SAT
13	4572	25998	3	356	1194	0,3	0,6	0,1	0	74,7	8	0	0	0,25	ADIT	SAT	SAT
110	10555	63186	20	394	2947	125	24	142	0	50,2	31	24	0,8792	0	REG	INCONCLU	REG
60	21842	68148	12	328	4602	61	10	32	0	64	19	22,7	0,8664	0	REG	INCONCLU	SAT
255	4129	69399	132	408	1891	151	294	48	0	26,8	55	0	0	0	RECOND	REG	RECOND
21	3742	16417	6	38	280	0,5	11	0,3	0	83,8	18	43,1	0,8854	0,49	SAT	INCONCLU	SAT
30	2260	51595	79	146	2617	3	180	0,6	0,005	82,5	9	40,3	0,8871	0,23	SAT	REG	SAT
56	1718	63388	117	719	3838	116	25	0,6	0,027	85,6	11	36,3	0,8816	1,39	SAT	REG	SAT
17	17358	77064	20	376	1867	58	5	0,3	0	0	5	0	0	0	SAT	REG	SAT
17	2246	42059	33	150	1550	4	29	0,3	0,019	76,9	10	36,1	0,8851	1,43	SAT	REG	SAT
15	4765	28931	7	185	645	3	1	32	0	79	12	0	0	0	REG	REG	ADIT
29	7458	58507	5	344	3093	23	1	3	0	68,7	19	0	0	3,12	SAT	INCONCLU	SAT
5	3023	57400	64	146	2036	4	93	0,1	0	87,4	13	0	0	1,41	SAT	SAT	SAT
125	3030	64632	67	427	1808	7	121	1	0,079	75,4	22	23,8	0,8917	10,5	REG	INCONCLU	REG

107	12104	69028	25	309	2650	151	23	202	0,083	45,6	29	22,6	0,8766	0	REG	INCONCLU	REG
22	11351	71693	4	993	3259	82	3	0,7	0,031	72,7	8	32	0,8826	1,16	ADIT	REG	SAT
127	4231	82506	22	528	3365	53	18	39	0	69,4	14	24,3	0,8819	0	REG	REG	REG
38	23783	73093	7	331	3920	55	8	24	0,065	67,2	29	22,4	0,8667	7,34	REG	INCONCLU	SAT
28	4955	21986	2	146	720	0,2	0,2	0,7	0,006	89,8	7	44,1	0,8904	0,13	ADIT	REG	ADIT
25	3879	14152	9	37	233	4	5	2	0	73,3	20	0	0	0,64	SAT	INCONCLU	SAT
57	3645	61964	114	346	1252	12	191	15	0	74,8	20	0	0	0	SAT	INCONCLU	REG
29	17947	70623	5	318	3516	31	6	8	0,118	53,6	16	21,8	0,8802	6,1	REG	INCONCLU	SAT
65	3328	81866	152	171	4747	21	248	1	0	89,3	13	0	0	0,69	SAT	SAT	RECOND
35	6644	34767	54	272	983	9	12	0,3	0,028	85,5	7	37,8	0,8812	0,64	SAT	REG	REG
34	11170	39876	2	239	983	0,7	0,7	0,2	0,001	70,3	20	37,7	0,8886	1,56	ADIT	INCONCLU	SAT
20	12811	73030	5	295	3604	33	1	28	0,002	63,4	19	36,1	0,8816	1,46	ADIT	INCONCLU	ADIT
229	1640	62904	503	679	2202	632	102	2	0	0	7	0	0	0	SAT	REG	SAT
211	5311	56133	107	410	1986	32	77	59	0	12	75	0	0	0	RECOND	REG	SAT
430	4663	27848	23	28	2130	4	24	3	0	0	16	0	0	0	SAT	REG	REG
141	3419	61954	36	385	2099	5	28	0,8	0,067	78,5	25	25,9	0,8903	6,06	SAT	INCONCLU	RECOND
57	11497	67547	8	436	4754	58	13	80	0,147	64,2	24	21,7	0,8761	0	REG	INCONCLU	SAT
28	23849	78995	16	306	3895	55	8	23	0,1	76,8	15	21	0,8792	6,46	REG	INCONCLU	SAT
1289	9565	78353	22	551	4691	29	12	30	0,134	50,8	20	20,3	0,8791	0	REG	INCONCLU	REG
22	7967	55407	3	339	3438	16	4	1	0	52,7	15	0	0	0,97	SAT	INCONCLU	SAT
63	2541	74334	19	276	2816	21	5	0,8	0	59,6	17	0	0	1,13	SAT	INCONCLU	SAT
40	4868	67412	65	269	2205	15	48	1	0,008	77,9	14	36,7	0,8846	0,62	SAT	REG	SAT
28	14212	68060	6	287	2638	10	1	6	0,016	75,8	18	35,8	0,8842	1,95	SAT	INCONCLU	SAT
47	2560	74930	8	725	5827	118	3	0,6	0,041	46,1	20	32,5	0,883	2,17	ADIT	INCONCLU	SAT
82	2220	44807	11	516	3708	2	2	0,5	0	89,6	8	0	0	0,57	SAT	SAT	SAT
23	13766	43041	3	333	2512	35	2	8	0	0	12	0	0	0	SAT	REG	SAT
139	3515	66492	57	535	1738	50	34	213	0,07	91,2	11	24,9	0,885	23,25	REG	REG	REG
103	5100	60808	24	359	1925	6	17	0,2	0,071	71,3	24	26,3	0,8899	0	SAT	INCONCLU	RECOND
28	4955	21986	2	146	720	0,2	0,2	0,7	0,006	89,8	7	44,1	0,8904	0,13	ADIT	REG	ADIT
13	6074	83485	14	474	4078	18	4	9	0,015	72	15	38,2	0,8868	0,78	SAT	INCONCLU	SAT
28	4955	21986	2	146	720	0,2	0,2	0,7	0,006	89,8	7	44,1	0,8904	0,13	ADIT	REG	ADIT
904	4360	40390	30	53	2853	8	32	7	0	0	25	0	0	0	RECOND	REG	RECOND
151	3533	76380	80	457	2236	10	148	2	0	61,5	23	0	0	0	REG	INCONCLU	REG