

**UNIVERSIDADE DO ESTADO DO AMAZONAS
ESCOLA SUPERIOR DE TECNOLOGIA**

DANIEL SOUSA DA SILVA

**REDES NEURAIIS APLICADAS A ESTIMATIVA DAS PERDAS DE
TRANSFORMADORES TRIFÁSICOS DE DISTRIBUIÇÃO**

DANIEL SOUSA DA SILVA

**REDES NEURAIS APLICADAS A ESTIMATIVA DAS PERDAS DE
TRANSFORMADORES TRIFÁSICOS DE DISTRIBUIÇÃO**

Projeto de pesquisa desenvolvido durante a disciplina de Trabalho de Conclusão de Curso II e apresentada à banca avaliadora do Curso de Engenharia Elétrica da Escola Superior de Tecnologia da Universidade do Estado do Amazonas.

Orientador: Wheidima Carneiro de Melo, M.sc.

Universidade do Estado do Amazonas – UEA
Escola Superior de Tecnologia - EST

Reitora:

Cleinaldo de Almeida Costa

Vice-Reitor:

Cleto Cavalcante de Souza Leal

Diretor da Escola Superior de Tecnologia:

Roberto Higino Pereira da Silva

Coordenador do Curso de Engenharia Elétrica:

Ingrid Sammyne Gadelha Figueiredo

Banca Avaliadora composta por: Data da defesa: 27/11/2018.

Prof. Daniel Gumzan del Rio,Dr, (Co-orientador)

Prof. Israel Gondres Torné,Dr,

Prof. Jozias Parente de Oliveira, Dr.

CIP – Catalogação na Publicação

Sousa, Daniel da Silva

Redes nerais aplicadas a estimativa das perdas de transformadores trifásicos de distribuição/ Daniel Sousa da Silva [orientado por]Wheidima Carneiro de Melo - Manaus:2018.

63 p.:il.

Trabalho de Conclusão de Curso (Graduação em Engenharia Elétrica). Universidade do Estado do Amazonas, 2018.

1. Estimativa das perdas de transformadores trifásicos
 2. Sistemas de Energia
 3. Redes Nerais Aplicadas a Estimativas das Perdas de Trafos.
- I. Melo, Wheidima Carneiro.
II. Rio, Daniel Guzman.

DANIEL SOUSA DA SILVA

REDES NEURAIIS APLICADAS A ESTIMATIVA DAS PERDAS DE
TRANSFORMADORES TRIFÁSICOS DE DISTRIBUIÇÃO

Pesquisa desenvolvida durante a disciplina de Trabalho de Conclusão de Curso II e apresentada à banca avaliadora do Curso e Engenharia Elétrica da Escola Superior de Tecnologia da Universidade do Estado do Amazonas, como pré-requisito para obtenção do título de Engenharia Eletricista.

Nota obtida: ____ (_____)

Aprovada em ____/____/____ ____/ /

Área de concentração: Sistemas de Energia

BANCA EXAMINADORA

Co-orientador: Daniel Guzman del Rio, Dr.

Avaliador: Jozias Parente de Oliveira, Dr.

Avaliador: Israel Gondres Torné, Dr.

AGRADECIMENTOS

Aos meus pais e meu irmão, por diretamente e indiretamente, terem me apoiado, concedendo a mim esta oportunidade de formação superior.

A esta Universidade, pela gama de aprendizados e lições proporcionadas a nós estudantes de Engenharia na Universidade do Estado do Amazonas.

Ao meus professores orientadores, Dr. Daniel Guzman Del Rio e M.sc Whedima Carneiro de Melo pela paciência em transmitir os direcionamentos e incentivos, sempre no objetivo de ajudar em minha formação. Proporcionando seu tempo em monitoria e tiragens de dúvidas para este projeto. Também, ao Dr. Israel Gondres, avaliador da banca, que me apoio fortemente na criação e elaboração de artigos acadêmicos que contribui muito na minha formação.

Ao meus amigos do meu estágio, José Maria Launé Jr, Waldemar Lucena Jr, Fabrício Felix, Jefferson Cena e Carlos Candido que me apoiaram e tiraram as minhas dúvidas quando solicitei.

A todos os meus amigos que nesta caminhada passaram pelo meu caminho e contribuíram de alguma forma para meu crescimento como pessoa e profissional.

Como também, à memória de M.sc . Charles Luiz Silva de Melo que sempre foi um excelente profissional e pessoa sempre incentivando a elaboração de trabalhos acadêmicos, visando a melhor formação dos alunos e também me incentivou no ponto inicial desta pesquisa.

RESUMO

Esta pesquisa apresenta um estudo da aplicação de redes neurais para estimação das perdas no núcleo e enrolamento de transformadores trifásicos de distribuição. A arquitetura da rede neural utilizada foi a topologia Multiple Layer Perceptron e algoritmo de aprendizagem Levenberg-Marquard que utiliza métodos não lineares. A partir de dados coletados é criado um banco de dados com todos os atributos selecionados para subsequentemente serem utilizados na simulação da rede neural artificial. Todas as amostras de aprendizagem foram coletadas de ensaios elétricos de transformados de software de automatização de ensaios de rotina usado em diversas fábricas de transformadores e concessionárias elétricas. O estágio de teste representa 15% das amostras, esta parte representa a etapa não supervisionada do processo de treinamento onde é possível observar o comportamento da rede neural artificial após o estágio de treinamento (70% das amostras) e validação (15% das amostras). A avaliação da rede neural artificial é feita pelas ferramentas Mean Square Error, Coeficiente de Correlação Linear e análise gráfica do processo de validação cruzada. A partir do processo de treino obteve-se exatidão de 80% e 96% das amostras de teste.

ABSTRACT

This research presents a study of neural network applied to estimate losses in core and winding of three-phase distribution network. The architecture of neural network used was the topology Multiple Layer Perceptron and training algorithm Levenberg-Marquard that use non-linear methods. From collate of data is create a database with all selected attribute for subsequently be used on simulation of artificial neural networks. All samples of learning are collected from transformers electric tests of automated software of routine testing used in diverse transformers industry and concessionaire of electric energy. The test stage represents 15% of samples, this part represents not supervision stage of training process where is possible observe ANN behavior after training stage (70% of samples) and validation (15% of samples). The evaluation of neural network was made by tools Mean Square Error, Linear Correlation Coefficient and graphic analyzer of cross validation process. From the train process obtain accuracy of 80% and 96% of data samples test.

LISTA DE FIGURAS

1	Neurônio Artificial	14
2	Função de Ativação Bipolar	14
3	Fronteira de Decisão Linear	15
4	Arquitetura Multiple Layer Perceptron	17
5	Função de Ativação Hiperbólica(Esquerda) e Logística(Direita)	18
6	Parada Antecipada	21
7	Exatidão e Precisão	22
8	Parte ativa do transformador	23
9	Curvas de perdas do núcleo	25
10	Núcleo empilhado transformador - Seção Transversal	26
11	Configuração para ensaio à vazio	27
12	Configuração para ensaio em curto-circuito	28
13	Valores garantidos de perdas, corrente de excitação, e tensões de curto-circuito para transformadores trifásicos	29
14	Tolerância	29
15	Fluxograma da Metodologia	30
16	Núcleo empilhado transformador	32
17	Esquema RNA MATLAB	35
18	Curva de performance da RNA de perdas nos enrolamentos para 20 neurônios escondidos	37
19	Coefficiente de correlação linear da RNA de perdas nos enrolamentos para 20 neurônios escondidos	38
20	Curva de performance da RNA de perdas nos enrolamentos para 15 neurônios escondidos	39
21	Curva de performance da RNA de perdas no núcleo para 20 neurônios escondidos	40
22	Coefficiente de correlação linear-R da RNA de perdas no núcleo para 20 neurônios escondidos	40
23	Curva de performance da RNA de perdas no núcleo para 10 neurônios escondidos	41
24	Curva de performance da RNA de perdas no núcleo para o experimento 2. . .	46
25	Coefficiente de correlação linear-R da RNA do experimento 2.	47
26	Curva de performance da RNA de perdas nos enrolamentos para 5 neurônios escondidos	52
27	Curva de performance da RNA de perdas nos enrolamentos para 10 neurônios escondidos	52
28	Curva de performance da RNA de perdas nos enrolamentos para 15 neurônios escondidos	53

29	Curva de performance da RNA de perdas nos enrolamentos para 20 neurônios escondidos	53
30	Curva de performance da RNA de perdas nos enrolamentos para 25 neurônios escondidos	54
31	Curva de performance da RNA de perdas nos enrolamentos para 30 neurônios escondidos	54
32	Curva de performance da RNA de perdas no núcleo para 5 neurônios escondidos	55
33	Curva de performance da RNA de perdas no núcleo para 10 neurônios escondidos	55
34	Curva de performance da RNA de perdas no núcleo para 15 neurônios escondidos	56
35	Curva de performance da RNA de perdas no núcleo para 20 neurônios escondidos	56
36	Curva de performance da RNA de perdas no núcleo para 25 neurônios escondidos	57
37	Curva de performance da RNA de perdas no núcleo para 30 neurônios escondidos	57
38	Código em MATLAB	62

SUMÁRIO

INTRODUÇÃO	11
1 REFERENCIAL TEÓRICO	13
1.1 REDES NEURAIS ARTIFICIAIS	13
1.2 ALGORITMO DE APRENDIZAGEM	15
1.3 REGRESSÃO LINEAR	15
1.4 LEAST-MEAN-SQUARE	16
1.5 MULTIPLE LAYER PERCEPTRON	16
1.6 BACKPROPAGATION	17
1.7 MOMENTUM	18
1.8 LEVENBERG-MAEQUATT	19
1.9 GENERALIZAÇÃO	19
1.10 VALIDAÇÃO CRUZADA	19
1.11 OVERFITTING E UNDERFITTING	20
1.12 PARADA ANTECIPADA	20
1.13 MATLAB	21
1.14 ACURÁCIA	21
1.15 TRANSFORMADOR	22
1.16 MATERIAL FERROMAGNÉTICO	23
1.17 NÚCLEO	23
1.18 CARACTERÍSTICAS DE DESEMPENHO	24
1.19 CORRENTE DE EXCITAÇÃO	24
1.20 PERDAS À VAZIO	24
1.21 PERDAS EM CARGA	26
1.22 ENSAIO À VAZIO	27
1.23 ENSAIO EM CURTO-CIRCUITO	28
1.24 NORMALIZAÇÃO DE TRANSFORMADORES	28
2 METODOLOGIA	30
2.1 ANÁLISE DOS PARÂMETROS DO TRANSFORMADOR PARA ESTIMAÇÃO DAS PERDAS DO TRANSFORMADOR	31
2.2 ANÁLISE DO PROJETO DE REDES NEURAIS PARA PREDIÇÃO DAS PER- DAS DO TRANSFORMADOR	31
2.3 COLETA DE DADOS E SIMULAÇÃO	31
2.4 ANÁLISE DO DESEMPENHO DA REDE NEURAL	31
2.5 AVALIAÇÃO DA APLICAÇÃO DE REDES NEURAIS NA PREDIÇÃO DAS PERDAS DO TRANSFORMADOR	31

3	IMPLEMENTAÇÃO	32
4	ANÁLISE DE RESULTADOS	37
	CONCLUSÃO	48
	TRABALHOS PUBLICADOS	49
	ANEXO A	52
	ANEXO B	58
	ANEXO C	62

INTRODUÇÃO

O transformador é fundamental no sistema elétrico, pois está presente nos três estágios do fornecimento de energia elétrica: geração, transmissão e distribuição (RIES, 2007). No Brasil, um reflexo de sua importância está no Sistema Interligado Nacional (SIN) que compreende as tensões de 230kV a 750kV, tem como principais funções: a transmissão de energia elétrica gerada pelas usinas para os grandes centros de cargas, também a integração entre os diversos elementos do sistema elétrico para garantir estabilidade e confiabilidade da rede (EPE, 2017).

Em função do transformador ser o grande impulsionador da transmissão e distribuição de energia elétrica, é indispensável a sua demanda no mercado de energia elétrica, inclusive para os próximos 15 anos, espera-se a taxa de 3,6% anuais o consumo brasileiro de eletricidade na rede até 2032 (EPE, 2018). Por conta disso, num cenário competitivo é preciso analisar as perdas associadas ao transformador que está na ordem de milhões de reais anuais (GRADIZ, 2009) e as indústrias de transformadores em consequência tendem a produzir de forma compatível, com qualidade, com baixo custo, itens diversificados e entregues a um determinado prazo (BESSA et al., 2018).

Dentro desse contexto, as fábricas de transformadores necessitam que o projeto de transformadores (valores calculados) esteja o mais próximo possível dos encontrados nos ensaios elétricos (valores reais) para obter controle do processo inicial da realização de um transformador, o cálculo elétrico, assim possibilitando transformadores mais eficientes com menos perdas. Logo, o problema que esta pesquisa se propõe a resolver refere-se a necessidade das empresas de adquirir valores mais precisos das perdas de transformadores, isto deve-se a dificuldade de calcular com precisão as perdas devido aos muitos fatores não são considerados por causa do seu comportamento complexo (SOUZA et al., 2011).

A partir da utilização de métodos de inteligência computacional, especificamente Redes Neurais Artificiais (RNA) pela capacidade desse método apreender em base de dados, é possível traçar a seguinte hipótese: por meio de RNA é possível realizar estimativa das perdas de transformadores devido ao histórico de dados já disponível nas indústrias do ramo por meio do software MATLAB que possui uma vasta biblioteca padrão.

Este trabalho teve o objetivo de propor por meio da aplicação das redes neurais artificiais (RNA) no cálculo elétrico de transformadores, com o propósito de estimar as perdas de transformadores trifásicos de distribuição (TTD) e acrescentar mais precisão do que a maneira padrão realizada nas fábricas de transformadores. Assim, haverá a redução das perdas dos transformadores por meio da estimação possibilitará a redução de custos nas redes de distribuição e maior agilidade aos tradicionais métodos utilizados na indústrias do ramo. O método proposto em contraste com a típica engenharia de simulações em que é necessário um grande esforço para a criação do modelo apreender a estrutura de dados a partir dos dados de treinamento (MAYR; MEYER; SEEFRIED, 2017).

Portanto, a proposta é estimar as perdas do TTD por meio da utilização de RNA, a arquitetura de rede é composta pela topologia Multiple Layer Perceptron e algoritmo de

aprendizagem Levenberg Marquard (LM). Na avaliação dos resultados encontrados, são utilizados as ferramentas Mean Square Error (MSE), Coeficiente de Correlação Linear (R) e também comparação com os resultados da indústria.

O presente trabalho encontra-se dividido na seguinte forma:

Apresenta-se uma breve introdução com o intuito de situar o leitor no contexto do trabalho de pesquisa bem como permitir uma visão geral do que será abordado.

O capítulo 1 apresenta a revisão bibliográfica da literatura necessária para a compreensão e realização do trabalho, com ênfase em RNA, algoritmo de aprendizagem, otimização de RNA, transformadores e seus aspectos construtivos, perdas de transformadores e normalização de transformadores.

O capítulo 2 apresenta a metodologia para o desenvolvimento do trabalho, contendo as seguintes etapas: Análise dos parâmetros do transformador para estimação das perdas do transformador, análise do projeto de redes neurais artificiais do transformador, coleta de dados e simulação, análise do desempenho da rede neural, avaliação da aplicação de redes neurais na predição das perdas do transformador.

O capítulo 3 descreve a implementação do projeto em que são detalhados as opções escolhidas para a modelagem da RNA proposta e experimentos para a validação da mesma.

NO capítulo 4 é mostrada a análise e qualificação do resultado final do trabalho. Por fim, será apresentado uma conclusão com o intuito de finalizar o trabalho com as considerações finais. E em seguida pode-se encontrar as referências bibliográficas citadas ao decorrer desta monografia.

1 REFERENCIAL TEÓRICO

O sistema proposto tem uma abrangência grande, pois envolve o ramo da computação devido à utilização de redes neurais e o da eletrotécnica por conta dos ensaios e projeto de transformadores. Desta forma, pretende-se fazer um vasto levantamento bibliográfico referente às duas áreas.

A aplicação de algoritmos computacionais para resolução dos mais variados problemas em diferentes áreas do conhecimento vem ganhando cada vez mais notoriedade e reconhecimento de pesquisadores e indústrias. Problemas são resolvidos em computação por meio da escrita de um algoritmo ou pseudocódigo, que especifica passo a passo como o problema pode ser resolvido (FACELI et al., 2011).

Assim como os estudos de projeto de transformadores apesar de serem mais antigos do que AM (Aprendizagem de Máquinas), ainda carecem de estudos mais recentes ou até muitas vezes as próprias indústrias não divulgam muitos avanços mais técnicos e teóricos por conta de questões empresariais. Outro ponto interessante da pesquisa são os aspectos trabalhados do transformador como as perdas do núcleo, pois as perdas do núcleo vem a partir do fato de cada manufatura do transformador ter a sua própria equação para o cálculo das perdas (SOUZA et al., 2011).

1.1 REDES NEURAIS ARTIFICIAIS

Conforme Silva, Hernane e Flauzino (2010, p.35) “[...] os elementos computacionais ou unidades processadoras, denominadas neurônios artificiais, são modelos bem simplificados dos neurônios biológicos”. A rede neural é o conjunto de ferramentas computacionais mais sofisticadas, que fossem mais autônomas, reduzindo a necessidade de intervenção humana e dependência de especialistas. Por conta, desse cenário de uma hipótese ou aproximação de função a partir da experiência passada surgiu o nome Aprendizagem de Máquinas (AM)”. A capacidade de melhorar o desempenho na vários neurônios artificiais análogo ao cérebro humano composto de milhares neurônios biológicos. A Figura 1 representa um neurônio artificial idealizado por (ROSEBLATT, 1958), também conhecido como perceptron, a forma mais simples.


Conforme a Figura 1 o neurônio artificial é composto:

- (i) as entradas x_1 e x_2 ;
- (ii) os pesos ponderados (ou pesos sinápticos) w_1 e w_2 , responsável por ponderar cada uma das entradas da rede permitindo quantificar sua variância;
- (iii) o θ (bias), responsável pelo deslocamento da reta formada pelo combinador linear no hiperplano;
- (iv) o somatório, responsável por fazer a combinação linear;
- (v) u a saída do combinador linear;
- (vi) a função de ativação $g(\cdot)$, responsável por limitar o saída do neurônio dentro de um

intervalo;

(vii) y é a saída final do neurônio.


Figura 1 – Neurônio Artificial



Fonte: Própria

A Figura 2 corresponde ao tipo de função de ativação bipolar. Esta função é considerada parcialmente diferenciável, pois possui pontos cujas derivadas de primeira ordem são inexistentes. Fazem parte desse tipo de função além da bipolar, as funções degrau e rampa simétrica.


Figura 2 – Função de Ativação Bipolar



Fonte: Própria

No entanto, fica evidente que apenas um neurônio artificial consegue apenas trabalhar com problemas linearmente separáveis conforme a Figura 3. Por conta dessa limitação, para que se possa trabalhar com outro tipo de problema é necessário que os neurônios artificiais sejam agrupados formando as diferentes arquiteturas de redes neurais. Vale ressaltar que as redes neurais são aplicadas com a finalidade de aproximar funções, reconhecimento de padrões, identificação e controle de processos, previsão de séries temporais e otimização de sistemas.

Figura 3 – Fronteira de Decisão Linear



Fonte: (HAYKIN, 2009)

1.2 ALGORITMO DE APRENDIZAGEM

Algoritmo de aprendizagem corresponde ao processo de treinamento de uma rede neural a partir de passos ordenados necessários para sintonização dos pesos sinápticos e limiares de seus neurônios (SILVA; HERNANE; FLAUZINO, 2010). O treinamento da rede pode ser supervisionado ou não-supervisionado. No treinamento supervisionado, o agente observa alguns exemplos de pares de entrada e saída, e aprende uma função que faz o mapeamento da entrada para saída (RUSSEL; NORVIG, 2013). Enquanto, na aprendizagem não supervisionada, o agente o agente aprende padrões na entrada, embora não seja fornecido nenhum *feedback* explícito (RUSSEL; NORVIG, 2013).

1.3 REGRESSÃO LINEAR

Problemas de regressão linear envolvem explorar as relações entre duas ou mais variáveis (MONTGOMERY; RUNGER, 2016). O modelo linear de regressão simples pode ser conforma a Equação onde B_0 é interseção, B_1 a inclinação e x , a variável independente. O modelo da Equação 1 pode ser descrito como uma função linear univariada.

$$Y = B_0 + B_1x \quad (1)$$

A regressão pode descrever uma relação entre uma saída e entrada sem que estejam completamente relacionadas em um sentido prático. Porém uma forte associação observada entre as variáveis não implica necessariamente que exista uma relação causal entre aquelas variáveis (MONTGOMERY; RUNGER, 2016). Desta forma, é necessário que haja planejamento do experimento, pois é a única maneira para determinar relações causa-efeito. Também, é necessário observar que relações de regressão são válidas somente para valores dentro da faixa dos dados originais. Assim, modelos de regressão não são necessariamente válidos para finalidades de extrapolação (MONTGOMERY; RUNGER, 2016). Porém, há situações na engenharia em que extrapolação é a única maneira de abordagem.

1.4 LEAST-MEAN-SQUARE

O algoritmo least-mean-square(LMS) é configurado para minimizar a função instantânea do custo, conforme a Equação 2 (HAYKIN, 2009).

$$\varepsilon = \frac{1}{2}.e^2(n) \quad (2)$$

Onde $e(n)$ é o erro do sinal em um determinado momento n . A diferenciação de $\varepsilon(w)$ com a variável independente w (peso sináptico), corresponde a Equação 2.

Basicamente, o algoritmo LMS pode ser tratado por diferentes métodos numérico, porém em relação a redes neurais é comumente usado o método da descida mais íngreme. O algoritmo LMS é aplicado em diferentes problemas de otimização que buscam minimizar diferente a função de custo, ou seja, o erro, e no caso de redes neurais é necessário associar o LMS com o peso sináptico(w), a interconexões dos neurônios. Assim, o LMS pelo método da descida mais íngreme é o ajuste sucessivo dos pesos sinápticos na direção da descida mais íngreme, buscando o mínimo ponto da função de custo (HAYKIN, 2009). A Equação 3 associa isto, o gradiente que represente esta variação para o mínimo ponto e a otimização do erro por meio da diferenciação.

$$\Delta = \varepsilon(w) \quad (3)$$

Logo, o método de descida de gradiente pode ser descrito conforme a Equação 4.

$$w(n + 1) = w(n) - \eta.g(n) \quad (4)$$


Onde η é a constante que representa a taxa de aprendizagem e $g(n)$ o gradiente do vetor (Equação 3) avaliado no ponto $w(n)$. A partir da iteração n até $n+1$, o algoritmo aplica a correção conforma a Equação 4.

$$\Delta w(n) = w(n + 1) - w(n) \rightarrow \Delta w(n) = -\eta.g(n) \quad (5)$$

1.5 MULTIPLE LAYER PERCEPTRON

Conforme a Figura 4, as redes *Multiple Layer Perceptron* (MLP) são caracterizadas pela presença de pelo menos uma camada intermediária (escondida) de neurônios, situados entre a camada de entrada e a respectiva camada neural de saída (SILVA; HERNANE; FLAUZINO, 2010). O treinamento deste tipo de rede é supervisionado, realizado pelo algoritmo *Backpropagation* que consiste em dois passos, o *forward* e o *backward* para o ajuste dos pesos sinápticos.

Figura 4 – Arquitetura Multiple Layer Perceptron



Fonte:(HAYKIN, 2009)

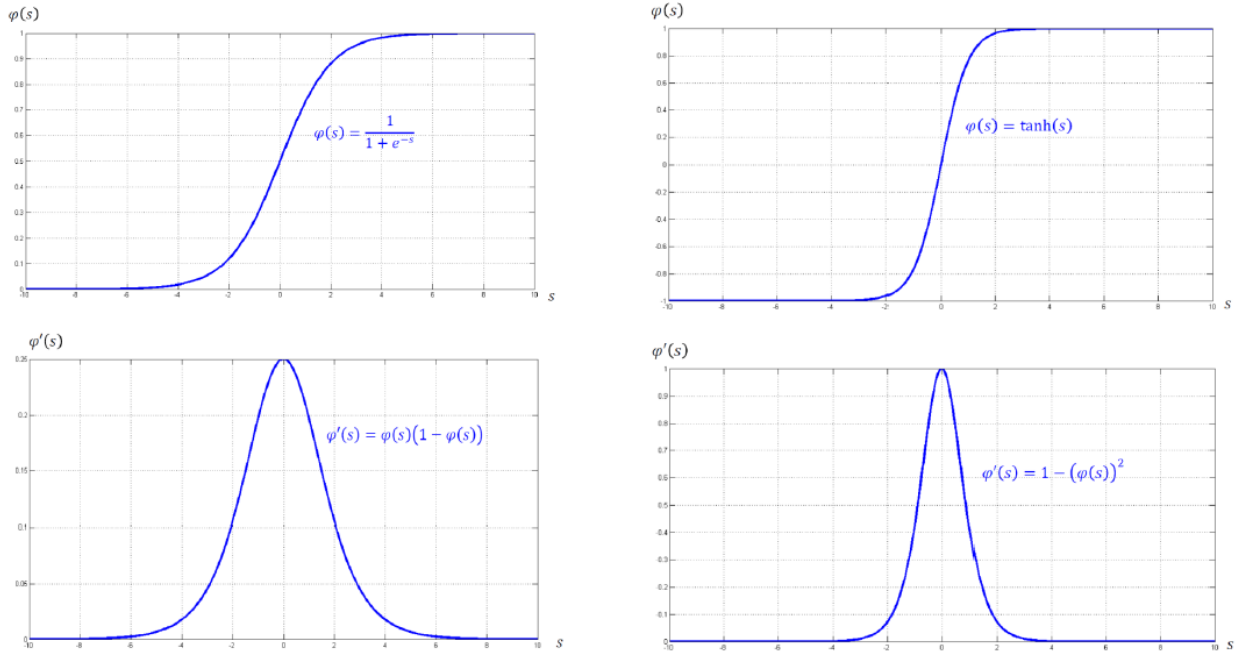
1.6 BACKPROPAGATION

Na fase *forward*, objeto é primeiramente recebido por cada um dos neurônios da primeira camada intermediária, quando é ponderado pelo peso associado a suas conexões de entrada correspondentes, em seguida são aplicadas as funções de ativação até a saída na rede e depois comparado ao valor desejado, produzindo um erro (FACELI et al., 2011). Na fase *backward*, o valor do erro de cada neurônio da camada de saída é então utilizado para ajustes dos pesos na entrada (FACELI et al., 2011). Conforme Haykin (2009, p.199) “[...] considera-se que o algoritmo de retro-propagação tenha convergido quando a taxa absoluta de variação de erro médio quadrado por época for suficientemente pequena.”.É evidente que para otimização, ocorre a utilização do mínimo global da superfície do erro, Equação 6, que é definido pelo gradiente do algoritmo mínimo quadrado médio.

$$\nabla \varepsilon(w) = \frac{\partial e}{\partial w} \quad (6)$$

Por conta da Equação 6 e também da fase *backward* do algoritmo *backpropagation*, é necessário que a função de ativação seja contínua já que sofrerá uma diferenciação no segundo passo do algoritmo, a Figura 5 demonstra as funções logística e hiperbólica.

Figura 5 – Função de Ativação Hiperbólica(Esquerda) e Logística(Direita)



Fonte:Própria

Enquanto que a aplicabilidade das RNA para problemas que buscam estimar parâmetros, é necessário que a RNA faça a aproximação da função de um conjunto de dados ao invés da classifica-lo. Com isto, problemas de classificação consistem em mapear o comportamento de um processo baseado em diversas medições realizadas em suas entradas e saídas (SILVA; HERNANE; FLAUZINO, 2010). Desta forma, é possível observar que para problemas de regressão, uma MLP com apenas uma camada intermediária pode mapear qualquer função não-linear contínua. Por fim, acrescentam-se o número de camadas intermediárias para otimizar o desempenho do treinamento da RNA (SILVA; HERNANE; FLAUZINO, 2010).

1.7 MOMENTUM

O termo momentum é uma das possíveis alterações aplicáveis ao algoritmo *backpropagation*. Conforme (SILVA; HERNANE; FLAUZINO, 2010) que “basta inserir um único parâmetro visando ponderar um único parâmetro visando ponderar o quão as matrizes sinápticas foram alteradas entre duas iterações anteriores sucessivas”. A equação 7 representa a inserção do termo momentum.

$$w_{ji}^{(L)}(t + 1) = w_{ji}^{(L)}(t) + \alpha.(w_{ji}^{(L)}(t) - w_{ji}^{(L)}(t - 1)) + \eta.\delta_j^{(L)}.Y_i^{(L-1)} \quad (7)$$

Onde α é definida como a taxa momentum e seu valor está compreendido entre zero e um. Observa-se que na equação (7) a segunda parcela(multiplicada por α) é o termo momentum que leva em consideração o efeito de mudanças anteriores de pesos na direção do movimento atual no espaço de pesos. Enquanto os termos restantes são os mesmo da equação 7. Desta

forma, caso o termo momentum seja zero, a equação 7 corresponderá a equação 3.

Quando a solução atual (refletida por suas matrizes de peso) estiver longe da solução final (mínimo da função de erro), a variação na direção oposta ao gradiente da função erro quadrático entre duas iterações sucessivas será também grande (SILVA; HERNANE; FLAUZINO, 2010).

O termo momentum faz com que a mudança seguinte de peso seja mais ou menos na mesma direção que a anterior, dependendo da situação este pequeno desvio pode evitar que a rede caia em um mínimo local (JR.; CRUZ, 1998). Assim, sendo possível melhorar a convergência do processo de treinamento da rede.

1.8 LEVENBERG-MAEQUATT

Conforme (SILVA; HERNANE; FLAUZINO, 2010) “O algoritmo Levenberg-Marquatt é um método gradiente de segunda ordem, baseado no método dos mínimos quadrados para modelos não-lineares, que pode ser incorporado ao algoritmo backpropagation a fim de potencializar a eficiência do treinamento”. O método backpropagation utiliza a descida de gradiente para minimizar a função do erro, enquanto no Levenberg-Marquatt LM, é aplicado o método numérico de Newton para atualização do pesos sinápticos (YU; WILAMOWSKI, Acessado em 10/08/2018). Desta forma, é introduzido o conceito da matriz hessiana no processo de treinamento conforma a equação 8.

$$\Delta w = (H(w) + \mu.I)^{-1}.J^T(w).E \quad (8)$$

Onde H é a matriz hessiana, J é a matriz jacobiana, μ é parâmetro que ajusta a taxa de convergência do algoritmo de Levenberg-Marquatt, I é a matriz identidade e E é o erro em forma matricial.

1.9 GENERALIZAÇÃO

O conceito de generalização quando referente a RNA deve-se a uma rede capaz de mapear valores de entra-saída não usados na amostra de treino, gerando valores próximos daqueles esperados. Haykin (2009, p.232) informa que “[...] a rede realiza boa interpolação fundamentalmente porque perceptrons de múltiplas camadas com funções de ativação contínuas produzem funções de saída que também são contínuas”. A generalização não se deve ao aumento excessivo de neurônios ou camadas. Como também o aumento de entradas da RNA, ou seja, aumenta a complexabilidade de mapeamento dificultam a generalização.

1.10 VALIDAÇÃO CRUZADA

A validação cruzada torna-se necessário para validação dos dados durante o processo de treino. Com isto, a amostra de dados é dividida em dois conjuntos: treino e teste. Porém o

conjunto de teste é dividido em dois subconjuntos: estimação e validação. O subconjunto de estimação busca selecionar o melhor modelo, enquanto o subconjunto de validação é usado para testar o validar o modelo. Conforme (HAYKIN, 2009) que "a motivação é avaliar o modelo com um conjunto de dados diferente daquele usado para estimar os parâmetros". Assim, é possível obter uma rede neural com boa generalização, ou seja, é capaz de produzir um mapeamento correto até mesmo quando a entrada for um pouco diferente daquelas usadas para treinar a rede.

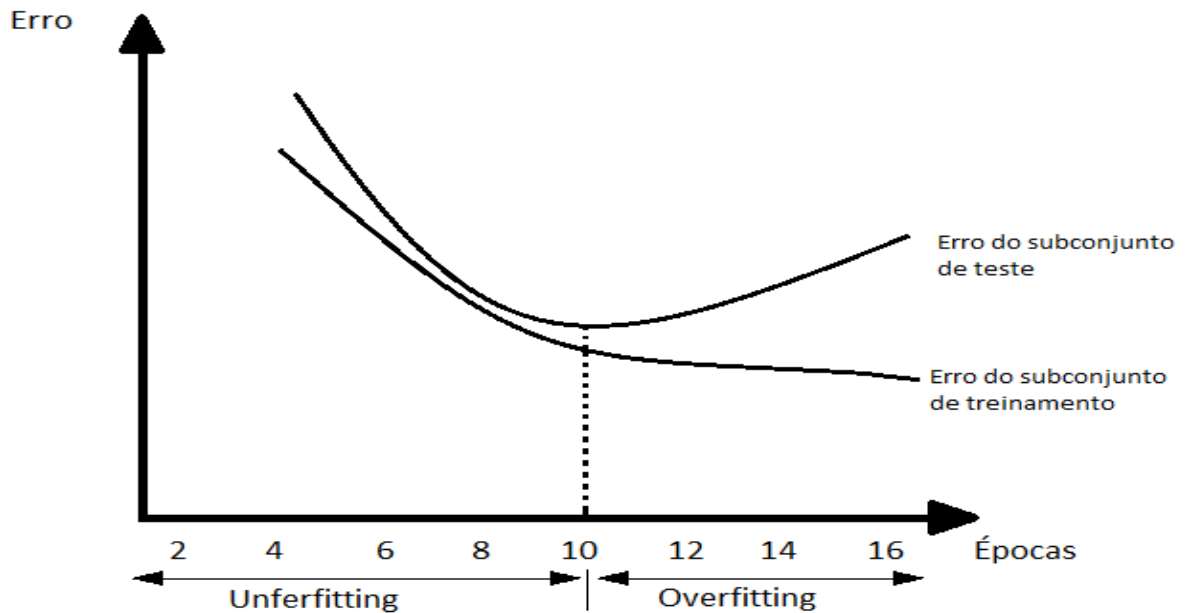
1.11 OVERFITTING E UNDERFITTING

Aumento do número excessivo de neurônios ou camadas fazem a RNA tender a memorização excessiva (*overfitting*). Nestas circunstâncias, Silva, Hernane e Flauzino (2010, p.153) informa que [...] o erro quadrático durante a fase de aprendizado tende a ser bem baixo". Enquanto na fase de generalização perante ao subconjunto de teste acontece, o erro quadrático assume valores elevados, assim caracterizando a situação de *overfitting*. A situação de *underfitting* é o oposto do *overfitting*. Pois, uma baixa quantidade de neurônios provoca uma baixa capacidade de aprendizagem da rede, o erro quadrático em *underfitting* é baixo na fase de treino e teste.

1.12 PARADA ANTECIPADA

Para otimização da técnica de validação cruzada é inserido o método da parada antecipada ou prematura (*early stopping*). Silva, Hernane e Flauzino (2010, p.155) informa que "[...] o processo de aprendizagem para uma topologia candidata é constantemente checado para aplicação dos subconjuntos de teste, sendo finalizado quando começar a haver elevação do erro quadrático (frente aos subconjuntos de teste) entre épocas sucessivas". É evidente que a RNA deve superar a condição de *overfitting* e evitar *underfitting*. A variação súbita que acontece na Figura 6, comumente pode ocorrer no processo de validação cruzada de uma RNA, pois sinaliza a tentativa de extração excessiva de características dos subconjuntos de treinamento.

Figura 6 – Parada Antecipada



Fonte:Própria

1.13 MATLAB

MATLAB (*Matrix Laboratory*) é uma plataforma de programação designada especialmente para engenheiros e cientistas, pois sua própria de linguagem de programação permite expressões matemáticas computacionais mais naturais, especificamente nas operações de matrizes. Além disso, há uma imensa variedade de funções, apps e otimizações para diversas aplicações, incluindo nas áreas de *deep learning* e *machine learning*. Com isto, é possível por meio do MATLAB analisar dados, desenvolver algoritmos e criar modelos.


1.14 ACURÁCIA

A ISO(International Standard Organization) estabelece por meio da ISO5725-1 que acurácia é empregada conforme a equação 9.

$$acurácia = exatidão + precisão \quad (9)$$

Precisão é a medida de dispersão de um conjunto de dados, assim quanto menor a precisão maior será variabilidade dos dados. Enquanto, exatidão é a relação entre um valor medido com o considerado de referência (valor verdadeiro). A Figura 7 ilustra por meio de uma função densidade de probabilidade normal, a exatidão e precisão.

Figura 7 – Exatidão e Precisão



Fonte: <http://www.revistabw.com.br>

A exatidão de um conjunto de amostras pode ser definido conforma a equação 10 que corresponderia similarmente ao erro quadrático médio.

$$Exatidão = \frac{\sum (Valor_{Medido} - Valor_{Referência})^2}{Número\ Total\ de\ Amostras} \quad (10)$$

1.15 TRANSFORMADOR

Conforme Umans, Fitzgerald e Kingsley (2014, p.63) “Essencialmente, um transformador consiste em dois ou mais enrolamentos acoplados por meio de um fluxo magnético comum.”. Desta forma, a partir da tensão alternada aplicada ao enrolamento primário estabelece um enlace através do fluxo comum com o enrolamento secundário, induzindo uma tensão conforme seu número de espiras.


Umans, Fitzgerald e Kingsley (2014, p.64) informa que “[...] O fluxo em sua maior parte fica confinado a um caminho delimitado de alta permeabilidade, enlaçando os enrolamentos”, este tipo de transformador é comumente chamada transformador de “núcleo de ferro”. Normalmente a propriedade magnética do material que compõem o núcleo é o ferromagnético.

Apesar do funcionamento do transformador ser relativamente simples, há aspectos muito difíceis de se trabalhar nele. Atualmente, é muito difícil calcular as perdas no núcleo, porque há muitos fatores que não são levados em consideração a seu comportamento complexo (SOUZA et al., 2011).

O transformador é responsável pela transformação de tensão elétrica entre as bobinas com a utilização de indução magnética. Isso se deve a dois componentes fundamentais no seu processo construtivo: núcleo e enrolamentos (RIES, 2007). O núcleo fornece caminho magnético para o fluxo por meio de tiras de grão orientado de aço-silício. Também, os enrola-

mentos, compostos de fio de cobre ou alumínio, distribuído em forma de bobinas concêntricas (conforme Figura 8), conduzem corrente elétrica que induz fluxo magnético no núcleo. Neste processo ocorrem as perdas que em caráter técnico nominal é a perda no núcleo (ou perda à vazio) e as perdas nos enrolamentos (ou perdas em carga).

Figura 8 – Parte ativa do transformador



Fonte: Própria

1.16 MATERIAL FERROMAGNÉTICO

Callister (2008, p.549) informa que “[...] certos materiais metálicos possuem um momento magnético permanente na ausência de um campo externo e manifestam magnetização muito grandes e permanentes”. Umans, Fitzgerald e Kingsley (2014, p.19) informa que “[...] os materiais ferromagnéticos são compostos por um grande número de domínios, isto é, regiões nas quais os momentos magnéticos de todos os átomos estão em paralelo, dando origem a um momento magnético líquido naquele domínio”.

1.17 NÚCLEO

O núcleo fornece o caminho magnético para o fluxo, consiste de tiras de aço de alta qualidade, chamadas laminações, que são separadas eletricamente por um fino revestimento material isolante (HARLOW, 2004).

Ries (2007, p.26) informa que “Os núcleos são montados com a lâminas dispostas de modo a diminuir, tanto quanto possível, os efeitos danosos dos entreferros nas junções. Os entreferros aumentam a corrente de magnetização.”

Umans, Fitzgerald e Kingsley (2014, p.27) informam que “[...] chapas, alinhadas na

direção de campo na direção das linhas de campo, estão isolados entre si por uma camada de óxido em suas superfícies ou por uma fina cobertura de esmalte ou verniz de isolamento”.

Tipicamente nas chapas que compõem o núcleo são utilizados materiais grão orientados, materiais que utilizam técnicas de fabricação adequado para alinhando as arestas do cristais que compõem a estrutura atômica do material de forma a favorecer a magnetização, diminuindo as perdas por histerese.

O campo magnético ou indução corresponde ao ponto de trabalho inicial para o cálculo de transformadores, pois é dado conforme a equação 11.

$$B = \frac{E}{4,44.f.N.Sn.10^{-4}} \quad (11)$$

Na metodologia de cálculo usual de projeto de transformadores, é através da indução conforme a equação 11, por meio de localização manual em gráfico de fabricantes que é calculado as perdas à vazio.

1.18 CARACTERÍSTICAS DE DESEMPENHO

As características de desempenho são necessárias para validação do transformador nas normas da ABNT. Definido as perdas do transformador. Ries (2007, p.17) informa que “As características de desempenho são aquelas as quais o transformador deve responder de acordo com as especificações básicas e de conformidade com as normas técnicas estabelecidas”.

1.19 CORRENTE DE EXCITAÇÃO

A corrente de excitação ou à vazio tem por função o estabelecimento do fluxo magnético e o suprimento das perdas a vazio (ROBERTO; ABREU, 1984). Normalmente, a corrente de excitação é dividida entre a corrente magnetizante, produz o fluxo mútuo entra os enrolamentos primário e secundário, e a corrente de perdas, produzida pelas perdas de histeres e corrente parasitas ou Foucault (RIES, 2007).

1.20 PERDAS À VAZIO

As perdas no núcleo originadas pelos efeitos de histerese do núcleo, correntes Foucault e perdas adicionais. Porém, as perdas no núcleo são difíceis de calcular com exatidão e também os resultados calculados são muito diferentes dos valores obtidos em ensaios (SOUZA et al., 2011).

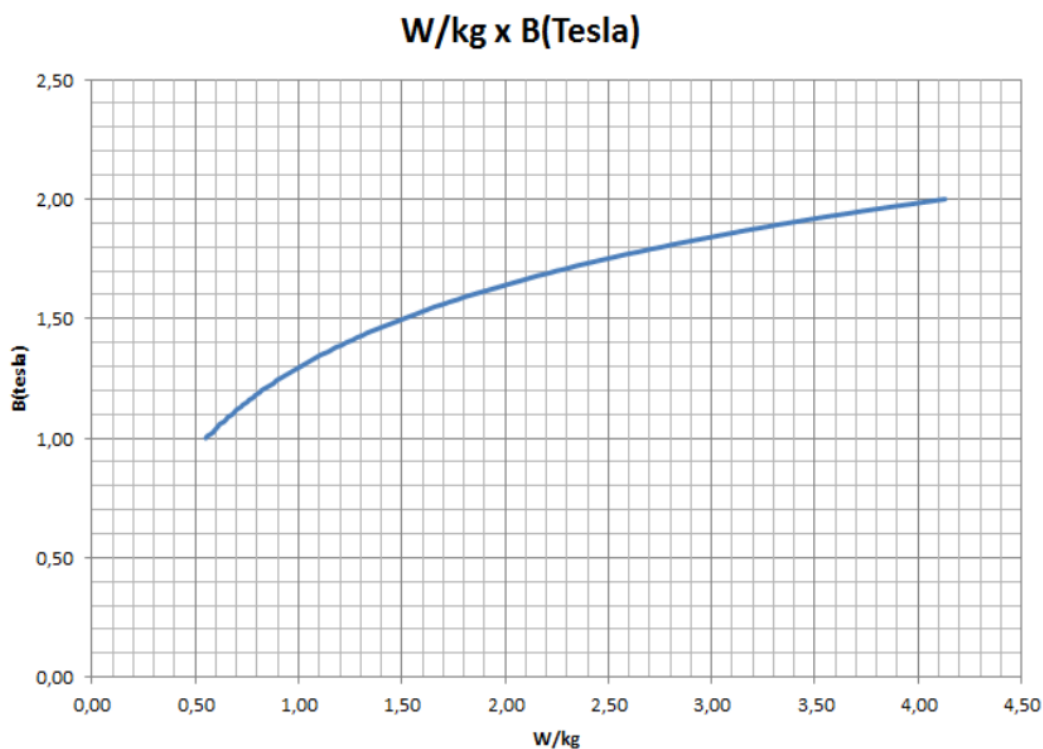
Harlow (2004, p.28) informa que “[...]A perda à vazio é essencialmente a potência necessária para manter o núcleo energizado. Elas são comumente referidas como as ‘perdas no núcleo’ e existem quando a unidade é energizada”. As perdas á vazio dependem primariamente da tensão e frequência, então em condições de operação eles levemente variam com as variações do sistema.

As perdas à vazio ou no núcleo são divididas nas perdas por histerese , as perdas responsáveis pela indução do fluxo magnético no núcleo , e perdas por correntes parasitas, corrente induzidas no núcleo que se opõe ao fluxo induzido pelo rolamento primário. Como também, há mais uma perda que são aquelas que não podem ser classificadas como nenhuma das anteriores, as perdas adicionais.

Umans, Fitzgerald e Kingsley (2014, p.42) informam que “[...] essas perdas dependem do aspecto metalúrgico do material , assim como da densidade de fluxo e da frequência . Os dados sobre perdas no núcleo são apresentados tipicamente em gráficos”.

Os fabricantes fornecem as curvas dada em $W/kg=f(B)$ para o cálculo das perdas à vazio, conforme a Figura 9.

Figura 9 – Curvas de perdas do núcleo




Fonte: Própria

As perdas no núcleo quando obtidas nas indústrias de transformadores, tradicionalmente podem ser determinadas com a utilização de curvas predeterminadas (W/kg) pelas características elétricas da chapa e valores de correção empíricos (WOJTKUN; BRÓDKA; STACHOWIAK, 2018).

Construtivamente o núcleo empilhado é feito conforme a Figura 10 e a partir disso a perda no núcleo do TTD pode ser definida conforme as equações 12 e 13.

Figura 10 – Núcleo empilhado transformador - Seção Transversal



Fonte: Própria

A equação 12 representa as perdas totais do transformador, pois como o núcleo empilhado é composto de diferente “degraus” (Equação 13), as perdas no núcleo empilhado é a soma das perdas de cada, esta análise é feita análoga aos autores (YADAV et al., 2011) e (GEORGILAKOS et al., 1999).

$$P_o = W_1 + W_2 + \dots + W_n \quad (12)$$

Conforme mencionado por (RIES, 2007) e (WOJTKUN; BRÓDKA; STACHOWIAK, 2018), a equação 13 representa as perdas no núcleo tradicionalmente calculado nas indústrias.

$$P_o = k_p \cdot p \cdot M \quad (13)$$

Onde k_p é o fator empírico de correção, M é a massa do núcleo em kg e p é a perda específica da chapa em W/kg.

1.21 PERDAS EM CARGA

Ries (2007, p.p. 40) informa que “Perdas joules nos enrolamentos produzidas pelas correntes de carga e que, por sua vez se dividem, para efeito de cálculo em: perdas ôhmicas, perdas parasitas e perdas por circulação de correntes em condutores paralelos”. As perdas em carga são causadas por:

- a) Perdas ôhmicas: Perda provocada pelo caráter resistivo do enrolamento em função da corrente flui através da resistência dos condutores e cabos (HARLOW, 2004);

- b) Perdas parasitas: Devido a corrente dos condutores serem alternadas acabam gerando fluxo que induz tensões e produz corrente parasita. Estas perdas são baixas e podem ser desprezadas com certos cuidados construtivos (RIES, 2007). ;
- c) Perdas por circulação de corrente: Ocorre por haver condutores em paralelo que, por construção, ficam com comprimentos diferente. Estas perdas são anuladas pelo efeito da transposição dos condutores em paralelo de modo torná-los iguais de comprimento (RIES, 2007);

As perdas nos enrolamentos nominalmente causadas pelas perdas ôhmicas que têm caráter resistivo em função da corrente que flui através da resistência dos condutores e cabos. A equação 14 pode ser considerada para as perdas nos enrolamentos de Alta Tensão(AT) e Baixa Tensão(BT) do TTD.

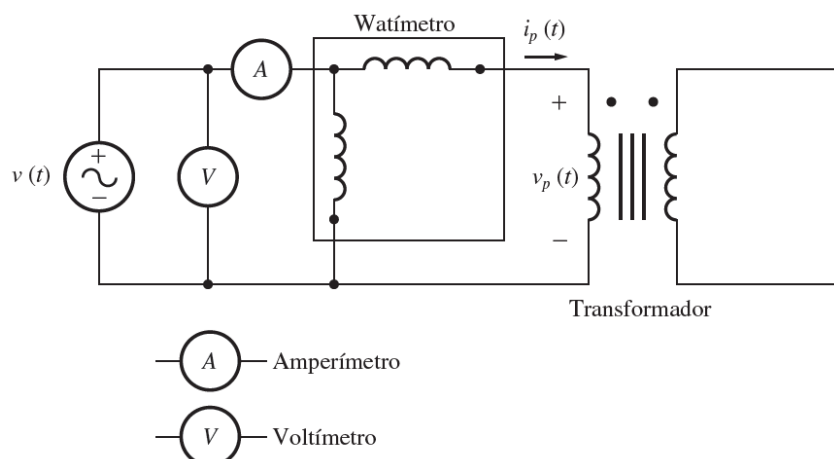
$$P_{cc} = \rho \cdot \frac{I}{l \cdot s} \quad (14)$$

Onde ρ é a resistividade do material, I é a corrente, l é o comprimento do fio e s é a seção do fio.

1.22 ENSAIO À VAZIO

Umans, Fitzgerald e Kingsley (2014, p. 27) afirma que “[..]O ensaio de circuito aberto (ou vazio) é realizado com secundário em aberto e a tensão nominal aplicada ao primário”. Por meio dessas condições, uma corrente de excitação de alguns poucos por cento da corrente de carga total é obtida. O principal objetivo desse ensaio é excitar o núcleo para obter as perdas na mesma, pois com como o ramo de magnetização estará em série com o enrolamento primário, é possível medir a potência desse ramo por meio de wattímetros, conforme a Figura 11.

Figura 11 – Configuração para ensaio à vazio

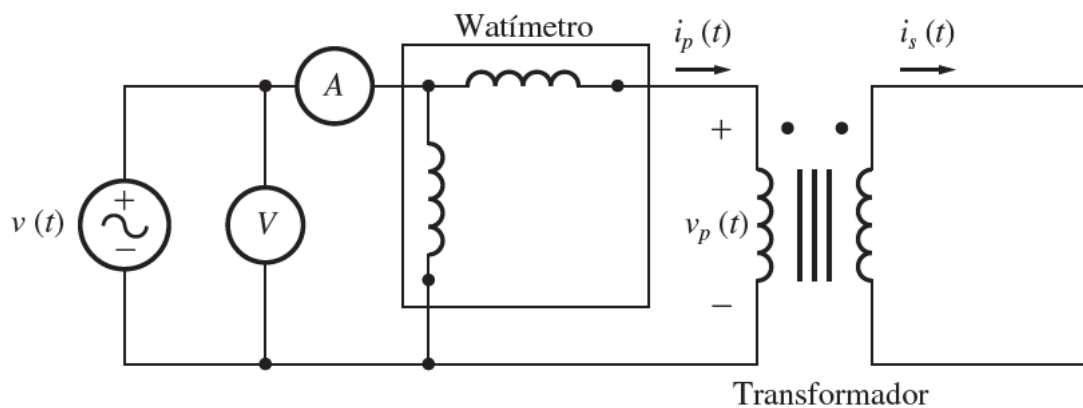


Fonte: (CHAPMAN, 2013)

1.23 ENSAIO EM CURTO-CIRCUITO

A Figura 12 corresponde à configuração ensaio em curto-circuito. Chapman(2013, p.91) informa que “[...] os terminais de baixa tensão de entrada do transformador são colocados em curto-circuito e os terminais de alta-tensão a uma fonte de tensão variável.” Há um ajuste na tensão de entrada até que a corrente de curto-circuito seja igual ao seu valor nominal. Diferente do ensaio à vazio, o ramo de magnetização é ignorado por estar em paralelo e ter uma impedância maior ao terminal curto-circuitado, assim encontra-se por meio de wattímetros as perdas nos enrolamentos, obtendo-as as perdas em curto-circuito(ou carga). A soma das perdas no núcleo e as perdas em carga correspondem às perdas totais do transformador.

Figura 12 – Configuração para ensaio em curto-circuito



Fonte:(CHAPMAN, 2013)

1.24 NORMALIZAÇÃO DE TRANSFORMADORES

O transformador por está acoplado no sistema elétrico é preciso estar de acordo por questões de padronização e também para maior equilíbrio do sistema elétrico e também questões de segurança. Observa-se que para homologação do transformador para concessionárias ou órgãos de fiscalização só será realizada se o produto estiver conforme as normas da ABNT referente ao mesmo.

Entre as muitas normas que se aplicam ao transformador, as principais e de maior relevância para esta pesquisa são as NBR(Norma Brasileira) 5356/5380 – “Transformadores de Potência” e NBR5440 – “ Transformadores para Redes Aéreas de Distribuição: Padronização”. Estas normas indicam a determinação das perdas, corrente de excitação e impedância que o transformador deve ter, conforme a Figura 13. No ramo da indústria de transformadores são parâmetros muito importante, pois a redução ou aumento nas perdas estão ligadas ao projeto e materiais utilizado que estão relacionados diretamente ao preço do produto, conforme a Figura 14.

Figura 13 – Valores garantidos de perdas, corrente de excitação, e tensões de curto-circuito para transformadores trifásicos

Potência do transformador [kVA]	Corrente de excitação [%]	Perdas em vazio [W]	Perda total [W]	Tensão de curto-circuito a 75° C [%]
15	4,8	100	440	3,5
30	4,1	170	740	
45	3,7	220	1.000	
75	3,1	330	1.470	
112,5	2,8	440	1.990	
150	2,6	540	2.450	4,5
225	2,3	765	3.465	
300	2,2	950	4.310	

Fonte: (CARDOSO, 2005)

Figura 14 – Tolerância

Características especificadas	Tolerância
<i>Impedância de curto-circuito</i>	± 7,5%
<u>Perdas em vazio</u>	
- em cada unidade da encomenda considerada individualmente	+ 10%
- na média aritmética obtida em encomendas de mais de uma unidade	0%
<u>Perdas totais</u>	
- em cada unidade da encomenda considerada individualmente	+ 6%
- na média aritmética obtida em encomendas de mais de uma unidade	0%
<u>Relação de tensões</u>	± 0,5%
<u>Corrente de excitação</u>	
- em cada unidade da encomenda considerada individualmente	+ 20%
- na média aritmética obtida em encomendas de mais de uma unidade	0%

Fonte:(CARDOSO, 2005)

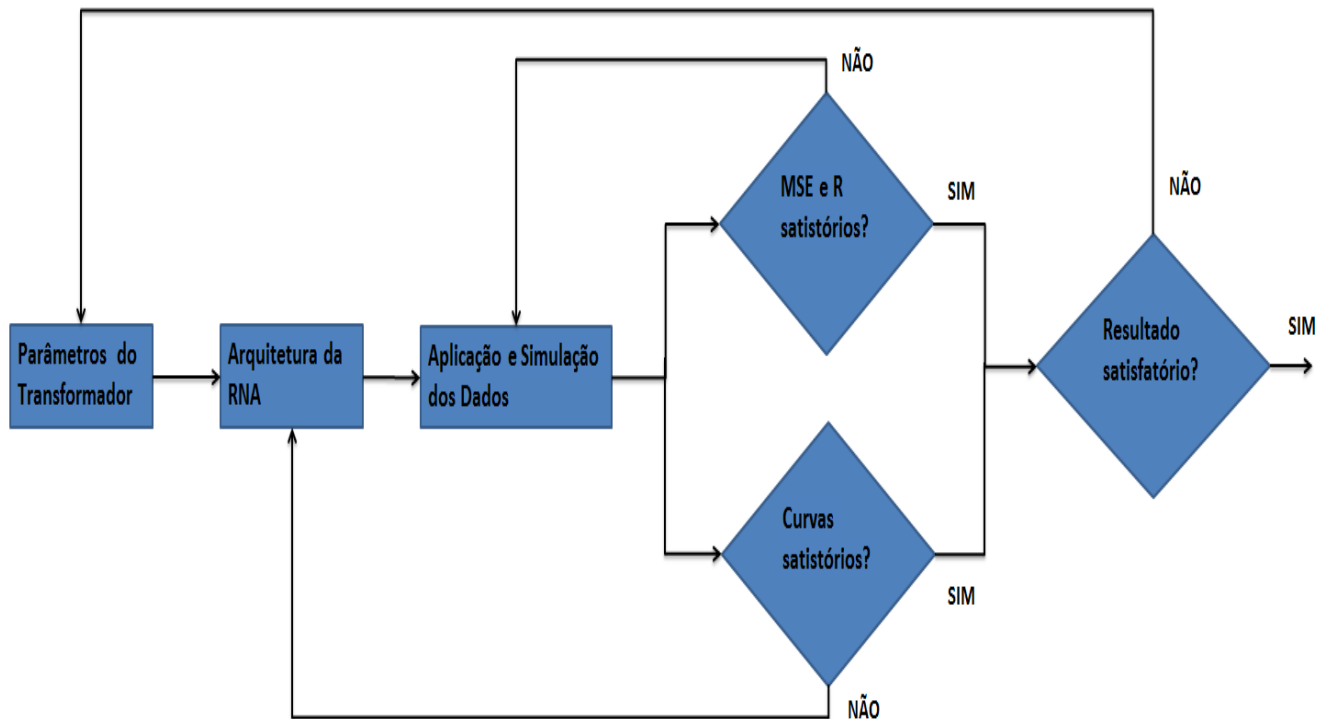
2 METODOLOGIA

A princípio foram realizadas pesquisas bibliográficas referentes aos aspectos teóricos e construtivos de transformadores trifásicos de distribuição (TTD), normas nacionais e internacionais que regem as características do transformador como a NBR5440 e NBR 5356, algoritmos de aprendizagem, arquitetura, desempenho e aplicações de redes neurais artificiais (RNA).

A metodologia proposta pretende relacionar por meio de métodos e ferramentas os conjuntos de entradas da RNA com a sua saída por meio da função de aprendizagem para seja possível a predição das perdas de TTD (GEORGE; DHAS; SATHEESH, 2015). Desta forma, métodos propõem meios eficientes para avaliação da RNA e ferramentas para avaliar de maneira quantitativa o modelo proposto em função do seu conjunto dados (YADAV; SHUKLA, 2016).

Nas próximas seções são apresentadas as partes da metodologia para elaboração do modelo de predição das perdas de TTD. Sendo elas referente aos parâmetros de transformadores, a topologia e algoritmo de aprendizagem da RNA, coleta de dados e simulação da RNA. Por fim, a análise do desempenho da rede neural e avaliação do modelo proposto. A metodologia utilizada corresponde a Figura 15.

Figura 15 – Fluxograma da Metodologia



Fonte: Própria

2.1 ANÁLISE DOS PARÂMETROS DO TRANSFORMADOR PARA ESTIMAÇÃO DAS PERDAS DO TRANSFORMADOR

A análise constituída por método exploratório em base a pesquisas bibliográficas busca identificar quais os parâmetros essenciais para a entrada da RNA em função da sua saída que são as perdas do transformador, núcleo e enrolamentos. Para isto utilizou-se as equações que regem o cálculo elétrico de TTD.

2.2 ANÁLISE DO PROJETO DE REDES NEURAIS PARA PREDIÇÃO DAS PERDAS DO TRANSFORMADOR

O projeto de RNA adequada depende do problema proposto, pois cada topologia e algoritmo de aprendizagem e algoritmo têm peculiaridades. Após definido os parâmetros de entrada da rede, é possível utilizar a arquitetura apropriada.

2.3 COLETA DE DADOS E SIMULAÇÃO

Todos as amostras de treinamento são coletadas de ensaios elétricos de software automatizado de ensaios de rotina utilizado em diversas fábricas de transformadores e concessionárias de energia elétrica. Dessa maneira, é garantido confiabilidade as amostras utilizadas para o treinamento da RNA. A partir da coleta de dados é criado um banco de dados com todos os atributos selecionados para posteriormente serem utilizados na simulação da RNA. A simulação é realizada no software MATLAB.

2.4 ANÁLISE DO DESEMPENHO DA REDE NEURAL

O desempenho da RNA é analisado por meio do MSE que possibilita determinar a capacidade de predição do modelo e também por meio do R que indica a relação linear entre a entrada e saída. Espera-se encontrar os valores típicos de MSE e R, respectivamente, em torno de 10^{-3} e próximo de 1. Como também, é feita análise gráfica das curvas de performance das amostras da validação cruzada.


2.5 AVALIAÇÃO DA APLICAÇÃO DE REDES NEURAIS NA PREDIÇÃO DAS PERDAS DO TRANSFORMADOR

A avaliação da RNA é feita por meio da etapa de teste validação cruzada (YADAV; SHUKLA, 2016). A fase de teste representa 15% das amostras, ela representa o estágio não supervisionado do processo de treinamento onde é possível observar o comportamento da RNA após as etapas de treino (70% das amostras) e validação (15% das amostras). Além disso, realizou-se dois experimentos para maior confiabilidade e aplicabilidade do modelo proposta, ou seja, por meio desses experimentos também avaliar os resultados gerais encontrados.

3 IMPLEMENTAÇÃO

A primeira etapa consiste em selecionar os parâmetros para entrada da RNA, são selecionado dois conjuntos para as perdas do TTD, pois eles são constituídos das perdas do núcleo e nos enrolamentos. Inicialmente, utilizou-se como base, os atributos para as perdas no núcleo na tabela 1 concebido conforme (YADAV et al., 2011) e (GEORGILAKOS et al., 1999), porém devidas características construtivas diferentes do núcleo são necessárias modificações, já que o núcleo em (YADAV et al., 2011) e (GEORGILAKOS et al., 1999) é enrolado, enquanto o utilizado nesta pesquisa é empilhado conforme a Figura 16.

Figura 16 – Núcleo empilhado transformador



Fonte: Própria

Em função do aspecto construtivo do núcleo ser diferente em relação (YADAV et al., 2011) e (GEORGILAKOS et al., 1999), analisou-se que é possível determinar os seguintes parâmetros da tabela 1 conforme a equação 13. Com isto, é necessário estabelecer a massa do núcleo, então relaciona-se as dimensões do núcleo que estão diretamente ligada com a massa, como a altura da janela, largura da janela e espessura da chapa utilizada e também por conta da equação 15, a relação volt/espira e seção do núcleo(diâmetro) relacionados ao ponto de operação do núcleo (indução do núcleo).

Na equação 15, conforme (MARTIGONI, 1969) e a Figura 10, pode-se aproximar por efeito de cálculo nessa situação a seção do núcleo como um círculo perfeito. Por fim, os fatores constantes são desconsiderados na RNA por fazerem nenhuma contribuição no processo de treinamento. Então, a partir dessa análise define-se as entradas semelhantes para a RNA de perdas no núcleo conforme (YADAV et al., 2011) e (GEORGILAKOS et al., 1999).

$$B = \frac{E}{4,44.f.N.S_n.10^{-4}} \rightarrow B = \frac{Volt/Espira}{4,44.f.\pi.D_n.10^{-4}} \quad (15)$$

Tabela 1 – Parâmetros de entrada da estimação das Perdas no núcleo

Símbolo	Descrição
ATRV1	Diâmetro
ATRV2	Altura da Janela do Núcleo
ATRV3	Largura da Janela do Núcleo
ATRV4	Perda Magnética Máxima a 1,5T em 60Hz
ATRV5	Perda Magnética Máxima a 1,7T em 60Hz
ATRV6	Espessura da Chapa de Silício
ATRV7	Volt/Espira

Fonte:Própria

Os parâmetros selecionados na tabela 1 correspondem às dimensões do núcleo (ATRV1-ATRV3), qualidade do material da chapa de silício (ATRV4-ATRV6) e a relação de volt por espira do TTD (ATRV7). Entre os principais aspectos correspondentes a perda em vazio, além das dimensões do núcleo é importante destacar na construção da tabela as características da chapa de silício, pois o método convencional de cálculo das perdas no núcleo é feito pela curva W/kg da chapa em função da indução magnética que sofre deslocamento devido aos ATRV4 e ATRV5 da tabela 1 (YADAV et al., 2011) e (GEORGILAKOS et al., 1999).

Enquanto, os parâmetros de entrada (tabela 2) para as perdas nos enrolamentos conforme a equação 14. Está sendo considerado na tabela, apenas o caráter nominal das perdas ôhmicas apesar de terem outros fatores que influenciam as perdas nos enrolamentos como as perdas parasitas. Isto é, não estão sendo considerados, pois aumentarão a complexidade do modelo dificultando a relação entre entrada e saída que afetará o R e também dificultando a generalização do modelo de perdas no enrolamentos.

Tabela 2 – Parâmetros de Entrada da Estimação das Perdas nos Enrolamentos

Símbolo	Descrição
ATRC1	Resistividade do Fio de Alta Tensão
ATRC2	Resistividade do Fio de Baixa Tensão
ATR3	Comprimento do Fio de Alta Tensão
ATRC4	Comprimento do Fio de Baixa Tensão
ATRC5	Corrente de Alta Tensão
ATRC6	Corrente de Baixa Tensão
ATRC7	Seção do Fio de Alta Tensão
ATRC8	Seção do Fio de Baixa Tensão

Fonte:Própria

Conforme as tabelas 1 e 2, por conta de serem várias entradas e o problema ser de predição utilizou-se a seguinte arquitetura: MLP e *backpropagation* por descida de gradiente

(BDG). Uma vez que o objetivo da RNA é a predição, é realizada uma regressão linear para criação do modelo (IZZAH et al., 2017). Porém, foi utilizada a variação *Backpropagation* Levenberg-Marquatt (BLM) do BDG visto que o BLM para RNA que possui centenas de peso adquire convergência mais rápida, alta precisão no processo de treinamento e MSE menor (YADAV et al., 2011). Enquanto no gradiente acrescentou-se o termo momentum, pois a partir de iterações sucessivas acelera a convergência e a superar o mínimo local causado pela inicialização aleatória dos pesos (SHU; XU, 2014). Desta forma, a topologia da RNA é definida inicialmente com uma camada intermediária (inicialmente 20 neurônios ocultos) e outra de saída, respectivamente, com função de ativação tangente hiperbólica e linear. Utilizou-se apenas uma camada oculta, já que o teorema da aproximação universal permite que somente uma camada escondida, pode-se mapear qualquer função não-linear (SILVA; HERNANE; FLAUZINO, 2010).

Porém, devido a escolha do algoritmo de treinamento BLM, haverá aumento da velocidade taxa de convergência da RNA, mas terá maior esforço computacional em relação ao método BDG (YU, 2011). Isto é possível de observar na tabela 3, no entanto este trabalho não está concentrado no processamento computacional, mas sim propor a aplicabilidade de RNA na estimação das perdas do TTD.

Tabela 3 – Especificação dos algoritmos de aprendizagem

Alg. de Aprend.	Atualização Peso	Tax. de Convergência	Complex. de Computação
BDG	$w_{k+1} = w_k - \alpha.g_k$	Estável, lento	Gradiente
BLM	$w_{k+1} = w_k - (J_k^T J_k)^{-1} J_k^T e_k$	Estável, rápido	Jacobiano

Fonte:(YU, 2011)

Nos dois modelos tratados tentou-se realizar parâmetros de entradas que possam ser utilizados em mais diferentes modelos de transformadores. Tanto à tabela 1 quanto à tabela 2, manteve-se o valor da espessura da chapa de silício apesar dos valores utilizados serem apenas de 0,27mm de espessura e a resistividade do fio que dos transformadores dos doados são todos de alumínio. Então, caso fossem utilizados outros tipos de chapa de aço e material de condutor diferente, o modelo proposto está sujeito a estas alterações.

Quanto ao tratamento dos dados utilizados em relação a normalização, o próprio MATLAB realiza a normalização por reescala. Para que os dados utilizados não trabalhassem nas regiões de saturação das funções de ativação e também para que o MSE não fosse alterado por conta disso, normalizou-se por meio de um valor nominal referente a NBR5540 conforme a potência utilizada.


Os dados utilizados são 400 amostras de TTD de 75KVA de núcleo empilhado fornecidos por uma empresa de transformadores, enquanto a simulação realizada no MATLAB e os parâmetros setados correspondem conforme a tabela 4 e a Figura 17 representam a RNA inicialmente utilizada.

Tabela 4 – Parâmetros da RNA para Simulação

Símbolo	Descrição
Função de Treino	trainlm
Função de Adaptação de Aprendizagem	learngdm
Épocas	1000
Mínimo Gradiente	1E-07
mu	0,001

Fonte:Própria

Figura 17 – Esquema RNA MATLAB



Fonte:Própria

Na tabela 4, o método BLM no MATLAB corresponde à função `trainlm` que foi utilizada, pois busca-se um método com convergência maior que o BDG, já que o modelo concebido envolve certa complexidade por conta das entradas utilizadas e quantidade de pesos sinápticos utilizados (inicialmente 160 para cada RNA), tanto para as perdas no núcleo quanto para as perdas nos enrolamentos, mas principalmente por conta das perdas no núcleo.

A função de adaptação de aprendizagem corresponde a um recurso de otimização da inserção do termo momentum no processo de iteração da RNA, conforme a equação 7. Por fim, a quantidade de épocas, mínimo gradiente e μ foram utilizados os próprios valores default do MATLAB, visto que o MATLAB utiliza o método da parada antecipada e assim dificilmente serão utilizadas as 1000 épocas, e por fim os valores padrões do mínimo gradiente e μ , caso necessários trocados para futura otimização. Porém, observa-se que quanto maior for o valor de μ , menor é a influência da informação de segunda ordem e mais este algoritmo se aproxima de um método de primeira ordem.

O desempenho da RNA foi medido pelo MSE e R, enquanto a separação de dados consistiu em 75% para treino, 12,5% validação e 12,5% teste. Avaliação da RNA foi feita na saída das amostras de teste para verificar a exatidão conforme a equação 10.

No processo de modelagem da RNA, é necessário que seja estabelecido o número ótimo de neurônios da camada oculta para que seja evitado a situação de *overfitting* e *underfitting*. Assim, são analisados as curvas de treinamento e teste da RNA, MSE e R para que não

haja comprometimento do desempenho da RNA durante o este processo. Após estabelecido o número ótimo de cada RNA, realizou-se dois experimentos como forma de validação da RNA modelada, a fim de garantir uma confiabilidade a mais e também analisar aspectos importante da aplicabilidade da RNA.


O experimento 1 consiste em comparar o resultado calculado tradicionalmente 17 amostras de ensaios de TTD de 75kVA de nível de eficiência D e E com os resultados encontrados pela RNA proposta de perdas no núcleo e nos enrolamentos. Estas amostras são independentes daquelas utilizadas no processo de treinamento e teste da rede.

Enquanto, o experimento 2 visa a capacidade de generalização da RNA com valores de TTD de diferente potências, foi usado apenas a RNA de perdas a vazio que teve algumas alterações por conta de algumas características que seriam desnecessárias nestas circunstâncias. Neste caso serão utilizadas as potências estabelecido pela norma NBR5440, entre elas, 30kVA, 45kVA, 75kVA, 112,5kVA e 150kVA. No caso a rede é treinada apenas com amostras de ensaios de transformadores de 30kVA e 112,5kVA. Busca-se encontrar os valores das perdas de transformadores de 45kVA, 75kVA, 112,5kVA e 150kVA. Foram utilizadas no total 124 amostras de TTD de 30kVA e 112,5kVA, respectivamente, 64 e 60 amostras.

4 ANÁLISE DE RESULTADOS

Durante o processo foram analisadas diversas alterações das estabelecidas inicialmente para otimização dos resultados. As duas redes estabelecidas, respectivamente, predição das perdas nos enrolamentos e no núcleo obtiveram resultados satisfatórios que foram avaliados por meio do MSE, R e análise das curvas da validação cruzada. A Figura 18 representa a performance da RNA de predição de perdas nos enrolamentos, é possível que o MSE obteve comportamento típico, isto é, teve comportamento decrescente até os valores menores e encontrar valores estáveis. Com isto, a melhor validação ocorreu na terceira época em que obteve o valor $9,58E-05$. Também pela Figura 18, o conjunto de teste teve comportamento satisfatório, apesar de apresentar baixa diferença em relação ao conjunto de treino, porém simboliza uma situação de *underfitting*.

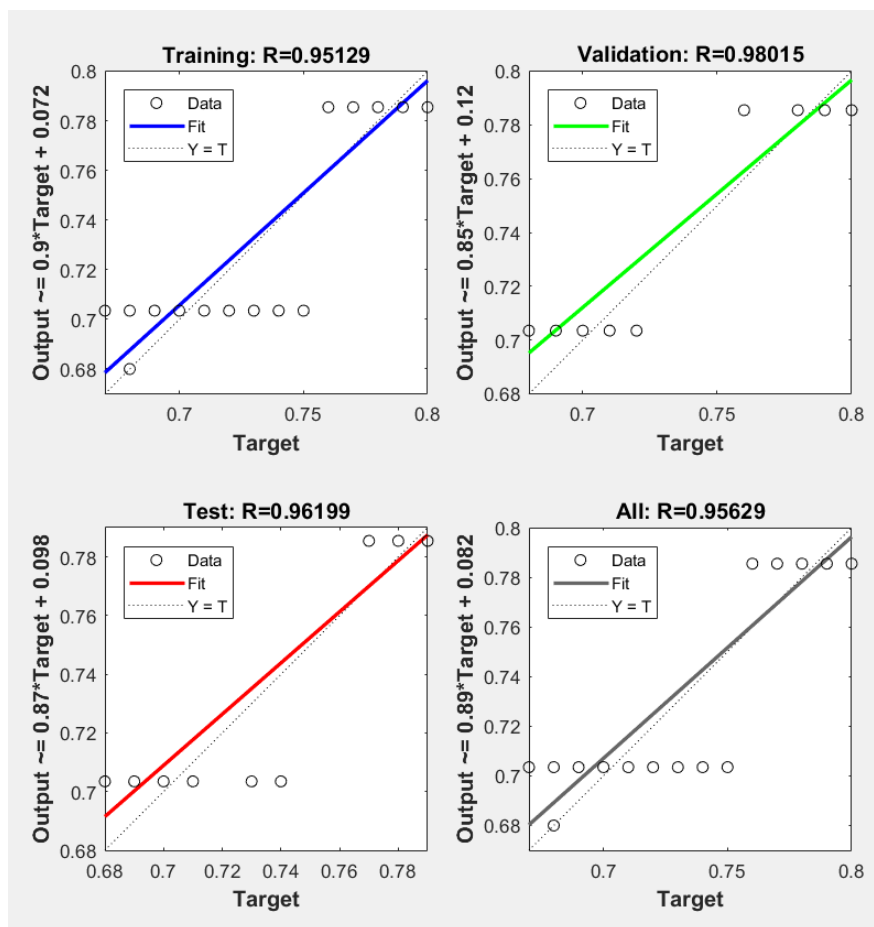
Figura 18 – Curva de performance da RNA de perdas nos enrolamentos para 20 neurônios escondidos



Fonte:Própria

A Figura 19 mostra melhor a elucidação dessa situação, pois é avaliado o R nos conjuntos de treino, validação e teste. Conforme a Figura 19, todos os conjuntos apresentam valores R próximos de 1, assim conclui-se que a relação dos conjuntos de dados de entradas corresponde aos valores de saída que são as perdas nos enrolamentos. Além disso, por meio do R pode se afirmar que a RNA obteve exatidão adequada, pois a reta de regressão posicionou-se perto da linha ideal de inclinação de 45° .

Figura 19 – Coeficiente de correlação linear da RNA de perdas nos enrolamentos para 20 neurônios escondidos



Fonte:Própria

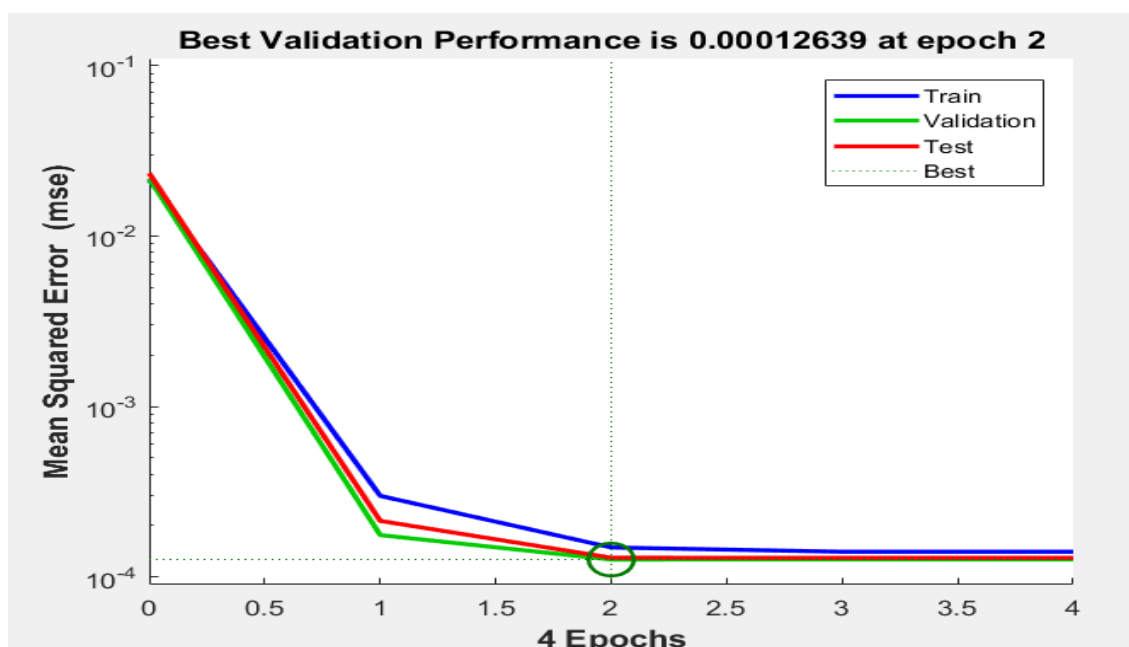
Por conta do resultado satisfatório da rede, é preciso verificar se o número de neurônios se encontra ideal para RNA (PINHEIRO; RÜTHER; LOVATO, 2017). Desta forma, foi elaborada a tabela 5 para esta análise. Os resultados da tabela 5 foram satisfatórios e por conta da análise da gráfica da curva de performance, o melhor resultado corresponde ao número de 15 neurônios na camada oculta. A Figura 20 representa a performance da rede com 15 neurônios. Observa-se que houve o ajustou do número de neurônios da camada oculta, isto é possível de visualizar na Figura 23, pois não há *underfitting* e *overfitting*.

Tabela 5 – Otimização dos neurônios da RNA de estimação das perdas no enrolamento

Neurônios	MSE	Época	Treino	Validação	Teste	Todas
5	6,63E-05	2	0,98116	0,98864	0,98013	0,98237
10	5,18E-05	2	0,9805	0,99054	0,98285	0,98237
15	9,01E-05	3	0,98067	0,98656	0,9869	0,98237
20	9,58E-05	2	0,98321	0,98538	0,97575	0,98237
25	1,01E-04	3	0,98258	0,98442	0,98155	0,98237
30	9,58E-05	3	0,98321	0,98538	0,97575	0,98237

Fonte:Própria


Figura 20 – Curva de performance da RNA de perdas nos enrolamentos para 15 neurônios escondidos



Fonte:Própria

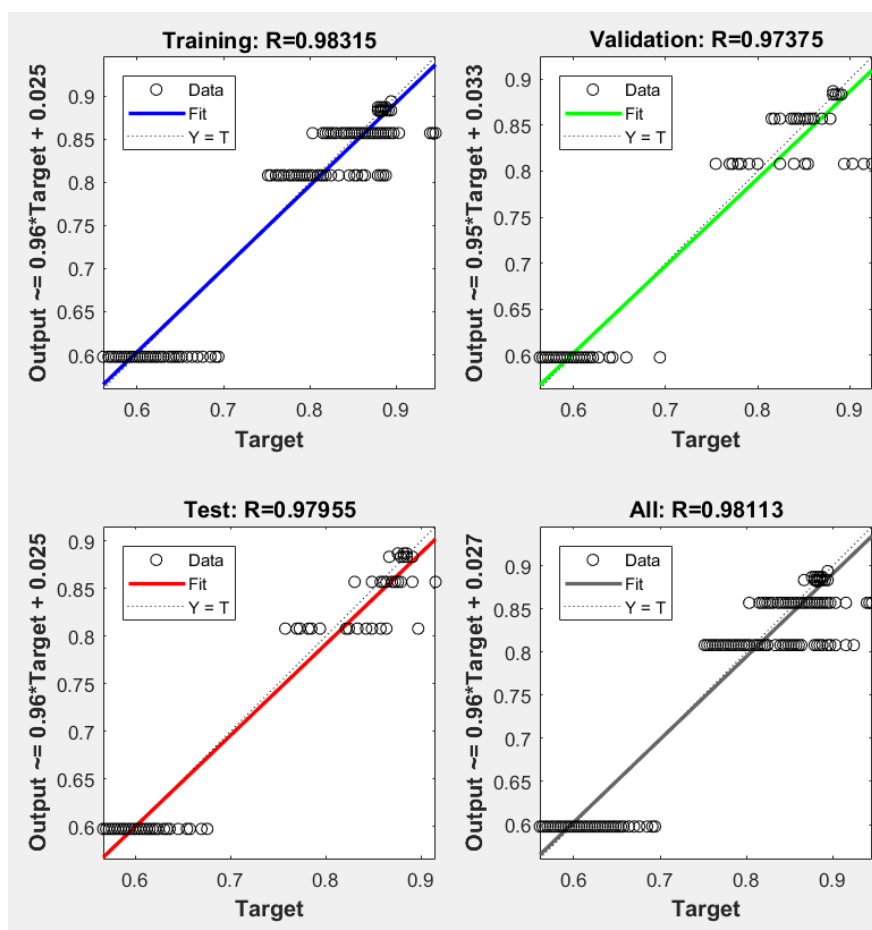
A Figura 21 representa o resultado encontrado da RNA de predição de perdas no núcleo. Com isto, analogamente a análise feita para RNA de predição de perdas nos enrolamentos, a RNA de perdas no núcleo para 20 neurônios, observa-se que o R (Figura 22) de 0.9818 obteve valor superior em relação ao modelo de RNA anterior.

Figura 21 – Curva de performance da RNA de perdas no núcleo para 20 neurônios escondidos



Fonte:Própria

Figura 22 – Coeficiente de correlação linear-R da RNA de perdas no núcleo para 20 neurônios escondidos



Fonte:Própria


Otimizou-se o número de neurônios da camada oculta da RNA de perdas no núcleo conforma a tabela 6 e em virtude da análise gráfica da performance da rede (Figura 21) optou-se por 10 neurônios na camada oculta (Figura 23).Observa-se que houve o ajusto do número de neurônios da camada oculta, isto é possível de visualizar na Figura 23, pois não há *underfitting* e *overfitting*.

Tabela 6 – Otimização dos neurônios da RNA de estimação das perdas no núcleo

Neurônios	MSE	Época	Treino	Validação	Teste	Todas
5	4,17E-04	2	0,99055	0,98926	0,98851	0,98994
10	1,75E-04	2	0,99098	0,99442	0,98498	0,98986
15	5,04E-04	3	0,9931	0,98553	0,98887	0,99011
20	3,87E-04	3	0,99173	0,98935	0,98375	0,99099
25	5,65E-04	3	0,99176	0,98292	0,98920	0,99011
30	4,70E-04	3	0,99046	0,98865	0,99119	0,99012

Fonte:Própria

Figura 23 – Curva de performance da RNA de perdas no núcleo para 10 neurônios escondidos



Fonte:Própria

Estabelecida as topologias ótimas das RNA, foi possível estabelecer a exatidão de cada rede (tabela 7) a partir dos resultados da amostra de teste. É possível observar na tabela 7 a exatidão de cada uma das RNA, a RNA de perdas no núcleo obteve desempenho superior em relação às perdas nos enrolamentos. Esta performance pode contar-se pelo coeficiente de

relação superior, pois se mostra que os dados estimados estão mais próximos dos esperados. Como também, deve-se ao fato de ter utilizado na criação do modelo das perdas nos enrolamentos apenas a equação 14 que tem caráter nominal, apesar de terem outros fatores como as perdas por correntes parasitas e perdas por circulação de corrente foram desconsideradas para o modelo proposto ter menor complexidade e melhorar a generalização da RNA.

Tabela 7 – Parâmetros da RNA para Simulação

Descrição RNA	Número de neurônios	Exatidão(%)
Perdas nos enrolamentos	15	80,12
Perdas no núcleo	10	96,05

Fonte:Própria

Na tabela 8, é possível observar que constam apenas 6 pesos sinápticos para cada entrada, pois como não houve alteração no parâmetro espessura da chapa de aço silício, a própria função de treinamento trainlm tratou de remover o dado visto que seria um dado redundante para a RNA.

As tabelas 8, 9, 10 e 11 correspondem aos pesos sinápticos das tabelas. Os pesos sinápticos são iniciados aleatoriamente uniformemente por meio do algoritmo Nguyen-Widrow, assim é garantido confiabilidade em relação aos pesos iniciais. Ou seja, um determinado conjunto de pesos sinápticos gerados aleatoriamente poderia fazer os valores encontrados da RNA do sistema totalmente dependentes desse conjunto.

Para constar que os valores encontrados não fossem totalmente dependentes do conjunto de pesos iniciais gerados, tanto a RNA das perdas nos enrolamento e a vazios foram iniciadas diferentes vezes e observou-se que a rede manteve-se estável em relação ao conjunto de pesos iniciais.

Tabela 8 – Pesos sinápticos entre entrada e camada oculta da RNA de perdas a vazío.

w_{11}^1	w_{21}^1	w_{31}^1	w_{41}^1	w_{51}^1	w_{61}^1	w_{71}^1
1,1169	-1,2149	0,55512	0,7256	-0,21959	-	-0,78927
w_{12}^1	w_{22}^1	w_{32}^1	w_{42}^1	w_{52}^1	w_{62}^1	w_{72}^1
1,02830	0,89680	-0,93117	-1,11170	-0,39481	-	0,47984
w_{13}^1	w_{23}^1	w_{33}^1	w_{43}^1	w_{53}^1	w_{63}^1	w_{73}^1
-0,93132	1,1517	0,9608	-064601	0,64955	-	0,48291
w_{14}^1	w_{24}^1	w_{34}^1	w_{44}^1	w_{54}^1	w_{64}^1	w_{74}^1
0,97643	0,043689	0,97953	-1,0353	0,68965	-	0,48291
w_{15}^1	w_{25}^1	w_{35}^1	w_{45}^1	w_{55}^1	w_{65}^1	w_{75}^1
0.38228	0.8483	0.35256	-1.375	-0.88859	-	-0.73797
w_{16}^1	w_{26}^1	w_{36}^1	w_{46}^1	w_{56}^1	w_{66}^1	w_{76}^1
-1.5196	-0.78779	0.35519	1.1251	0.27235	-	0.15057
w_{17}^1	w_{27}^1	w_{37}^1	w_{47}^1	w_{57}^1	w_{67}^1	w_{77}^1
-0.71138	-0.30467	0.88327	0.63014	-0.2253	-	1.5775
w_{18}^1	w_{28}^1	w_{38}^1	w_{48}^1	w_{58}^1	w_{68}^1	w_{78}^1
0.1966	1.6432	-0.42878	-0.73198	0.57172	-	-0.62964
w_{19}^1	w_{29}^1	w_{39}^1	w_{49}^1	w_{59}^1	w_{69}^1	w_{79}^1
1.3156	0.72185	0.47355	1.1661	0.49129	-	0.19788
w_{110}^1	w_{210}^1	w_{310}^1	w_{410}^1	w_{510}^1	w_{610}^1	w_{710}^1
1.0001	1.0098	-0.69552	-0.99801	0.56437	-	-0.61776

Fonte:Própria

Tabela 9 – Pesos sinápticos entre entrada camada oculta e saída da RNA de perdas a vazío.

w_{21}^2	w_{22}^2	w_{23}^2	w_{24}^2	w_{25}^2	w_{26}^2	w_{27}^2	w_{28}^2	w_{29}^2	w_{210}^2
0.30768	-0.64716	0.35403	-0.068177	0.15889	0.47237	-0.066768	-0.47208	-0.53714	-0.28478

Fonte:Própria

Tabela 10 – Bias da camada oculta da RNA de perdas a vazío.

b_{11}^1	b_{12}^1	b_{13}^1	b_{14}^1	b_{15}^1	b_{16}^1	b_{17}^1	b_{18}^1	b_{19}^1	b_{110}^1
-2,0618	-1,6902	1,0908	-0,68025	-0,2429	0,062122	-0,70331	1,1502	1,5478	2,0663

Fonte:Própria

Tabela 11 – Biais da camada de saída da RNA de perdas a vazio.

$$\frac{b_2^2}{0,86114}$$

Fonte:Própria

Após estabelecido o número ótimo de neurônios da camada oculta de cada RNA, realizou-se o experimento 1 para estimar 15 resultados de ensaios de transformadores de 75kVA de classe D e E que estariam em processo de fabricação e comparou-se com os seus resultados de ensaios após a fabricação deles. Isto deve-se para validação da modelagem da RNA proposta, também para aumento da confiabilidade do modelo.

Nas tabelas 12 e 13 é possível observar os resultados encontrados durante o experimento, porém, respectivamente, na tabela 13 compara o valor estimado pela RNA proposta com o valor real do ensaio e a tabela 14, o valor calculado padrão de uma indústria de transformadores com o real. A tabela 13 utilizou-se o mesmo conjunto de pesos sinápticos (tabelas 8, 9, 10 e 11) que foram encontrados na modelagem da RNA, enquanto na tabela 14 foram reinicializados os pesos sinápticos para cada amostra de ensaio de transformadores para verificar se a RNA manter-se-ia estável e encontraria valores próximos daqueles dos ensaios de transformadores do experimento.

Tabela 12 – Experimento 1 - Comparação valor da RNA com real sem reinicialização.

Amostra	Perdas no Núcleo			Perdas nos Enrolamentos		
	Real	Est.RNA	Erro(%)	Real	Est.RNA	Erro(%)
1	291	292,26	0,4300	1054,6	1096,10	3,935
2	292	292,26	0,089	1041,3	1096,10	5,263
3	292	292,26	0,089	1054,6	1096,10	3,935
4	291	292,26	0,433	1054,6	1096,10	3,935
5	291	292,26	0,433	1054,6	1096,10	3,935
6	291	292,26	1,128	1054,6	1096,10	3,935
7	289	292,26	0,779	1054,6	1096,10	3,935
8	290	292,26	3,340	1054,6	978,51	3,935
9	191	197,38	1,220	974,55	978,51	0,406
10	195	197,38	0,8140	934,15	978,51	0,447
11	199	197,38	2,269	974,15	978,51	4,748
12	193	197,38	0,704	974,15	978,51	0,447
13	196	197,38	0,704	907,8	978,51	7,789
14	196	197,38	0,704	934,5	978,51	4,709
15	196	197,38	0,704	947,80	978,51	3,240

Fonte:Própria

Tabela 13 – Experimento 1 - Comparação valor da RNA com real com reinicialização.

Amostra	Perdas no Núcleo			Perdas nos Enrolamentos		
	Real	Est.RNA	Erro(%)	Real	Est.RNA	Erro(%)
1	291	290,750	0,086	1054,6	1096,023	3,927
2	292	288,459	1,212	1041,3	1095,800	5,233
3	292	290,020	0,678	1054,6	1095,716	3,898
4	291	291,667	0,229	1054,6	1095,884	3,914
5	291	292,600	0,549	1054,6	1096,372	3,960
6	291	290,637	0,124	1054,6	1095,800	3,960
7	289	291,251	0,778	1054,6	1092,480	3,591
8	290	292,600	0,896	1054,6	1095,605	3,888
9	191	198,780	4,073	974,15	975,502	0,097
10	195	198,853	1,975	974,15	976,503	0,241
11	199	198,771	0,115	934,15	977,380	4,627
12	193	199,245	3,235	974,15	979,489	0,548
13	196	198,660	1,357	907,80	987,460	8,775
14	196	198,120	1,081	934,50	979,401	4,804
15	196	198,486	1,268	947,80	978,141	3,201

Fonte:Própria

Tabela 14 – Experimento 1 - Comparação valor da padrão da indústria com real.


Neurônios	Perdas no Núcleo			Perdas nos Enrolamentos		
	Real	Est.Padrão	Erro(%)	Real	Est.Padrão	Erro(%)
1	291	284,34	2,288	1054,6	1101	4,399
2	292	284,34	2,623	1041,3	1101	5,733
3	292	284,34	2,623	1054,6	1101	4,399
4	291	284,34	2,286	1054,6	1101	4,399
5	291	284,34	2,286	1054,6	1101	4,399
6	291	284,34	2,286	1054,6	1101	4,399
7	289	284,34	1,612	1054,6	1101	4,399
8	290	284,34	1,951	1054,6	1101	4,399
9	191	145	24,083	974,15	1012	3,842
10	195	145	25,641	974,15	1012	3,885
11	199	145	27,135	934,15	1012	8,333
12	193	145	24,870	974,15	1012	3,885
13	196	145	26,020	907,80	1012	11,478
14	196	145	26,020	934,50	1012	8,293
15	196	145	26,020	947,8	1012	6,773

Fonte:Própria

Na realização do experimento 2 foram necessárias algumas modificações devido às amostras utilizadas. As amostras de ensaios de transformadores utilizados no experimento foram 30kVA, 45kVA, 75kVA, 112,kVA e 150kVA e devido a todos os transformadores serem da mesma eficiência e usarem o mesmo tipo de núcleo, logo foram removidas as entradas ATRV4, ATRV5 e ATRV6 do modelo da RNA de perdas no núcleo. Logo, a rede precisou ser treinada com os novos valores das amostras, os resultados correspondem as Figuras 24 e 25. No processo de treinamento usou-se apenas as potências 30kVA, 45kVA e 112,5kVA com o intuito de encontrar outros valores de perdas no núcleo por meio desses valores treinados.

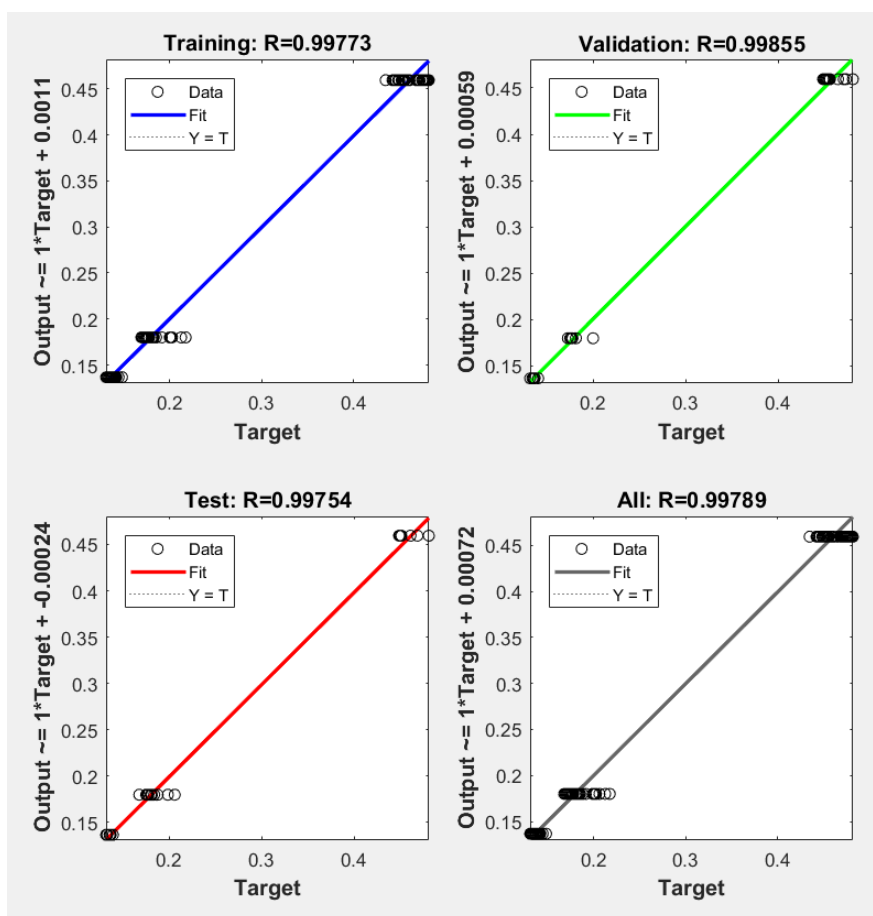
Por fim, na RNA simulou-se os valores de ensaios de transformadores de 30kVA, 45kVA, 75kVA, 112,5KVA e 150kVA, porém observa-se que as potências 75kVA e 150kVA não foram treinadas pela RNA. A tabela 15 representa os valores encontrados e por meio desses valores é possível observar que a RNA do experimento 2, conseguiu estimar o valor de perda do transformador de 75kVA com erro de 0.842% e para o transformador de 150kVA obteve-se erro de 2,955%. Desta forma, pode-se concluir que pelo resultado do transformador de 75kVA da RNA do experimento 2 ocorreu a interpolação pelo ajuste de curva da Figura 25, enquanto pelo resultado do trafo de 150kVA não houve extrapolação da curva da Figura 25. Ou seja, não possível estimar de forma confiável perdas de transformadores que não estejam na faixa das potências das amostras pela metodologia abordada na pesquisa.

Figura 24 – Curva de performance da RNA de perdas no núcleo para o experimento 2.



Fonte:Própria

Figura 25 – Coeficiente de correlação linear-R da RNA do experimento 2.



Fonte:Própria

Tabela 15 – Experimento 2 - Comparação dos resultados do experimento 2 para perdas no núcleo.

Perdas no Núcleo						
Potência (kVA)	Real	Est.RNA	Erro(%)	Real	Est.Padrão	Erro(%)
30	108	110,29	2,120	108	95,58	33,160
45	164	167,26	1,949	164	140,97	16,336
75	293	295,49	0,842	293	284,34	2,955
112,5	373	371,87	0,303	373	364,13	3,045
150	401	365,92	0,087	401	482	16,805

Fonte:Própria

CONCLUSÃO

De acordo com a metodologia descrita foi possível realizar um estudo para estimação das perdas dos TTD por meio das RNA com o algoritmo de treino LM. A partir disso, verificou-se que foi possível relacionar parâmetros das características elétricas do TTD com as perdas no núcleo e nos enrolamentos para a proposta de um modelo para a RNA.

Através de dados de relatórios de ensaio de uma indústria de transformadores foi possível realizar o processo de treinamento da RNA para estimação das perdas do TTD. Assim, foi possível obter uma relação linear entre as entradas da RNA com as saídas (perdas) um coeficiente de correlação de 95% e 98%, respectivamente, perdas no núcleo e nos enrolamentos, verificando que a escolha dos parâmetros foram adequados para o modelo proposto.

Os resultados alcançados por meio do método da validação cruzada foram satisfatórios, onde obteve-se exatidão nas amostras de teste de 80% para perdas nos enrolamentos e 96% para as perdas no núcleo.

Desta forma, conclui-se que o modelo proposto conseguiu acurácia. Por meio do experimento 1, simulou-se as perdas de 15 TTD e atingiu-se no pior caso erro de apenas 3,340% e no melhor caso 0,089% em comparação com os relatórios do TTD para as amostras sem reinicialização, resultado superior aos resultados padrões utilizado nas indústrias de transformadores que foram, respectivamente, 1,612% e 26,020% para melhor e pior caso. Também, pelo experimento 2 permitiu concluir que estimar as perdas de transformadores que não foram treinados pela RNA de perdas no núcleo, por meio de interpolação da reta de ajuste de curva, o melhor resultado para esse experimento foi 0,303%.

Portanto, o modelo proposto mostrou-se adequado apesar da complexidade devido aos diversos fatores que compreendem os TTD. Como também, vale salientar a importância de estudo de métodos computacionais em equipamentos elétricos como transformadores em decorrência da sua grande relevância para o sistema elétrico.

Sugere-se, portanto, em virtude dos resultados encontrados nesta pesquisa, acrescentar um estudo referente ao pré-processamento dos dados de entradas para otimizar os resultados encontrados e diminuição dos *outliers* (amostras espúrias). Como também, a criação de uma ferramenta computacional para estimação das perdas de TTD e até mesmo de transformadores de força (acima de 500kVA).

TRABALHOS PUBLICADOS

O presente trabalho foi apresentado e publicado no evento científico BRAZILIAN TECHNOLOGY SYMPOSIUM 2018 (BTSym'18). O trabalho foi publicado na opção B que são os *proceedings* do evento e também foi convidado para integrar a opção A do mesmo que é o livro Proceedings of the 4th Brazilian Technology Symposium - Emerging Trends and Challenges in Technology que será publicado pela editora Springer Nature e indexado nas bases de dados Web of Science (WoS) e EI Compendex.


Referências

- BESSA, J. et al. Alteração de um layout funcional um layout motivado pelos fundamentos da manufatura. *Holos - Federal Institute of Rio Grande do Norte*, 2018.
- CALLISTER, W. *Ciência e Engenharia de Materiais Uma Introdução*. [S.l.]: LTC - Livros Técnicos e Científicos Editora S.A., 2008.
- CARDOSO, B. P. *Eficiência de Transformadores de Média Tensão*. Dissertação (Mestrado) — Universidade de Federal de Itajaúba, 2005.
- CHAPMAN, S. *Fundamento de Máquinas Elétricas*. 1. ed. [S.l.]: Editora LTC, 2013.
- EPE. *Empresa de Pesquisa Energética - Transmissão de Energia Elétrica*. [S.l.], 2017.
- EPE. *Empresa de Pesquisa Energética - Caderno de Demanda de Eletricidade N1*. [S.l.], 2018.
- FACELI, K. et al. *Inteligência Artificial - Uma Abordagem de Aprendizado de Máquinas*. [S.l.]: LTC, 2011.
- GEORGE, L. P.; DHAS, J. E. R.; SATHEESH, M. Forecasting of machining quality using predictive neural networks. 2015 International Conference on Control, Instrumentation, Communication and Computational Technologies (ICCICCT), 2015.
- GEORGILAKOS, P. et al. A neural network framework for predicting transformer core losses. 1999 Proceeding of the 21st International Conference on Power Industry Computer Applications Connecting Utilities PICA99 To the Millennium and Beyond, 1999.
- GRADIZ, E. Eficiência energética em transformadores de distribuição: Procobre. 2009.
- HARLOW, J. *Electric Power Transformer Engineering*. [S.l.]: CRR Press LLC, 2004.
- HAYKIN, S. *Neural Networks and Learning Machines*. [S.l.]: Pearson, 2009.
- IZZAH, A. et al. Mobile app for stock prediction using improved multiple linear regression. 2017 International Conference on Sustainable Information Engineering and Technology (SIET), 2017.
- JR., R. A. L. F. P. P. da C.; CRUZ, F. R. B. da. Minimização do erro no algoritmo backpropagation aplicado ao problema de manutenção de motores. *Pesquisa Operacional v.18, n.1, jun de 1998*, 1998.
- MARTIGONI, A. *Transformadores*. [S.l.]: Editora Globo, 1969.
- MAYR, A.; MEYER, A.; SEEFRIED, J. Potentials of machine learning in electric drives production using the example of contacting processes and selective magnet assembly. *International Conference on Industrial Engineering and Operations Management*, 2017.
- MONTGOMERY, D.; RUNGER, G. *Estatística Aplicada e Probabilidade Para Engenheiros*. [S.l.]: LTC, 2016.
- PINHEIRO, E.; RÜTHER, R.; LOVATO, A. Aplicabilidade do algoritmo de levenberg-marquardt para análise de geração de energia elétrica de um sistema fotovoltaico. *Revista Científica Eletrônica de Engenharia de Produção*, 2017.
- RIES, W. *Transformadores: fundamentos para projeto e cálculo*. [S.l.]: EDIPUCRS, 2007.
- ROBERTO, J.; ABREU, J. P. G. de. *Transformadores: teoria e ensaios*. [S.l.]: Editora Edgard Blucher Ltda, 1984.

- ROSEBLATT. *The Perceptron: A Preceiving and Recognizing Automation*. [S.l.], 1958.
- RUSSEL, S.; NORVIG, P. *Inteligência Artificial*. [S.l.]: Campus, 2013.
- SHU, H.; XU, Y. Application of additional momentum in pid neural network. 2014 4th IEEE International Conference on Information Science and Technology, 2014.
- SILVA, I. N. da; HERNANE, S.; FLAUZINO, R. A. *Redes Neurais Artificiais Para Engenharia e Ciências Aplicadas – Curso Prático*. [S.l.]: Artliber, 2010.
- SOUZA, K. et al. Prediction of core losses on a three-phase transformer using neural networks. *IEEE International Symposium of Circuits and Systems (ISCAS)*, 2011.
- UMANS, S.; FITZGERALD, A. E.; KINGSLEY, C. *Máquinas Elétricas*. [S.l.]: McGraw-Hill, 2014.
- WOJTKUN, J.; BRÓDKA, B.; STACHOWIAK, D. The influence of core geometry on no-load losses of medium power transformers. 2018 International Interdisciplinary PhD Workshop - IIPhDW, 2018.
- YADAV, A. K. et al. Application research based on artificial neural network (ann) to predict no-load loss for transformer's design. 2011 International Conference on Communication Systems and Network Technologies, 2011.
- YADAV, S.; SHUKLA, S. Analysis of k-fold cross-validation over hold-out validation on colossal datasets for quality classification. 2016 IEEE 6th International Conference on Advanced Computing (IACC), 2016.
- YU, H. *Advanced Learning Algorithms of Neural Networks*. Dissertação (Mestrado) — Graduate Faculty of Auburn University, 2011.
- YU, H.; WILAMOWSKI, B. Levenberg-marquatt training. Disponível em <http://www.eng.auburn.edu/wilambm/pap /2011/K10149C012>, Acessado em 10/08/2018.


ANEXO A

Figura 26 – Curva de performance da RNA de perdas nos enrolamentos para 5 neurônios escondidos



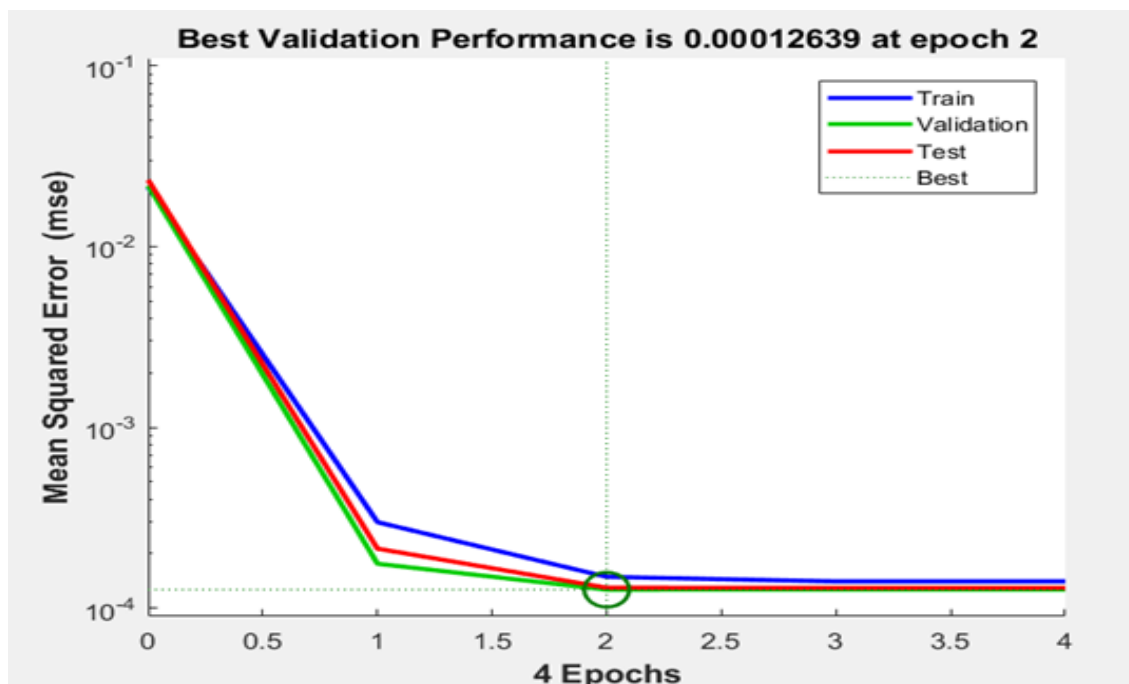
Fonte:Própria

Figura 27 – Curva de performance da RNA de perdas nos enrolamentos para 10 neurônios escondidos




Fonte:Própria

Figura 28 – Curva de performance da RNA de perdas nos enrolamentos para 15 neurônios escondidos




Fonte:Própria

Figura 29 – Curva de performance da RNA de perdas nos enrolamentos para 20 neurônios escondidos



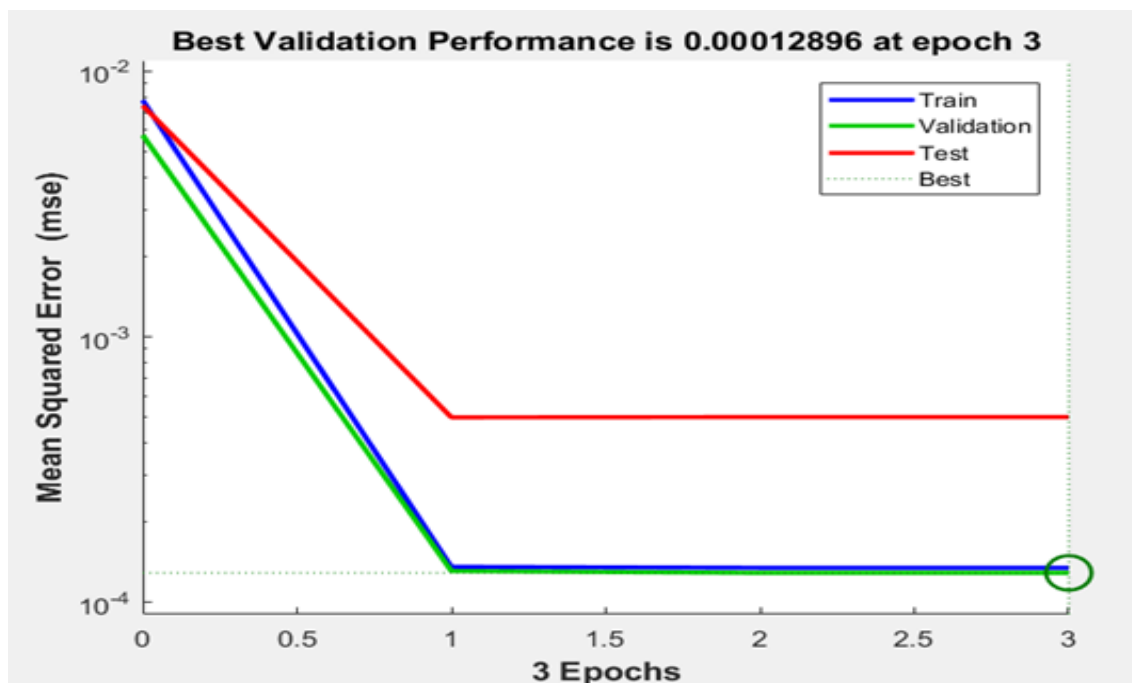
Fonte:Própria

Figura 30 – Curva de performance da RNA de perdas nos enrolamentos para 25 neurônios escondidos




Fonte:Própria

Figura 31 – Curva de performance da RNA de perdas nos enrolamentos para 30 neurônios escondidos




Fonte:Própria

Figura 32 – Curva de performance da RNA de perdas no núcleo para 5 neurônios escondidos




Fonte:Própria

Figura 33 – Curva de performance da RNA de perdas no núcleo para 10 neurônios escondidos




Fonte:Própria

Figura 34 – Curva de performance da RNA de perdas no núcleo para 15 neurônios escondidos




Fonte:Própria

Figura 35 – Curva de performance da RNA de perdas no núcleo para 20 neurônios escondidos




Fonte:Própria

Figura 36 – Curva de performance da RNA de perdas no núcleo para 25 neurônios escondidos



Fonte:Própria

Figura 37 – Curva de performance da RNA de perdas no núcleo para 30 neurônios escondidos



Fonte:Própria

ANEXO B

Tabela 16 – Pesos sinápticos entre entrada e camada oculta da RNA de perdas nos enrolamentos.

w_{11}^1	w_{21}^1	w_{31}^1	w_{41}^1	w_{51}^1	w_{61}^1	w_{71}^1	w_{81}^1
-	-	1.8572	0.29536	-	-	-1.1223	-1.6752
w_{12}^1	w_{22}^1	w_{32}^1	w_{42}^1	w_{52}^1	w_{62}^1	w_{72}^1	w_{82}^1
-	-	-0.17669	-0.53205	-	-	2.6435	-0.55461
w_{13}^1	w_{23}^1	w_{33}^1	w_{43}^1	w_{53}^1	w_{63}^1	w_{73}^1	w_{83}^1
-	-	-1.0351	-1.9312	-	-	-1.2104	-1.2616
w_{14}^1	w_{24}^1	w_{34}^1	w_{44}^1	w_{54}^1	w_{64}^1	w_{74}^1	w_{84}^1
-	-	0.86677	0.97723	-	-	-1.9336	1.4686
w_{15}^1	w_{25}^1	w_{35}^1	w_{45}^1	w_{55}^1	w_{65}^1	w_{75}^1	w_{85}^1
-	-	1.7811	0.43297	-	-	0.94075	1.8409
w_{16}^1	w_{26}^1	w_{36}^1	w_{46}^1	w_{56}^1	w_{66}^1	w_{76}^1	w_{86}^1
-	-0.	1.3881	1.4652	-	-	1.7044	0.7681
w_{17}^1	w_{27}^1	w_{37}^1	w_{47}^1	w_{57}^1	w_{67}^1	w_{77}^1	w_{87}^1
-	-	1.5727	0.31884	-	-	2.0171	0.97448
w_{18}^1	w_{28}^1	w_{38}^1	w_{48}^1	w_{58}^1	w_{68}^1	w_{78}^1	w_{88}^1
-	-	0.99554	1.393	-	-	-0.77099	2.0232
w_{19}^1	w_{29}^1	w_{39}^1	w_{49}^1	w_{59}^1	w_{69}^1	w_{79}^1	w_{89}^1
-	-	0.6952	0.5603	-	-	2.2183	1.369
w_{110}^1	w_{210}^1	w_{310}^1	w_{410}^1	w_{510}^1	w_{610}^1	w_{710}^1	w_{810}^1
-	-	1.1551	2.5592	-	-	0.16492	0.32536
w_{111}^1	w_{211}^1	w_{311}^1	w_{411}^1	w_{511}^1	w_{611}^1	w_{711}^1	w_{811}^1
-	-	-0.056648	2.6455	-	-	-0.22444	-0.80418
w_{112}^1	w_{212}^1	w_{312}^1	w_{412}^1	w_{512}^1	w_{612}^1	w_{712}^1	w_{812}^1
-	-	2.0002	0.036015	-	-	1.7467	0.72967
w_{113}^1	w_{213}^1	w_{313}^1	w_{413}^1	w_{513}^1	w_{613}^1	w_{713}^1	w_{813}^1
-	-	-1.6967	1.135	-	-	-1.7756	-0.53447
w_{114}^1	w_{214}^1	w_{314}^1	w_{414}^1	w_{514}^1	w_{614}^1	w_{714}^1	w_{814}^1
-	-	2.021	-0.11706	-	-	-1.8277	-0.39909
w_{115}^1	w_{215}^1	w_{315}^1	w_{415}^1	w_{515}^1	w_{615}^1	w_{715}^1	w_{815}^1
-	-	-1.9268	1.5793	-	-	1.003	-0.62781

Fonte:Própria

Tabela 17 – Pesos sinápticos entre entrada camada oculta e saída da RNA de perdas nos enrolamentos.

w_{21}^2	w_{22}^2	w_{23}^2	w_{24}^2	w_{25}^2	w_{26}^2	w_{27}^2	w_{28}^2	w_{29}^2	w_{210}^2
-0.039363	-0.27075	0.59415	-0.26446	-0.30673	0.15022	-0.037582	-0.44147	0.14798	0.80948
w_{111}^2	w_{112}^2	w_{113}^2	w_{114}^2	w_{115}^2	-	-	-	-	-
-0.55893	-0.42946	-0.53863	-0.16359	0.37627	-	-	-	-	-

Fonte:Própria

Tabela 18 – Bias da camada oculta da RNA de perdas nos enrolamentos.

b_{11}^1	b_{12}^1	b_{13}^1	b_{14}^1	b_{15}^1	b_{16}^1	b_{17}^1	b_{18}^1	b_{19}^1	b_{110}^1
2.356	1.88522	-1.5417	-1.1634	-0.79212	-0.39204	0.048797	0.39335	0.59236	
b_{111}^1	b_{112}^1	b_{113}^1	b_{114}^1	b_{115}^1	-	-	-	-	-
-1.1416	1.5789	-1.9657	2.3608	-2.7532	-	-	-	-	-

Fonte:Própria

Tabela 19 – Bias da camada de saída da RNA de perdas nos enrolamentos.

$$\frac{b_2^2}{0.18587}$$

Fonte:Própria

Tabela 20 – Pesos sinápticos entre entrada e camada oculta da RNA do experimento 2.

w_{11}^1	w_{21}^1	w_{31}^1	w_{41}^1	w_{51}^1	w_{61}^1	w_{71}^1
-1.6736	-1.6875	-0.43217	-	-	-	0.638
w_{12}^1	w_{22}^1	w_{32}^1	w_{42}^1	w_{52}^1	w_{62}^1	w_{72}^1
1.6848	-1.0762	1.2813	-	-	-	0.74853
w_{13}^1	w_{23}^1	w_{33}^1	w_{43}^1	w_{53}^1	w_{63}^1	w_{73}^1
1.3965	-1.4683	0.94863	-	-	-	-1.0926
w_{14}^1	w_{24}^1	w_{34}^1	w_{44}^1	w_{54}^1	w_{64}^1	w_{74}^1
0.67211	-1.5171	-1.1793	-	-	-	-1.4348
w_{15}^1	w_{25}^1	w_{35}^1	w_{45}^1	w_{55}^1	w_{65}^1	w_{75}^1
1.551	1.9465	-0.061545	-	-	-	-0.0097958
w_{16}^1	w_{26}^1	w_{36}^1	w_{46}^1	w_{56}^1	w_{66}^1	w_{76}^1
1.0847	0.8692	-0.24277	-	-	-	2.0511
w_{17}^1	w_{27}^1	w_{37}^1	w_{47}^1	w_{57}^1	w_{67}^1	w_{77}^1
-0.88089	-1.4977	1.2052	-	-	-	-1.3065
w_{18}^1	w_{28}^1	w_{38}^1	w_{48}^1	w_{58}^1	w_{68}^1	w_{78}^1
0.73454	2.1263	0.98899	-	-	-	0.40301
w_{19}^1	w_{29}^1	w_{39}^1	w_{49}^1	w_{59}^1	w_{69}^1	w_{79}^1
-1.1912	-1.6899	0.93683	-	-	-	-0.99925
w_{110}^1	w_{210}^1	w_{310}^1	w_{410}^1	w_{510}^1	w_{610}^1	w_{710}^1
1.2785	-0.38776	-1.4021	-	-	-	1.5604

Fonte:Própria

Tabela 21 – Pesos sinápticos entre entrada camada oculta e saída da RNA do experimento 2.

w_{21}^2	w_{22}^2	w_{23}^2	w_{24}^2	w_{25}^2	w_{26}^2	w_{27}^2	w_{28}^2	w_{29}^2	w_{210}^2
-0.45998	-0.017027	0.34426	0.80202	0.89792	0.073859	-0.70494	-0.72178	-0.47363	0.73953

Fonte:Própria

Tabela 22 – Bias da camada oculta da RNA de perdas do experimento 2.

b_{11}^1	b_{12}^1	b_{13}^1	b_{14}^1	b_{15}^1	b_{16}^1	b_{17}^1	b_{18}^1	b_{19}^1	b_{110}^1
2.4826	-1.9362	-1.3766	-0.82918	-0.27639	0.27664	-0.83396	1.3827	-1.9444	2.4956

Fonte:Própria

Tabela 23 – Bias da camada de saída da RNA de perdas do experimento 2.

$$\frac{b_2^2}{-0.42868}$$

Fonte:Própria

ANEXO C

Segue em anexo o código base em MATLAB utilizado na execução dos modelos propostos. Porém, observa-se que durante a pesquisa utilizou-se outras funções e o app nntool.

Figura 38 – Código em MATLAB

```
%código
net=newfit(minmax(inputvz_2),[20 1],{'tansig','purelin'},'trainlm'); %A rede possui 20 neurônios na camada oculta e 1 na saída
net.trainParam.epochs = 1000; %Função da camada oculta tangente hiperbólica
%net.divideParam.trainRatio = 0.7 %70% para treino %Função da camada de saída linear
%net.divideParam.valRatio = 0.15 %15% para validação %Algoritmo de aprendizagem é Levenberg-Marquatt
%net.divideParam.testRatio = 0.15 %15% para teste
[net,tr]=trainlm(net,input,target);
Y = sim(net,input);
```

Fonte:Própria