



## ESTUDO DA APLICAÇÃO DE REDES NEURAIS ARTIFICIAIS PARA IDENTIFICAÇÃO DE CURTO-CIRCUITOS NO SISTEMA ELÉTRICO DE DISTRIBUIÇÃO

### STUDY OF THE APPLICATION OF ARTIFICIAL NEURAL NETWORKS FOR IDENTIFICATION OF SHOT-CIRCUITS IN THE ELECTRICAL DISTRIBUTION SYSTEM

Luis Eduardo Anitelli Artero, Weslen Gabriel Dos Santos Piveta, Rafael Bratfich, Marcelo Marques da Silva

Universidade do Oeste Paulista – UNOESTE, Presidente Prudente, SP. E-mail: [rafaelbratfich@gmail.com](mailto:rafaelbratfich@gmail.com)

**RESUMO** – O algoritmo de redes neurais artificiais (RNA), são modelos computacionais que possuem a capacidade de realizar generalização, inferências, identificação e classificação de informações e padrões. De modo que, nesse trabalho foi desenvolvido um estudo através da criação de uma rede neural classificadora de padrões a fim de identificar e classificar os tipos de curto-circuito que ocorrem no sistema elétrico de distribuição. Assim, desenvolveu-se uma rede neural perceptron multicamadas no software Matlab com 3 camadas escondidas, 25 neurônios em cada camada escondida e função de ativação do tipo tangente hiperbólica. A PMC foi treinada utilizando-se dados simulados de curto-circuito no software ATPDraw e apresentou uma eficiência de 94.7% na identificação dos curtos-circuitos na etapa de validação. A rede treinada também conseguiu avaliar curtos-circuitos em um barramento de testes de 9 barras da IEEE demonstrando potencial para ser aplicada como medida adicional de informação da rede nos centros de operação integrado (COI).

**Palavras-chave:** Redes neurais artificiais; modelos computacionais; classificar, curto-circuito, Perceptron multicamadas, função de ativação, PMC, barramento, IEEE.

**ABSTRACT** – The algorithm of artificial neural networks (RNA), are computational models that can perform generalization, inferences, identification, and classification of information and patterns. Thus, in this work, a study was developed through the creation of a neural network classifying patterns to identify and classify the types of short circuits that occur in the electrical distribution system. Thus, a multilayer perceptron neural network was developed in the Matlab software with 3 hidden layers, 25 neurons in each hidden layer, and a hyperbolic tangent activation function. The PMC was trained using simulated short-circuit data in the ATPDraw software and presented an efficiency of 94.7% in the identification of short circuits in the validation stage. The trained network was also able to evaluate short circuits on an IEEE 9-bar test bus demonstrating the potential to be applied as an additional measure of network information in integrated operation centers (IOC).

**Keywords:** Artificial neural networks; computational models; sort, short circuit, multilayer perceptron, activation function, PMC, bus, IEEE.

## 1. INTRODUÇÃO

Com a urbanização que ocorreu no Brasil nos últimos 50 anos, grande parte da população brasileira migrou para os centros urbanos com a intenção de buscar melhor qualidade de vida em termos de saneamento básico, segurança pública, infraestrutura, como acesso a água potável e energia elétrica (PRASAD; EDWARD, 2017).


Para garantir o consumo de energia elétrica aos cidadãos, complexas estruturas de redes de transmissão e distribuição foram criadas com o intuito de garantir fornecimento seguro e de qualidade. Para promover a melhor qualidade de fornecimento de energia frente a perturbações causados por curtos-circuitos, a rede é composta de equipamentos como, disjuntores, cabos, chaves, relés, transformadores, dentre outros (OLESKOVICZ, 2001). Contudo, dependendo do tamanho da perturbação e seu nível de gravidade, faz-se necessário a detecção e a identificação do problema como em casos de curto-circuito.

Considerando esses aspectos, desenvolveu-se uma rede neural artificial aplicada em diferentes modelos de circuito do sistema de distribuição, com foco em média tensão, a fim de identificar e classificar os tipos de curto-circuito. E após avaliação dos seus resultados, a RNA proposta apresentou potencial para ser aplicada nos centros de operação integrados como medida adicional de informação.

## 2. NEURÔNIO

O sistema nervoso do ser humano funciona através dos estímulos captados do ambiente externo ou do próprio organismo. Esses estímulos são enviados ao cérebro por meio de impulsos, e o órgão responsável por fazer esse processamento são os neurônios. A Figura 1 ilustra o neurônio biológico e as suas partes constituintes.

**Figura 1.** Neurônio Biológico



Fonte: (SILVA, 2019, p. 22)

A estrutura do Neurônio Biológico é descrita a seguir:

1. **Dendritos:** Os dendritos funcionam de forma contínua, captando os estímulos recebidos do seu próprio meio externo ou vindo de outros neurônios. Região responsável pela captação dos sinais de entrada;
2. **Corpo celular:** Região constituinte das principais organelas citoplasmáticas. O corpo celular é o núcleo do neurônio, responsável por processar as informações recebidas dos dendritos.
3. **Axônio:** Prolongamento único que se ramifica em diversos terminais sinápticos. Canal responsável pela transferência do impulso elétrico recebido do corpo celular para os neurônios.
4. **Sinapses:** Região onde o axônio de um neurônio entra em contato com os dendritos de outros. Os neurotransmissores liberados ponderam a transmissão dos impulsos elétricos liberados de um neurônio para o outro, estabelecendo a comunicação entre eles.

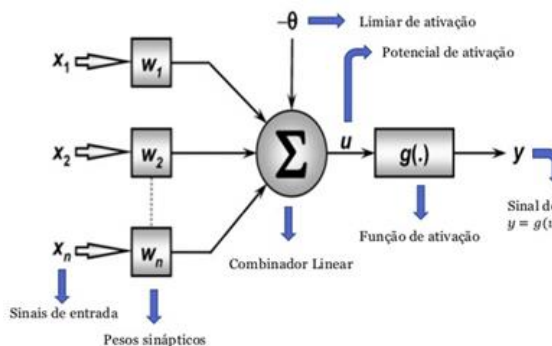
O processamento da informação do neurônio é realizado através do contato dos terminais sinápticos de um neurônio com os dendritos de outro. Quando a célula é estimulada além de um limiar de ativação (-55mV), ocasionado pela variação interna dos íons de sódio ( $Na^+$ ) e potássio ( $K^+$ ), é disparado um impulso elétrico através do prolongamento do axônio, com amplitude máxima de 35mV (Silva, Spatti, & Flauzino, 2010). (SILVA; SPATTI; FLAUZINO, 2010)

## 2.1. Redes Neurais Artificiais

As redes neurais artificiais são modelos matemáticos inspirado na estrutura de funcionamento de neurônios visando o processamento dos dados de forma semelhante ao cérebro humano.

A Figura 2 ilustra o modelo computacional RNA, onde os sinais de entrada representam os dendritos do neurônio biológico, e o sinal de saída representa o axônio.

Figura 2. Rede Neural Artificial



Fonte: (Vinícius, 2017)

A estrutura da Rede Neural Artificial é descrita a seguir:

- 1. Sinais de entrada:** Os sinais de entrada são informações proveniente de um banco de dados, pela qual a rede neural irá ter o primeiro contato durante o seu funcionamento. Cada sinal de entrada é tratado anteriormente a sua inserção na rede a fim de otimizar os dados de saída da RNA.
- 2. Pesos sinápticos e Combinador Linear:** Os pesos sinápticos são responsáveis por atribuir pesos das variáveis que entram nas RNAs, uma a uma, a fim de medir

a sua importância, durante o processamento da mesma. Em seguida, esses valores ponderados são agrupados pelo combinador linear, conforme a Equação (1) a fim de criar um valor inicial.

$$\sum_{i=1}^n x_i w_i \quad (1)$$

- 3. Limiar de Ativação:** O limiar de ativação ( $\theta$ ), é responsável por definir o encaminhamento do valor agrupado pelo combinador linear para saída do neurônio.
- 4. Potencial de ativação:** Potencial de ativação ( $u$ ), é o resultado da diferença entre o valor agrupado pelo combinador linear e a constante limiar de ativação. Considera-se um neurônio excitado quando esse potencial é maior ou igual a zero, o mesmo possuirá características inibitórias quando for menor que zero. A Equação (2) demonstra o cálculo realizado.

$$u = \sum_{i=1}^n x_i w_i - \theta \quad (2)$$

- 5. Função de ativação:** Função comum que possui a responsabilidade de limitar os valores de saída do neurônio a um intervalo reduzido.
- 6.**
- 7. Sinal de saída:** Valor de saída equivalente ao treinamento realizado.
- 8.**

## 2.2. Função de ativação

As funções de ativação podem ser separadas em dois grupos principais, funções parcialmente diferenciáveis e funções totalmente diferenciáveis. (Silva, Spatti, & Flauzino, 2010). As funções que serão abordadas nesse artigo pertencem ao segundo grupo, devido a sua capacidade de aproximar funções, e estabelecer padrões.

### 2.2.1 Funções totalmente diferenciáveis

Função cuja derivada de primeira ordem existe e é conhecido para todos os pontos de seu domínio. As principais funções desse grupo são, a função hiperbólica, função logística e função linear (Silva, Spatti, & Flauzino, 2010).


#### a) Função Linear

A função linear ou função identidade, tem por característica a não limitação dos seus valores de saída. Nota-se que os valores de saída e o valor do potencial de ativação são os mesmos. A função matemática equivalente está representada na Equação (3), e a Figura 3 ilustra o comportamento da função.

$$g(u) = v_u \quad (3)$$

Fonte: (Silva, Spatti, & Flauzino, 2010)

Figura 3. Figura Linear



Fonte: Os autores.

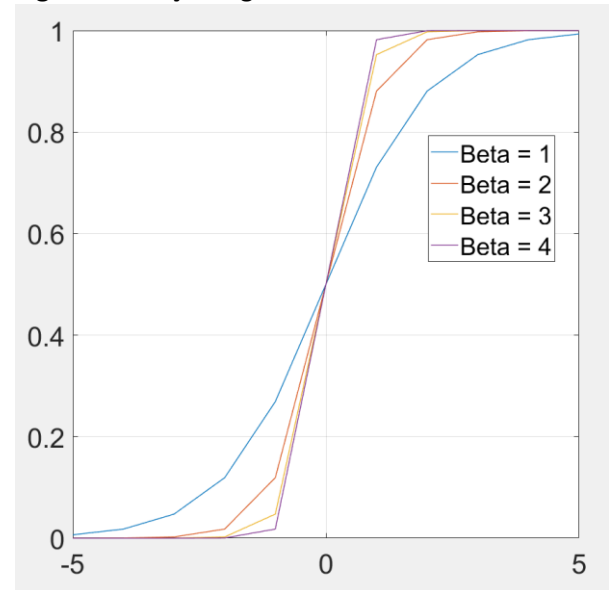
#### b) Função Logística

Também chamada de curva sigmoideal ou função sigmoide, o resultado da saída produzido por essa função sempre assumirá valores reais entre zero e um. A função está representada pela Equação (4), e a Figura 4 ilustra o comportamento dela em função de u.

$$g(u) = \frac{1}{1 + e^{-\beta u}} \quad (4)$$

Fonte: (Silva, Spatti, & Flauzino, 2010)

Figura 4. Função Sigmoide



Fonte: Os autores.

#### c) Função Tangente Hiperbólica

A função tangente hiperbólica também pertence ao grupo das funções totalmente diferenciáveis, e o seu valor de saída é compreendido entre -1 e 1. A Equação (5) representa o cálculo matemático da função.

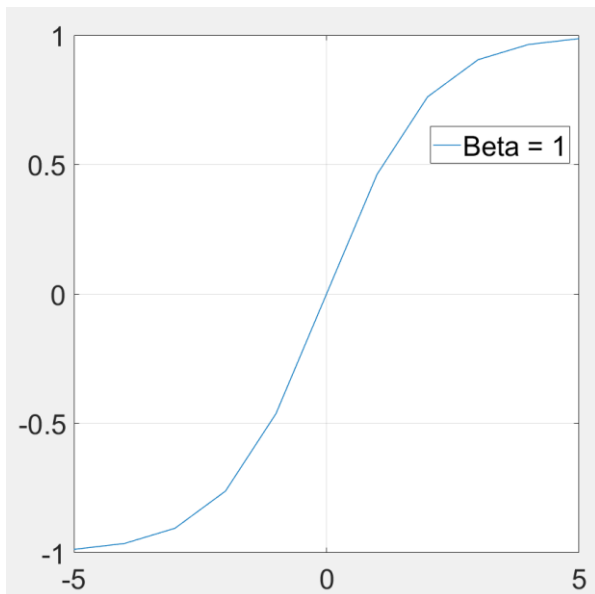
$$g(u) = \frac{1 - e^{-\beta u}}{1 + e^{-\beta u}} \quad (5)$$

Fonte: (Silva, Spatti, & Flauzino, 2010)

O valor de beta está diretamente ligado ao ângulo de inclinação que a função possui no seu ponto de inflexão, que é o ponto em que a curvatura da função tangente hiperbólica troca o sinal, ou seja, momento em que a função assume característica contrário de como havia começado. A apresentação gráfica é demonstrada pela Figura 5.

**Figura 5.** Função Tangente Hiperbólica

**Figura 6 -** Rede Feedforward de Múltiplas Camadas



Fonte: Os autores.


### 3. ARQUITETURA DE REDE

A arquitetura de uma rede artificial estabelece como os seus neurônios estão estruturados uns em relação aos outros. Essa estruturação é possível através do direcionamento das conexões sinápticas dos neurônios.

O que caracteriza uma rede neural é a forma como seus neurônios estão interligados e a quantidade de camadas existentes. Por exemplo, uma mesma arquitetura de rede pode ter mais de uma topologia existente, com diferentes números de neurônios e trabalhando com diferentes funções de ativação (Silva, Spatti, & Flauzino, 2010).

As principais arquiteturas de redes neurais são: Arquitetura *feedforward* de camada simples, camada múltiplas, arquitetura recorrente e em estrutura reticulada.

### 3.1. Rede *feedforward* de múltiplas camadas



A arquitetura de rede *feedforward* de múltiplas camadas apresentam uma ou mais camadas ocultas de neurônios. Esse modelo de rede, ilustrado pela figura 6, é principalmente utilizado em problemas relacionados a classificação e aproximação de padrões, identificação de sistemas e controle de processos.

De acordo com Silva, Spatti e Flauzino (2010), entre os principais tipos de redes feedforward de múltiplas camadas temos o Perceptron multicamadas (Multilayer Perceptron – MLP) e as redes de base radial (radial basis function – RBF). Uma característica dessa rede é a capacidade de solucionar funções de maiores complexidades através do aumento dos números de neurônios de camada intermediária.

### 4. DISCUSSÃO E RESULTADOS

Dessa forma, utilizando-se o software Matlab 2015, desenvolveu-se uma rede neural perceptron multicamadas, através de um algoritmo específico de criação e realizou-se diversos testes de validação para verificar qual estrutura da PMC apresenta maior eficiência para o problema apresentado. E a seguir, os gráficos que demonstram a eficiência em função das seguintes características impostas.

Para realizar o treinamento e a validação, foi criada uma base de dados. Gerou-se 6 modelos de circuitos, onde a resistência de falta era alterada 2 vezes, com isso tem-se 12 modelos. E por fim, foram aplicados 11 modelos de faltas e 1 com o circuito funcionando normalmente em cada circuito gerado. Logo, foi obtido 144 amostras de dados.

Tratando-se de um treinamento supervisionado, é necessário separar as amostras


de treinamento e validação, ou seja, o treinamento da RNA é dividido em duas partes. A primeira, a apresentação de cerca 70% do banco de dados gerados para treinar, tanto dados de entrada (correntes de fase, tensão de linha e tensão e corrente de sequência zero), quanto os dados de saída (binário). Após essa etapa, os outros 30% é apresentado para ela novamente, com isso é realizado uma comparação dos dados que foram assertivos, e demonstrado a partir de uma matriz de confusão, ou seja, sua eficiência.

#### 4.1. Avaliando a função de Ativação

Para definir qual função de ativação obteve maior eficiência, todas as três foram impostas ao mesmo tipo de situação. Onde foram colocadas, somente 1 camada para teste, com diferentes números de neurônio.

A Figura 7, mostra a eficiência das funções de ativação em função da quantidade de neurônio por camada, quando submetida a um treinamento com 60 épocas.


**Figura 7.** Análise das funções de ativação com 60 épocas



Fonte: Os autores.

O gráfico a seguir, apresentado na Figura 8, demonstra a eficiência das funções de ativação conforme o gráfico anterior, diferindo somente no número de épocas de treinamento, onde nesse temos 80 épocas.


**Figura 8.** Análise das funções de ativação com 80 épocas



Fonte: Os autores.

Por fim, o gráfico da Figura 9 apresenta a eficiência conquistada por cada função de ativação quando submetida a 100 épocas de treinamento.

**Figura 9.** Análise das funções de ativação com 100 épocas



Fonte: Os autores.

Após a análise de cada gráfico, foram definidas a função de ativação necessária para o treinamento da RNA, que é a tangente hiperbólica submetida a 100 época de treinamento. Devida sua capacidade de alcance para altas eficiências e estabilidade nessas condições.

#### 4.2. Avaliação do número de neurônio por camada e número de camadas da PMC

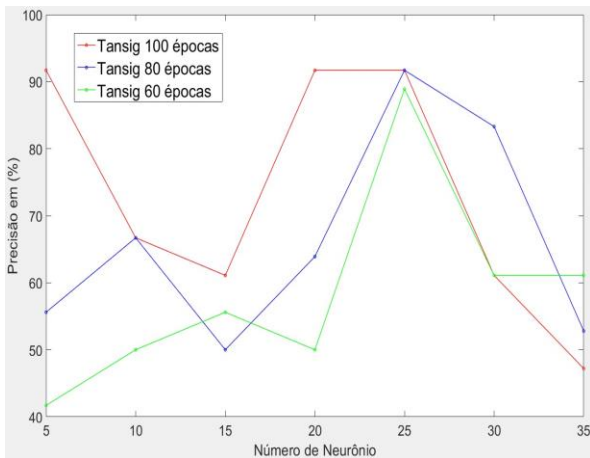
Após definir a função de ativação, se fez necessário avaliar o número de camadas e número de neurônios por camada da RNA.

A Figura 10, demonstra o desempenho da função tangente hiperbólica em termos de



eficiência em função do número de neurônio em camada única em sua estrutura.

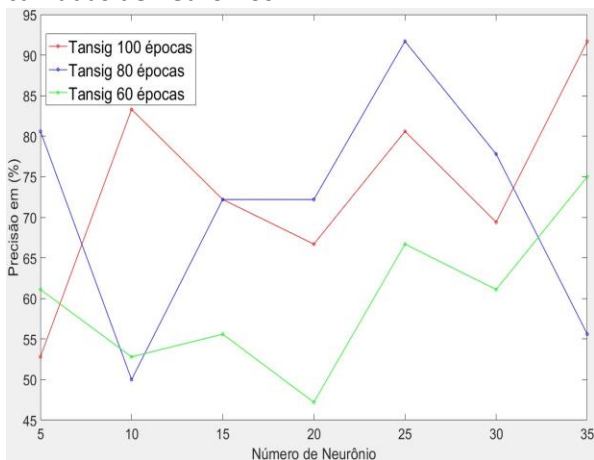
**Figura 10.** Análise da função Tansig com uma camada de neurônio



Fonte: Os autores.

A Figura 11, mostra o desempenho do treinamento, para 2 camadas na estrutura da RNA. Para diferentes números de épocas ao qual a rede neural foi submetida.

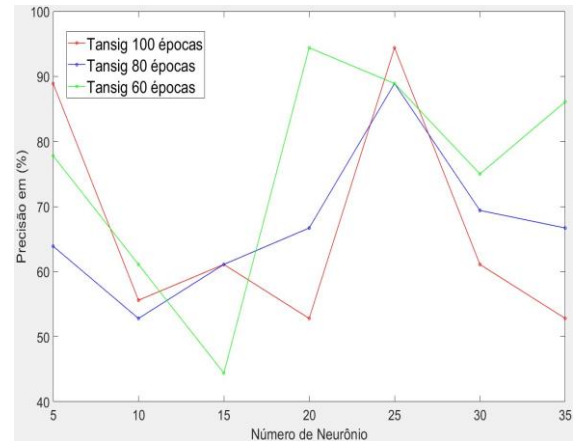
**Figura 11.** Análise da função Tansig com duas camadas de neurônios



Fonte: Os autores.

O gráfico apresentando na Figura 12, mostra o desempenho para 3 camadas de neurônios.


**Figura 12.** Análise da função Tansig com três camadas de neurônios



Fonte: Os autores.

E por fim, a Figura 13, demonstra a eficiência do treinamento para 4 camadas de neurônios.

**Figura 13.** Análise da função Tansig com quatro camadas de neurônio



Fonte: Os autores.

Com base na eficiência apresentada nos gráficos, a tangente hiperbólica para 100 épocas se comportou melhor. Após isso, bastou determinar o número de camadas e o número de neurônios por camadas, e sendo assim, visando o maior percentual de acerto e o mantimento da eficiência entre as etapas de teste. A estrutura com 25 neurônios e com 3 camadas se adequou melhor. Portanto, a estrutura até então é uma RNA com 3 camadas e 25 neurônios por camadas, sendo submetida a 100 épocas de treinamento.

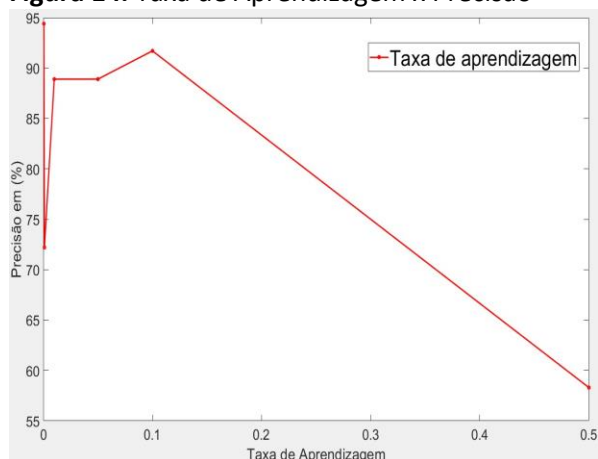
### 4.3. Taxa de Aprendizagem

Por fim, todas as simulações foram feitas com taxa de aprendizagem de 0,0005, com o objetivo de realizar ajustes rigorosos dos pesos sinápticos para

umentar a eficiência da rede, visto que não há um valor obrigatório. Porém, Kingma e Ba (2015), criadores do algoritmo otimizador Adam, sugere o valor de 0,001, então se fez necessário novamente realizar novos testes com diferentes valores de taxas de aprendizagem, com intuito de encontrar a melhor eficiência.

A Figura 14, é o gráfico da precisão em função da taxa de aprendizagem.

**Figura 14.** Taxa de Aprendizagem x Precisão

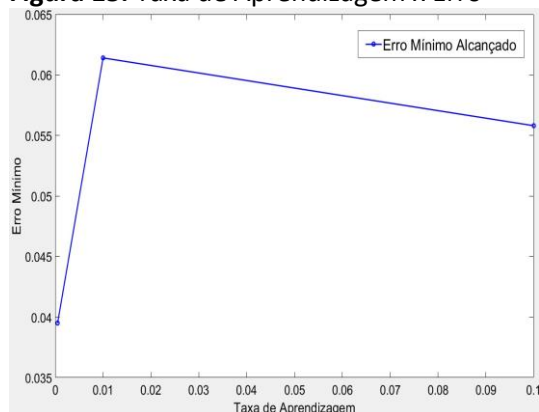


Fonte: Os autores.

É evidente que uma taxa de aprendizagem com 0,0005, com base no gráfico anterior, é o melhor a ser utilizada. No entanto, a taxa de 0,1 se manteve muito próximo, mostrando a necessidade de verificar mais uma característica do treinamento da rede neural artificial, que é o erro mínimo.

Nem sempre o menor erro mínimo apresenta a maior eficiência, porém, ele indica a possibilidade de um melhor treinamento. Logo o gráfico apresentado na Figura 15, representa o erro mínimo alcançado em função da taxa de aprendizagem.

**Figura 15.** Taxa de Aprendizagem x Erro



Fonte: Os autores.

Logo, visando alcançar o menor erro possível, vemos que a taxa de 0,0005 se saiu melhor. Sendo assim, temos que a taxa de 0,0005 é a mais indicada para esse tipo de estrutura.

#### 4.4. Estrutura da RNA definida

Depois de realizado todos os testes para definição e ajustes dos parâmetros, na Tabela 1, encontra-se os valores ideais para uma estrutura adequada de RNA para esse tipo de problema.

**Tabela 1.** Exemplo de tabela.

Parâmetros	Resultados Selecionados
Função de ativação	Tangente Hiperbólica
Número de camadas	3
Número de Neurônios por camadas	25
Número de épocas	100
Taxa de Aprendizagem	0,0005

Fonte: Os autores.

#### 4.5. Resultados


Após definidos os parâmetros da estrutura da RNA, ela foi aplicada em dois modelos de circuitos. Ambos os modelos foram simulados no SIMULINK (extensão do MATLAB), para validação dos seu desempenho. Vale ressaltar, que nenhum dado dos modelos foram apresentados para a RNA anteriormente.

##### 4.5.1 Modelo Simulink Teste

A Figura 16, apresenta o circuito ao qual a Rede Neural Artificial foi aplicada. Nesse circuito temos que a tensão de alimentação é dada por 11,4 kV e que a frequência do sistema é de 60 Hz.



**Figura 16.** Circuito Simulink Teste



Fonte: Os autores.

Os dados de cada elemento do circuito são apresentados nas Tabelas 2 e 3.

Na Tabela 2, tem-se os dados de carga do circuito de teste.

**Tabela 2.** Tabela de Carga de Validação

Parâmetros	Valores
Tensão nominal fase-fase (RMS)	1000
Frequência (Hz)	60
Potência (W)	3
Potência Reativa Indutiva (VAr)	100
Taxa de Aprendizagem	0,0005

Fonte: Os autores.

Na Tabela 3, tem-se os dados das resistências de falta.

**Tabela 3.** Tabela de Carga de Validação

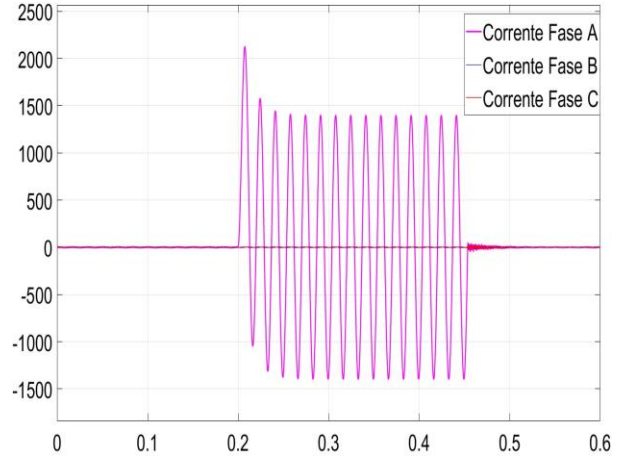
Parâmetros	Valores
Resistência de falta (ohm)	0,6
Resistência de Aterramento (ohm)	0,00001

Fonte: Os autores.

Aplicando o bloco da rede neural próximo a fonte e a falta próximo ao transformador, foram obtidos os seguintes resultados ocasionados tanto pela perturbação da falta quanto pela identificação em binária por parte da RNA. Onde a perturbação é um gráfico senoidal da corrente, e a resposta da RNA é dado por um pulso binário no mesmo momento que ocorreu a falta.

A Figura 17, mostra a perturbação ocasionada pela falta Fase terra, no caso a falta na fase A.


**Figura 17.** Gráfico senoidal Falta Fase-Terra



Fonte: Os autores.

A Figura 18, mostra a resposta da RNA em resposta a perturbação ocasionada.

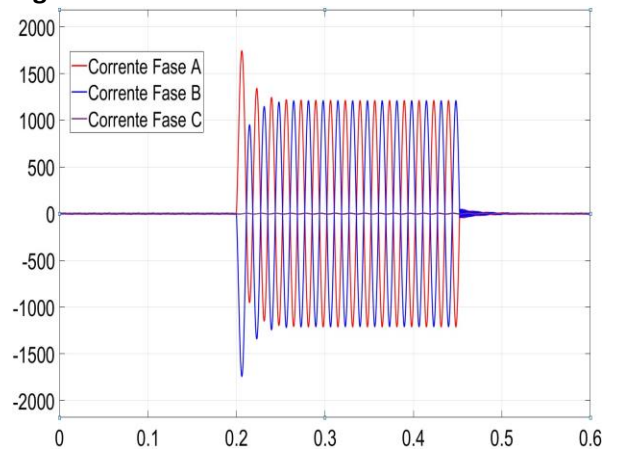
**Figura 18.** Detecção da Falta Fase-Terra



Fonte: Os autores.

A Figura 19, demonstra a perturbação ocasionada por uma falha que envolve a fase A e B somente, sem o terra.


**Figura 19.** Falta Fase-Fase



Fonte: Os autores.

Em seguida, na Figura 20 a classificação por parte da RNA.

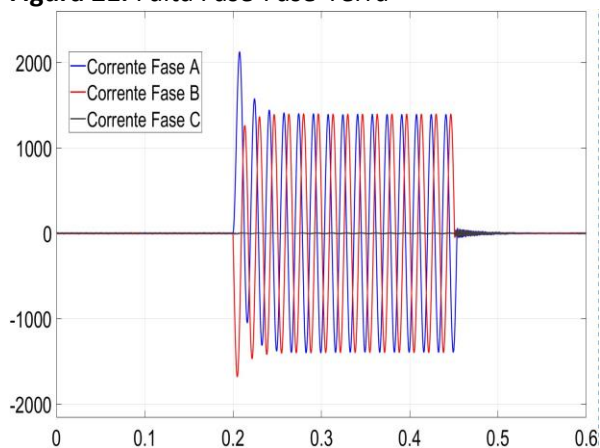
**Figura 20.** Detecção da Falta Fase-Fase



Fonte: Os autores.

A Figura 21, se refere a falta envolvendo as fases A e B junto ao terra.


**Figura 21.** Falta Fase-Fase-Terra



Fonte: Os autores.

A Figura 22, demonstra a resposta da RNA para perturbação causada por uma falta que envolve a fase A e B junto ao terra.

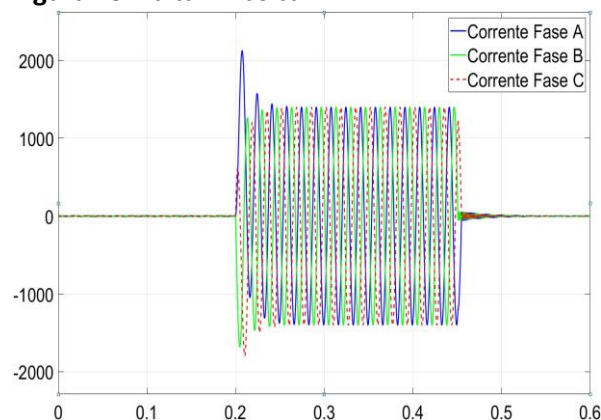
**Figura 22.** Detecção Falta Fase-Fase-Terra



Fonte: Os autores.

Por fim, temos na Figura 23 o gráfico senoidal da corrente que caracteriza a perturbação ocasionada pela falta ABC, sem envolvimento do terra.

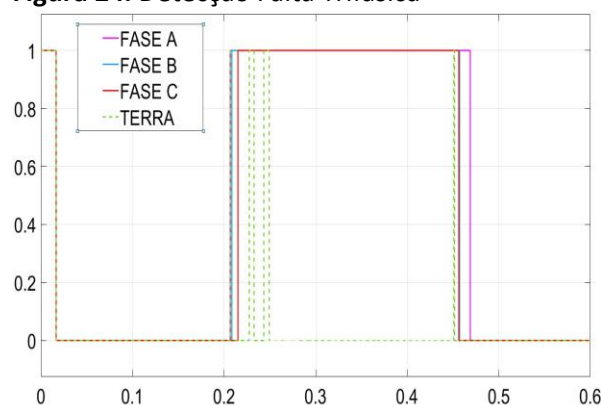
**Figura 23.** Falta Trifásica



Fonte: Os autores.

A Figura 24, representa a resposta por parte da RNA.

**Figura 24.** Detecção Falta Trifásica

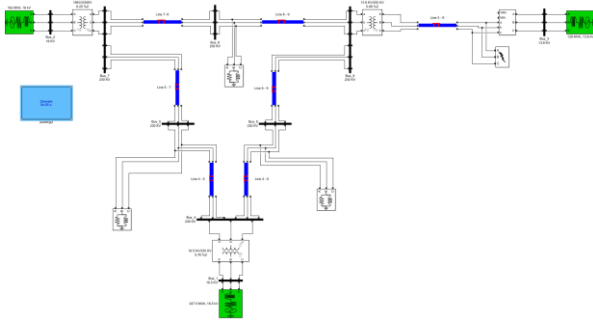


Fonte: Os autores.

#### 4.5.2 Modelo de teste 9 barras da IEEE

A etapa final da validação da Rede Neural Artificial se deu a partir da aplicação de faltas num barramento de testes de 9 barras da IEEE. Com isso, foi aplicado num barramento de 13.8kV o bloco de falta, conforme a Figura 25. Com isso a rede neural foi aplicada no circuito, para a fim de detectar e classificar o curto-circuito.

**Figura 25.** Circuito Exemplo IEEE de 9 barras software Simulink



Fonte: [<https://al-roomi.org/power-flow/9-bus-system>]

Nota: Adaptado pelos autores.

Nas tabelas seguintes, temos os dados de cada elemento do circuito da IEEE.

Na Tabela 4, temos os valores dos parâmetros dos geradores.

**Tabela 4.** Dados dos Geradores

Gerador	Config	Tensão fase-fase (RMS)	Curto-Circuito Na Base MVA
1	Yg	16,5	247,5
2	Yg	18	192
3	Yg	13,8	128

Vale ressaltar que os valores de resistência da fonte são todos 0,529 ohms e que a indutância de todas as fontes possui o valor de 0,0140 H.

A Tabela 5, informa os dados dos transformadores, cujos os valores em comum são de resistência de sequência positiva e negativa, que são ambas  $1 * 10^{-5} pu$ . E a capacidade de todos é 100 MVA.

**Tabela 5.** Dados dos Transformadores

De	Para	Equipamento	L1	L2
1	4	Transfo. 1	0	0,0576
2	7	Transfo. 2	0	0,0625
3	9	Transfo. 3	0	0,0586

A Tabela 6, demonstram os dados de linhas de transmissão do barramento. Todas as linhas possuem o comprimento de 100 km e Tensão em todas as linhas exceto as que conectam os trafo em baixa tensão são de 230 kV.

**Tabela 6.** Dados das linhas de transmissão e dos barramentos

De	Para	Resistencia sequência positiva e zero (Ohms/km)	Indutância sequencia positiva e zero (mH/km)	Capacitância sequencia positiva e zero (nF/km)
4	5	0,0529; 0,13225	1,92; 2,38	8,82; 5,188
4	6	0,08993; 0,224825	1,29; 3,22	7,922; 4,74
5	7	0,16928; 0,4232	2,259; 5,64	15,34; 9,025
6	9	0,20631; 0,5157	2,38; 6,09	17,95; 10,55
7	8	0,044965; 0,11241	1,01; 2,02	7,471; 4,394
8	9	0,062951; 0,15737	1,414; 3,53	10,47; 6,15
3	9	0,044965; 0,11241	1,01; 2,02	7,471; 4,394

Na Tabela 7, informam os dados de carga que estão inseridas nos barramentos.


**Tabela 7.** Dados das cargas

Cagar	Tensão fase-fase nominal Vrms (kV)	Potência ativa (MW)	Potência reativa (MVAR)
1	230	125	50
2	230	100	35
3	230	90	30

Por fim, temos os dados gerados pelas perturbações e resposta por parte da RNA nas figuras seguintes.


A Figura 26, representa a perturbação de onda causa pela falta fase-terra. E na Figura 27, tem-se a resposta da rede neural, confirmando o tipo de falta representado.

**Figura 26. Falta Fase - Terra**



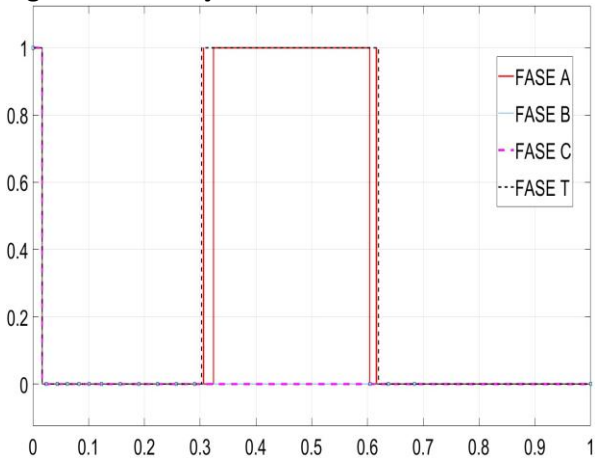
Fonte: Os autores.

**Figura 29. Detecção Falta Fase-Fase-Terra**



Fonte: Os autores.

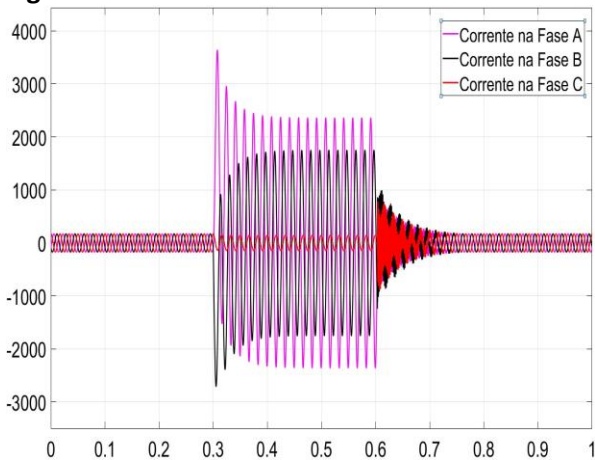
**Figura 27. Detecção Falta Fase - Terra**



Fonte: Os autores.

A Figura 28, representa o curto-circuito fase-fase-terra. Em seguida, a resposta dada pela RNA é dada na Figura 29.

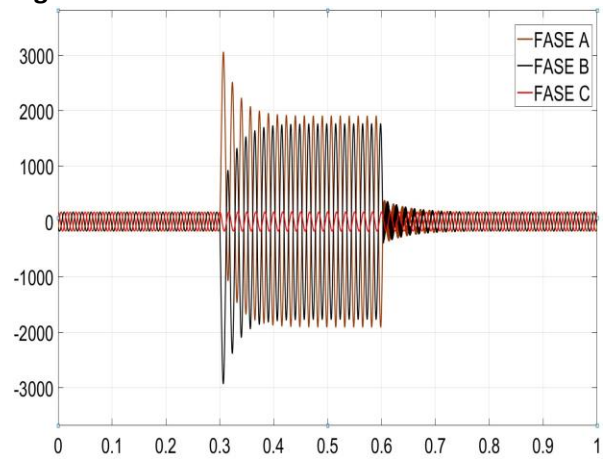
**Figura 28. Falta Fase- Fase- Terra**



Fonte: Os autores.

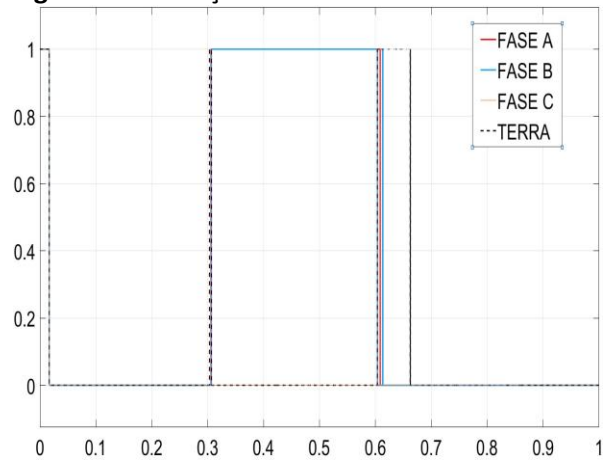
O curto-circuito fase-fase é representado pela senóide na Figura 30. Quando a rede neural detecta o modelo e classifica, a resposta é representada na Figura 31.

**Figura 30. Falta Fase-Fase**



Fonte: Os autores.

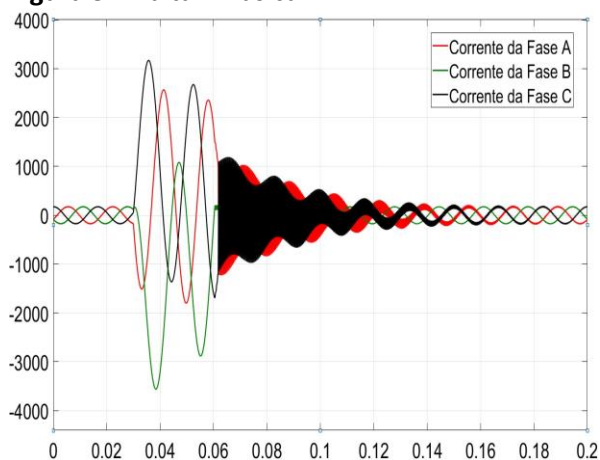
**Figura 31. Detecção Falta Fase - Fase**



Fonte: Os autores.


Por fim, a falta trifásica é representada na Figura 32. E a resposta dada pela RNA corresponde ao que está na Figura 33.

**Figura 32.** Falta Trifásica



Fonte: Os autores

**Figura 33.** Detecção Falta Trifásica



Fonte: Os autores

Contudo, nota-se uma oscilação a partir do tempo 0,06 na figura 31. Na qual a rede identifica a participação do terra numa falta que não envolve o terra. Para resolver esse tipo de problema, é necessário um maior volume de dados para serem apresentados para a RNA durante o treinamento.

## 5. CONSIDERAÇÕES FINAIS

Desenvolveu-se uma rede PMC descrever a rede na qual foi treinada com m amostras bem como foram apresentados dois circuitos testes sendo um de 9 barras IEEE para sua avaliação.

Com base nos resultados obtidos, é possível determinar que a RNA demonstrou ser capaz de identificar e classificar as principais faltas as quais ela foi submetida. Todavia, faz-se necessário aumentar o volume de dados de treinamento a fim de evitar incongruências da detecção da falta trifásica não envolvendo o terra. Entretanto, diante do exposto a RNA desenvolvida e avaliada apresenta potencial de

ser aplicada nos centros de operação integrada como fonte adicional de informação para identificar e classificar curtos-circuitos em pontos de interesse nos barramentos da rede de distribuição e auxiliar os operadores nas decisões frente a eventos intempestivos.

## AGRADECIMENTOS

Ao departamento de Engenharia Elétrica da Universidade do Oeste Paulista – Campus II, pelo apoio no desenvolvimento deste projeto.

## REFERÊNCIAS

- HOIDALEN, H. K. N. **Atpdraw**, [2020]. Disponível em: <https://www.atpdraw.net/news.php>. Acesso em: 12 ago. 2021.
- HAQUE, M. T.; KASHTIBAN, A. Application of Neural Networks in Power Systems; AReview. **World Academy of Science, Engineering and Technology**, 2005.
- HAYKIN, S. **Redes neurais artificiais princípios e prática**. 2. ed. São Paulo: Prentice Hall, 2001.
- KALOGIROU, S.; KALOGIROU, S. A. Artificial neural networks in renewable energy systems applications: a review. **Renew Sustain**, v. 5, 2001. [https://doi.org/10.1016/S1364-0321\(01\)00006-5](https://doi.org/10.1016/S1364-0321(01)00006-5)
- KINDERMANN, G. **Curto –circuito**. 2. ed. Porto Alegre: Sagra Luzzato, 1997.
- KINGMA, D. P.; BA, J. L. Adam: a method for stochastic optimization. *In*: INTERNATIONAL CONFERENCE ON LEARNING REPRESENTATIONS. 2015. **Anais [...]**. 2015. Disponível em: <chrome-extension://dagcmkpagilhakfdhnbomgmjdpkdklff/enhanced-reader.html?openApp&pdf=https%3A%2F%2Farxiv.org%2Fpdf%2F1412.6980.pdf> Acesso em: 20 abr. 2022.
- KOHAVI, R. A study of cross-validation and bootstrap for accuracy estimation and model selection. *In*: INTERNATIONAL JOINT CONFERENCE ON ARTIFICIAL INTELLIGENCE. 1995. **Anais [...]**. Canadá: Stanford: Computer Science Department, 1995.



MATHWORKS. 1994. Disponível em: [https://www.mathworks.com/company.html?s\\_tid=hp\\_ff\\_a\\_company](https://www.mathworks.com/company.html?s_tid=hp_ff_a_company) Acesso em: 10 ago. 2021.

MORETO, Miguel. **Localização de Falhas de Alta Impedância em Sistemas de Distribuição de Energia: Uma Metodologia Baseada em Redes Neurais Artificiais**. Porto Alegre, 2005. 125p. Escola de Engenharia, Universidade Federal do Rio Grande do Sul.

NERI JUNIOR, A. L. Uma revisão da transformada wavelet aplicada à localização de faltas de energia em redes elétricas de transmissão e distribuição. *In*: SIMPÓSIO BRASILEIRO DE SISTEMAS ELÉTRICOS, 2016. Natal, RN. **Anais [...]**. Natal: SBSE, 2016.

OLESKOVICZ, M. **Aplicação de redes neurais artificiais na proteção de distância**. 2001. Tese (Doutorado em Sistemas Elétricos de Potência) - Universidade de São Paulo, São Carlos, SP, 2001.

OLIVEIRA, Â. R. **Redes neurais artificiais aplicadas na detecção, classificação**. Juiz de Fora: Universidade Federal de Juiz de Fora, 2005.

PRASAD, A.; EDWARD, B. J. Importance of Artificial Neural Networks for Location. *In*: INTERNATIONAL CONFERENCE ON INTELLIGENT SYSTEMS AND CONTROL. 2017. **Anais [...]**. 2017. p. 11.

RUMELHART, D. E.; HINTON, G. E.; WILLIAMS, R. J. Learning Internal Representations by Error Propagation. *In*: **Parallel Distributed Processing**: explorations in the microstructure of cognition, foundations. Cambridge, MA: MIT Press, 1986. v. 1. <https://doi.org/10.7551/mitpress/5236.001.0001>

SILVA, I. N.; SPATTI, D. H.; FLAUZINO, R. A. **Redes neurais artificiais: para Engenharia e Ciências Aplicadas** 2. ed. São Paulo: Artliber, 2010.

SILVA, J. V. M. **Learning para detecção de faltas em um sistema elétrico** 2019. Trabalho de Conclusão de Curso (Graduação em Engenharia Elétrica) - Universidade Federal de

Santa Catarina, Florianópolis, SC, 2019. Disponível em: <https://repositorio.ufsc.br/bitstream/handle/123456789/203010/TCC.pdf?sequence=1&isAllowed=y>. Acesso em: 11 nov. 2021.

STEVENSON, W. D. **Elementos de análise de sistemas de potência**. 2. ed. São Paulo: McGraw-Hill, 1986.