UNIVERSIDADE FEDERAL FLUMINENSE ESCOLA DE ENGENHARIA DEPARTAMENTO DE ENGENHARIA ELÉTRICA PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA E DE TELECOMUNICAÇÕES

BRUNO RAMOS SODRÉ

REDES NEURAIS ARTIFICIAIS PARA A PREVISÃO DO TEMPO PARA FALHA DE TRANSFORMADORES DE POTÊNCIA UTILIZANDO VARIÁVEIS OPERACIONAIS

NITERÓI 2021

BRUNO RAMOS SODRÉ

REDES NEURAIS ARTIFICIAIS PARA A PREVISÃO DO TEMPO PARA FALHA DE TRANSFORMADORES DE POTÊNCIA UTILIZANDO VARIÁVEIS OPERACIONAIS

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Engenharia Elétrica e de Telecomunicações da Universidade Federal Fluminense como requisito parcial para Obtenção do Grau de Mestre em Engenharia Elétrica e de Telecomunicações.

Área de concentração: Sistemas de Energia Elétrica.

Orientadores Prof. Guilherme Gonçalves Sotelo, D.Sc. Prof. Vitor Hugo Ferreira, D.Sc.

> Niterói 2021

Bruno Ramos Sodré

REDES NEURAIS ARTIFICIAIS PARA A PREVISÃO DO TEMPO PARA FALHA DE TRANSFORMADORES DE POTÊNCIA UTILIZANDO VARIÁVEIS OPERACIONAIS

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Engenharia Elétrica e de Telecomunicações da Universidade Federal Fluminense como requisito parcial para a Obtenção do Grau de Mestre em Engenharia Elétrica e de Telecomunicações.

Área de concentração: Sistemas de Energia Elétrica.

BANCA EXAMINADORA

alle me hanco

Prof. Dr. Guilherme Gonçalves Sotelo - Orientador Universidade Federal Fluminense - UFF

> Assinado de forma digital por VITOR HUGO FERREIRA vhferreira@id.uff.br:01277679673 Dados: 2021.04.08 19:10:13 -03'00'

Prof. Dr. Vitor Hugo Ferreira - Orientador Universidade Federal Fluminense - UFF

have Ember A.K

Prof. Dr. Marcio Zamboti Fortes Universidade Federal Fluminense - UFF

Prof. Dr. Alexandre Rasi Aoki Universidade Federal do Paraná - UFPR

Niterói (março/2021)

DEDICATÓRIA

Aos meus pais, Ana e Jair, que sempre foram uma referência de vida pessoal e profissional.

A minha esposa, Renata, que sempre me apoiou em todos os momentos.

AGRADECIMENTOS

Agradeço primeiramente a Deus por sempre ter me mostrado o caminho certo em diversas dificuldades encontradas durante essa caminhada.

À minha mãe, Eng. Ana Maria Pinto Ramos, que sempre foi uma referência de vida pessoal e profissional. Agradeço sua admirável força de vontade, por formar a mim e meu irmão, como pessoas de bem, apesar das grandes dificuldades que a vida nos impôs.

Em memória, ao meu pai, Eng. Jair Pereira Sodré, agradeço as memórias de infância ao seu lado.

À minha esposa, Renata Costa Mendes Franco, por me apoiar em todos os desafios de vida e de carreira.

Ao meu filho, Lucas Mendes Franco Sodré, por trazer uma alegria infinita as nossas vidas.

Em memória, a minha avó, Aracy Pinheiro Ramos, que foi parte essencial da minha criação.

Ao meu irmão, Jair Ramos Sodré, por me apoiar e incentivar em todos os meus projetos de vida.

Aos meus orientadores, Guilherme Gonçalves Sotelo e Vitor Hugo Ferreira, por me apoiarem no tema proposto, e estarem sempre presentes durante o andamento deste trabalho.

"A persistência é o menor caminho do êxito"

Charles Chaplin

RESUMO

Métodos clássicos de diagnóstico de falhas, como por exemplo, a análise de gases dissolvidos no óleo do transformador, podem ser utilizados com o objetivo de realizar a previsão de falhas em transformadores de potência. Esta análise tem como objetivo determinar as concentrações de gases formados a partir de uma determinada falha no equipamento. A utilização de sensores para o monitoramento da concentração desses gases, pode ser aplicada, porém o custo para implementação destes pode se tornar relevante quando considerados transformadores de potência como os contemplados no escopo deste trabalho, os quais apresentam potência nominal de 2 ou 3 MVA.

Assim, esse trabalho tem como objetivo propor um modelo baseado em inteligência artificial, utilizando redes neurais artificiais, que tem como finalidade estimar o tempo para a falha de transformadores de potência. A metodologia proposta utiliza como dados de entrada grandezas operacionais, como a corrente de operação em regime e correntes de curto-circuito. A denominação do fabricante do equipamento também é considerada como uma variável de entrada. A maioria dos trabalhos encontrados na literatura considera como variáveis de entrada os dados das concentrações de gases dissolvidos no óleo do transformador. Dessa forma, há uma carência de estudos que não utilizem estes dados. A contribuição desta dissertação é propor um estudo que estima o tempo de falha em transformadores sem utilizar informações das concentrações dos gases dissolvidos no óleo do transformador.

A arquitetura dos modelos de RNAs utilizadas foram MLPs com uma camada escondida, processo de aprendizagem do tipo supervisionado e algoritmo de aprendizagem do tipo retropropagação do erro. A determinação da quantidade ótima de neurônios na camada escondida foi estabelecida a partir do processo de variação desses neurônios na etapa de simulações. Este trabalho considerou 21 subestações, nas quais foram constatadas pelo menos uma falha em seus transformadores de potência (posições de transformação), a partir de janeiro de 2016. Foram modeladas redes neurais para cada uma das posições de transformação individualmente, bem como uma única rede neural que representasse todas as posições.

O modelo de rede neural que representava as posições de cada transformação individualmente apresentou erros médios, em sua maioria, inferiores a 30 dias. Já a representação que considerava o modelo genérico apresentou desempenho bastante inferior, visto que apenas uma posição apresentou erro médio menor do que 30 dias.

Palavras-chave: Transformadores de Potência, Redes Neurais Artificiais, Diagnóstico de falhas em transformadores

ABSTRACT

Classical fault diagnosis methods, such as the analysis of gases dissolved in the transformer oil, can be used in order to carry out the prediction of failures in power transformers. This analysis aims to determine the concentrations of gases formed from a certain failure in the equipment. The use of sensors to monitor the concentration of these gases can be applied, but the cost for implementing them can become relevant when considering power transformers such as those contemplated in the scope of this work, which have a nominal power of 2 or 3 MVA.

Thus, this work aims to propose a model based on artificial intelligence, using artificial neural networks, which aims to estimate the time for the failure of power transformers. The proposed methodology uses operational data as inputs, such as the operating current in regime and short-circuit currents. The designation of the equipment manufacturer is also considered an input variable. Most of the works found in the literature consider as inputs data the concentrations of gases dissolved in the transformer oil. Thus, there is a lack of studies that do not use these data. The contribution of this dissertation is to propose a study that estimates the failure time in transformers without using the concentrations of gases dissolved in the transformer oil.

The architecture of the RNA models used was MLPs with a hidden layer, supervised learning process and error propagation learning algorithm. The determination of the optimum quantity of neurons in the hidden layer was established from the process of variation of these neurons in the simulations stage. This work considered 21 substations, in which at least one failure was found in their power transformers (transformation positions), as of January 2016. Neural networks were modeled for each of the transformation positions individually, as well as a single network neural system that represented all positions.

The model of neural network that represented the positions of each transformation individually showed average errors, mostly, less than 30 days. The representation that considered the generic model had a much lower performance, since only one position had an average error less than 30 days.

Keywords: Power Transformers, Artificial Neural Networks, Fault diagnosis in transformers

LISTA DE FIGURAS

Figura 1 - Dados de compensações financeiras pagas pelas distribuidoras, devido a violação	
dos indicadores de continuidade	.2
Figura 2 – Foto do modelo padrão de subestação, contemplado no espoco desta dissertação	.4
Figura 3 – Porcentagem relativa da concentração de gases dissolvidos em função da	
temperatura	.9
Figura 4 – Triângulo de Duval	11
Figura 5 – Categorização dos tipos de falhas	16
Figura 6 – Esquema de conexão do ensaio FRA	22
Figura 7 - Testes do ensaio FRA. a) circuito aberto; b) curto-circuito; c) capacitância entre	
enrolamentos; d) indutância entre enrolamentos	23
Figura 8 - Resposta da magnitude do ensaio SFRA, no ensaio de circuito aberto	23
Figura 9 - Resposta da fase do ensaio SFRA, no ensaio de circuito aberto	24
Figura 10 - Deslocamento radial do enrolamento de um transformador de potência	25
Figura 11 - Deslocamento axial do enrolamento de um transformador de potência	25
Figura 12 - Modelo não-linear de um neurônio	27
Figura 13 - MLP de múltiplas camadas	28
Figura 14 - Função de Limiar	29
Figura 15 - Função Linear por Partes	30
Figura 16 – Função Sigmóide	30
Figura 17 – Diagrama de blocos ilustrando o processo de aprendizagem supervisionado	32
Figura 18 – Ilustração da propagação para a frente no algoritmo de retropropagação do erro	35
Figura 19 - Ilustração da propagação para trás no algoritmo de retropropagação do erro	36
Figura 20 – Representação de um modelo com ajuste excessivo de dados (overfitting)	37
Figura 21 – Ilustração do método early stopping	39
Figura 22 - Variáveis acumuladas referentes as correntes de CC simétricas relativas a posiçã	0
TUT1	47
Figura 23 - Variáveis acumuladas referentes aos períodos acumulados de sobrecarga relativo)S
a posição TUT1	51
Figura 24 - Variáveis acumulada referente a redução percentual de vida útil devido ao ciclo	de
carregamento do transformador de potência, relativo a posição TUT1	52
Figura 25 – Fluxograma utilizado para a realização das simulações	57
Figura 26 – Resultado das simulações referentes ao cenário 0	60
7	/iii

Figura 27 – Resultado das simulações referentes ao cenário 1	62
Figura 28 – Resultado das simulações referentes ao cenário 2	65
Figura 29 – Resultado das simulações referentes ao cenário 3	68
Figura 30 – Resultado das simulações referentes ao cenário 4	71
Figura 31 – Resultado das simulações que obtiverem os melhores resultados nos cenários	
simulados	74
Figura 32 – Desempenho dos modelos de RNAs que consideram todas as posições	75
Figura 33 – Desempenho de cada posição considerando o modelo de RNA com melhor	
desempenho	77

LISTA DE TABELAS

abela 1 - Taxas de Falha em transformadores de potência no período de 1968 a 20053							
abela 2 - Dados típicos dos transformadores de potência estudados no escopo desta							
dissertação3							
Tabela 3 - Orçamento referente a instalação de sistema de monitoramento on-line de umidade							
e gases dissolvidos no óleo							
Tabela 4 - Método de Rogers10							
Tabela 5 – Tabela das concentrações de gases considerada no método do triângulo de Duval							
Tabela 6 - RNAs propostas em [26]14							
Tabela 7 – Exemplos de classificações do local e causa de falhas em transformadores15							
Tabela 8 – Valores mínimos de impedâncias de CC sugeridos pela norma IEC 60076-5 18							
Tabela 9 – Valores máximos permissíveis da temperatura média de cada enrolamento após							
evento de CC19							
Tabela 10 – Fatores de pico em função da relação X/R21							
Tabela 11 – Exemplos de funções sigmoidais							
Tabela 12 – Resumo do algoritmo de atualização de pesos sinápticos considerando o							
perceptron de camada única							
Tabela 13 – Entradas para cada variável inicial43							
Tabela 14 – Histórico de falhas das posições de transformação contempladas no escopo deste							
trabalho44							
Tabela 15 – Variáveis de entrada que representam a posição do transformador de potência48							
Tabela 16 – Variáveis de entrada que representam o fabricante de cada transformador de							
potência49							
Tabela 17 – Variáveis derivadas da variável inicial: corrente eficaz simétrica de CC50							
Tabela 18 – Variáveis derivadas da variável inicial: tempo em sobrecarga53							
Tabela 19 – Descrição das varáveis utilizadas nos cenários das simulações							
Tabela 20 - Comparação do desempenho dos modelos de RNA, considerando as varáveis de							
entrada consideradas nos cenários 0 e 1							
Tabela 21 - Comparação do desempenho dos modelos de RNA, considerando as varáveis de							
entrada consideradas nos cenários 0, 1 e 266							
Tabela 22 - Comparação do desempenho dos modelos de RNA, considerando as varáveis de							
entrada consideradas nos cenários 0, 1, 2 e 369							

Tabela 23 - Comparação do desempenho dos modelos de RNA, considerando as varáveis de	e
entrada consideradas nos cenários 0, 1, 2 e 3.	.72

SUMÁRIO

1	INT	ſRO	DUÇÃO	1
	1.1	CO	NSIDERAÇÕES INICIAIS	1
	1.2	MC	DTIVAÇÃO	2
	1.3	OB	JETIVO	4
	1.4	CO	NTRIBUIÇÃO	4
	1.5	EST	ΓRUTURA DA DISSERTAÇÃO	6
2	MÉ	TO	DOS DE DIAGNÓSTICO DE FALHAS EM TRANSFORMADORES DE	
P	OTEN	CIA		7
	2.1	AN	ÁLISE DE GASES DISSOLVIDOS	7
	2.2 RESU	MÉ ILTA	TODOS CLÁSSICOS DE DIAGNÓSTICOS DE FALHAS UTILIZANDO ADOS DA DGA	8
	2.2	.1	Método de Rogers	9
	2.2	.2	Método do Triângulo de Duval	10
	2.3 IA	RE [*] 12	VISÃO BIBLIOGRÁFICA DO DIAGNÓSTICOS DE FALHAS UTILIZAND	0
	2.4	CL	ASSIFICAÇÃO DE FALHAS	15
	2.4	.1	Falhas térmicas	16
	2.4	.2	Falhas Elétricas	17
	2.4	.3	Falhas Mecânicas	17
	a)	S	uportabilidade térmica a eventos de CC	18
	b)	S	uportabilidade dinâmica a eventos de CC	20
	c)	F	Trequency Response Analysis (FRA)	21
	2.5	CO	NSIDERAÇÕES FINAIS	26
3	RE	DES	NEURIAS ARTIFICIAS	27
	3.1	INT	TRODUÇÃO	27
	3.2	FUI	NÇÕES DE ATIVAÇÃO	28
	3.2	.1	Função de Limiar	29
	3.2	.2	Função Linear por Partes	29
	3.2	.3	Função Sigmóide	30
	3.3	PRO	OCESSOS DE APRENDIZAGEM	31
	3.3	.1	Aprendizagem Supervisionada	31
	3.3	.2	Aprendizagem Não Supervisionada	32
	3.4	PE	RCEPTRON DE CAMADA ÚNICA	33

	3.5	PER	RCEPTRON DE MÚLTIPLAS CAMADAS	34	
	3.6	5 MÉTODOS DE CONVERSÃO DE ESCALAS			
	3.6	.1	Normalização	38	
	3.6	.2	Padronização	38	
	3.7	EAF	RLY STOPPING	38	
	3.8	COI	NSIDERAÇÕES FINAIS	40	
4	ME	TOI	DOLOGIA PROPOSTA	41	
	4.1	CAI	RACTERIZAÇÃO DO PROBLEMA	41	
	4.2	MO	DELO DE DADOS DE ENTRADA E SAÍDA DAS RNAS	42	
	4.2.	.1	Posição do Transformador	45	
	4.2	.2	Fabricante	45	
	4.2.	.3	Corrente eficaz simétrica de CC	45	
	4.2	.4	Tempo em sobrecarga	51	
	4.3	DES	SCRIÇÃO DOS CENÁRIOS PROPOSTOS PARA AS SIMULAÇÕES	54	
	4.4	AR	QUITETURA DA RNA UTILIZADA	56	
5	RE	SUL	TADOS	58	
	5.1 CONS	RES SIDE	SULTADOS DAS SIMULAÇÕES DOS MODELOS DE RNAS RANDO CADA POSIÇÃO DE TRANSFORMAÇÃO	58	
	5.1. Cer	.1 nário	Resultados das simulações considerando as variáveis de entrada propostas no 0	59	
	5.1. Cer	.2 nário	Resultados das simulações considerando as variáveis de entrada propostas no 1	61	
	5.1. Cer	.3 nário	Resultados das simulações considerando as variáveis de entrada propostas no 2	63	
	5.1. Cer	.4 nário	Resultados das simulações considerando as variáveis de entrada propostas no 3	66	
	5.1. Cer	.5 nário	Resultados das simulações considerando as variáveis de entrada propostas no 4	69	
	5.1	.6	Conclusões Parciais	72	
	5.2 TODA	RES AS A	SULTADOS DAS SIMULAÇÕES DO MODELO DE RNA CONSIDERAND S POSIÇÕES DE TRANSFORMAÇÃO	0 75	
	5.3	COI	NSIDERAÇÕES FINAIS	76	
6	CO	NCL	USÕES E TRABALHOS FUTUROS	78	
	6.1	COI	NCLUSÕES	78	
	6.2	TRA	ABALHOS FUTUROS	79	
R	EFER	ÊNC	CIAS	80	

1 INTRODUÇÃO

1.1 CONSIDERAÇÕES INICIAIS

O suprimento contínuo de energia elétrica é uma realidade mundial, de modo que a infraestrutura necessária para garantir esse suprimento tem se tornado um desafio para os seguimentos de operação e manutenção de distribuidoras e transmissoras, as quais muitas vezes admitem condições severas de operação dos equipamentos da rede. Neste cenário, o transformador de potência fica suscetível a diferentes tipos de falhas, que podem ocasionar interrupções no fornecimento de energia.

Conforme descrito em [1] o monitoramento dos transformadores de potência é essencial para a avaliação da vida útil remanescente desses equipamentos.. Assim, uma possível falha pode ter como consequência, uma interrupção de longa duração, influenciando no fornecimento de energia elétrica aos clientes atendidos por esse equipamento. Adicionalmente, o impacto para a distribuidora está relacionado com a degradação dos indicadores de continuidade individuais e coletivos do fornecimento de energia elétrica, definidos pela Agência Nacional de Energia Elétrica (ANEEL), os quais são estabelecidos nos Procedimentos de Distribuição de Energia Elétrica no Sistema Elétrico Nacional (PRODIST), módulo 08 [2].

Para ilustrar o impacto nas contas das concessionárias de distribuição de energia elétrica, as compensações financeiras decorrentes de interrupções de longa duração, as quais violaram os indicadores individuais, somaram cerca de R\$ 1.500 milhões entre 2017 e 2019 [3], conforme a Figura 1.

Assim o tema referente a melhoria na continuidade do fornecimento de energia é bastante atual e cada vez mais exigido pelo órgão regulador, desta forma gerando como consequência para as distribuidoras o aprimoramento da gestão dos ativos que concentram grande número de clientes.

Neste viés, falhas em transformadores de potência de subestações podem ter impacto relevante nos indicadores de continuidade, tendo em vista que concentram milhares de clientes.



Figura 1 - Dados de compensações financeiras pagas pelas distribuidoras, devido a violação dos indicadores de continuidade Fonte: Adaptado de [3]

1.2 MOTIVAÇÃO

Na literatura existem diversas definições para o termo falha, onde umas são mais abrangentes como as normas IEEE C57-125 [4] e IEC 60050 [5], que consideram como falha, a retirada de um equipamento de serviço pelo tempo de operação, mesmo este desempenhando suas funções.. Em contrapartida, em [6], a definição de falha é mais restrita, considerando apenas ocorrências em equipamentos que resultam na retirada de operação do mesmo por defeito. Apesar das diferenças entre as definições, ambos consideram divisões das falhas de acordo com a severidade, tempo e tipos de interrupção.

Conforme [7], a estatística de taxas de falhas em transformadores de potência é bastante limitada na literatura, tendo em vista que os resultados e as metodologias das pesquisas direcionadas às empresas de serviços de energia elétrica no mundo não são disponibilizadas publicamente devido a confidencialidade e a concorrência entre elas. Alguns países como Austrália, Brasil, Canadá, Alemanha e Japão possuem bases de dados consolidadas através de pesquisas internas referentes ao tema em questão. De modo a estabelecer um valor de *benchmark*, a Tabela 1, apresenta as taxas de falha de pesquisas realizadas em alguns países no período de 1968 a 2005 [7], pode ser utilizada como referência, visto que a divulgação deste dado pelas distribuidoras e transmissoras é

bastante limitada. A percepção prática de algumas distribuidoras do Brasil em relação a taxa de falhas de transformadores de potência é que, equipamentos com fabricação mais recente, apresentam maior taxa de falha.

A motivação para a realização do presente trabalho está fundamentada no impacto financeiro e social decorrente de falhas em transformadores de potência de subestações de uma distribuidora de energia elétrica, que apresentou nos últimos quatro anos taxa de falha próximo de 10%. A Tabela 1, apresenta índices de falhas típicos para transformadores de potência, os quais são bastante reduzidos, quando comparados as taxas de falha dos transformadores de potência do escopo deste trabalho. Os transformadores de potência estudados no escopo desta dissertação estão presentes em subestações que podem chegar a uma configuração final de 12 MVA (quatro transformadores de 3 MVA), as quais atendem em média 4.000 clientes. Como exemplo, a Tabela 2apresenta os dados típicos dos transformadores estudados. Já a Figura 2, apresenta uma foto que ilustra o modelo padrão de subestação estudado.

Pesquisa	Aplicação/Classificação	Período de Falha	Taxa de Falha (%)
Cigré Internacional	Todos os níveis de tensão (60 kV - 700 kV)	1968-1978	2
Reino Unido	Todos os níveis de tensão	Antes de 1987	< 2
US-NGRID, Estados Unidos	Distribuição (115 kV,69 kV, >69 kV)	-	0,35 - 0,8
Hydro Quebec, Canada	Todos os níveis de tensão	-	< 0,5
American Electric Power	345 kV e 765 kV	Antes de 1986	1,3 - 2,9
American Electric Power	345 kV e 765 kV	Antes de 1986	0,35 - 1,35
Austrália e Nova Zelândia	Faltas com impacto financeiro elevado	Antes de 1996	0,4

Tabela 1 - Taxas de Falha em transformadores de potência no período de 1968 a 2005Fonte: Adaptado de [7]

Tabela 2 - Dados típicos dos transformadores de potência estudados no escopo desta dissertaçãoFonte: Elaborado pelo autor

Fases	Frequência (Hz)	Impedância (%)	Potência (kVA)	Tensão Nominal(kV)	Óleo Isolante	Volume (l)
3	60	5,58	3.000	25,5/13,8	Parafínico	2.000
Te	ensões Suporta	áveis (kV)		AT	ВТ	
Frequência Industrial			70		15	
	Impulso Atmo	osférico	170		110	



Figura 2 – Foto do modelo padrão de subestação, contemplado no espoco desta dissertação Fonte: Elaborado pelo autor

1.3 OBJETIVO

Os transformadores de potência passam por manutenções preventivas, realizadas de forma periódica, e por manutenções preditivas, as quais são realizadas com base na operação em tempo real do equipamento. A estimativa do tempo para falha acaba se tornando uma variável relevante para o planejamento das manutenções preditivas, bem como para tomada de decisão pelo centro de operações de realizar o impedimento do equipamento.

Assim, o objetivo deste trabalho é fundamentado em evitar a falha de transformadores de potência, assim monitorando o tempo para a falha desse equipamento.

Dessa forma, é proposta nessa dissertação um modelo baseado em Inteligência Artificial (IA), utilizando Redes Neurais Artificiais (RNAs), com o objetivo de estimar o tempo para falha de transformadores de potência.

1.4 CONTRIBUIÇÃO

Na literatura, a maioria dos trabalhos relacionados ao tema referente a previsão de falhas em transformadores de potência consideram como dado de entrada as concentrações ou relações entre gases dissolvidos no óleo em tempo real [8]–[14], de forma que para a obtenção destas grandezas são necessários sensores específicos e

infraestrutura de comunicação na subestação. As subestações no escopo deste trabalho atendem predominantemente a áreas rurais, com menor quantidade de clientes quando comparadas a subestações projetadas para atendimento a grandes centros urbanos. Aquelas, apresentam padrão simplificado, com barramentos ao tempo, sem casa de comando e com proteção realizada por chave fusível, no primário do transformador e religador no secundário do mesmo. O transformador de potência vinculado ao padrão em questão pode ter potência de 2 MVA ou 3 MVA.

Assim, uma justificativa para a utilização de uma metodologia alternativa à que considera a previsão de falhas utilizando relações de gases dissolvidos em tempo real se dá por conta do custo de implantação dessa solução nas subestações contempladas no escopo desse trabalho. Nesse sentido, o transformador apresenta o maior custo referente a parte elétrica, com custo médio de R\$ 150.000,00 na data da escrita desta dissertação. Assim a implantação de sensores com o objetivo de monitorar os gases dissolvidos no óleo do transformador apenas faria sentido caso o custo de implantação fosse muito menor que o valor do transformador. Um orçamento referente a implantação destes sensores está mostrado na Tabela 3, o qual foi cotado no ano de 2019, desta forma, atualizando esses valores com o câmbio atual, o custo deste sistema ultrapassa o valor do transformador.

lt	Código	Descrição do Produto ou Serviço	Qtde	Valor Unitário c/Impostos (R\$)
		SISTEMA DE MONITORAMENTO ON		
1	1SYA011A	LINE DE UMIDADE E GASES EM OLEO - Modelo: HYDRAN M2	1	126.985,00

 Tabela 3 - Orçamento referente a instalação de sistema de monitoramento on-line de umidade e gases dissolvidos no óleo

 Fonte: Elaborado pelo autor

Portanto fica evidente que a aplicação do sistema de monitoramento dos gases dissolvidos não é viável para o nicho de transformadores de potência estudados. Logo, é proposto neste trabalho, que acaba se tornando sua principal contribuição, a utilização de dados de entrada para o modelo de previsão que tentem retratar a degradação da vida útil do transformador e que ao mesmo tempo estejam disponíveis nos centros de controle.

Para o estudo de caso proposto foram utilizadas as seguintes variáveis: carregamento, eventos de curtos-circuitos (CC) na rede de distribuição e o fabricante do transformador.

1.5 ESTRUTURA DA DISSERTAÇÃO

O presente trabalho está dividido em seis capítulos, da seguinte forma. No capítulo 1, são apresentadas as considerações iniciais sobre o tema proposto, a motivação e objetivo do trabalho, bem como sua contribuição.

No capítulo 2, é realizada uma revisão bibliográfica acerca das metodologias utilizadas para o diagnóstico de falhas em transformadores de potência, bem como as possíveis classificações de falhas nesses equipamentos.

No capítulo 3, é apresentada uma breve descrição sobre os modelos teóricos de RNAs, com enfoque nas redes de múltiplas camadas e algoritmo de aprendizagem do tipo retropropagação do erro.

No capítulo 4, é descrita a caracterização do problema, o modelo de dados de entrada e saída das RNAs utilizadas durante as simulações, que considerou características de operação de 21 transformadores de potência, os cenários propostos para as simulações, os quais consideram combinações de variáveis de entrada a partir do cenário base. Por fim, é apresentado a arquitetura das RNAs utilizadas nas simulações.

No capítulo 5, são apresentados os resultados de desempenho das RNAs considerando o modelo de RNA individual para cada transformador de potência, bem como o desempenho de uma única RNA representando todos os transformadores.

No capítulo 6, são apresentadas as conclusões finais do trabalho, bem como propostas de trabalhos futuros.

2 MÉTODOS DE DIAGNÓSTICO DE FALHAS EM TRANSFORMADORES DE POTÊNCIA

O diagnóstico de falhas em transformadores de potência é comumente realizado através da análise e interpretação das concentrações dos gases dissolvidos no óleo, que são formados em decorrência de estresses térmicos, mecânicos, elétricos e químicos. A interpretação desses resultados pode envolver critérios clássicos, como os métodos de Rogers e triângulo de Duval [15], [16], ou o envolvimento desses critérios atrelados a IA. A vantagem da utilização da IA na previsão de falhas se dá por conta da retirada da subjetividade de interpretação dos métodos clássicos. A grande maioria dos trabalhos na literatura utiliza como dados de entrada para as previsões de falha o monitoramento online das concentrações de gases dissolvidos no óleo, porém, nas subestações contempladas no escopo deste trabalho, que utilizam transformadores de 2 ou 3 MVA, o custo para o monitoramento desta grandeza pode ultrapassar o custo do transformador. Assim são propostas, como dados de entrada, grandezas operacionais disponíveis no Sistema de Controle e Aquisição de Dados (SCADA), como correntes de curto-circuito (CC) ocasionadas por eventos na rede de distribuição e correntes de operação.

As falhas térmicas se caracterizam pela presença de etileno (C_2H_4) e etano (C_2H_6), no óleo isolante do transformador, bem como monóxido de carbono (CO) e dióxido de carbono (CO_2), causados respectivamente pela elevação da temperatura do óleo e degradação do papel isolante. Falhas elétricas são caracterizadas pela presença de hidrogênio (H_2) e metano (CH_4), no óleo isolante do transformador, bem como acetileno (C_2H_2), causados respectivamente por descargas parciais de baixa energia e arcos elétricos no interior do equipamento. Falhas mecânicas são causadas por esforços mecânicos no transformador, provenientes de CC, que tem como consequência alteração na geometria do equipamento. Esse tipo de falha pode ser detectado através da Análise de Resposta em Frequência (FRA). Durante a especificação do transformador é imprescindível conhecer junto ao fabricante do mesmo, sua suportabilidade térmica e dinâmica, com o objetivo de dimensionar esse ativo para as condições de operação.

2.1 ANÁLISE DE GASES DISSOLVIDOS

A seção em questão tem como objetivo apresentar uma breve descrição dos métodos clássicos de análise de gases dissolvidos em transformadores de potência, visto sua relevância na literatura. Conforme descrito na seção 1.4, este trabalho tem como

objetivo propor variáveis operacionais para a previsão de falhas, tendo em vista a característica dos transformadores de 2 e 3 MVA, assim essa seção se torna importante para a contextualização do tema.

Dependendo do estresse que o transformador de potência possa ser submetido pode ocorrer a deterioração do material isolante, que a partir da análise cromatográfica do óleo isolante são detectadas concentrações de gases como: hidrogênio (H_2), metano (CH_4), acetileno (C_2H_2), etileno (C_2H_4), etano (C_2H_6), monóxido de carbono (CO) e dióxido de carbono (CO_2). Estes gases ficam dissolvidos no óleo isolante do equipamento e podem levá-lo a falha. Neste viés, o diagnostico através da Análise dos Gases Dissolvidos (DGA) é amplamente reconhecido como uma técnica de diagnóstico efetiva para a detecção de faltas incipientes no transformador. Entretanto, a interpretação clássica dos resultados referentes a DGA não envolve qualquer tipo de formulação matemática e sua interpretação é baseada em métodos heurísticos que podem variar de acordo com a experiência do analista [8]–[14]. Como métodos de diagnósticos clássicos, encontram-se as normas IEEE C57-104 [15] e IEC 60599 [16], as quais definem limites para as concentrações de gases, ou razões entre essas, utilizando os métodos: Rogers e Triângulo de Duval [15], [16].

A formação de gases no óleo do transformador depende de uma série de fatores como, por exemplo, idade, carregamento, presença de faltas internas, duração de faltas e eventos externos ao equipamento. A relação complexa entre essas variáveis é, em grande parte, a razão pela qual os métodos clássicos podem gerar certa subjetividade na interpretação dos resultados A maioria dos trabalhos relacionados ao tema na literatura, aplicam o método em transformadores de potência. Já em transformadores de distribuição (MT//BT), que contem menos óleo para diluir o gás [10], não fica claro como os limites ou razões das concentrações de aplicariam a esses transformadores.

2.2 MÉTODOS CLÁSSICOS DE DIAGNÓSTICOS DE FALHAS UTILIZANDO RESULTADOS DA DGA

Desde o desenvolvimento da DGA na década de 60 [15], muitos métodos de interpretação foram desenvolvidos, onde neste trabalho serão apresentados os dois principais métodos: Método de Rogers e Triângulo de Duval [15], [16]. A interpretação clássica do resultado da DGA associa razões das concentrações dos gases dissolvidos no óleo do transformador as falhas incipientes. Assim, serão descritos nos tópicos seguintes os principais gases dissolvidos no óleo do transformador, formados a partir da

característica de operação do mesmo [15].

- Os gases hidrogênio (H₂) e metano (CH₄) são formados inicialmente a partir de descargas parciais no interior do transformador, as quais constituem descargas de baixa energia;
- Os gases etileno (C₂H₄) e etano (C₂H₆) são formados a partir do aquecimento do óleo isolante do transformador, bem como o gás metano (CH₄);
- O gás acetileno (C₂H₂) é associado a arcos elétricos, descargas de alta energia formadas em altas temperaturas acima de 1000°C no interior do transformador, oriundos de descargas parciais não tratadas. Em transformadores com dispositivos de proteção contra a ocorrência deste tipo de evento, como fusíveis internos ou chaves, não será constatada a presença de acetileno em condições normais de operação. É comum encontrar altas concentrações de gás hidrogênio (H₂) e etileno (C₂H₄) quando detectado gás acetileno (C₂H₂). A faixa de temperatura que os gases descritos são formados, pode ser observada na Figura 3;
- Os gases monóxido de carbono (CO) e dióxido de carbono (CO₂) estão associados a degradação térmica do papel isolante do transformador.



Figura 3 – Porcentagem relativa da concentração de gases dissolvidos em função da temperatura. Fonte: Adaptado de IEEE C57-104 [15]

2.2.1 Método de Rogers

O método de Rogers associa as razões das concentrações de cinco gases (acetileno (C_2H_2) , etileno (C_2H_4) , metano (CH_4) , hidrogênio (H_2) , etano (C_2H_6)) em três razões, as quais associam os valores dessas razões ao tipo de falha do transformador. Assim, a Tabela 4 apresenta as faixas das razões das concentrações associadas ao tipo de falta, conforme determina o método de Rogers.

Caso	$C_2 H_2 / C_2 H_4$	CH_4/H_2	$C_2 H_4 / C_2 H_6$	Sugestão de Falta
0	< 0,1	0,1 até 1,0	< 1,0	Condição Normal
				Descargas Parciais (Arcos de baixa densidade
1	< 0,1	< 0,1	< 1,0	de energia)
2	0,1 até 3,0	0,1 até 1,0	3,0	Arcos de alta densidade de energia
3	< 0,1	0,1 até 1,0	1,0 até 3,0	Falta térmica de baixa temperatura
				Falta térmica com temperatura menor que
4	< 0,1	> 1,0	1,0 até 3,0	700 °C
				Falta térmica com temperatura maior que
5	< 0,1	> 1,0	> 3,0	700 °C

Tabela 4 - Método de RogersFonte: IEEE C57-104 [15]

A limitação da utilização do método de Rogers se dá por conta da não associação da razão (C_2H_2 / C_2H_4) aos limites estabelecidos na primeira coluna da Tabela 4 em uma amostra relativamente alta de resultados de DGAs, ou seja, pode ocorrer que uma amostra apresente valores da razão C_2H_2 / C_2H_4 fora dos limites estabelecidos nessa coluna, dessa forma impossibilitando seu diagnóstico segundo este método.

2.2.2 Método do Triângulo de Duval

O método do Triângulo de Duval [15] associa a concentração de três gases com o objetivo de identificar o aumento da energia ou temperatura no interior do transformador. Faltas que envolvem descargas parciais de baixa energia ou baixas temperaturas são associadas ao gás metano (CH_4). Faltas que tem como consequência altas temperaturas no interior do transformador são associadas ao gás etileno (C_2H_4). Já o gás acetileno (C_2H_2) é associado a altíssimas temperaturas, arcos elétricos e descargas parciais de alta de energia.

A concentração dos três gases descritos acima e sua associação aos tipos de faltas é representada na Figura 2 e sumarizada na Tabela 5.

A vantagem do método do triângulo de Duval se dá pelo fato de que sempre é possível associar a concentração dos gases propostos neste método a um defeito, bem como a capacidade de acompanhar visualmente a evolução de uma falha no equipamento. Por outro lado, como este método sempre propõe um diagnóstico, é necessário utilizá-lo em conjunto com outras informações que propõe uma possível falha. Assim, o fato de uma possível falha ser identificada não quer dizer que necessariamente exista.



Tabela 5 – Tabela das concentrações de gases considerada no método do triângulo de Duval Fonte: Adaptado da IEEE C57-104 [15]

Falta	Variável	%CH ₄	% <i>C</i> ₂ <i>H</i> ₄	% <i>C</i> ₂ <i>H</i> ₂
Descargas parciais do tipo corona	PD	≥ 98	-	-
Falta térmica, t < 300 ⁰C	T1	< 98	< 20	< 4
Falta térmica, 300 °C < t < 700 °C	Т2	-	$\geq 20 \ e \ < 50$	< 4
Falta térmica, t < 700 ⁰C	Т3	-	≥ 50	< 15
Zana da tuanziaña antre faltes	DT	-	< 50	$\geq 4 \ e \ < 13$
Zona de transição entre faitas		-	$\geq 40 \ e \ < 50$	$\geq 13 \ e \ < 29$
territeas/eletricas		-	≥ 50	$\geq 15 \ e \ < 29$
Descargas de baixa energia	D1	-	< 23	≥ 13
Descargas de alta oporgia	50	-	≥ 23	≥ 29
Descargas de alta effergia	D2	-	$\geq 23 \ e \ < 40$	$\geq 13 \ e \ < 29$

O método de Rogers, bem como o método do triângulo de Duval, não devem ser utilizados em amostras com baixos níveis de gases, o que pode levar a uma conclusão não confiável e imprecisa.

2.3 REVISÃO BIBLIOGRÁFICA DO DIAGNÓSTICOS DE FALHAS UTILIZANDO IA

Avanços na inteligência computacional e técnicas de aprendizado de máquina, combinadas a DGA clássica, aprimoraram rapidamente a previsão de falhas incipientes em transformadores de potência, desta forma descobrindo relações entre padrões de falha e parâmetros característicos do equipamento [8]. Redes Neurais Artificias (RNA), Sistemas Inteligentes (SI) e Lógica Fuzzy (LF), são exemplos de técnicas baseadas em IA, onde a maioria dos trabalhos na literatura utiliza como entradas as concentrações ou razões de gases da DGA para a previsão de falhas em transformadores de potência

Os SI e LF envolvem conhecimentos humanos e têm muitas aplicações, porém o grande desafio é transformar a experiência adquirida pelos especialistas em regras de decisão e funções de associação. Os resultados do diagnóstico também dependem em grande parte da representação precisa da experiência ou conhecimento humano acumulado. A LF fornece uma maneira simples de tirar conclusões a partir de informações vagas, ambíguas ou imprecisas, que de certo modo, assemelha-se a tomada de decisão humana em sua capacidade de encontrar soluções com base em dados aproximados. Esta pode ser utilizada de várias maneiras diferentes para implementar um sistema de diagnóstico, onde o mais comum é construir um conjunto de regras a partir dos quais conclusões e ações podem ser tiradas [17]. Em [18]–[20] são exemplificados trabalhos que utilizam essas técnicas.

O mecanismo de diagnóstico de falhas por RNAs difere do diagnóstico por LF ou SI, tendo em vista que aquele armazena o conhecimento em uma base, o qual é discretamente distribuído em toda a rede de acordo com a aprendizagem da amostra. Assim, sistemas complexos podem ser caracterizados com pouco conhecimento explícito usando RNAs, como, por exemplo, a relação entre gases dissolvidos no óleo e a condição de falta incipiente, a qual será detectada pela RNA através de amostras para o treinamento [11]. De modo a exemplificar essa relação, em [21]–[25] são utilizadas RNAs com arquitetura do tipo feedfoward baseadas nos Perceptrons de Múltiplas Camadas (MLP), as quais serão detalhadas no capítulo 3 A grande maioria dos trabalhos relacionados a previsão de falhas em transformadores de potência consideram como dado de entrada principal o monitoramento on-line da concentração ou relação dos gases dissolvidos no óleo do equipamento [8], [11], [18]–[25], onde a partir destes dados são aplicadas as mais diversas técnicas para a realização das previsões. Todavia, em [26], é apresentado um trabalho que não são utilizadas entradas baseadas na DGA para a previsão de falhas em transformadores de potência. O objetivo principal deste trabalho [26], é a proposição de variáveis de entrada relacionadas a operação do transformador com o propósito de treinar seis RNAs individuais. A partir dos melhores resultados encontrados dessas RNAs, é possível combina-las em uma única RNA. Detalhando as entradas proposta pelo autor, temos:

- Idade do transformador, em meses (1 entrada)
- Potência nominal do transformador, em kVA (1 entrada);
- Local de instalação do transformador: rede aérea ou subterrânea (2 entradas binárias);
- Condição do tempo, onde são sugeridas 7 opções para esta variável (3 entradas binárias);
- Buchas danificadas: bucha primária, bucha secundária, ambas ou nenhuma (2 entradas binárias);
- Invólucro danificado: invólucro primário, invólucro secundário, ambos ou nenhum (2 entradas binárias);
- Vazamento de óleo: vazamento no primário, vazamento no secundário, ambo ou nenhum (2 entradas binárias);
- Falta no enrolamento: falta no enrolamento primário, falta no enrolamento secundário, ambos ou nenhum (2 entradas binárias).

Assim, os dados referentes as 14 entradas mencionadas acima, são utilizados para o treinamento de seis RNAs, individuais, que tem como objetivo representar o comportamento de seis variáveis, as quais cada uma tem uma quantidade de saídas desejadas. Detalhando as propostas das variáveis selecionadas para cada RNA, temos:

- Idade do transformador (três saídas possíveis);
- Tempo (quatro saídas possíveis);

- Buchas danificadas (três saídas possíveis);
- Invólucro danificado (quatro saídas possíveis)
- Vazamento de óleo (duas saídas possíveis)
- Falta no enrolamento (sete saídas possíveis)

O treinamento para as seis RNAs individuais é realizado com o mesmo conjunto de dados, após, são selecionadas as RNAs com melhor desempenho, baseadas nos menores erros percentuais encontrados. Essas RNAs são combinadas de forma a determinar uma única RNA que melhor represente o comportamento esperado para cada RNA individual. A Tabela 6, apresenta os melhores resultados obtidos para as 06 RNAs individuais, bem como propõe a quantidade de neurônios na camada escondida e a quantidade de saídas para a RNA combinada.

RNA	Quantidade de Entradas	Número de neurônios na camada escondida	Quantidade de saídas	% Erro
Idade	14	3	3	6,0
Tempo	14	3	4	4,5
Buchas Danificadas	14	3	3	8,5
Invólucro danificado	14	5	4	7,5
Vazamento de óleo	14	3	2	0,0
Falta no enrolamento	14	9	7	7,0
RNA Combinada	14	26	12	

Tabela 6 - RNAs propostas em [26] Fonte: [26]

O artigo em questão [26] necessita de aprimoramentos, pois não apresenta de forma clara na RNA combinada a decisão de manter ou retirar o transformador de operação, visto que é necessária a análise de 12 variáveis de saída.

A proposta desta dissertação também não utilizará os resultados da DGA, pois conforme mencionado na seção 1.4 os custos referentes aos equipamentos para esse monitoramento superam o valor do transformador de potência contemplado no escopo deste trabalho. Assim, serão utilizadas para cada transformador as seguintes variáveis armazenadas em um sistema SCADA: valores de correntes de CC na rede de distribuição, bem como as correntes de operação, onde a saída esperada será única: tempo para a falha do equipamento. O detalhamento das entradas e a arquitetura da RNA serão vistas no

capítulo 4.

2.4 CLASSIFICAÇÃO DE FALHAS

Em [7] as falhas em transformadores são classificadas de acordo com o local, causa e modo. O local da falha se refere ao componente principal do equipamento, onde a falha foi iniciada, já a causa se refere as circunstâncias da falha. A Tabela 7 apresenta exemplos destas classificações.

O modo de falha ou natureza da falha se refere ao modo pelo qual a falha ocorreu e pode ser classificada como:

- Térmica (aquecimento de uma forma global no equipamento ou ponto quente);
- Dielétrica (descargas parciais);
- Elétrica (CC);
- Mecânica (falhas internas);
- Físico-química (contaminação (umidade, partículas de gás), corrosão);
- Não identificada.

Tabela 7 - Exemplos de classificações do local e causa de fal	lhas em transformadores
Fonte: Adaptado de [7]	

Local da Falha	Causa da Falha			
Enrolamentos	Design, Fabricação e Materiais			
Buchas	Transporte, Manejo e Armazenamento			
Comutador	Manutenção Imprópria			
Cobre e Circuito Magnético	Sobrecargas Anormais			
Isolação Elétrica	Sobretensões			
Tanque	CC Externos			

Quando originárias de modos de falha térmicos ou elétricos, estas falhas têm por característica a superação dos limites de resistência térmica e elétrica do equipamento. Assim, a DGA detalhada na seção 2.1 torna-se uma importante ferramenta de diagnóstico de falhas incipientes [27]. A partir da categorização dos tipos de falhas, cada categoria evolui conforme certos tipos de gases, conforme a Figura 5.



Figura 5 – Categorização dos tipos de falhas Fonte: Adaptado de [27].

2.4.1 Falhas térmicas

Os fatores que indicam falha térmica no transformador são a presença de gases como etileno (C_2H_4) e etano (C_2H_6) , formados a partir da elevação de temperatura no óleo isolante do equipamento, devido por exemplo a um ponto quente no equipamento ou a exposição do mesmo a carregamentos maiores que os especificados pelo fabricante.

A presença de monóxido de carbono (CO) e dióxido de carbono (CO_2), também são indicativos de falha térmica no transformador, os quais são formados a partir da degradação térmica do papel isolante dos enrolamentos, que se deteriora a partir do envelhecimento do equipamento e das condições de operação do mesmo. A degradação do papel isolante é fortemente influenciada pela umidade, temperatura e estresse elétrico. O parâmetro utilizado para a medição do envelhecimento do papel é o Grau de Polimerização (DP) que quantifica a degradação da celulose [28]–[30].

O principal desafio deste método é o fato do mesmo necessitar de uma amostra de papel retirada do transformador. Esta é uma ação intrusiva que requer serviço qualificado, necessitando ser realizada com o equipamento fora de operação. A amostra não pode ser retirada do interior do enrolamento, mas é normalmente retirada de uma das derivações do secundário na parte superior do transformador. Em contrapartida, a termografia mostra-se interessante para a detecção de possíveis problemas térmicos, onde na utilização deste método não é necessário a retirada de operação do equipamento. Os resultados dessa análise podem ser utilizados como complemento a DGA [31].

2.4.2 Falhas Elétricas

Falhas elétricas podem ser caracterizadas pela presença de hidrogênio (H_2) e acetileno (C_2H_2) dissolvidos no óleo do transformador, formados a partir de arcos elétricos no interior do equipamento, os quais constituem descargas de alta energia originadas pela ruptura dielétrica do óleo entre enrolamentos, entre espiras ou entre espiras e massa. Outra evidência da existência de falha elétrica é constatada pela presença de (H_2) e metano (CH_4) formados a partir de Descargas Parciais (PD – *partial discharge*), que constituem descargas de baixa energia entre partes do transformador com diferença de potencial, que se não forem tratadas podem dar origem a arcos elétricos.

PDs degradam o isolamento dielétrico gradualmente, podendo causar a falha do transformador por conta da formação de arco elétrico. Assim, a localização da origem das PDs, bem como testes da isolação do equipamento, podem prevenir a ocorrência de falhas. Os métodos mais comuns destinados a detecção de PDs incluem medições através de rádio frequência [32], com destaque para aquelas de Ultra Alta Frequências (UHF) [33], [34] e localização acústica [33], [34]. O método de localização através de sensores UHF tem alta resistência a interferências e alta sensibilidade, porém a instalação deve ser realizada em locais específicos do transformador [32], onde pode não ser trivial sua instalação. Já os sensores que utilizam localização acústica permitem fácil instalação através de ímãs na carcaça do transformador, além disso não são influenciados pela interferência eletromagnética e são mais baratos que os sensores UHF. Entretanto são sensíveis a vibrações mecânicas, o que pode causar erro na detecção e localização das PDs [32], [35]–[37]. Outras metodologias além das convencionais propõem a utilização de fibra ótica para o diagnóstico das PDs e a combinação dos métodos de UHF e localização acústica [33], [34].

2.4.3 Falhas Mecânicas

Falhas mecânicas são caraterizadas por algum tipo de anormalidade na parte interna do transformador, as quais podem ser causadas por esforços mecânicos provenientes de forças axiais ou radiais originárias de CC. A suportabilidade do transformador a CC é prevista na norma IEC 60076-5, a qual tem como escopo identificar os requisitos para que estes suportem, sem sofrer danos, os efeitos de sobrecorrentes originadas por CC externos, descrevendo amplitudes e durações máximas das sobrecorrentes simétricas que causam efeitos térmicos no equipamento, e assimétricas causadoras de efeitos dinâmicos. Um ponto abordado por essa norma diz respeito às características de operação e da rede de distribuição em que o transformador será conectado. Esta recomenda que em condições de operação severas, caracterizadas por altas frequências de defeitos externos e elevados níveis de sobrecorrentes de CC, deve haver acordo mútuo entre as partes, fabricante e cliente, no tocante aos limites de correntes e frequências de ocorrências de CC. São sugeridos valores mínimos de impedância conforme a potência nominal do equipamento, os quais são mostrados na Tabela 8, onde valores abaixo dos sugeridos também devem ser acordados entre as partes. Outro ponto que também merece destaque são os limites definidos de suportabilidade térmica e dinâmica, os quais podem ser determinados a partir de formulações matemáticas ou testes no equipamento.

Potência Nominal (kVA)		Impediência Mínima de Curto-Circuito (%)				
Até	630	4				
631	1250	5				
1251	2500	6				
2501	6300	7				
6301	25000	8				
25001	40000	10				
40001	63000	11				
63001	100000	12,5				
Abaixo	100000	>12,5				

Tabela 8 – Valores mínimos de impedâncias de CC sugeridos pela norma IEC 60076-5 Fonte: Adaptado de [38]

a) Suportabilidade térmica a eventos de CC

A suportabilidade térmica a eventos de CC pode ser demonstrada através de cálculos envolvendo as seguintes variáveis:

- Valor da corrente de CC simétrica;
- Duração da corrente de CC simétrica;
- Valor máximo da temperatura média de cada enrolamento.

Em relação a corrente de CC simétrica RMS, para o caso de transformadores trifásicos com enrolamentos separados no tap principal, esta pode ser calculada em (1):

$$I_{cc} = \frac{U}{\sqrt{3} \cdot (Z_t + Z_s)}$$
(kA), (1)

Onde Z_t representa a impedância do transformador, Z_s a impedância do sistema, ambas em [Ω] e U a tensão nominal do sistema em [kV]. A duração da corrente de CC simétrica utilizada para o cálculo da suportabilidade térmica deve ser de 2 segundos, a não ser que seja especificada pelo fabricante uma condição diferente. O valor máximo da temperatura média de cada enrolamento pode ser calculado através de (2) e (3), onde esses valores, após o carregamento da corrente de CC especificada em (1) no intervalo de tempo de 2 segundos, não podem ultrapassar os limites definidos na Tabela 9, estando o transformador em qualquer tap [38]:

$$\theta_1 = \theta_0 + \frac{2.(\theta_0 + 235)}{\frac{106000}{J^2.t} - 1} \text{ para cobre,}$$
(2)

$$\theta_1 = \theta_0 + \frac{2.(\theta_0 + 225)}{\frac{45700}{J^2.t} - 1} \text{ para alumínio,}$$
(3)

Onde θ_0 representa a temperatura inicial do enrolamento, medida em [°C], *J* é a densidade de corrente, em [A/mm²], tomando como referência o valor de corrente de CC simétrica.

Fonte: Adaptado de [58]						
Temperatura do	Temperatura Máxima (ºC)					
Sistema de Isolação (classe térmica entre parênteses)	Cobre	Alumínio				
105 (A)	250	200				
105 (A)	180	180				
120 (E)	250	200				
130 (B)	350	200				
155 (F)	350	200				
180 (H)	350	200				
220	350	200				
	Temperatura do Sistema de Isolação (classe térmica entre parênteses) 105 (A) 105 (A) 120 (E) 130 (B) 155 (F) 180 (H) 220	Tomperatura do Temperatura do Temperatura Sistema de Isolação (classe térmica entre parênteses) Cobre 105 (A) 250 105 (A) 180 120 (E) 250 130 (B) 350 155 (F) 350 180 (H) 350 220 350				

Tabela 9 – Valores máximos permissíveis da temperatura média de cada enrolamento após evento de CC Eonte: Adantado de [38]

b) Suportabilidade dinâmica a eventos de CC

A suportabilidade dinâmica a eventos de CC externos pode ser demonstrada através de ensaios ou de cálculos, por exemplo, através de simulações por elementos finitos e considerações do arranjo do transformador. Os ensaios devem ser realizados de acordo com os seguintes requisitos [38]:

- Condição do transformador antes do ensaio de CC;
- Ensaio para a determinação do valor de pico da corrente de CC assimétrica, considerando transformadores de dois enrolamentos;
- Tolerâncias das correntes de CC assimétricas de pico e a corrente simétrica RMS no ensaio de CC;
- Utilização dos procedimentos para o ensaio de CC, para transformadores de dois ou mais enrolamentos e autotransformadores;
- Detecção de faltas e avaliação dos resultados.

O requisito que merece destaque é o ensaio para a determinação do valor de pico da corrente de CC assimétrica, que representa a corrente máxima que o transformador estará submetido, valor este que costuma ser informado ao fabricante do transformador no caso de uma solicitação de garantia [38]. Com o objetivo de determinar a corrente de CC em função do tempo, pode-se considerar uma fonte de corrente alternada, cuja tensão é representada por $v(t) = V. sen(wt + \alpha)$ em série com uma resistência (R) e indutância (L) constantes. Assim, o valor da corrente de CC em função do tempo pode ser obtido em (4):

$$i_{cc}(t) = \sqrt{2} . I_{rms} . \left[\sin(wt + \alpha - \beta) - e^{-t/\tau} . \sin(\alpha - \beta) \right], \tag{4}$$

 I_{rms} representa o valor RMS da corrente de CC simétrica, τ a constante de tempo do circuito RL, a qual pode ser determinada pela razão L/R e β o ângulo de fase, que é igual a tan⁻¹ X/R. Assim, a corrente máxima assimétrica é determinada, assumindo que $\alpha = 0$ e $\beta = \pi/2$, em (5).

$$I_{m \pm x} = \sqrt{2} . I_{rms} . k , \qquad (5)$$

em que k representa o fator de assimetria, determinado pela equação:

$$k = \left(1 + e^{-\pi \cdot \frac{R}{X}}\right). \tag{6}$$

Para aplicações práticas a IEC 60076-5 [38] define valores para os fatores de pico ($\sqrt{2}$. *k*), em função da razão X/R, que são apresentados na Tabela 10.

X/R	1	1,5	2	3	4	5	6	8	10	14
k x √2	1,51	1,64	1,76	1,95	2,09	2,19	2,27	2,38	2,46	2,55

Tabela 10 – Fatores de pico em função da relação X/R Fonte: Adaptado de [38]

c) Frequency Response Analysis (FRA)

Falhas mecânicas podem ser identificadas a partir do ensaio FRA, bastante difundido na literatura, que consiste em um ensaio não intrusivo e não destrutivo, que pode ser utilizado de forma independente ou em conjunto com outros métodos de diagnóstico de falha [39]. Este ensaio tem por objetivo obter a resposta em frequência do transformador, considerando o mesmo como um circuito RLC, onde a referência inicial, que deve ser obtida após sua fabricação, é comparada com futuros ensaios realizados durante sua operação de modo a identificar possíveis falhas. Assim, o ensaio FRA é um teste de comparação, onde devido a sua alta sensibilidade pode detectar falhas que possivelmente outras técnicas não seriam capazes de detectar. Ele é recomendado nas seguintes situações segundo a norma IEEE C57-149 [40]:

- Após os testes de CC de fábrica de modo a garantir que não houve nenhum tipo de dano ao equipamento durante o ensaio;
- Após o transporte, reposicionamento e comissionamento;
- Após eventos de CC ou incidência de descargas atmosféricas próximas ao transformador;
- Após alarme com indicação de anormalidades.

O ensaio de FRA deve ser realizado com o transformador totalmente isolado do sistema, com os cabos ou barramentos desconectados das buchas, e no caso de um transformador com conexão estrela, o neutro deve ser desconectado. O ensaio é realizado a partir da injeção de um sinal em dos terminais do transformador, o qual pode ser um

impulso, tensão de passo ou frequência de varredura, onde este último é o mais comum, sendo denominado *Sweep Frequency Response Analysis* (SFRA). A saída, geralmente representada por um sinal de tensão, mede a variação de impedância em relação a frequência injetada. A magnitude da resposta em frequência é a razão entre os sinais de entrada e saída, geralmente representada em dB. Da mesma forma, o ângulo da resposta em frequência é representado pela defasagem angular entre os sinais de entrada e saída. A Figura 6 apresenta o esquema de conexão de um ensaio FRA.



Figura 6 – Esquema de conexão do ensaio FRA Fonte: Elaborado pelo autor.

Conforme [41], os testes frequentemente realizados no ensaio de FRA são os de circuito aberto, curto-circuito, capacitância entre enrolamentos e indutância entre enrolamentos. No teste de circuito aberto o sinal de referência é injetado em um terminal do enrolamento e o sinal de saída é medido no outro terminal, onde todos os outros terminais devem ficar em aberto, conforme apresentado na Figura 7a. Os resultados são afetados principalmente pelas características do núcleo, principalmente em baixas frequências. Desta forma esse teste é apropriado para avaliação do núcleo do transformador. O teste de CC é semelhante ao de circuito aberto, porém os terminais do secundário da mesma fase devem estar curto-circuitados, conforme Figura 7b, ou também é possível realizar um CC trifásico no secundário. O efeito do núcleo neste teste é removido, desta forma o teste de CC é conveniente para a avaliação dos enrolamentos. Quanto ao teste de capacitância entre enrolamentos, é aplicada a entrada a um terminal de um enrolamento, onde a saída é medida no terminal secundário da mesma fase, conforme Figura 7c. Este teste é principalmente afetado pelo acoplamento capacitivo
entre enrolamentos. Já o teste de indutância entre enrolamentos deve apresentar as mesmas conexões do teste de capacitância entre enrolamentos, porém com os terminais secundários na fase de teste aterrados, conforme a Figura 7d. Este teste mostra como resposta nas baixas e médias frequências a relação de transformação do equipamento e pode-se dizer que para altas frequências não existem informações relevantes.



Figura 7 - Testes do ensaio FRA. a) circuito aberto; b) curto-circuito; c) capacitância entre enrolamentos; d) indutância entre enrolamentos Fonte: [41]

De modo a exemplificar o ensaio SFRA através do teste de circuito aberto, são apresentados na Figura 8 e na Figura 9 as respostas de magnitude e fase de um transformador de potência, o qual apresenta as especificações descritas na seção 1.2, representando assim uma amostra dos transformadores que fazem parte do escopo deste trabalho.



Figura 8 - Resposta da magnitude do ensaio SFRA, no ensaio de circuito aberto Fonte: Elaborado pelo autor



Figura 9 - Resposta da fase do ensaio SFRA, no ensaio de circuito aberto Fonte: Elaborado pelo autor

Embora as mudanças no ensaio de FRA decorrentes de falhas não sejam iguais em transformadores com características diferentes, o padrão de mudança e a faixa de frequência afetada é bastante similar, especialmente em equipamentos de mesmo tamanho. Os trabalhos relacionados a este tema classificam as faixas de frequência em baixa, média e alta com o objetivo de mostrar para cada falta a faixa de frequência afetada. Assim, entre as amplas possibilidades de defeitos em transformadores, as falhas que possuem maior destaque são as deformações radiais, axiais e CC envolvendo enrolamentos [41].

As deformações radiais são decorrentes de esforços mecânicos provenientes de CC, as quais são provocadas pela componente axial do campo magnético, que atuam na direção do raio do enrolamento. A identificação deste tipo de falha por meio do ensaio FRA pode ser observada por meio dos testes de circuito aberto e CC, onde a curva de resposta é deslocada, em altas frequências, porém em baixas e médias frequências não há alterações significativas no formato da mesma [40], [42]–[45].

As deformações axiais são também decorrentes de esforços mecânicos provenientes de CC, assim como as radiais, porém são provocadas pela componente radial do campo magnético, que atuam na direção do eixo do enrolamento. A detecção deste tipo de defeito através do ensaio FRA é mais aparente em médias e altas frequências em todos os testes apresentados neste trabalho, embora o teste de CC pode ser afetado em baixas frequências. Neste tipo de deformação, o formato da curva de resposta é alterado

para todas as faixas de frequências mencionadas [40], [42], [43], [46]–[48]. De modo a exemplificar os tipos de deformações mencionadas, as Figura 10 e Figura 11 apresentam transformadores com deformações radiais e axiais, respectivamente. Já os CC envolvendo enrolamentos causam deslocamento à direita na resposta do teste de CC em aproximadamente todas as faixas de frequências [40], [43], [49]–[51]. O resultado do teste de circuito aberto será parecido com o teste de CC, para este tipo de defeito [40].



Figura 10 - Deslocamento radial do enrolamento de um transformador de potência Fonte: Elaborado pelo autor



Figura 11 - Deslocamento axial do enrolamento de um transformador de potência Fonte: Elaborado pelo autor

Tradicionalmente a interpretação do ensaio FRA, conforme apresentado nos

parágrafos anteriores, ainda depende de grande interferência humana, assim podendo causar análises equivocadas caso o operador não tenha experiência e conhecimento suficientes. Com o intuito de atenuar essa subjetividade de interpretação, índices matemáticos foram criados, como por exemplo, os coeficientes de correlação [40], com o objetivo de comparar as curvas do FRA e identificar os desvios entre elas. Entretanto, ainda é preciso decidir sobre a existência da falta, de forma que esses indicadores ainda não são capazes de determinar o tipo de falta, a extensão e a localização [41]. Assim, técnicas de IA veem sendo utilizadas com o objetivo de minimizar a necessidade de interpretação humana [52]–[55] . A base para a utilização desses métodos se dá através da extração de características do resultado do ensaio FRA, por meio de análises estatísticas ou algoritmos do tipo *vector fitting*, as quais são utilizadas para o treinamento de técnicas como LF [52], máquinas de vetor suporte [53], rede neurais probabilísticas [54] e redes neurais artificiais [55], que podem ser utilizadas para a detecção do tipo de falta, ou até mesmo sua localização [55].

2.5 CONSIDERAÇÕES FINAIS

Neste capítulo foram apresentados os métodos de diagnósticos de falhas em transformadores de potência, iniciando assim pelos métodos clássicos, os quais possuem considerável relevância na literatura. Após, foi apresentada uma revisão bibliográfica dos métodos de diagnósticos de falha utilizando IA, que utilizam em sua maioria como dados de entrada para os modelos, variáveis referentes as concentrações de gases dissolvidos no óleo isolante do transformador. Essas referências se tornam importantes para este trabalho, visto que a maioria não utiliza dados de grandezas operacionais para os modelos de previsão, desta forma reiterando a contribuição desta dissertação.

Foram apresentados também os tipos de falhas em transformadores de potência, detalhando suas especificidades e métodos para seu diagnóstico.

3 REDES NEURIAS ARTIFICIAS

Neste capítulo será abordada uma breve revisão sobre a teoria referente aos modelos de previsão utilizados em RNAs, com enfoque nas redes de múltiplas camadas, que utilizam algoritmo de aprendizagem do tipo retropropagação do erro. Serão apresentados exemplos de funções de ativação, bem como a descrição da sua finalidade. Serão apresentados também os tipos de processo de aprendizagem: supervisionado e não supervisionado, métodos de conversão de escala e um método para mitigar o *overfitting* no treinamento de RNAs, denominado *EarlyStopping*.

3.1 INTRODUÇÃO

Conforme [56], as RNAs são modelos estatísticos, adaptativos baseados em uma estrutura inspirada no cérebro humano. Estes modelos apresentam como principais características a adaptabilidade e a capacidade de resolução de problemas não-lineares, utilizando uma ou mais camadas escondidas formadas por neurônios, que são interligados por um conjunto de pesos w, denominados pesos sinápticos. A Figura 12 apresenta um modelo de neurônio, denominado perceptron, onde $x_1, x_2, ..., x_n$ representam as entradas, $w_1, w_2, ..., w_n$ os pesos sinápticos, b é uma constante denominada bias, y a saída e $\emptyset(.)$ representa a função de ativação, que tem como objetivo inserir uma não-linearidade na saída do neurônio. Tipicamente esta função é limitada nos seguintes intervalos normalizados [0,1] ou [-1,1].



Figura 12 - Modelo não-linear de um neurônio Fonte: Adaptado de [56]

A equação matemática que descreve o neurônio representado na Figura 12 é definida como:

$$y = \emptyset \left(\sum w_i x_i + b \right), \tag{7}$$

A aprendizagem de uma RNA ocorre, geralmente, por um processo iterativo de atualização do conjunto de pesos sinápticos, denominado algoritmo de aprendizagem, onde idealmente a rede se torna mais instruída sobre o seu ambiente após cada iteração do processo de aprendizagem. Diversos algoritmos de aprendizagem podem ser encontrados na literatura, cada qual oferece vantagens específicas para cada tipo de ambiente [56]. A Figura 13 apresenta uma RNA de múltiplas camadas, com duas camadas ocultas ou escondidas. Neste trabalho, será utilizada uma RNA de múltiplas camadas, com uma camada escondida, algoritmo de aprendizagem do tipo retropropagação do erro e processo de aprendizagem do tipo supervisionado.



Figura 13 - MLP de múltiplas camadas Fonte: Adaptado de [56]

3.2 FUNÇÕES DE ATIVAÇÃO

As funções de ativação têm o objetivo de limitar, a um valor finito, a amplitude de saída do neurônio. Essas podem ser identificadas em três tipos básicos:

- Função de Limiar;
- Função Linear por Partes;
- Função Sigmóide.

3.2.1 Função de Limiar

Para esta função, apresentada na Figura 14, considerando $\varphi(x)$ como a função de ativação, temos:



$$\varphi(x) = \begin{cases} 1 \text{ se } x \ge 0\\ 0 \text{ se } x < 0 \end{cases}$$
(8)

Figura 14 - Função de Limiar Fonte: Elaborado pelo autor

3.2.2 Função Linear por Partes

Para esta função, apresentada na Figura 15, temos:

$$\varphi(x) = \begin{cases} 1 \ se \ x \ge +\frac{1}{2} \\ x \ se \ \frac{1}{2} > x \ > -\frac{1}{2}, \\ 0 \ se \ x \le -\frac{1}{2} \end{cases}$$
(9)



Figura 15 - Função Linear por Partes Fonte: Elaborado pelo autor

3.2.3 Função Sigmóide

A função Sigmóide, que possui como característica não-linear com formato em "S", é uma das funções de ativação mais comuns na construção de RNAs. Um exemplo de função sigmóide é a função logística, definida por:

$$\varphi(x) = \frac{1}{1 + e^{-ax}},$$
(10)

a é o parâmetro de inclinação da função. Variando-se esse parâmetro, é possível obter curvas com diferentes inclinações, conforme apresentado a Figura 16. A Tabela 11 apresenta outros tipos de funções sigmoidais.



Figura 16 – Função Sigmóide Fonte: Elaborado pelo autor

NomeEquaçãoTangente Hiperbólica $\varphi(x) = \tanh(x) = \frac{2}{1 + e^{-2x}} - 1$ Rectified Linear Unit
(ReLU) $\varphi(x) = \tanh(x) = \frac{2}{1 + e^{-2x}} - 1$ Parametric Rectified
Linear Unit (PReLU) $\varphi(x) = \begin{cases} x \ se \ x \ge 0 \\ ax \ se \ x < 0 \end{cases}$ Exponencial Rectified
Linear Unit (ELU) $\varphi(x) = \begin{cases} x \ se \ x \ge 0 \\ ax \ se \ x < 0 \end{cases}$ Softmax $\varphi(x)_i = \frac{e^{x_i}}{\sum_{j=1}^K e^{x_i}} \ se \ i = 1, ..., K \ e \ x = (x_1, ..., x_K)$

Tabela 11 – Exemplos de funções sigmoidais Fonte: Adaptado de [57]

3.3 PROCESSOS DE APRENDIZAGEM

A RNA aprende a partir do processo iterativo de atualização dos pesos sinápticos através de estímulos fornecidos pelo ambiente. Desta forma, o processo de aprendizagem é determinado a partir da maneira que os pesos são ajustados e pode ocorrer por meio de dois modos:

- Aprendizagem Supervisionada;
- Aprendizagem Não Supervisionada.

3.3.1 Aprendizagem Supervisionada

Neste processo o treinamento ocorre através de um conjunto de exemplos de entradas e saídas desejadas, os quais representam o ambiente que inicialmente não é conhecido pela rede. A Figura 17 apresenta um diagrama de blocos que ilustra este processo de aprendizagem. A RNA começa a conhecer este ambiente através de um estímulo, o qual é representado por um vetor de entradas e saída desejadas, denominado vetor de treinamento. Em virtude do conhecimento acumulado no vetor de treinamento, a RNA pode fornecer uma saída estimada para este, gerando assim um sinal de erro, que representa a diferença entre a saída desejada e a resposta da RNA (saída estimada). Os parâmetros da rede são ajustados sob a influência combinada do vetor de treinamento e do sinal de erro, assim este processo é realizado de forma iterativa, tentando fazer com que a RNA reproduza com menor erro possível a saída desejada.



Figura 17 – Diagrama de blocos ilustrando o processo de aprendizagem supervisionado Fonte: Adaptado de [56]

A medição de desempenho do sistema, denominada função de custo, pode ser realizada, por exemplo, em termos do erro médio quadrático ou da soma dos erros ao quadrado, entre a saída desejada e a saída estimada. Esta função pode ser visualizada como uma superfície de erro, assim o sistema melhora à medida que o ponto de operação dessa superfície seja deslocado para baixo, atingindo um valor de mínimo, o qual pode ser local ou global. A busca pela minimização do erro acaba se tornando um problema de otimização, com o objetivo de minimizar a função custo em relação ao vetor de pesos. Em [56] são encontrados métodos de otimização que se baseiam na descida iterativa, os quais são descritos como: Método de Newton, Método de Gauss-Newton e Método da Descida do Gradiente. Este último será apresentado de forma mais detalhada, tendo em vista sua utilização neste trabalho.

3.3.2 Aprendizagem Não Supervisionada

Na aprendizagem não supervisionada, não há um conjunto de exemplos de saída, ou seja, não existe nenhum estímulo externo para supervisionar o processo de aprendizagem, desta forma esse método trabalha com dados não rotulados. Nesse caso, é preciso identificar como os exemplos de entrada podem ser agrupados em classes, sempre com base em características (atributos) dos mesmos. O sistema de reconhecimento deverá identificar o número de classes e quais amostras pertencem a essas classes.

Os métodos dos processos não supervisionados, também chamados de *clustering*, tendem a apresentar bons resultados quando as classes (nuvens de pontos) estão bem separadas no espaço de atributos, e apresentam dificuldades se elas estiverem sobrepostas.

3.4 PERCEPTRON DE CAMADA ÚNICA

A atualização dos pesos sinápticos no *perceptron* de camada única é comumente realizada por meio do algoritmo dos mínimos quadrados, que tem como objetivo minimizar o erro médio quadrático. No método da descida do gradiente, os ajustes iterativos aplicados ao vetor de pesos w são realizados em direção contrária ao do vetor gradiente. O algoritmo deste método é apresentado em (11).

$$\boldsymbol{w}(n+1) = \boldsymbol{w}(n) - \eta \boldsymbol{\nabla} \boldsymbol{e}(w), \qquad (11)$$

assim w(n + 1) representa o vetor de pesos na iteração n+1, w(n) o vetor de pesos na iteração n, η é uma constante positiva denominada taxa de aprendizado e $\nabla e(w)$ representa o vetor gradiente calculado no ponto w(n). Considerando o algoritmo dos mínimos quadrados, o qual utiliza valores instantâneos para a função de custo, assim representado pela equação (12).

$$e(\mathbf{w}) = \frac{1}{2}e(n), \qquad (12)$$

em que e(n) representa o sinal de erro medido no tempo . Diferenciando e(w) em relação ao vetor de pesos w,

$$\frac{\partial e(w)}{\partial w} = e(n)\frac{\partial e(n)}{\partial w}.$$
(13)

O sinal de erro é representado por (14), considerando que o algoritmo dos mínimos quadrados opera com um neurônio linear.

$$e(n) = d(n) - \mathbf{x}^{T}(n) \mathbf{w}(n), \qquad (14)$$

d(n) representa a saída desejada. Assim, derivando e(n) e e(w) em relação a w(n):

$$\boldsymbol{\nabla}\boldsymbol{e}(w) = -\boldsymbol{x}(n)\,\boldsymbol{e}(n). \tag{15}$$

Substituindo (15) em (11), tem-se:

$$w(n+1) = w(n) + \eta x(n)e(n).$$
 (16)

A equação (16) é conhecida como regra delta, sendo utilizada para a atualização dos pesos sinápticos nos perceptrons de camada única. A Tabela 12 resume o processo de atualização de pesos utilizando a regra delta, considerando o perceptron de camada única.

Tabela 12 – Resumo do algoritmo de atualização de pesos sinápticos considerando o perceptron de camada única Fonte: Adaptado de [56]

Definição das Amostras para o treinamento:	Vetor do sinal de entrada (x(n)) Resposta Desejada (d(n))
Definição da taxa de aprendizagem:	η

Computar para n=1,2,...

 $e(n) = d(n) - \mathbf{x}^{T}(n) \mathbf{w}(n)$ $\mathbf{w}(n+1) = \mathbf{w}(n) + \eta x(n)e(n)$

3.5 PERCEPTRON DE MÚLTIPLAS CAMADAS

A atualização dos pesos sinápticos no MLP é comumente realizada pelo algoritmo de retropropagação do erro, que, como o *perceptron* de camada única, tem como objetivo a minimização do erro médio quadrático. O algoritmo de retropropagação do erro apresenta dois passos distintos para sua implementação. O primeiro, é conhecido como passo para frente, ou propagação, o segundo é denominado como passo para trás ou retropropagação.

No passo para frente, os pesos sinápticos se mantem inalterados em toda a rede. Os sinais funcionais, definidos como sinais que incidem no terminal de entrada da rede propagam-se para frente emergindo no terminal de saída. Estes são calculados individualmente, neurônio por neurônio. O sinal que aparece na saída de um neurônio *j* da rede é calculado como:

$$y_j = \emptyset(v_j(k)), \tag{17}$$

 $v_i(k)$ é definido por:

$$v_j(k) = \sum_{i=0}^m w_{ji}(k) y_i(k),$$
 (18)

m é o número de entradas total de entradas (exceto o *bias*) aplicadas ao neurônio *j*, $w_{ji}(k)$ é o peso sináptico que conecta o neurônio *i* ao neurônio *j* na *k*-ésima iteração, $y_i(k)$ é o sinal de entrada do neurônio *j* na *k*-ésima iteração, que é equivalente ao sinal funcional que aparece na saída do neurônio *i*. Esta saída é comparada a resposta desejada $d_j(k)$, obtendo-se assim o sinal de erro $e_j(k)$ para o *j*-ésimo neurônio de saída. Assim, a fase de propagação é iniciada pela primeira camada oculta, com a apresentação do vetor de entrada, e termina na camada de saída calculando o sinal de erro de cada neurônio desta camada. A Figura 18 apresenta uma ilustração desta etapa, assim x (k) representa o vetor de entradas, y (k) o vetor de saídas e W (k) o vetor de pesos sinápticos.



Figura 18 – Ilustração da propagação para a frente no algoritmo de retropropagação do erro Fonte: Adaptado de [56]

O passo de retropropagação, ilustrado na Figura 19, é iniciado na camada de saída, em direção contrária a primeira etapa, ou seja, para a esquerda através da rede, camada por camada, assim recursivamente são calculadas as atualizações dos pesos sinápticos de acordo com a regra delta, conforme apresentado em (19):

$$\Delta w_{ii}(k) = \eta \cdot \delta_i(k) \cdot y_i(k) \quad , \tag{19}$$

 $\Delta w_{ji}(k)$ representa a correção dos pesos sinápticos na *k*-ésima iteração, η a taxa de aprendizado, $y_i(k)$ o sinal de entrada do neurônio *j* e $\delta_j(k)$ é o gradiente local, que pode ser calculado caso:

1. O neurônio *j* seja um nó na camada de saída, $\delta_j(k)$ é igual ao produto da derivada $\emptyset'_j(v_j(k))$ pelo sinal de erro $e_j(k)$, ambos sendo associados ao neurônio *j*, conforme (20).

$$\delta_j(k) = e_j(k) \phi'_j(v_j(k)) , \qquad (20)$$

2. O neurônio *j* seja um nó em uma camada oculta, $\delta_j(k)$ é igual ao produto da derivada $\phi'_j(v_j(k))$ pelo soma ponderada dos gradientes locais calculados para os neurônios na próxima camada oculta, ou camada de saída, representada por *l* em (21), que estão conectadas ao neurônio *j*.

$$\delta_j(k) = \emptyset'_j(v_j(k)) \sum \delta_l(k) w_{lj}(k) , \qquad (21)$$

 $\delta_l(k)$ é definido como:

$$\delta_l(k) = e_l(k) \phi'_l(v_l(k)) , \qquad (22)$$



Figura 19 - Ilustração da propagação para trás no algoritmo de retropropagação do erro Fonte: Adaptado de [56]

A escolha da taxa de aprendizado é fundamental para uma aprendizagem mais lenta ou mais rápida, consequentemente podendo deixar o treinamento da rede estável ou instável. Taxas de aprendizado pequenas tem como característica menores variações dos pesos sinápticos, durante cada iteração, deixando assim o treinamento da rede mais estável, porém como consequência o aprendizado se torna mais lento. Em contrapartida, taxas de aprendizado maiores podem acelerar o processo de aprendizado, porém podem trazer instabilidade ao treinamento da rede, tendo em vista grandes modificações nos pesos sinápticos. Com o objetivo de aumentar a taxa de aprendizado e evitar a instabilidade da rede, a equação que representa a regra delta, pode ser modificada, inserindo um termo de momento, conforme apresentado em (23).

$$\Delta w_{ji}(k) = \eta \cdot \delta_j(k) \cdot y_i(k) + \alpha \Delta w_{ji}(k-1) \quad , \tag{23}$$

 α é usualmente positivo, denominado de constante de momento. A inclusão da constante de momento no algoritmo de retropropagação do erro é uma modificação pequena, a qual proporciona benefícios sobre o comportamento de aprendizagem do algoritmo, como por exemplo, evitar que o processo de aprendizagem termine em um mínimo local na superfície de erro.

Outro aspecto relevante nos modelos MLP é a determinação dos neurônios na camada escondida, pois essa variável pode influenciar os erros dos nós, aos quais suas saídas são conectadas. A grande quantidade de neurônios na camada escondida pode causar o ajuste excessivo dos dados de treinamento, causando o fenômeno denominado *overfitting*, conforme mostrado na Figura 20. Assim, determinar a quantidade adequada de neurônios na camada escondida representa um desafio no projeto de RNAs.



Figura 20 – Representação de um modelo com ajuste excessivo de dados (overfitting) Fonte: Elaborado pelo autor

3.6 MÉTODOS DE CONVERSÃO DE ESCALAS

Em modelos de IA é comum adequar os dados das amostras a mesma escala,

tendo em vista a utilização de variáveis que podem pertencer a grandezas diferentes. Neste trabalho, por exemplo, as correntes de CC simétricas são medidas em Ampères e o tempo em sobrecarga em horas, assim é necessário adequar todas as variáveis de entrada a mesma escala, que pode ser realizado através de duas técnicas populares, a normalização e a padronização. Além disto, estas técnicas evitam que o algoritmo fique enviesado para as variáveis com maior ordem de grandeza.

3.6.1 Normalização

Na técnica de normalização, as variáveis são transformadas em uma escala de 0 a 1 ou de -1 a 1, por meio da equação (24). Esta técnica é útil para dimensionar as variáveis de entrada para um modelo que depende da magnitude dos valores, bem como na preparação dos coeficientes de regressão [58].

$$x_e = \frac{x - x_{min}}{x_{max} - x_{min}},\tag{24}$$

 x_e representa uma amostra da variável considerada convertida na nova escala, x representa a amostra na escala original, $x_{máx}$ o valor máximo das amostras na escala original e x_{min} o valor mínimo das amostras na escala original.

3.6.2 Padronização

A técnica de padronização consiste em converter a escala original em uma escala cuja média das amostras é zero e o desvio padrão é unitário. Para a realização desta conversão a equação (25) pode ser utilizada:

$$z = \frac{x - \mu}{\sigma},\tag{25}$$

z representa uma amostra da variável considerada convertida na nova escala, μ é a média das amostras e σ o desvio padrão.

3.7 EARLY STOPPING

Um dos maiores desafios em relação ao treinamento de RNAs é determinar o quão longo deve ser o treinamento. Caso ocorra o treinamento excessivo, significa que o modelo terá ajuste excessivo dos dados de treinamento, gerando assim um modelo com *overfitting*, ao contrário, caso ocorra o treinamento reduzido das amostras disponíveis, o modelo irá apresentar características de *underfitting*.

Como regra geral o modelo deve ser treinado com as amostras destinadas ao treinamento, assim este treinamento deve ser interrompido no momento em que o desempenho do conjunto de dados destinados a validação começa a diminuir. Essa técnica amplamente utilizada para o treinamento de RNAs é denominada early stopping. A aplicação desta estratégia necessita da definição de um ponto de mínimo (gatilho) para finalizar o treinamento, o qual monitora o desempenho baseado em uma métrica escolhida, que pode ser, por exemplo, a avaliação da função de custo após cada época. Na Figura 21 são apresentadas duas curvas de aprendizado, uma referente ao conjunto de dados destinados ao treinamento e outra destinada a validação da RNA. Geralmente, o modelo apresenta erros maiores na curva de validação, em comparação a curva de treinamento, visto que seu projeto é baseado nos dados dessa etapa. Tipicamente, a curva na etapa de treinamento diminui de acordo com o número de épocas. Por outro lado, a curva de validação diminui até um ponto de mínimo, que pode ser local ou global, e depois começa a aumentar conforme o treinamento prossegue. Quando observada a curva de treinamento, pode parecer que quanto maior o número de épocas após o ponto de erro mínimo da curva de validação melhor desempenho teria o modelo. Todavia, após esse ponto a rede está aprendendo o ruído contido nos dados de treinamento. Assim, essa heurística sugere que o ponto de mínimo na curva de validação seja utilizado para parar o treinamento [56].



Figura 21 – Ilustração do método early stopping Fonte: Adaptado de [56]

O treinamento pode ser interrompido assim que o desempenho do conjunto de

dados destinados a validação começa a diminuir, quando comparado ao resultado da época anterior.

Contudo, em aplicações práticas é importante definir uma quantidade de épocas após atingido o ponto de mínimo para finalização do treinamento, de modo a verificar se o desempenho do modelo continua de fato se deteriorando [59].

3.8 CONSIDERAÇÕES FINAIS

Neste capítulo foi apresentada uma breve introdução sobre os modelos de RNAs, descrevendo as principais funções de ativação, processos de aprendizagem e detalhamento da modelagem do *perceptron* de camada única e do *perceptron* de múltiplas camadas. Foram apresentados também os métodos de conversão de escala, bem como o método *Early Stopping*, ferramentas essas utilizadas para a modelagem das RNAs deste trabalho.

4 METODOLOGIA PROPOSTA

A metodologia proposta neste trabalho envolve a previsão de falhas em transformadores de potência utilizando RNAs. Para a realização das previsões foram selecionadas 21 posições de transformação de subestações pertencentes a uma distribuidora do Rio de Janeiro, as quais tiveram pelo menos uma falha a partir do mês de janeiro de 2016. Para cada posição foi modelada uma RNA, utilizando como dados de entrada o valor eficaz da corrente de CC simétrica externa ao equipamento, valor eficaz da corrente de operação e o fabricante do transformador, assim a partir dessas variáveis iniciais foram derivadas 56 variáveis de entrada, as quais compuseram o cenário base das simulações. A saída de cada RNA, foi definida como o tempo para falha, em dias, do equipamento.

Com objetivo de verificar o desempenho de cada RNA, foram propostos mais 4 outros cenários, derivados do cenário base (cenário 0), que consideravam algumas variáveis do cenário base. Também foi proposta a utilização de uma única RNA, com o objetivo de representar todas as posições.

Em relação a arquitetura, foram consideradas RNAs de múltiplas camadas (MLP), uma camada escondida, processo de aprendizagem do tipo supervisionado. A quantidade de neurônios na camada escondida foi alterada em todos os cenários, com o objetivo de verificar o melhor desempenho dos modelos.

4.1 CARACTERIZAÇÃO DO PROBLEMA

Conforme apresentado na seção 1.4, o escopo deste trabalho consiste em utilizar grandezas convencionais disponíveis em qualquer centro de controle, que monitore seus transformadores de potência através de um sistema SCADA, com o objetivo de prever falhas nesses equipamentos. A utilização de tais grandezas se mostra atrativa frente ao elevado custo de implantação de sensores para a análise de gases dissolvidos em tempo real, quando comparado ao valor dos transformadores que estão contemplados no escopo deste trabalho.

O modelo de previsão utilizado será uma RNA, com múltiplas camadas utilizando o processo de aprendizagem do tipo supervisionado e algoritmo de aprendizagem do tipo retropropagação do erro. As entradas para a RNA serão variáveis pertencentes às seguintes grandezas: valor eficaz da corrente de CC simétrica externa ao equipamento, valor eficaz da corrente de operação e o fabricante, assim a partir dessas variáveis principais serão extraídas 56 variáveis de entrada, as quais serão detalhadas na seção 4.2. A saída da RNA será representada pela quantidade de dias para falha do transformador. Serão consideradas para as simulações as grandezas mencionadas de 21 subestações, no período de 2016 a 2019, que tiveram pelo menos um transformador falhado neste período. De modo a verificar a representatividade de cada variável de entrada no modelo, foram considerados cinco cenários, que serão compostos pela combinação das variáveis de entrada. Este detalhamento será visto na seção 4.3.

4.2 MODELO DE DADOS DE ENTRADA E SAÍDA DAS RNAS

Considerando as amostras dos transformadores abrangidos neste trabalho, é definido o conceito de posição de transformação, que representa a sequência numérica atribuída a cada transformador em uma determinada subestação, assim o transformador 1 da subestação "A" é definido como A1. A partir da definição dessas posições, as variáveis de entrada para a RNA, foram definidas de acordo com as seguintes variáveis iniciais: valor eficaz da corrente de CC simétrica externa ao equipamento, valor eficaz da corrente de operação e o fabricante do transformador. Na Tabela 14, são apresentadas as posições de transformação contempladas no escopo deste trabalho, que são determinadas pelo conjunto de três letras, as quais representam a subestação, e a posição do transformador, que é determinada na sequência, por um algarismo. São apresentados também o tempo de operação de cada transformador, em sua respectiva posição, bem como os fabricantes de cada unidade. As posições que não apresentam dados referentes a terceira falha, possuem transformadores ainda em operação.

Logo, para cada posição foi construído um modelo de RNA, assim as etapas de treinamento, validação e testes foram realizadas a partir da quantidade de exemplos representados pelo tempo de operação, em dias. Foi considerado também uma única RNA, representativa de todas as posições, com o objetivo de comparar os resultados individuais de cada RNA com este modelo. Quanto as variáveis de entrada, apresentadas na Tabela 13, foram derivadas das variáveis iniciais descritas no parágrafo anterior, totalizando assim 56 variáveis de entrada, as quais serão detalhadas nas seções posteriores.

Quanto a saída desejada de cada RNA, foi expressa por meio da quantidade de dias para falha. Assim, a primeira amostra de cada posição apresentou como saída desejada o tempo total de operação do transformador na respectiva posição, assim para as demais amostras o tempo de operação foi reduzido linearmente até sua falha.

Todos os dados de entrada e saída foram normalizados, considerando a técnica de normalização, na escala de 0 a 1.

Variável	Quantidade de Entradas
Posição do transformador	21
Fabricante	15
Corrente eficaz simétrica de CC	10
Tempo em sobrecarga	10

Tabela 13 – Entradas para cada variável inicial Fonte: Elaborado pelo autor

Posição	Data Primeira Falha	Fabricante da Primeira Falha	Data de Instalação do Transformador após a primeira falha	Data Segunda Falha	Fabricante da Segunda Falha	Tempo em operação - Segunda Falha (dias)	Data de Instalação do Transformador após a segunda falha	Data Terceira Falha	Fabricante da Terceira Falha	Tempo em operação - Terceira Falha (dias)
AIM2	09/04/2016	А	10/04/2016	26/03/2018	J	715				
AUS1	28/01/2015	В	29/01/2015	24/04/2019	Ι	1546	25/04/2019	13/09/2019	L	141
BRP2	01/02/2018	С	02/02/2018	30/11/2018	Κ	301				
CAB1	13/02/2018	D	14/02/2018	08/10/2018	L	236				
CLN3	17/04/2017	В	18/04/2017	05/10/2017	Ι	170				
CPN1	04/05/2018	В	08/05/2018	31/07/2019	Κ	449				
CPV2	08/02/2018	Е	13/02/2018	12/04/2019	L	423				
CTL1	20/03/2015	В	21/03/2015	07/01/2019	J	1388	08/01/2019	15/03/2019	L	66
GTB3	25/07/2018	D	26/07/2018	04/09/2018	L	40				
IPB1	14/03/2016	F	15/03/2016	05/01/2018	Μ	661				
JUN4	25/09/2015	С	26/09/2015	30/08/2016	Ι	339	31/08/2016	31/12/2016	J	122
MRN2	07/07/2016	G	08/07/2016	07/12/2017	J	517	08/12/2017	21/03/2019	Κ	468
MZB2	11/03/2016	Н	12/03/2016	01/05/2019	Ι	1145				
PII1	02/07/2018	С	02/07/2018	14/12/2018	L	165	20/12/2018	16/07/2019	L	208
PIR1	12/03/2018	А	13/03/2018	19/12/2018	L	281				
QCS1	30/08/2016	Ι	01/09/2016	31/01/2019	Ι	882				
TUT1	28/04/2016	J	29/04/2016	30/11/2018	J	945				
UNV1	29/11/2016	Ι	30/11/2016	29/05/2019	С	910	30/05/2019	01/07/2019	Κ	32
VDN1	10/03/2016	Ι	11/03/2016	18/12/2018	Ι	1012				
VPB1	06/04/2016	J	07/04/2016	15/10/2018	J	921				
VTR4	29/07/2016	В	29/07/2016	08/12/2016	Ι	132	09/12/2016	15/02/2018	Ο	433

Tabela 14 – Histórico de falhas das posições de transformação contempladas no escopo deste trabalho Fonte: Elaborado pelo autor

4.2.1 Posição do Transformador

A representação desta variável foi realizada atribuindo a cada posição de transformação um vetor com 21 posições, conforme apresentado na Tabela 15. Essa representação é essencial para diferenciar cada posição, no modelo de RNA que reúne todas as posições.

4.2.2 Fabricante

De acordo com os exemplos disponíveis, foram considerados 15 fabricantes diferentes que entraram nos modelos de RNAs, os quais tiveram seus nomes preservados, estando identificados por letras, conforme apresentado na Tabela 16. A representação desta variável seguiu o mesmo conceito da variável posição do transformador, assim cada fabricante é representado por um vetor de 15 posições, logo esta variável também é essencial no modelo de RNA que considera todas as posições, visto que esta pode evidenciar o impacto de cada fabricante no tempo de falha do equipamento.

4.2.3 Corrente eficaz simétrica de CC

Considerando os transformadores de potência do escopo deste trabalho, o equipamento responsável por obter os valores, por fase, das correntes simétricas de CC, oriundas de defeitos no circuito de distribuição, é o religador, o qual é responsável pela proteção do circuito que o transformador está conectado. Este equipamento possui interface com o sistema SCADA, que registra a data e horário de abertura, bem como as correntes de CC nas três fases e no neutro. A partir dessas informações, foi possível elaborar 10 variáveis de entrada, formadas a partir desta grandeza, conforme apresentado na Tabela 17. A



Figura 22, apresenta como exemplo as variáveis acumuladas referentes as correntes de CC da posição TUT1, a qual operou por 945 dias.



Figura 22 - Variáveis acumuladas referentes as correntes de CC simétricas relativas a posição TUT1 Fonte: Elaborado pelo autor

Ν	Posições	POS1	POS2	POS3	POS4	POS5	POS6	POS7	POS8	POS9	POS10	POS11	POS12	POS13	POS14	POS15	POS16	POS17	POS18	POS19	POS20	POS21
1	AIM2	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
2	AUS1	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
3	BRP2	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
4	CAB1	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
5	CLN3	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
6	CPN1	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
7	CPV2	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0
8	CTL1	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0
9	GTB3	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0
10	IPB1	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0
11	JUN4	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0
12	MRN2	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0
13	MZB2	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0
14	PII1	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0
15	PIR1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0
16	QCS1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0
17	TUT1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0
18	UNV1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0
19	VDN1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0
20	VPB1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0
21	VTR4	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1

Tabela 15 – Variáveis de entrada que representam a posição do transformador de potência Fonte: Elaborado pelo autor

Ν	Fab.	Fab.1	Fab.2	Fab.3	Fab.4	Fab.5	Fab.6	Fab.7	Fab.8	Fab.9	Fab.10	Fab.11	Fab.12	Fab.13	Fab.14	Fab.15
1	А	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0
2	В	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0
3	С	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0
4	D	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0
5	Е	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0
6	F	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0
7	G	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0
8	Н	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0
9	Ι	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0
10	J	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0
11	К	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0
12	L	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0
13	Μ	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0
14	Ν	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0
15	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1

Tabela 16 – Variáveis de entrada que representam o fabricante de cada transformador de potência Fonte: Elaborado pelo autor

Variável de Entrada	Descrição
SOMA_Corrente_CC_MAX	Somatório das correntes simétricas de CC diárias
SOMA_Corrente_CC_MAX_acumulado	Somatório das correntes simétricas de CC acumuladas
QTD_CC	Quantidade de CC diários
QTD_CC_acumulado	Quantidade de CC acumulados
QTD_CC_TEMPO_3_MIN	Quantidade de CC diários em até 3 minutos
QTD_CC_TEMPO_3_MIN_acumulado	Quantidade de CC acumulados em até 3 minutos
QTD_CC_TEMPO_30_MIN	Quantidade de CC diários em até 30 minutos
QTD_CC_TEMPO_30_MIN_acumulado	Quantidade de CC acumulados em até 30 minutos
QTD_CC_TEMPO_300_MIN	Quantidade de CC diários em até 300 minutos
QTD_CC_TEMPO_300_MIN_acumulado	Quantidade de CC acumulados em até 300 minutos

Tabela 17 – Variáveis derivadas da variável inicial: corrente eficaz simétrica de CC Fonte: Elaborado pelo autor

4.2.4 Tempo em sobrecarga

Assim como os valores de correntes de CC, as correntes de operação do transformador são obtidas pelo religador e chegam até o centro de operações através de uma plataforma SCADA. Para este trabalho, foram consideradas as correntes de operação diárias, em intervalos de 15 minutos. Assim, a partir desta grandeza foi possível elaborar 10 variáveis de entrada, conforme apresentado na Tabela 18. A Figura 23 apresenta como exemplo as variáveis acumuladas do tempo de operação em sobrecarga nas faixas definidas referente à posição TUT1.



Figura 23 - Variáveis acumuladas referentes aos períodos acumulados de sobrecarga relativos a posição TUT1 Fonte: Elaborado pelo autor

As duas últimas grandezas da Tabela 18 representam a redução do percentual de vida útil devido ao ciclo de carregamento do transformador de potência, a qual está diretamente ligada ao carregamento que este é submetido ao longo do seu período de operação [60]. Conforme definido na norma IEEE C57-91 [61], o óleo isolante do transformador se deteriora como uma função do tempo e da temperatura, e como as temperaturas nos transformadores não são uniformemente distribuídas é comum utilizar a temperatura do ponto mais quente. Dessa forma o cálculo do percentual de redução da vida útil (%PV) é determinado através de (26), a qual se baseia na teoria de Arrhenius considerando o ponto mais quente como referência:

$$PV(\%) = 10^{-\left(\left(\frac{B}{273 + \theta_{en}}\right) + A\right)} \Delta t_i . 100,$$
(26)

PV representa a perda percentual de vida útil do transformador, Δt_i é o tempo de operação em horas, θ_{en} é a temperatura do ponto mais quente em Kelvin, A e B são parâmetros definidos na norma IEEE C57-91 [61]. As constantes A e B são definidas a partir das características de elevação de temperatura dos transformadores considerados no escopo deste trabalho, os quais admitem até 55 °C, assim B=6.972,15 e A=14,1333. Tendo em vista a limitação das informações referentes a temperatura do ponto mais quente do transformador, em [60], é admitida uma aproximação, embasada em ensaios de laboratório, para a determinação desta grandeza, que considera a proporcionalidade entre a temperatura do ponto mais quente e o carregamento do transformador, assim para θ_{en} igual a 95 °C, corresponde ao carregamento de 100% do transformador. Assim, como os carregamentos são disponíveis em intervalos de 15 minutos, para cada ponto foi aplicada a equação (26). Logo, para a determinação do percentual de redução da vida útil diário, foi considerado o somatório de cada intervalo. A Figura 24, apresenta como exemplo a variável acumulada referente a redução percentual de vida útil devido ao ciclo de carregamento do transformador, referente a posição TUT1.



Figura 24 - Variáveis acumulada referente a redução percentual de vida útil devido ao ciclo de carregamento do transformador de potência, relativo a posição TUT1 Fonte: Elaborado pelo autor

Variável de Entrada	Descrição
Carga_level_100_110	Tempo que o transformador foi submetido a sobrecarga, durante um dia, na faixa de carregamento: maior que 100% e menor ou igual a 110% de sua capacidade nominal
Carga_level_100_110_acum	Tempo que o transformador foi submetido a sobrecarga, durante seu período de operação, na faixa de carregamento: maior que 100% e menor ou igual a 110% de sua capacidade nominal
Carga_level_110_120	Tempo que o transformador foi submetido a sobrecarga, durante um dia, na faixa de carregamento: maior que 110% e menor ou igual a 120% de sua capacidade nominal
Carga_level_110_120_acum	Tempo que o transformador foi submetido a sobrecarga, durante seu período de operação, na faixa de carregamento: maior que 110% e menor ou igual a 120% de sua capacidade nominal
Carga_level_120_130	Tempo que o transformador foi submetido a sobrecarga, durante um dia, na faixa de carregamento: maior que 120% e menor ou igual a 130% de sua capacidade nominal
Carga_level_120_130_acum	Tempo que o transformador foi submetido a sobrecarga, durante seu período de operação, na faixa de carregamento: maior que 120% e menor ou igual a 130% de sua capacidade nominal
Carga_level_130	Tempo que o transformador foi submetido a sobrecarga, durante um dia, na faixa de carregamento: maior que 130% de sua capacidade nominal
Carga_level_130_acum	Tempo que o transformador foi submetido a sobrecarga, durante seu período de operação, na faixa de carregamento: maior que 130% de sua capacidade nominal
PV(%)_dia	Redução do percentual de vida útil diária, devido ao carregamento
PV(%)_acumulado	Redução do percentual de vida útil, devido ao carregamento, durante seu período de operação

Tabela 18 – Variáveis derivadas da variável inicial: tempo em sobrecarga Fonte: Elaborado pelo autor.

4.3 DESCRIÇÃO DOS CENÁRIOS PROPOSTOS PARA AS SIMULAÇÕES

Com o objetivo de verificar quais variáveis de entrada iriam representar a melhor resposta para os modelos de RNA, foram estabelecidos cinco cenários, os quais consideraram as variáveis descritas na seção 4.2, bem como a combinação de algumas dessas, conforme apresentado na Tabela 19.

O cenário 0 contempla todas as variáveis descritas na seção 4.2, já os cenários 1 e 2 não consideram as variáveis de tempo em sobrecarga nas respectivas faixas definidas, logo a diferença entre eles está no fato do cenário 2 considerar apenas as variáveis acumuladas. Os cenários 3 e 4 não consideram a variável referente a perda percentual de vida útil do transformador devido a seu ciclo de carregamento e consideram as faixas de tempo de operação em sobrecarga. A diferença desses dois cenários também se dá pelo fato do cenário 4 considerar apenas as grandezas acumuladas.

A descrição dos cenários exemplificados na Tabela 19 foi utilizada para a construção de uma RNA para cada posição, assim as variáveis posição do transformador e fabricante, para as posições que tiveram apenas uma falha, permaneceram constantes.

Com o objetivo de representar em uma única RNA todos os exemplos, foram considerados nos cenários descritos um modelo que contemplasse todas as posições, assim nesse caso, as variáveis posição do transformador e fabricante não permanecem constantes.

Cenário 0	Cenário 1	Cenário 2	Cenário 3	Cenário 4
Posição do Transformador	Posição do Transformador	Posição do Transformador	Posição do Transformador	Posição do Transformador
Fabricante	Fabricante	Fabricante	Fabricante	Fabricante
Soma das correntes de CC máximas diárias e acumuladas	% perda vida útil diária e acumulada	% perda vida útil acumulada	Tempo em sobrecarga na faixa de 100% até 110%, diária e acumulada	Tempo em sobrecarga na faixa de 100% até 110%, acumulada
Quantidade de CC diários e acumulados	Soma das correntes de CC máximas diárias e acumuladas	Soma das correntes de CC máximas acumuladas	Tempo em sobrecarga na faixa de 110% até 120%, diária e acumulada	Tempo em sobrecarga na faixa de 110% até 120%, acumulada
Quantidade de CC em até 3 min diários e acumulados	Quantidade de CC diários e acumulados	Quantidade de CC acumulados	Tempo em sobrecarga na faixa de 120% até 130%, diária e acumulada	Tempo em sobrecarga na faixa de 120% até 130%, acumulada
Quantidade de CC em até 30 min diários e acumulados	Quantidade de CC em até 3 min diários e acumulados	Quantidade de CC em até 3 min acumulados	Tempo em sobrecarga na faixa de maior que 130%, diária e acumulada	Tempo em sobrecarga na faixa de maior que 130%, acumulada
Quantidade de CC em até 300 min diários e acumulados	Quantidade de CC em até 30 min diários e acumulados	Quantidade de CC em até 30 min acumulados	Soma das correntes de CC máximas diárias e acumuladas	Soma das correntes de CC máximas acumuladas
% perda vida útil diária e acumulada	Quantidade de CC em até 300 min diários e acumulados	Quantidade de CC em até 300 min acumulados	Quantidade de CC diários e acumulados	Quantidade de CC acumulados
Tempo em sobrecarga na faixa de 100% até 110%, diária e acumulada			Quantidade de CC em até 3 min diários e acumulados	Quantidade de CC em até 3 min acumulados
Tempo em sobrecarga na faixa de 110% até 120%, diária e acumulada			Quantidade de CC em até 30 min diários e acumulados	Quantidade de CC em até 30 min acumulados
Tempo em sobrecarga na faixa de 120% até 130%, diária e acumulada			Quantidade de CC em até 300 min diários e acumulados	Quantidade de CC em até 300 min acumulados
Tempo em sobrecarga na faixa de maior que 130%, diária e acumulada				

Tabela 19 – Descrição das varáveis utilizadas nos cenários das simulações Fonte: Elaborado pelo autor

4.4 ARQUITETURA DA RNA UTILIZADA

A implementação das arquiteturas dos modelos de RNAs foi realizada em Python, utilizando modelos MLPs com uma camada escondida, com processo de aprendizagem do tipo supervisionado e algoritmo de aprendizagem do tipo retropropagação do erro. A função de ativação utilizada tanto na camada escondida quanto na camada de saída foi a *Sigmoid*. A técnica de conversão de escala utilizada foi a normalização no intervalo de 0 a 1.

Os exemplos para o treinamento, validação e testes de cada RNA foram selecionados de forma intercalada. As amostras selecionadas para o treinamento receberam os seguintes exemplos: primeiro, quarto, sétimo e assim por diante. Assim, as amostras destinadas à etapa de testes, receberam os próximos exemplos: segundo, quinto, oitavo e assim por diante. Nas amostras destinadas a validação, foi aplicada a mesma estratégia, de forma que, cada etapa recebeu 33,33% dos dados disponíveis.

O processo de simulação envolveu a variação do número de neurônios na camada escondida para cada posição nos cinco cenários propostos. A heurística utilizada para a determinação da quantidade máxima de neurônios na camada escondida de cada RNA é apresentada em (27), em que D representa a quantidade de exemplos e E a quantidade de entradas da RNA. Assim, foi determinado para cada RNA a quantidade máxima de neurônios, tendo em vista que cada RNA possuía quantidades de exemplos distintos, bem como entradas distintas para cada cenário simulado. Esta variável foi utilizada durante as simulações como valor limite da quantidade de neurônios na camada escondida para cada RNA.

$$N_{máx} = \frac{D-1}{E-2},\tag{27}$$

O parâmetro utilizado para medir o desempenho de cada RNA foi o erro médio absoluto, em dias, calculado na etapa de testes do modelo, o qual foi gerado nas etapas de treinamento e validação.

Foi considerado durante o processo de treinamento e validação até 4.000 épocas, utilizando monitoramento *Early Stopping*, com tolerância de 1.000 épocas. A função de custo utilizada teve como objetivo minimizar o erro quadrático médio, utilizando a método de otimização SGD, abreviação de *Stochastic Gradient Descent*. Os parâmetros necessários para este método são a taxa de aprendizado e a constante de momento, os quais permaneceram constantes em 0,01 e 0,9, respectivamente, durante todas as simulações.

A Figura 25 apresenta o fluxograma utilizado para a realização das simulações em cada RNA.



Figura 25 – Fluxograma utilizado para a realização das simulações Fonte: Elaborado pelo autor

5 RESULTADOS

Neste capítulo são apresentados os resultados das simulações a partir da variação da quantidade de neurônios na camada escondida de cada modelo de RNA, considerando os cenários apresentados na Tabela 19. Serão apresentados os resultados referentes ao modelo de uma única RNA, composta pelos exemplos de todas as posições, a qual tem o objetivo de representar o comportamento das posições, conforme descrito na seção 4.2.

5.1 RESULTADOS DAS SIMULAÇÕES DOS MODELOS DE RNAS CONSIDERANDO CADA POSIÇÃO DE TRANSFORMAÇÃO

A partir das variáveis de entrada definidas para cada cenário, foram realizadas as simulações para cada posição, gerando assim 21 modelos de RNAs. Nas próximas seções serão discutidos os resultados das simulações dos cenários descritos, apresentando o erro médio mínimo obtido para cada RNA durante as simulações, a quantidade de neurônios associada a essa variável, o desvio padrão relacionado as amostras e a quantidade de exemplos para cada posição. A variável escolhida para medir o desempenho dos modelos foi o erro médio em valor absoluto, o qual é calculado na etapa de testes do modelo, utilizando 33,33% dos dados disponíveis, considerando o módulo da diferença entre os valores da previsão gerados a partir das etapas de treinamento e validação e os valores desejados, conforme apresentado em (28). Já o desvio padrão foi calculado a partir de (29).

$$\bar{e} = \frac{1}{N} |Y_{dif}|, \qquad (28)$$

$$\sigma = \sqrt{\frac{1}{N} \sum_{i=1}^{N} (Y_{dif}(i) - \mu)^2},$$
(29)

Assim,

$$Y_{dif} = Y_m - Y_d , \qquad (30)$$

$$\mu = \frac{1}{N} \sum_{i=1}^{N} Y_{dif}(i), \qquad (31)$$

58
N representa o total de exemplos, Y_m o vetor com as previsões, Y_d o vetor com os valores desejados e μ a média dos elementos do vetor Y_{dif} .

5.1.1 Resultados das simulações considerando as variáveis de entrada propostas no Cenário 0

Conforme apresentado na Tabela 19, o cenário 0 considera todas as variáveis de entrada propostas nesta dissertação, ou seja, contempla todas as variáveis diárias e acumuladas oriundas dos eventos de CC e sobrecarga.

Os resultados das simulações considerando as variáveis contempladas neste cenário, são apresentados Figura 26. A posição AUS1, obteve o maior erro médio quando comparada as outras posições, pelo fato do alimentador associado a esse transformador de potência possuir uma quantidade de paralelos com outros alimentadores acima da média dos circuitos contemplados nesse estudo, dessa forma fazendo com que sua configuração mude constantemente, por conta da necessidade de provimento de recurso em caso de contingências.

Já a posição CLN3, obteve o melhor desempenho neste cenário. O alimentador desta posição apresenta uma quantidade de paralelos dentro da média dos demais circuitos, dessa forma tornando sua configuração mais estável.

Este cenário será tomado como base para a comparação com os demais cenários, visto que contempla todas as variáveis sugeridas neste trabalho. Assim, nas próximas seções serão apresentados os resultados das simulações das RNAs dos outros cenários propostos, os quais suas variáveis são derivadas do cenário 0.



Figura 26 – Resultado das simulações referentes ao cenário 0 Fonte: Elaborado pelo autor

5.1.2 Resultados das simulações considerando as variáveis de entrada propostas no Cenário 1

Conforme apresentado na Tabela 19, o cenário 1 considera todas as variáveis, tanto diárias quanto acumuladas, originadas dos eventos de CC. Em relação as variáveis oriundas das sobrecargas verificadas, são considerados os percentuais diários e acumulados de perda de vida útil, calculados a partir de (26), assim desprezando as variáveis que contabilizam o tempo em cada faixa de carregamento proposta.

Os resultados das simulações considerando as variáveis contempladas neste cenário, são apresentados na Figura 27.

O impacto referente a não consideração desta variável, se traduz em desempenhos inferiores das RNAs deste cenário, quando comparadas as RNAs que consideram as variáveis propostas no cenário 0, conforme pode ser observado na Tabela 20. Dessa forma, considerando os cenários 0 e 1, é possível concluir que a variável referente ao tempo que o transformador de potência opera segundo as faixas sugeridas nesse trabalho não pode ser desconsiderada, visto o melhor desempenho observado nas RNAs do cenário 0, explicando assim de forma mais adequada a degradação do transformador.



Figura 27 – Resultado das simulações referentes ao cenário 1 Fonte: Elaborado pelo autor

SE	Erro Médio Cen0 (dias)	Erro Médio Cen1 (dias)	Variação Erro Médio entre o Cen0 e Cen1 (%)		
AIM2	20,23	20,00	-1,11%		
AUS1	57,10	67,09	17,48%		
BRP2	9,67	9,63	-0,47%		
CAB1	14,77	14,99	1,49%		
CLN3	2,43	1,54	-36,50%		
CPN1	23,90	32,88	37,53%		
CPV2	27,97	29,50	5,46%		
CTL1	31,62	55,18	74,50%		
GTB3	3,45	3,62	4,90%		
IPB1	2,81	2,84	1,00%		
JUN4	10,85	10,83	-0,20%		
MRN2	29,68	29,82	0,49%		
MZB2	21,14	27,36	29,45%		
PII1	19,85	28,70	44,60%		
PIR1	19,25	19,27	0,10%		
QCS1	19,78	24,45	23,59%		
TUT1	14,63	23,29	59,16%		
UNV1	6,14	8,61	40,17%		
VDN1	34,04	35,23	3,51%		
VPB1	45,74	45,56	-0,39%		
VTR4	14,03	17,57	25,23%		

Tabela 20 - Comparação do desempenho dos modelos de RNA, considerando as varáveis de entrada consideradas nos cenários 0 e 1.

Fonte: Elaborado pelo autor

5.1.3 Resultados das simulações considerando as variáveis de entrada propostas no Cenário 2

Conforme apresentado na Tabela 19, o cenário 2 admite as mesmas variáveis do cenário 1, porém considera apenas valores acumulados, de todas as variáveis oriundas dos eventos de CC e os percentuais de perda de vida útil devido ao carregamento do transformador.

Os resultados das simulações considerando as variáveis contempladas neste cenário, são apresentados na Figura 28.

As RNAs simuladas considerando as variáveis contempladas no cenário 2 apresentaram, em sua maioria, melhor desempenho, quando comparadas aos resultados do cenário 1, conforme pode ser observado na Tabela 21. Assim, como estes cenários possuem as mesmas variáveis, pode-se concluir que a representação a partir de valores acumulados, tem melhor desempenho para o estudo de caso apresentado neste trabalho.

Mesmo o cenário 2 apresentando melhor desempenho em relação ao cenário 1, o cenário 0, ainda possui o melhor desempenho quando comparado aos demais cenários.



Figura 28 – Resultado das simulações referentes ao cenário 2 Fonte: Elaborado pelo autor

SE	Erro	Erro	Erro	Variação Erro	Variação Erro	Cenário de
	iviedio	iviedio	iviedio	iviedio entre	iviedio entre	Melhor
	CenU	Cen1	Cen2	o Cenú e	o Cen1 e	Desempenho
	(días)	(días)	(dias)	Cen2 (%)	Cen2 (%)	•
AIM2	20,23	20,00	19,51	-3,54%	-2,46%	Cen2
AUS1	57,10	67,09	66,23	15,98%	-1,28%	Cen0
BRP2	9,67	9,63	8,98	-7,10%	-6,67%	Cen2
CAB1	14,77	14,99	15,65	5,94%	4,39%	Cen0
CLN3	2,43	1,54	2,40	-1,44%	55,22%	Cen1
CPN1	23,90	32,88	38,33	60,36%	16,60%	Cen0
CPV2	27,97	29,50	28,21	0,84%	-4,39%	Cen0
CTL1	31,62	55,18	35,79	13,19%	-35,13%	Cen0
GTB3	3,45	3,62	3,27	-5,30%	-9,72%	Cen2
IPB1	2,81	2,84	2,47	-12,04%	-12,91%	Cen2
JUN4	10,85	10,83	11,00	1,36%	1,56%	Cen1
MRN2	29,68	29,82	30,35	2,28%	1,78%	Cen0
MZB2	21,14	27,36	27,28	29,05%	-0,31%	Cen0
PII1	19,85	28,70	28,72	44,71%	0,08%	Cen0
PIR1	19,25	19,27	18,89	-1,84%	-1,94%	Cen2
QCS1	19,78	24,45	22,47	13,61%	-8,07%	Cen0
TUT1	14,63	23,29	23,50	60,57%	0,88%	Cen0
UNV1	6,14	8,61	7,36	19,88%	-14,47%	Cen0
VDN1	34,04	35,23	34,34	0,89%	-2,53%	Cen0
VPB1	45,74	45,56	38,93	-14,89%	-14,55%	Cen2
VTR4	14,03	17,57	17,84	27,13%	1,51%	Cen0

Tabela 21 - Comparação do desempenho dos modelos de RNA, considerando as varáveis de entrada consideradas nos cenários 0, 1 e 2. Fonte: Elaborado pelo autor

5.1.4 Resultados das simulações considerando as variáveis de entrada propostas no Cenário 3

Conforme apresentado na Tabela 19, o cenário 3 considera as variáveis diárias e acumuladas, oriundas dos eventos de CC e sobrecargas, desconsiderando a variável de perda percentual de vida útil, considerando assim os tempos de operação do transformador de potência nas faixas de carregamento propostas.

Os resultados das simulações considerando as variáveis contempladas neste cenário, são apresentados na Figura 29

É possível perceber, através da Tabela 22, uma melhora, em relação ao desempenho na maioria das RNAs que utilizam as variáveis contempladas no cenário 3, quando comparadas as respostas das RNAs dos cenários 1 e 2. Assim, a partir dos cenários discutidos até o momento, a variável que mais se adequada para representar o impacto do carregamento na vida útil dos transformadores propostos neste trabalho é o tempo que

este opera segundo as faixas de carregamento sugeridas.

Nos cenários 1 e 2 foram consideradas as variáveis referentes a perda percentual de vida útil, levando assim a desempenhos inferiores as RNAs simuladas considerando as variáveis propostas no cenário 3.

O cenário 0 ainda possui melhor desempenho quando comparado aos demais cenários apesentados até o momento.

Ao contrário dos cenários 0, 1 e 2, a posição que obteve o melhor desempenho foi UNV1, que apresenta, assim como CLN3, configuração bastante estável. A posição com pior desempenho, nos cenários até aqui apresentados continua sendo AUS1.



Figura 29 – Resultado das simulações referentes ao cenário 3 Fonte: Elaborado pelo autor

					Variação	Variação	Variação	
	Erro	Erro	Erro	Erro	Erro	Erro	Erro	Cenário de
SF	Médio	Médio	Médio	Médio	Médio	Médio	Médio	Melhor
52	Cen0	Cen1	Cen2	Cen3	entre o	entre o	entre o	Desempenho
	(dias)	(dias)	(dias)	(dias)	Cen0 e	Cen1 e	Cen2 e	2 000
					Cen3 (%)	Cen3 (%)	Cen3 (%)	
AIM2	20,23	20,00	19,51	20,29	0,29%	1,41%	3,97%	Cen2
AUS1	57,10	67,09	66,23	66,21	15,95%	-1,30%	-0,02%	Cen0
BRP2	9,67	9,63	8,98	11,38	17,66%	18,21%	26,66%	Cen2
CAB1	14,77	14,99	15,65	16,87	14,20%	12,52%	7,79%	Cen0
CLN3	2,43	1,54	2,40	13,33	448,48%	763,77%	456,49%	Cen1
CPN1	23,90	32,88	38,33	27,02	13,03%	-17,82%	-29,52%	Cen0
CPV2	27,97	29,50	28,21	27,67	-1,08%	-6,21%	-1,90%	Cen3
CTL1	31,62	55,18	35,79	31,91	0,89%	-42,18%	-10,86%	Cen0
GTB3	3,45	3,62	3,27	8,87	157,00%	145,00%	171,39%	Cen2
IPB1	2,81	2,84	2,47	13,31	373,90%	369,22%	438,74%	Cen2
JUN4	10,85	10,83	11,00	22,08	103,49%	103,91%	100,77%	Cen1
MRN2	29,68	29,82	30,35	26,39	-11,08%	-11,51%	-13,06%	Cen3
MZB2	21,14	27,36	27,28	26,13	23,63%	-4,50%	-4,20%	Cen0
PII1	19,85	28,70	28,72	19,15	-3,51%	-33,27%	-33,32%	Cen3
PIR1	19,25	19,27	18,89	21,10	9,62%	9,51%	11,68%	Cen2
QCS1	19,78	24,45	22,47	19,04	-3,73%	-22,10%	-15,26%	Cen3
TUT1	14,63	23,29	23,50	14,54	-0,64%	-37,58%	-38,12%	Cen3
UNV1	6,14	8,61	7,36	7,77	26,49%	-9,76%	5,51%	Cen0
VDN1	34,04	35,23	34,34	34,05	0,02%	-3,37%	-0,86%	Cen0
VPB1	45,74	45,56	38,93	47,69	4,26%	4,67%	22,50%	Cen2
VTR4	14,03	17,57	17,84	16,41	16,92%	-6,64%	-8,03%	Cen0

Tabela 22 - Comparação do desempenho dos modelos de RNA, considerando as varáveis de entrada consideradas nos cenários 0, 1, 2 e 3.

Fonte: Elaborado pelo autor

5.1.5 Resultados das simulações considerando as variáveis de entrada propostas no Cenário 4

Conforme apresentado na Tabela 19, o cenário 4 considera as variáveis acumuladas, oriundas dos eventos de CC e sobrecargas, desconsiderando a variável de perda percentual de vida útil, considerando assim os tempos de operação do transformador de potência nas faixas de carregamento propostas.

Os resultados das simulações considerando as variáveis contempladas neste cenário, são apresentados na Figura 30.

As variáveis utilizadas nas RNAs simuladas no cenário 4, foram as que

apresentaram melhor desempenho, conforme pode ser observado na Tabela 23. Logo, é possível ratificar, que a variável mais adequada para representar a perda de vida útil do transformador devido ao seu carregamento é o tempo que este opera segundo as faixas sugeridas. Além disso, a representação das variáveis através de seus valores acumulados se configura também como a representação mais adequada.

Assim as variáveis sugeridas no cenário 4, se mostram como as mais adequadas, para a representação do problema proposto neste trabalho.



Figura 30 - Resultado das simulações referentes ao cenário 4

						Variação	Variação	Variação	Variação	
	Frro	Frro	Frro	Frro	Frro	Erro	Erro	Erro	Erro	
	Médio	Médio	Médio	Médio	Médio	Médio	Médio	Médio	Médio	Cenário de
SE	Cen0	Cen1	Cen2	Cen3	Cen4	entre o	entre o	entre o	entre o	Melhor
	(dias)	(dias)	(dias)	(dias)	(dias)	Cen0 e	Cen1 e	Cen2 e	Cen3 e	Desempenho
	(ulus)	(ulus)	(ulus)	(ulus)	(ulus)	Cen4	Cen4	Cen4	Cen4	
						(%)	(%)	(%)	(%)	
AIM2	20,23	20,00	19,51	20,29	19,34	-4,38%	-3,30%	-0,86%	-4,65%	Cen4
AUS1	57,10	67,09	66,23	66,21	60,43	5,84%	-9,92%	-8,75%	-8,73%	Cen0
BRP2	9,67	9,63	8,98	11,38	8,97	-7,22%	-6,78%	-0,12%	-21,15%	Cen4
CAB1	14,77	14,99	15,65	16,87	14,65	-0,79%	-2,24%	-6,35%	-13,12%	Cen4
CLN3	2,43	1,54	2,40	13,33	1,97	-18,89%	27,74%	-17,70%	-85,21%	Cen1
CPN1	23,90	32,88	38,33	27,02	31,00	29,68%	-5,71%	-19,13%	14,73%	Cen0
CPV2	27,97	29,50	28,21	27,67	26,16	-6,49%	-11,33%	-7,26%	-5 <i>,</i> 46%	Cen4
CTL1	31,62	55,18	35,79	31,91	31,39	-0,75%	-43,12%	-12,31%	-1,63%	Cen4
GTB3	3,45	3,62	3,27	8,87	2,62	-24,08%	-27,62%	-19,83%	-70,46%	Cen4
IPB1	2,81	2,84	2,47	13,31	2,67	-4,88%	-5,82%	8,14%	-79,93%	Cen2
JUN4	10,85	10,83	11,00	22,08	11,00	1,44%	1,64%	0,08%	-50,15%	Cen1
MRN2	29,68	29,82	30,35	26,39	30,15	1,57%	1,08%	-0,69%	14,23%	Cen3
MZB2	21,14	27,36	27,28	26,13	20,83	-1,44%	-23,86%	-23,63%	-20,28%	Cen4
PII1	19,85	28,70	28,72	19,15	18,82	-5,18%	-34,43%	-34,48%	-1,73%	Cen4
PIR1	19,25	19,27	18,89	21,10	18,82	-2,22%	-2,33%	-0,39%	-10,81%	Cen4
QCS1	19,78	24,45	22,47	19,04	18,77	-5,11%	-23,22%	-16,48%	-1,43%	Cen4
TUT1	14,63	23,29	23,50	14,54	13 <i>,</i> 38	-8,59%	-42,57%	-43,07%	-8,00%	Cen4
UNV1	6,14	8,61	7,36	7,77	5,61	-8,58%	-34,78%	-23,74%	-27,73%	Cen4
VDN1	34,04	35,23	34,34	34,05	32,77	-3,72%	-6,98%	-4,56%	-3,74%	Cen4
VPB1	45,74	45,56	38,93	47,69	45,30	-0,94%	-0,56%	16,38%	-4,99%	Cen2
VTR4	14,03	17,57	17,84	16,41	14,14	0,75%	-19,55%	-20,75%	-13,83%	Cen0

Tabela 23 - Comparação do desempenho dos modelos de RNA, considerando as varáveis de entrada
consideradas nos cenários 0, 1, 2 e 3.

Fonte: Elaborado pelo autor

5.1.6 Conclusões Parciais

A partir dos resultados da Figura 31 é possível observar os melhores desempenhos de cada cenário simulado, considerando o erro médio, de cada RNA. Assim, fica claro que as variáveis selecionadas no cenário 4 foram as que apresentaram o melhor desempenho do conjunto de dados simulados. Desta forma é possível concluir que as variáveis acumuladas e as que não sofreram nenhum tipo de transformação, como a variável de tempo em sobrecarga, apresentam maior relevância para o problema estudado.

Em relação aos resultados obtidos, foram satisfatórios, tendo em vista que a maioria das posições apresentaram erros médios menores do que trinta dias, desta forma considerando o cenário de manutenção destes transformadores de potência é bastante

razoável considerar o erro médio e o desvio padrão de cada modelo com o objetivo de direcionar inspeções de manutenção mais detalhadas nesses ativos.

A implementação desta metodologia como ferramenta de diagnóstico para a manutenção, indica a necessidade de intervenção no ativo monitorado, dessa forma evitando sua falha, que tem como consequência para a distribuidora a degradação dos indicadores de qualidade do serviço.

O acompanhamento deste monitoramento também pode ser utilizado pela operação em tempo real da distribuidora, a qual pode tomar ações nos transformadores mais críticos, com o objetivo de reduzir a exposição a sobrecargas e curtos-circuitos sucessivos.

Assim, a partir da implementação da metodologia proposta, podem ser monitorados os ativos de maior valor nas subestações, ou seja, seus transformadores de potência. Desta forma, a metodologia sugerida neste trabalho pode ser replicada para qualquer outra subestação ou distribuidora que não possua o diagnóstico on-line dos gases dissolvidos em seus transformadores.



Figura 31 – Resultado das simulações que obtiverem os melhores resultados nos cenários simulados Fonte: Elaborado pelo autor

5.2 RESULTADOS DAS SIMULAÇÕES DO MODELO DE RNA CONSIDERANDO TODAS AS POSIÇÕES DE TRANSFORMAÇÃO

Com o objetivo de representar todas as posições a partir de uma única RNA, todos os exemplos foram agrupados em uma única base de dados e simulados considerando o fluxo da Figura 25, gerando assim os resultados apresentados na Figura 32.

A partir das simulações, foi verificado que o cenário 2 apresentou o melhor desempenho, assim o modelo de RNA gerado nesse cenário foi utilizado para realizar as previsões considerando todas as 21 posições, gerando assim o resultado apresentado na Figura 33.



Figura 32 – Desempenho dos modelos de RNAs que consideram todas as posições Fonte: Elaborado pelo autor

Quanto ao resultado obtido referente a tentativa de representação de todas as posições através de um único modelo de RNA, fica evidente pela Figura 33, que o desempenho foi muito inferior quando comparado ao desempenho dos modelos independentes para cada posição.

Esse fato se dá por conta de que todas as posições têm seus circuitos associados, os quais possuem características diferentes de operação e de carregamento, tendo em vista que as amostras selecionadas fazem parte de regiões diferentes da área de concessão da distribuidora estudada.

Dessa forma, a especificidade de cada localidade se torna preponderante para o desempenho do modelo de RNA, logo a representação individual de cada modelo é relevante para a realização das previsões.

5.3 CONSIDERAÇÕES FINAIS

Conforme apresentado no estado da arte dos modelos de previsão de falhas em transformadores de potência, não foram identificados trabalhos nesta linha que estimassem o tempo para a ocorrência do defeito levando em consideração as variáveis de entrada aqui utilizadas, sem adotar as relações de gases dissolvidos no óleo do transformador.

Foram obtidos, na grande maioria dos casos, erros médios inferiores a 30 dias quando considerados os modelos de RNAs independentes. Assim, quando comparado ao tempo de vida útil deste ativo, que em média é de 30 anos, o presente resultado se torna satisfatório.



Figura 33 – Desempenho de cada posição considerando o modelo de RNA com melhor desempenho Fonte: Elaborado pelo autor

6 CONCLUSÕES E TRABALHOS FUTUROS

6.1 CONCLUSÕES

O presente trabalho propôs a utilização de grandezas operacionais para a realização de previsões do tempo para falhas de transformadores de potência utilizando modelos de RNAs. Comumente os modelos de previsão utilizam o monitoramento online das concentrações de gases dissolvidas no óleo do transformador obtidas a partir da DGA para a realização de previsões de falhas. Porém, nas subestações contempladas no escopo deste trabalho, que possuem configuração de até 12 MVA (quatro transformadores de 3 MVA), o custo para este monitoramento pode representar o custo do transformador, assim tornando sua aplicação inviável.

A contribuição deste trabalho está fundamentada na utilização de grandezas disponíveis em qualquer centro de operação, as quais são: valor eficaz da corrente de CC simétrica externa ao equipamento, proveniente de um CC na rede de distribuição, valor eficaz da corrente de operação e o fabricante do transformador. A partir dessas variáveis iniciais, foram criadas segmentações dessas, chegando assim a 56 entradas definidas no cenário base (cenário 0). Em relação a variável de saída, foi definida como o tempo, em dias, para a falha do equipamento.

Para a realização das simulações foram consideradas 21 posições de transformação de uma distribuidora do Rio de Janeiro, as quais tiveram pelo menos uma falha a partir de janeiro de 2016. A metodologia utilizada baseou-se na modelagem individual de uma RNA por posição, bem como a tentativa de representar através de uma única RNA todas as posições. Com o objetivo de verificar o desempenho de cada RNA, de acordo com os dados de entrada, foram propostos quatro outros cenários, os quais consideravam algumas variáveis do cenário base.

As simulações foram realizadas através de rotinas desenvolvidas no ambiente Python, utilizando a arquitetura dos modelos MLP, uma camada escondida, com processo de aprendizagem do tipo supervisionado e algoritmo de aprendizagem do tipo retropropagação do erro. A função de custo teve como objetivo minimizar o erro quadrático médio, utilizando o método de otimização do gradiente descendente estocástico. As etapas de treinamento, validação e testes, receberam, cada uma, 33,33% dos dados disponíveis em cada modelo, com a atribuição ocorrendo de forma intercalada entre as etapas. O processo de simulação envolveu a variação da quantidade de neurônios na camada escondida. A métrica estabelecida para verificar o desempenho de cada RNA foi o erro médio absoluto, em dias. A função de ativação sigmoid foi considerada durante todas as simulações. Durante as simulações foram admitidas até 4.000 épocas, utilizando monitoramento *Early Stopping*, com tolerância de até 1.000 épocas.

Os resultados obtidos a partir da representação de cada posição através de RNAs independentes mostraram-se satisfatórios, com a maioria dos erros médios menores do que 30 dias. As variáveis sugeridas no cenário 4, que considerou a perda de vida útil do transformador através do tempo em que este opera segundo as faixas sugeridas e as demais variáveis representadas por meio de seus valores acumulados, se mostraram como as mais adequadas para a representação do problema proposto neste trabalho.

Assim, as RNAs que consideravam as variáveis do cenário 4 apresentaram, em sua maioria, melhor desempenho quando comparadas as RNAs dos demais cenários.

Além da representação de RNAs individuais para cada posição, foi proposta uma única RNA, com objetivo de representar todas as posições. A RNA que considerava as variáveis propostas no cenário 2, foi a que obteve o melhor desempenho.

Logo, a partir desse modelo foram realizadas as previsões de falhas individuais de cada posição, que obtiveram desempenho bastante inferior, quando comparado aos modelos de RNAs individuais por posição. Portanto, é possível concluir que a especificidade de cada posição, visto que as posições apresentam circuitos com características distintas, possuem grande relevância no desempenho do modelo, logo a representação de cada RNA através de seu modelo independente é ideal para o problema proposto.

6.2 TRABALHOS FUTUROS

Como sugestões de trabalhos futuros, propõe-se a validação desta metodologia através da comparação dos resultados obtidos por meio da modelagem de RNAs utilizando como dados de entrada as concentrações de gases obtidas através da DGA. Além disso, também é proposto a formação de clusters de posições de transformação que se assemelham, com o objetivo de representar através de uma única RNA o comportamento destas posições.

REFERÊNCIAS

- S. L. Lima, O. R. Saavedra, and V. Miranda, "A two-level framework to fault diagnosis and decision making for power transformers," *IEEE Trans. Power Deliv.*, vol. 30, no. 1, pp. 497–504, Feb. 2015, doi: 10.1109/TPWRD.2014.2355176.
- [2] Agência Nacional de Energia Elétrica (ANEEL), "Procedimentos de Distribuição de Energia Elétrica no Sistema Elétrico Nacional PRODIST Módulo 8 Qualidade da Energia Elétrica Rev. 10," 2018. https://www.aneel.gov.br/documents/656827/14866914/Módulo_8-Revisão_10/2f7cb862-e9d7-3295-729a-b619ac6baab9 (accessed Feb. 06, 2020).
- [3] Agência Nacional de Energia Elétrica (ANEEL), "Compensação pela Transgressão dos Limites de Continuidade." https://www.aneel.gov.br/indicadores-de-compensacao-de-continuidade (accessed Feb. 12, 2020).
- [4] IEEE, IEEE Guide for Failure Investigation, Documentation, Analysis, and Reporting for Power Transformers and Shunt Reactors. IEEE Std C57.125-2015, 2015.
- [5] IEC, *IEC International electrotechnical vocabulary Chapter 191 -Dependability and quality of service*. IEC Std. 60050-191, 1990.
- [6] A. Bossi, J. E. Dind, J. M. Frisson, U. Khoudiakov, H. F. Light, and E. Al., "An International Survey of Failures in Large Power Transformers in Service," *Final report of the CIGRE Working Group 12.05, Electra*, no. 88. pp. 21–48, 1983.
- [7] CIGRE WG A2.37, "Transformer Reliability Survey," *CIGRE Session*. 2015.
- [8] S. Li, G. Wu, B. Gao, C. Hao, D. Xin, and X. Yin, "Interpretation of DGA for Transformer Fault Diagnosis with Complementary SaE-ELM and Arctangent Transform," pp. 586–595, 2015, doi: 10.1109/TDEI.2015.005410.
- [9] F. Zakaria, "Artificial Neural Network (ANN) Application in Dissolved Gas Analysis (DGA) Methods for the Detection of Incipient Faults in Oil-Filled Power Transformer," pp. 23–25, 2012.
- [10] P. Mirowski and Y. Lecun, "Statistical Machine Learning and Dissolved Gas Analysis : A Review," vol. 27, no. 4, pp. 1791–1799, 2012.
- [11] Y. Zhang, X. Ding, Y. Liu, and P. J. Griffin, "An Artificial Neural Network Approach to Transformer Fault Diagnosis," vol. 11, no. 4, pp. 1836–1841, 1996.

- [12] A. Shintemirov, W. Tang, Q. H. Wu, and S. Member, "Power Transformer Fault Classification Based on Dissolved Gas Analysis by Implementing Bootstrap and Genetic Programming," vol. 39, no. 1, pp. 69–79, 2009.
- [13] S. Singh and M. Bandyopadhyay, "Dissolved gas analysis technique for incipient fault diagnosis in power transformers: A bibliographic survey," *IEEE Electr. Insul. Mag.*, vol. 26, no. 6, pp. 41–46, 2010, doi: 10.1109/MEI.2010.5599978.
- [14] N. Bakar, A. Abu-Siada, and S. Islam, "A review of dissolved gas analysis measurement and interpretation techniques," *IEEE Electr. Insul. Mag.*, vol. 30, no. 3, pp. 39–49, 2014, doi: 10.1109/MEI.2014.6804740.
- [15] IEEE, IEEE Guide for the Interpretation of Gases Generated in Mineral Oil-Immersed Transformers. IEEE Std C57.104TM-2019, 2019.
- [16] IEC, IEC Mineral oil-filled electrical equipment in service Guidance on the interpretation of dissolved and free gases analysis. IEC Std. 60599:2015 RLV, 2015.
- [17] H. Sun, Y. Huang, and C. Huang, "Fault Diagnosis of Power Transformers Using Computational Intelligence : A Review," 2012, doi: 10.1016/j.egypro.2011.12.1080.
- [18] C. Yuan, "Developing a new transformer fault diagnosis system through evolutionary fuzzy logic," *IEEE Trans. Power Del*, vol. 12, no. 2, pp. 761–767, 1997.
- [19] R. Naresh, V. Sharma, and M. Vashisth, "An integrated neural fuzzy approach for fault diagnosis of transformers," *IEEE Trans. Power Deliv.*, vol. 23, no. 4, pp. 2017–2024, 2008, doi: 10.1109/TPWRD.2008.2002652.
- [20] D. Wang, Z. Zhou, and H. Chen, "Fault diagnosis of power transformers : application of fuzzy set theory, expert systems and artificial neural networks," *IEE Proc.-Sei. Meas. Technol*, vol. 44file:///, no. 1, pp. 39–44, 1997.
- [21] H. T. Yang and Y. C. Huang, "Intelligent decision support for diagnosis of incipient transformer faults using self-organizing Polynomial Networks," *IEEE Power Eng. Rev.*, vol. 17, no. 12, p. 62, 1997, doi: 10.1109/pica.1997.599378.
- [22] Z. Wang, Y. Liu, and P. J. Griffin, "A combined ANN and expert system tool for transformer fault diagnosis," 2000 IEEE Power Eng. Soc. Conf. Proc., vol. 2, no. c, pp. 1261–1269, 2000, doi: 10.1109/PESW.2000.850127.
- [23] J. L. Guardado, J. L. Naredo, P. Moreno, and C. R. Fuerte, "A Comparative Study of Neural Network Efficiency in Power Transformers Diagnosis Using

Dissolved Gas Analysis," *IEEE Power Eng. Rev.*, vol. 21, no. 7, p. 71, 2001, doi: 10.1109/MPER.2001.4311491.

- [24] V. Miranda and A. R. G. Castro, "Improving the IEC table for transformer failure diagnosis with knowledge extraction from neural networks," *IEEE Trans. Power Deliv.*, vol. 20, no. 4, pp. 2509–2516, 2005, doi: 10.1109/TPWRD.2005.855423.
- [25] D. J. Allan, "Evolving Neural Nets for Fault Diagnosis of Power Transformers," *Electr. Eng. Ref. B. Sixt. Ed.*, vol. 18, no. 3, pp. 1–30, 2003, doi: 10.1016/B978-075064637-6/50033-2.
- [26] A. S. Farag, M. Mohandes, and A. Al-shaikh, "Diagnosing failed distribution transformers using neural networks," vol. 16, no. 4, pp. 631–636, 2001.
- [27] E. T. Mharakurwa, G. N. Nyakoe, and A. O. Akumu, "Power Transformer Fault Severity Estimation Based on Dissolved Gas Analysis and Energy of Fault Formation Technique," *J. Electr. Comput. Eng.*, vol. 2019, doi: https://doi.org/10.1155/2019/9674054.
- [28] A. J. Kachler and I. Höhlein, "Aging of cellulose at transformer service temperatures. Part 1: Influence of type of oil and air on the degree of polymerization of pressboard, dissolved gases, and furanic compounds in oil," *IEEE Electr. Insul. Mag.*, vol. 21, no. 2, pp. 15–21, 2005, doi: 10.1109/MEI.2005.1412215.
- [29] A. M. Emsley and G. C. Stevens, "Review of chemical indicators of degradation of cellulosic electrical paper insulation in oil-filled transformers," *IEE Proc. Sci. Meas. Technol.*, vol. 141, no. 5, pp. 324–334, 1994, doi: 10.1049/ipsmt:19949957.
- [30] L. E. Lundgaard, W. Hansen, D. Linhjell, and T. J. Painter, "Aging of Oil-Impregnated Paper in Power Transformers," *IEEE Trans. Power Deliv.*, vol. 19, no. 1, pp. 230–239, 2004, doi: 10.1109/TPWRD.2003.820175.
- [31] C.Bengtsson, "Status and Trends in Transformer Monitoring," *IEEE Trans. Power Deliv.*, vol. 11, no. 3, pp. 1379–1384, 1996.
- [32] Y. B. Wang *et al.*, "Acoustic localization of partial discharge sources in power transformers using a particle-swarm-optimization-route-searching algorithm," *IEEE Trans. Dielectr. Electr. Insul.*, vol. 24, no. 6, pp. 3647–3656, 2017, doi: 10.1109/TDEI.2017.006857.
- [33] C. Gao, L. Yu, Y. Xu, W. Wang, S. Wang, and P. Wang, "Partial discharge localization inside transformer windings via fiber-optic acoustic sensor array,"

IEEE Trans. Power Deliv., vol. 34, no. 4, pp. 1251–1260, 2019, doi: 10.1109/TPWRD.2018.2880230.

- [34] S. Coenen and S. Tenbohlen, "Sensitivity of UHF PD Measurement," *IEEE Trans. Dielectr. Electr. Insul.*, vol. 15, no. 6, pp. 1–12, 2008.
- [35] P. J. Moore, I. E. Portugues, and I. A. Glover, "Partial discharge investigation of a power transformer using wireless wideband radio-frequency measurements," *IEEE Trans. Power Deliv.*, vol. 21, no. 1, pp. 528–530, 2006, doi: 10.1109/TPWRD.2005.848438.
- [36] V. Jeyabalan and S. Usa, "Statistical techniques for partial-discharge location in transformer windings," *IEEE Trans. Power Deliv.*, vol. 26, no. 3, pp. 2064–2065, 2011, doi: 10.1109/TPWRD.2011.2112490.
- [37] Suwarno and Santosh, "Effects of electric arcing on partial discharge characteristics in liquid high voltage insulation," *Asia-Pacific Power Energy Eng. Conf. APPEEC*, pp. 2–5, 2012, doi: 10.1109/APPEEC.2012.6307322.
- [38] IEC, *IEC Power transformers Part 5: Ability to withstand short circuit.* IEC Std 60076-5:2000, 2000.
- [39] S. S. Patil, S. E. Chaudhari, H. Voltage, P. Technology, and C. G. Limited, "An Attempt to Investigate the Transformer Failure by using DGA and SFRA Analysis," pp. 1–4, 2012.
- [40] IEEE, *IEEE Guide for the Application and Interpretation of Frequency Response Analysis for Oil-Immersed Transformers.* IEEE Std C57.149-2012, 2012.
- [41] R. Khalili, J. Sadeh, and H. Borsi, "Frequency response analysis (FRA) of transformers as a tool for fault detection and location : A review," *Electr. Power Syst. Res.*, vol. 155, pp. 172–183, 2018, doi: 10.1016/j.epsr.2017.10.014.
- [42] T. Y. Ji, W. H. Tang, and Q. H. Wu, "Detection of power transformer winding deformation and variation of measurement connections using a hybrid winding model," *Electr. Power Syst. Res.*, vol. 87, pp. 39–46, 2012, doi: 10.1016/j.epsr.2012.01.007.
- [43] A. Abu-Siada, N. Hashemnia, S. Islam, and M. Masoum, "Understanding power transformer frequency response analysis signatures," *IEEE Electr. Insul. Mag.*, vol. 29, no. 3, pp. 48–56, 2013, doi: 10.1109/MEI.2013.6507414.
- [44] N. Hashemnia, A. Abu-Siada, and S. Islam, "Improved power transformer winding fault detection using FRA diagnostics-part 2: Radial deformation simulation," *IEEE Trans. Dielectr. Electr. Insul.*, vol. 22, no. 1, pp. 564–570,

2015, doi: 10.1109/TDEI.2014.004592.

- [45] E. Rahimpour, J. Christian, K. Feser, and H. Mohseni, "Transfer function method to diagnose axial displacement of transformer windings," *Eur. Trans. Electr. Power*, vol. 12, no. 3, pp. 225–233, 2002, doi: 10.1002/etep.4450120309.
- [46] A. A. Pandya and B. R. Parekh, "Interpretation of Sweep Frequency Response Analysis (SFRA) traces for the open circuit and short circuit winding fault damages of the power transformer," *Int. J. Electr. Power Energy Syst.*, vol. 62, pp. 890–896, 2014, doi: 10.1016/j.ijepes.2014.05.011.
- [47] M. Khanali, A. Hayati-Soloot, H. K. Høidalen, and S. Jayaram, "Study on locating transformer internal faults using sweep frequency response analysis," *Electr. Power Syst. Res.*, vol. 145, pp. 55–62, 2017, doi: 10.1016/j.epsr.2016.11.016.
- [48] J. A. S. B. Jayasinghe, Z. D. Wang, P. N. Jarman, and A. W. Darwin,
 "Investigations on sensitivity of FRA technique in diagnosis of transformer winding deformations," *Conf. Rec. IEEE Int. Symp. Electr. Insul.*, no. September, pp. 496–499, 2004, doi: 10.1109/elinsl.2004.1380661.
- [49] N. Hashemnia, A. Abu-Siada, and S. Islam, "Detection of power transformer bushing faults and oil degradation using frequency response analysis," *IEEE Trans. Dielectr. Electr. Insul.*, vol. 23, no. 1, pp. 222–229, 2016, doi: 10.1109/TDEI.2015.005032.
- [50] C. Ekanayake and T. Saha, "Examining the Ageing of Transformer Insulation Using FRA and FDS Techniques," *IEEE Trans. Dielectr. Electr. Insul.*, vol. 22, no. 2, pp. 1258–1265, 2015, doi: 10.1109/TDEI.2014.004695.
- [51] O. M. Aljohani and A. Abu-Siada, "Impact of power transformer insulating mineral oil degradation on FRA polar plot," *IEEE Int. Symp. Ind. Electron.*, vol. 2015-Septe, pp. 567–572, 2015, doi: 10.1109/ISIE.2015.7281530.
- [52] A. Contin, G. Rabach, J. Borghetto, M. De Nigris, R. Passaglia, and G. Rizzi,
 "Frequency-response analysis of power transformers by means of fuzzy tools," *IEEE Trans. Dielectr. Electr. Insul.*, vol. 18, no. 3, pp. 900–909, 2011, doi: 10.1109/TDEI.2011.5931079.
- [53] M. Bigdeli, M. Vakilian, and E. Rahimpour, "Transformer winding faults classification based on transfer function analysis by support vector machine," *IET Electr. Power Appl.*, vol. 6, no. 5, pp. 268–276, 2012, doi: 10.1049/iet-epa.2011.0232.

- [54] M. Bigdeli, M. Vakilian, and E. Rahimpour, "A probabilistic neural network classifier-based method for transformer winding fault identification through its transfer function measurement," *Int. Trans. Electr. Energy Syst.*, vol. 23, no. 3, pp. 392–404, 2012, doi: 10.1002/etep.668.
- [55] A. J. Ghanizadeh and G. B. Gharehpetian, "ANN and cross-correlation based features for discrimination between electrical and mechanical defects and their localization in transformer winding," *IEEE Trans. Dielectr. Electr. Insul.*, vol. 21, no. 5, pp. 2374–2382, 2014, doi: 10.1109/TDEI.2014.004364.
- [56] S. Haykin, *Redes Neurais: Princípios e Prática*, 2nd ed. Bookman, 2001.
- [57] "Keras Framewok." https://keras.io/api/layers/activation_layers/ (accessed May 24, 2020).
- [58] J. Brownlee, "Rescaling Data for Machine Learning in Python with Scikit-Learn.".
- [59] J. Brownlee, "How to Choose Loss Functions When Training Deep Learning Neural Networks.".
- [60] J. M. Filho, *Manual de Equipamentos Elétricos*, 3. ed. Rio de Janeiro: LTC, 2005.
- [61] IEEE, *IEEE Guide for Loading Mineral- Oil-Immersed Transformers and Step-Voltage Regulators.* IEEE Std C57.91-2012, 2012.