

UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ
CÂMPUS CORNÉLIO PROCÓPIO
DIRETORIA DE GRADUAÇÃO E EDUCAÇÃO PROFISSIONAL
CURSO DE ENGENHARIA ELÉTRICA

EVANDRO GABRIEL DA SILVA CORREIA

**APLICAÇÃO DE REDES NEURAS ARTIFICIAIS NA LOCALIZAÇÃO DE FALTAS
EM LINHAS DE TRANSMISSÃO**

TRABALHO DE CONCLUSÃO DE CURSO

CORNÉLIO PROCÓPIO
2018

EVANDRO GABRIEL DA SILVA CORREIA

**APLICAÇÃO DE REDES NEURAS ARTIFICIAIS NA LOCALIZAÇÃO DE FALTAS
EM LINHAS DE TRANSMISSÃO**

Trabalho de Conclusão de Curso em Engenharia Elétrica, do Departamento Acadêmico de Engenharia Elétrica, da Universidade Tecnológica Federal do Paraná – UTFPR, como requisito parcial para obtenção do título de Engenheiro Eletricista.

Orientador: Prof. Dr. Murilo da Silva

CORNÉLIO PROCÓPIO
2018



**Universidade Tecnológica Federal do Paraná
Campus Cornélio Procópio
Departamento de Engenharia Elétrica
Curso de Engenharia Elétrica**



FOLHA DE APROVAÇÃO

Evandro Gabriel da Silva Correia

Aplicação de redes neurais artificiais na localização de faltas em linhas de transmissão

Trabalho de conclusão de curso apresentado às 08:30hs do dia 30/05/2018 como requisito parcial para a obtenção do título de Engenheiro Eletricista no programa de Graduação em Engenharia Elétrica da Universidade Tecnológica Federal do Paraná. O candidato foi arguido pela Banca Avaliadora composta pelos professores abaixo assinados. Após deliberação, a Banca Avaliadora considerou o trabalho aprovado.

Prof(a). Dr(a). Murilo da Silva - Presidente (Orientador)

Prof(a). Dr(a). Gabriela Helena Bauab Shiguemoto - (Membro)

Prof(a). Dr(a). Silvio Aparecido de Souza - (Membro)

A folha de aprovação assinada encontra-se na coordenação do curso.

A Deus,
Aos meus pais.

AGRADECIMENTOS

Primeiramente agradeço a Deus a quem devo minha vida.

À minha família, em especial meu pai Valdecir e a minha Lucineia, pois, sem eles está caminhada não seria possível. Ao meu irmão Rafael, meus sobrinhos Karlos e Guilherme, que sempre estiveram ao meu lado.

Em especial ao meu orientador Prof. Dr. Murilo, que sempre com paciência e sabedoria me encaminhou para a realização deste trabalho. Estendo o agradecimento aos demais professores desta instituição, que sempre estiveram dispostos a compartilhar seus conhecimentos.

Agradeço a Thamires, pela paciência e companheirismo.

Agradeço aos bons amigos que tive a oportunidade de conhecer ao longo desta caminhada, que com certeza tornaram esta jornada mais fácil, com momentos descontraídos e também momentos de estudos e dedicação.

RESUMO

CORREIA, Evandro G. S. **Aplicação de redes neurais artificiais na localização de faltas em linhas de transmissão.** 2018. 72 f. Trabalho de Conclusão de Curso (Graduação) – Engenharia Elétrica. Universidade Tecnológica Federal do Paraná. Cornélio Procópio, 2017.

O trabalho apresenta a aplicação de Redes Neurais Artificiais (RNAs) na localização de faltas em linhas de transmissão (LT). Duas diferentes metodologias são propostas, o primeiro método, denominado generalista não utiliza o módulo de classificação, ou seja, uma topologia RNA é utilizada para estimar a localização de todos os tipos de faltas. Neste método, foram utilizados como entradas os dados registrados em ambos terminais da linha de transmissão e os dados de somente um terminal da LT. Já o segundo, possui uma topologia RNA funcionando como módulo de classificação de faltas, e uma topologia para cada tipo de falta para estimar a distância. Este método utiliza como entrada as correntes do barramento local. Para realização dos testes foi utilizado o *software* ATP, considerando-se as faltas fase-terra, fase-fase, fase-fase-terra e fase-fase-fase para gerar o banco de dados. Já para implementação das topologias de RNA foi utilizado a *toolbox* NNTOOL do *software* Matlab®. Após a realização dos testes constatou-se a eficiência dos métodos que utilizam RNA para localização de faltas, tanto com o método generalista quanto com o método de classificação e localização.

Palavras-chave: Localização de faltas, Redes neurais artificiais, Linhas de transmissão, Transformada Discreta de *Fourier*, Sistemas de potência.

ABSTRACT

CORREIA, Evandro G. S. **Aplicação de Redes Neurais Artificiais na localização de faltas em linhas de transmissão.** 2018. 72 f. Trabalho de Conclusão de Curso (Graduação) – Engenharia Elétrica. Universidade Tecnológica Federal do Paraná. Cornélio Procópio, 2017.

The work presents the application of Artificial Neural Networks (ANNs) in the location of faults in transmission lines (TL). Two different methodologies are proposed, the first method, called generalist does not use the classification module, ie an ANN topology is used to estimate the location of all types of faults, in this method, were used as inputs the data recorded in both transmission line terminals and data from only one terminal of the TL, while the second has an ANN topology functioning as a fault classification module, and a topology for each type of fault to estimate the distance, this method uses as input the currents of the local bus. In order to perform the tests, the ATP software was used, considering the faults phase-earth, phase-phase, phase-phase-earth and phase-phase-phase to generate the database, already for implementation of the topologies ANN was used the NNTOOL toolbox of Matlab® software. After the tests were carried out, it was verified the efficiency of the methods that use ANN to locate faults, both with the generalist method and with the method of classification and location.

Keywords: Fault location, Artificial Neural Network, Transmission line, Discrete Fourier Transform, Power Systems.

LISTA DE FIGURAS

Figura 1 - Oferta interna de energia elétrica (OIEE) 2016 vs. 2017	14
Figura 2 - Dados médios relativos às interrupções no sistema brasileiro	15
Figura 3 – Possíveis situações de faltas no sistema de transmissão	19
Figura 4 - Ocorrência por tipos de faltas	19
Figura 5 - Localizadores de falta	21
Figura 6 - Neurônio Artificial	26
Figura 7 - Funções de ativação	28
Figura 8 - Função de ativação degrau	29
Figura 9 - Função de ativação degrau bipolar	29
Figura 10 - Função de ativação rampa simétrica	30
Figura 11 - Função de ativação logística	31
Figura 12 - Função de ativação tangente hiperbólica	31
Figura 13 - Função de ativação linear	32
Figura 14 - <i>Perceptron</i> Multicamadas (PMC)	33
Figura 15 - Oscilografia de uma corrente de uma linha em falta, definindo os diferentes períodos	39
Figura 16 - Representação do sistema elétrico original	40
Figura 17 - Sistema elétrico analisado	41
Figura 18 - Silhueta de torre da linha de 440kV	42
Figura 19 - Formas de onda de tensão de uma falta fase-fase-terra aplicada a 100 km da barra A	45
Figura 20 - Formas de onda de corrente de uma falta fase-fase-terra aplicada a 100 km da barra A	45
Figura 21 - Arquivo de dados de saída do <i>software</i> ATP	46
Figura 22 – Ciclo utilizado para extrair os fasores dos dados em falta	47
Figura 23 - Fluxograma de execução da primeira etapa do algoritmo de busca da melhor topologia RNA	50
Figura 24 - Fluxograma de execução da segunda etapa do algoritmo de busca da melhor topologia RNA	51
Figura 25 - Esquemático geral do algoritmo generalista de localização de faltas	53
Figura 26 - Esquemático geral do algoritmo de classificação e localização de faltas	56
Figura 27 - Comparação do desempenho das quatro topologias testadas	63

Figura 28 - Relação entre o erro relativo e a distância de faltas na linha de transmissão	64
Figura 29 - Resultados obtidos com a topologia de classificação de faltas quanto às fases envolvidas.....	66

LISTA DE TABELAS

Tabela 1 - Extensão da Rede de Transmissão brasileira 2016 vs. 2019	14
Tabela 2 - Custo médio de interrupção para as categorias de consumo no estado de São Paulo no ano de 2000	16
Tabela 3 - Parâmetros da linha de transmissão de 440kV	43
Tabela 4 - Parâmetros dos equivalentes de geração das barras D e G	43
Tabela 5 - Dados das barras de geração D e G	43
Tabela 6 - Parâmetros fixados para as topologias RNA	49
Tabela 7 - Definição das relações entre % treinamento e % teste	54
Tabela 8 - Representação binária de cada tipo de falta com relação às fases envolvidas	55
Tabela 9 - Características da topologia RNA 1	57
Tabela 10 - Resultados obtidos com a aplicação da topologia RNA 1	58
Tabela 11 - Características da topologia RNA 2	59
Tabela 12 - Resultados obtidos com a aplicação da topologia RNA 2	59
Tabela 13 - Características da topologia RNA 3	60
Tabela 14 - Resultados obtidos com a aplicação da topologia RNA 3	61
Tabela 15 - Características da topologia RNA 4	62
Tabela 16 - Resultados obtidos com a aplicação da topologia RNA 4	62
Tabela 17 - Características da topologia RNA para classificação de faltas	65
Tabela 18 - Características da topologia RNA 5	67
Tabela 19 - Resultados obtidos com a aplicação da topologia RNA 5	67

SUMÁRIO

1 INTRODUÇÃO	12
1.1 Identificação do problema.....	13
1.2 Justificativas	16
1.3 Objetivos.....	17
1.3.1 Objetivo geral.....	17
1.3.2 Objetivos específicos	17
2 FUNDAMENTAÇÃO TEÓRICA	18
2.1 Faltas em Sistemas Elétricos de Potência.....	18
2.2 Localizadores de faltas para linhas de transmissão.....	20
2.2.1 Métodos baseados nos componentes de frequência fundamental	22
2.2.1.1 Métodos que utilizam dados provenientes de um único terminal da LT..	22
2.2.1.2 Métodos que utilizam dados proveniente de mais de um terminal da LT	23
2.3 Redes neurais artificiais	24
2.3.1 Neurônio Artificial.....	26
2.3.2 Função de ativação.....	28
2.3.2.1 Funções de ativação parcialmente diferenciáveis	28
2.3.2.2 Funções de ativação totalmente diferenciáveis	30
2.3.3 Rede <i>Perceptron</i> Multicamadas (PMC)	32
2.3.4 Processo de treinamento do PMC	34
2.3.4.1 Algoritmo de <i>Levenberg-Marquardt</i>	34
2.4 Processamento dos dados	38
2.4.1 Seleção dos dados de entrada	38
2.4.2 Estimação dos fasores fundamentais	39
2.5 Sistema de potência analisado	40
2.5.1 Configuração do sistema de potência.....	40
2.5.2 Modelagem da linha de transmissão	41

2.5.3 Parâmetros do sistema elétrico	42
3 ASPECTOS DA METODOLOGIA UTILIZADA.....	44
3.1 Banco de dados de entrada das redes neurais artificiais	44
3.1.1 Variações nas simulações no sistema de potência	44
3.1.2 Estimação dos fasores fundamentais	46
3.2 Definição da melhor topologia de rede neural artificial.....	48
3.2.1 Algoritmo de escolha da melhor topologia RNA dependendo das entradas utilizadas.....	48
3.3 Localizador de faltas utilizando redes neurais artificiais	51
3.3.1 Algoritmo RNA 1	52
3.3.2 Algoritmo RNA 2	54
4 RESULTADOS E DISCUSSÕES.....	57
4.1 Algoritmo RNA 1	57
4.1.1 Topologia RNA 1.....	57
4.1.2 Topologia RNA 2.....	58
4.1.3 Topologia RNA 3.....	60
4.1.4 Topologia RNA 4.....	61
4.2 Algoritmo RNA 2	64
5 CONCLUSÃO	68
6 PERSPECTIVAS PARA TRABALHOS FUTUROS	69
REFERÊNCIAS.....	70

1 INTRODUÇÃO

Com a grande e constante evolução que a indústria vive, em busca sempre de processos cada vez mais modernos e automatizados, a energia elétrica se torna cada dia mais essencial. Visto por este panorama, a energia elétrica se transforma em um fator importantíssimo para o desenvolvimento econômico de uma nação, bem como para qualidade de vida de seus cidadãos. Deste modo, é de grande importância que os Sistemas Elétricos de Potência (SEP) garantam um fornecimento contínuo, com confiabilidade e a qualidade desejada da energia elétrica. Por outro lado, anomalias que geram a interrupção no fornecimento de energia elétrica podem ser causadas por diversos fatores e nos mais variados elementos que compõem um SEP, dentre estes, as Linhas de Transmissão (LTs) são as mais suscetíveis à ocorrência de faltas elétricas, pois fatores como dimensão física, aumento constante da complexidade operacional e a hostilidade do ambiente na qual se encontram instaladas devem ser levados em consideração.

Descontinuidades no fornecimento de energia elétrica podem gerar prejuízos financeiros aos consumidores das mais variadas áreas, como, indústria, comércio, agronegócio, além do infortúnio causado aos consumidores domésticos, podem acarretar também em penalizações por parte da agência reguladora do setor a Agência Nacional de Energia Elétrica (Aneel) aos responsáveis. Além do mais, podem acarretar prejuízos em virtude de ações legais devido às perdas e danos causados a consumidores grandes ou pequenos, ao mesmo tempo que pode gerar insatisfação por parte destes. A regulamentação do setor e um monitoramento rígido por parte das entidades responsáveis por tal fiscalização, vem fazendo com que empresas concessionárias do setor invistam em equipamentos modernos, que permitam, além de uma proteção mais confiável, um melhor gerenciamento dos sistemas elétricos (SILVA, 2008).

Nas últimas décadas, a utilização de microprocessadores para resolução de problemas relacionados aos SEPs se tornou cada vez mais frequente, e a cada dia sendo mais estudada e analisada por engenheiros e pesquisadores. Grande parte deste desenvolvimento se dá ao grande avanço desta tecnologia, tanto no que se relaciona ao *hardware*, quanto ao que se deve ao *software* (COURY; OLESKOVICZ e GIOVANINI, 2007). Neste segmento pode-se destacar estudos realizados a partir de

algoritmos de sistemas inteligentes, dentro deste grupo daremos um destaque aos que tem como base as Redes Neurais Artificiais (RNAs).

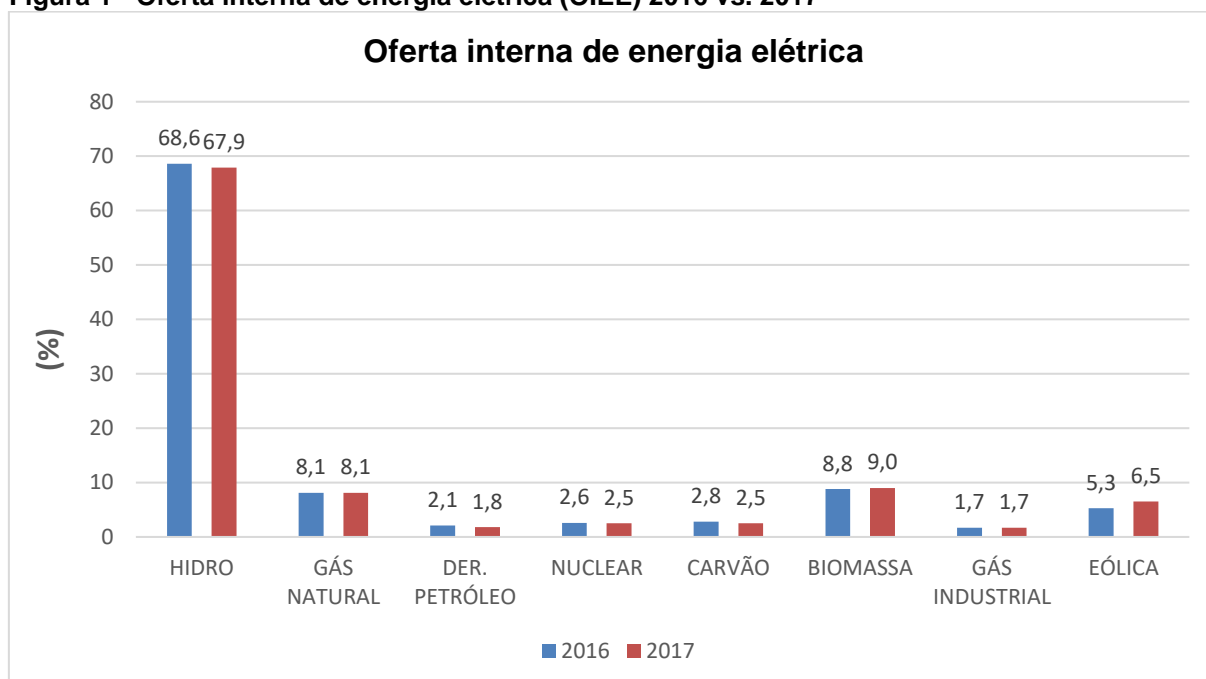
Entre estes estudos se destacam Jorge; Coury e Carvalho (1999), Gracia; Mazón e Zamora (2005) e Abdollahi e Seyedtabaai (2010), que apresentam diferentes metodologias com a finalidade de localizar faltas em linhas de transmissão utilizando algoritmos de redes neurais artificiais.

Este trabalho propõem a aplicação de redes neurais artificiais na localização de faltas em um sistema de transmissão com dois barramentos com ângulo de incidência e resistência de faltas diversificados, utilizando como entrada da RNA componentes das tensões e correntes trifásicas do barramento local e também do barramento remoto em frequência fundamental.

1.1 Identificação do problema

Fatores como a Oferta Interna de Energia Elétrica (OIEE), composta principalmente pela fonte hídrica, Figura 1, e a extensa dimensão territorial brasileira, dão ao sistema elétrico nacional características únicas, pois, na maioria dos casos, os grandes centros de consumo se encontram distantes geograficamente dos grandes centros de geração. No intuito de aproximar esses centros e garantir uma operação mais confiável, o sistema elétrico brasileiro foi em grande parte interligado. Esta interligação recebe o nome de Sistema Interligado Nacional o (SIN).

Figura 1 - Oferta interna de energia elétrica (OIEE) 2016 vs. 2017



Fonte: Ministério de Minas e Energia (2017).

O SIN é composto por uma grande variedade de linhas de transmissão, com características distintas, tanto em níveis de tensão quanto em dimensões físicas e complexidade construtiva.

Segundo levantamento realizado pelo Operador Nacional do Sistema Elétrico (ONS), em 2016 a extensão total da rede de transmissão brasileira foi 134.765 km, com previsão para que em 2019 este valor chegue a 154.748 km, incluindo as linhas que operam em corrente contínua. A Tabela 1 mostra a relação de extensão da rede de transmissão nacional de acordo com os níveis de tensão.

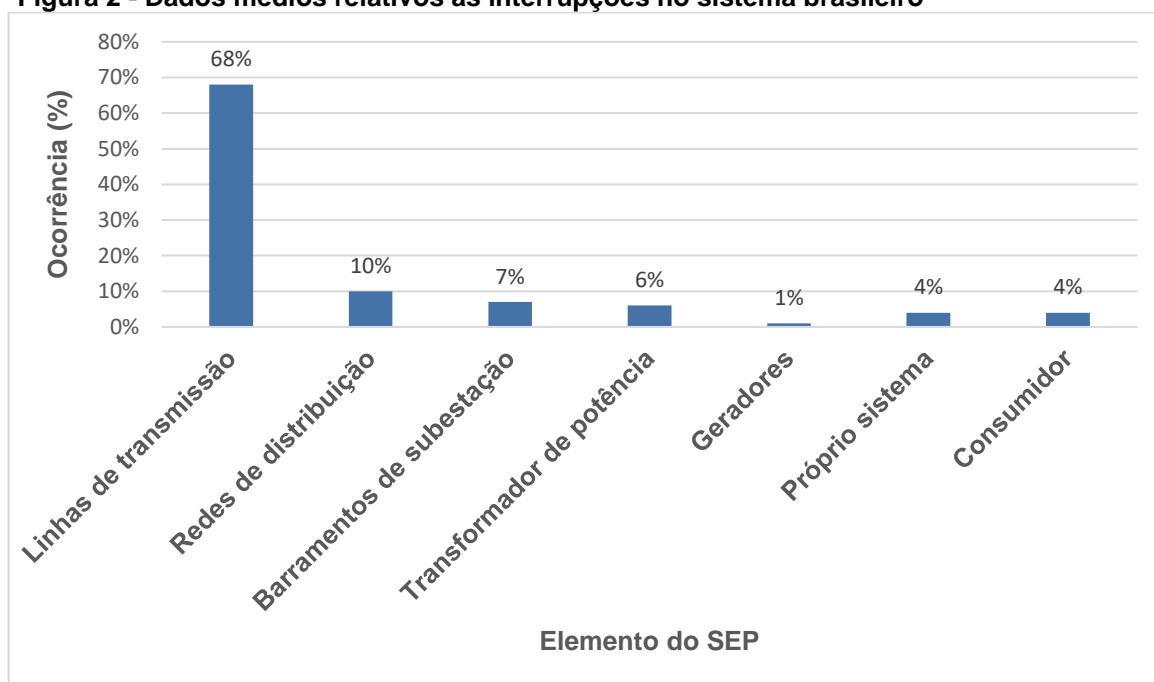
Tabela 1 - Extensão da Rede de Transmissão brasileira 2016 vs. 2019

Níveis de tensão	2016	2019
800 kV CC	0	9.316 km
750 kV	2.683 km	2.683 km
600 kV CC	12.816 km	12.816 km
500 kV	46.630 km	52.817 km
440 kV	6.748 km	6.887 km
345 kV	10.320 km	10.472 km
230 kV	55.568 km	59.757 km
Total	134.765 km	154.748 km

Fonte: Operador Nacional do Sistema Elétrico (2017).

Segundo Mamede Filho e Mamede (2011), o elemento que mais sofre com a ocorrência de faltas em um SEP são justamente os de maiores dimensões e exposição, ou seja, as linhas de transmissão, como pode-se observar na Figura 2. Estas faltas podem ser causadas por fatores como, desgaste de equipamentos, descargas elétricas, quedas de árvores, pela própria operação humana, além de queimadas e fatores diversos. O restabelecimento do fornecimento de energia elétrica não é uma tarefa trivial, pois o serviço deve ser restabelecido rapidamente, e da melhor maneira possível (GOMES, 2011).

Figura 2 - Dados médios relativos às interrupções no sistema brasileiro



Fonte: Adaptado de Mamede Filho e Mamede (2011).

No contexto citado, é de suma importância que as concessionárias responsáveis pelo sistema de transmissão possuam ferramentas que facilitem a localização de faltas, para que haja um restabelecimento rápido, fazendo com que as perdas econômicas não sejam ainda maiores, devido a penalizações pelo tempo de interrupção no fornecimento de energia elétrica e inconformidades nos controles de qualidade do fornecimento regulados pela ANEEL.

1.2 Justificativas

As concessionárias dos sistemas de energia têm como uma de suas principais metas, garantir a qualidade do serviço e assegurar um bom funcionamento de suas instalações e equipamentos elétricos (COURY; OLESKOVICZ; GIOVANINI, 2007). Porém, apesar de grandes esforços por parte das concessionárias, os sistemas elétricos estão sujeitos em tempo integral a incidentes que podem gerar a interrupção no fornecimento de energia elétrica causando grandes prejuízos a consumidores de diversos setores, mas, principalmente do industrial e comercial, além do desconforto causado aos consumidores residenciais e demais consumidores.

A Tabela 2 a seguir expõem o custo médio por kWh, definido por categoria de consumidor, o levantamento foi realizado no estado de São Paulo no ano de 2000.

Tabela 2 - Custo médio de interrupção para as categorias de consumo no estado de São Paulo no ano de 2000

Categorias utilizadas na pesquisa	Custo de interrupção médio (US\$/kWh Interrompido)
Residencial	0,9
Comercial	1,7
Industrial	5,3

Fonte: Adaptado de (MAGALHÃES et al.,2001)

Além dos prejuízos causados aos consumidores, as empresas do setor de energia atuam sob um ambiente regulamentado e fiscalizado pela ANEEL, que através de indicadores da qualidade do fornecimento de energia elétrica pode gerar punições a empresas que atuam fora dos parâmetros regulamentados.

Dado o exposto, é de grande importância para as empresas do setor de transmissão de energia elétrica possuam ferramentas capazes de auxiliar na manutenção do sistema e no restabelecimento do fornecimento de energia elétrica.

Entre estas ferramentas os localizadores de faltas se destacam, pois, além de auxiliar na recuperação e manutenção corretiva do sistema de transmissão, pode também auxiliar no planejamento das atividades de manutenções preventivas através de monitoramentos prévios de ocorrências de faltas transitórias e intermitentes,

apontando pontos fracos no sistema, com potenciais para o ocasionamento de futuras faltas sustentadas.

1.3 Objetivos

Neste tópico serão apresentados os objetivos geral e específico deste trabalho.

1.3.1 Objetivo geral

Estudar a aplicação de redes neurais artificiais ao problema de localização de faltas em um sistema de transmissão de energia elétrica de duas barras.

1.3.2 Objetivos específicos

Para alcançar o objetivo geral, alguns objetivos específicos foram levantados, são eles:

- Realizar de revisão bibliográfica sobre: Localização de faltas em linhas de transmissão; redes neurais artificiais;
- Definir e modelar no *software* ATP do sistema de potência a ser utilizado.
- Simular as situações de faltas no sistema de transmissão.
- Processar os dados de entrada para as topologias de redes neurais artificiais.
- Implementar das arquiteturas RNAs mais adequadas dependendo dos dados de entrada, em plataforma Matlab®.
- Realizar análises dos resultados obtidos.

2 FUNDAMENTAÇÃO TEÓRICA

2.1 Falhas em Sistemas Elétricos de Potência

As faltas em linhas de transmissão de energia elétrica podem ser entendidas como sendo basicamente uma falha total ou parcial na continuidade do fornecimento de eletricidade. As faltas podem ser geradas pelos mais diversos motivos, entre fatores externos ou internos ao sistema (GOMES, 2011). As faltas podem ser definidas em falta momentânea ou transitória, falta sustentada ou permanente e falta intermitente.

A falta momentânea ou transitória é a que se extingue com a atuação da proteção, seguido da tentativa de religamento executada com sucesso, extinguindo a necessidade de reparo imediato no sistema. Segundo dados estatísticos a grande maioria dos defeitos são de origem transitória (ENERGISA, 2012).

A falta sustentada ou permanente é a falta causada por contato permanente ou duradouro, entre fases ou entre fases e a terra, este tipo de incidência geralmente necessita de reparo imediato e provoca interrupções prolongadas para recomposição do sistema (ENERGISA, 2012).

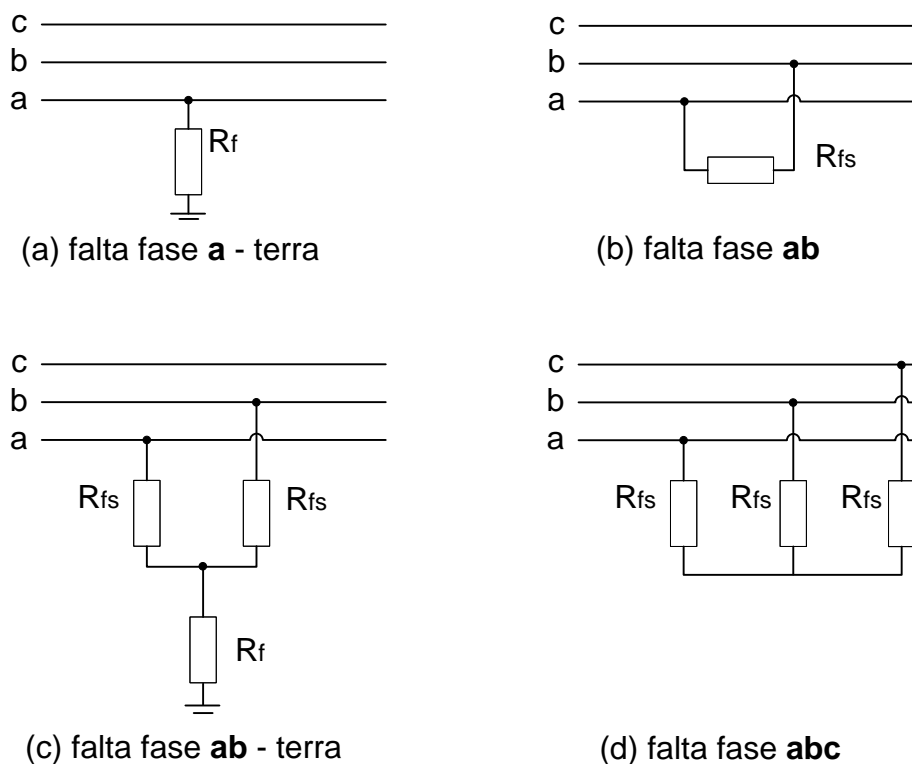
A falta intermitente é a falta que se auto extingue com a atuação da proteção, seguido da tentativa de religamento executada com sucesso, surgindo posteriormente no mesmo local, em intervalos de tempo, causando o mesmo tipo de interrupção (ENERGISA, 2012).

As faltas podem ser caracterizadas ainda de acordo com as fases envolvidas. São elas:

- Algum condutor fase à terra: falta fase-terra;
- Entre dois condutores fase à terra: falta fase-fase-terra;
- Entre dois condutores fase: falta fase-fase;
- Entre os três condutores fase: falta fase-fase-fase ou trifásica.

A Figura 3 ilustra a configuração de cada tipo de falta, sendo a, b e c as fases da linha de transmissão e R_f é a resistência de falta.


Figura 3 – Possíveis situações de faltas no sistema de transmissão



Fonte: Adaptado de (SILVA, 2008).

Segundo dados apresentados em Mamede Filho e Mamede (2011), as faltas que mais ocorrem são as que possuem em sua configuração a ocorrência de um curto entre uma das fases à terra, seguida dos curtos que envolvem duas fases da linha de transmissão e, por último, as que envolvem as três fases da LT, como exposto na Figura 4.

Figura 4 - Ocorrência por tipos de faltas



Fonte: MAMEDE FILHO e MAMEDE, 2011.

2.2 Localizadores de faltas para linhas de transmissão

A função primordial de um localizador digital de faltas, como o próprio nome sugere, é apontar o mais precisamente possível, o local de ocorrência de uma falta em linhas de transmissão, auxiliando para que o sistema de potência seja operado de maneira confiável e econômica. Como mencionado anteriormente, tendo o conhecimento da localização da falta, leva-se um tempo menor para a realização dos serviços de manutenção e reparo, permitindo, assim, a rápida restauração da operação após a ocorrência de uma falta sustentada. Outra aplicação interessante do localizador de faltas é a utilização deste para estimar distâncias de ocorrências de faltas transitórias, permitindo alertar para possíveis pontos fracos no sistema de transmissão, evitando transtornos posteriores de maiores dimensões (SILVA, 2003).

Segundo Girgis; Hart e Peterson (1992), um localizador de faltas pode ser implementado de três maneiras distintas, são elas:

- Como um dispositivo *stand-alone*: ou seja, o localizador possui um *hardware*, de maneira similar a um relé digital, atuando de forma independente como um dispositivo único;
- Como parte de um relé digital de proteção: implementado desta maneira, o localizador de faltas seria considerado como parte acrescida a um relé digital de proteção, ou seja, a localização de faltas seria uma função a mais no próprio relé;
- Como um algoritmo independente: neste caso utiliza-se dados adquiridos por meio de registradores digitais de faltas. Desta forma, o *software* do localizador de faltas pode estar instalado em um dispositivo independente, um *notebook* por exemplo, com base nos dados registrado o *software* é utilizado para localizar a falta.

Vale ressaltar que, como os localizadores de falta utilizam dados registrados digitalmente de modo *off-line* e, por este motivo, não se sujeitam às restrições de processamento impostas aos relés de proteção, já que estes devem operar em modo *on-line*. Trabalhar de modo *off-line* permite aos algoritmos de localização de faltas um aumento considerável de sofisticação e, logo, na precisão relacionada à localização de faltas, o que é de grande importância para linhas de transmissão longas e localizadas em terrenos acidentados, locais estes que poucos

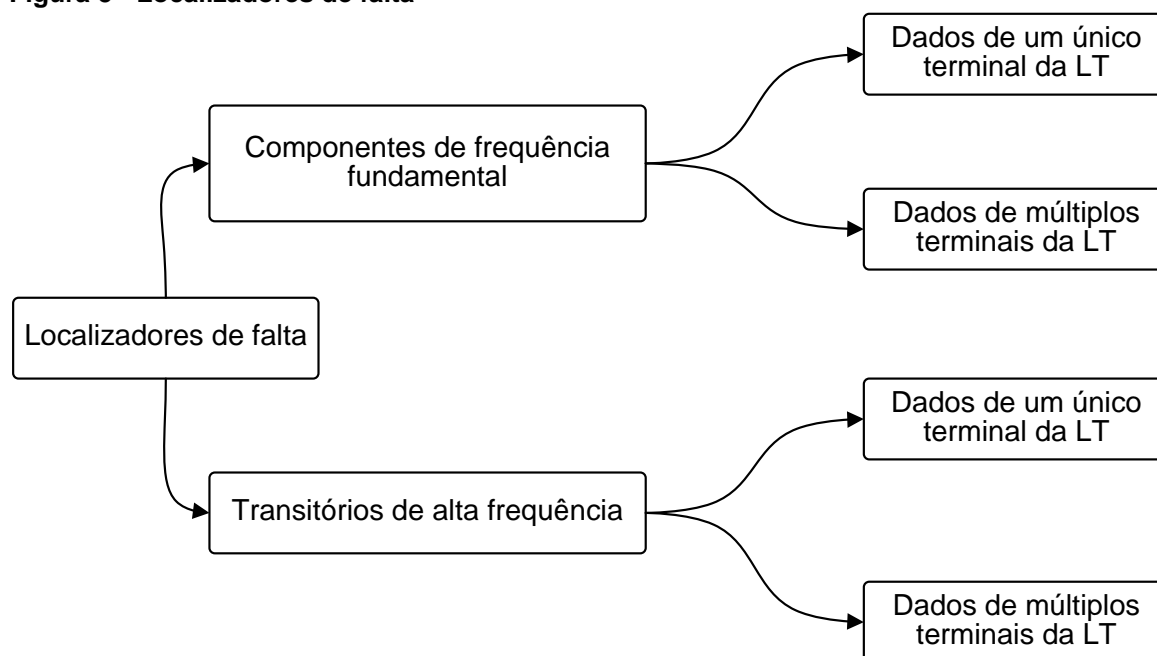
quilômetros de imprecisão podem dificultar consideravelmente a continuidade do fornecimento da energia elétrica (GAUTIER (1996), *apud* SILVA (2008)).

De acordo com Lain e Salama (1996), os localizadores de faltas podem ser classificados em três categorias diferentes, são elas:

- Métodos baseados em componentes de frequência fundamental;
- Métodos baseados nos componentes de alta frequência, ou, como são conhecidos também na literatura, métodos de ondas viajantes;
- Métodos baseados na solução de equações diferenciais do sistema elétrico.

Segundo Silva (2008), as duas primeiras metodologias são as mais utilizadas, porém, neste trabalho serão abordados com mais detalhes os métodos que utilizam dados em frequência fundamental. As duas metodologias mais utilizadas são divididas em mais duas classes, que se referem à origem de obtenção dos dados: (1) dados provenientes de um único terminal da linha de transmissão, (2) dados provenientes de múltiplos terminais da linha de transmissão. A Figura 5 mostra uma visão geral dos localizadores de falta mais tradicionais, e a relação de obtenção dos dados.

Figura 5 - Localizadores de falta



Fonte: Autoria própria.

Os métodos de localização de faltas apresentados serão abordados com mais detalhes nos próximos tópicos.

2.2.1 Métodos baseados nos componentes de frequência fundamental

Primeiramente, serão abordados alguns dos principais métodos que utilizam componentes de frequência fundamental com dados provenientes de somente um terminal da linha de transmissão, e, posteriormente, serão abordados alguns métodos que utilizam dados provenientes de múltiplos terminais da linha de transmissão.

2.2.1.1 Métodos que utilizam dados provenientes de um único terminal da LT

Grande parte dos métodos de localização de faltas que utilizam dados em frequência fundamental partem do princípio da estimação da impedância aparente da linha de transmissão durante o período de falta. Esta impedância é geralmente obtida a partir dos parâmetros da linha de transmissão e dos fasores fundamentais, de tensão e corrente, obtidos por registradores digitais de falta, em um único terminal da LT. E mais recentemente são empregados também sistemas inteligentes para o desenvolvimento de métodos de localização de faltas.

Lima (2013) propôs um método de localização de faltas baseado na impedância aparente, utilizando dados de apenas um terminal a partir de equacionamentos desenvolvidos em componentes simétricas. O método desenvolvido utiliza como dados de entrada componentes fundamentais dos valores registrados de corrente e tensão do terminal local e a potência de curto circuito do circuito equivalente conectado ao terminal remoto. Para realização dos cálculos considerou-se: o sistema equilibrado, resistência de falta constante e que a resistência de falta é a mesma para todas as fases em falta.

Jorge, Coury e Carvalho (1999) apresentaram um algoritmo de localização de faltas em linhas de transmissão utilizando redes neurais artificiais do tipo *Perceptron* Multicamadas (PMC). Para a aplicação do método deve-se conhecer os valores de tensão e correntes pré e pós falta em um terminal da LT. Neste método utilizou-se uma topologia de RNA para cada tipo de falta, com o intuito de simplificar os cálculos computacionais e a representação do problema.

Já Abdollahi e Seyedtabaie (2010) propuseram uma comparação de duas metodologias distintas, na primeira delas foram utilizados dados de tensão e corrente do terminal local da linha de transmissão em frequência fundamental filtrados

utilizando a Transformada Discreta de Fourier (TDF). Esses dados serviriam de entrada a topologias de RNA para classificação e localização dos pontos de faltas. O segundo método testado utiliza componentes de alta frequência em conjunto com a transformada *Wavelet*. Ambos métodos de localização de faltas trabalham em conjunto com um método de classificação de falta referente às fases envolvidas.

2.2.1.2 Métodos que utilizam dados proveniente de mais de um terminal da LT

Os métodos de localização de faltas que utilizam dados em frequência fundamental, advindos de ambos terminais da linha de transmissão, foram criados no intuito de melhorar a precisão dos algoritmos. Na grande maioria dos casos, estas técnicas não dependem da impedância da falta. Em contrapartida, faz-se necessário a utilização de um meio de comunicação entre os terminais da linha, bem como, a determinação de um referencial comum para os dados registrados em ambos terminais da linha de transmissão.

Di santo; Pereira e Zanetta Jr (2011) propuseram um método de localização de faltas para linhas de transmissão continuamente transpostas e com múltiplas derivações. O método utiliza como entrada os fasores de tensão e corrente pré e pós-falta medidos em regime permanente, obtidos no terminal local e remoto. As respostas obtidas com a aplicação do método são o trecho em que a falta ocorreu, a distância da falta e a resistência de falta. O método proposto tem como característica um processo de varredura da rede, num primeiro momento a falta é localizada dentro de cada um dos segmentos da linha, onde utiliza-se uma função objetivo para minimizar a diferença entre as tensões e correntes medidas e calculadas nos terminais, tanto local quanto remoto. O algoritmo compara o erro obtido pela função objetivo entre cada segmento, eliminando assim o segmento que obtiver o maior erro.

Raybolt (2011), utiliza um método de localização de faltas para linhas de transmissão em circuito duplo, utilizando sinais de tensão e corrente originários de ambos terminais da LT para servirem de entradas para topologias de redes neurais artificiais, em módulos de classificação e módulos de localização de faltas. O método avalia os principais fatores que podem influenciar algoritmos convencionais a errar na estimativa de distância de faltas em linhas de transmissão, com destaque para fatores como, distância de falta, ângulo de incidência de falta, resistência de falta, tipo de falta e o efeito do acoplamento mútuo existente entre linhas paralelas.

Oliveira (2016) avaliou o desempenho de um algoritmo de detecção, classificação e localização de faltas em sistemas de transmissão com compensação série. Foram utilizados para os testes algoritmos baseados em redes neurais artificiais, utilizando como entrada os sinais trifásicos de tensão e corrente pós-falta registrados em ambos terminais da linha de transmissão. Foram avaliados ainda, os efeitos que causam dificuldades para os sistemas convencionais de proteção de distância a partir do ponto de vista da compensação série. Os principais efeitos observados foram a ressonância subsíncrona da componente DC e da ação da proteção de sobretensão de capacitores série na precisão da medição da impedância nos relés convencionais e os impactos que estes efeitos causam no desempenho das topologias de redes neurais.

2.3 Redes neurais artificiais

As redes neurais artificiais (RNAs) são modelos computacionais que se baseiam nos princípios de funcionamento do sistema nervoso biológico. As RNAs podem ser implementadas em dispositivos eletrônicos e são compostas por unidades artificiais de processamento. As quais são comumente chamadas de neurônios artificiais, em que cada neurônio representa uma relação específica de entrada/saída (VON ZUBEN; CASTRO).

Algumas das principais características das RNAs são descritas por Silva; Spatti e Flauzino (2010).

- **Adaptação por experiência:** A partir da apresentação sucessiva de dados que representam determinado sistema, a rede consegue obter conhecimento através do ajuste de seus parâmetros, normalmente os pesos sinápticos.
- **Capacidade de aprendizado:** A partir de um processo de treinamento, a rede é capaz de relacionar diversas variáveis existentes, referentes à aplicação.
- **Habilidade de generalização:** Após o processo de treinamento a rede é capaz de associar de forma generalista o conhecimento obtido, possibilitando estimar soluções que até então eram desconhecidas.
- **Organização de dados:** A rede é capaz de separar grupos de dados a partir de características intrínsecas de um grupo de dados maior.
- **Tolerância a falhas:** O grande número de interconexões entre as unidades de processamento, permite que a rede se torne tolerante a falhas quando parte de

sua estrutura interna é sensivelmente comprometida, o que evidencia a robustez das redes neurais artificiais.

- **Armazenamento distribuído:** Devido a distribuição de conhecimento entre as sinapses de suas unidades de processamento interna sobre um determinado sistema, as RNAs se mantem robustas mesmo perante a inoperação de alguns neurônios artificiais.
- **Facilidade de prototipagem:** A maioria das arquiteturas neurais, após o seu processo de treinamento podem ser facilmente implementadas em *software* ou em *hardware*.

Devido a sua grande versatilidade, as RNAs podem ser aplicadas em diversos problemas relacionados as áreas das engenharias e ciências modernas, dentre estas aplicações são descritas por Silva; Spatti e Flauzino (2010):

- **Aproximador universal de funções:** Utiliza-se RNAs para relacionar o funcionamento real de um determinado processo a partir de um conjunto limitado de dados representativos. As aplicações são diversas e são mais comumente utilizadas em problemas que em métodos convencionais são de difíceis modelagem.
- **Controle de processos:** Consiste em aplicar RNAs no controle de processo, de modo a garantir os requisitos mínimos de qualidade, eficiência e segurança de processos. É muito aplicado nas áreas de controle de robótica, aeronaves elevadores, satélites, etc.
- **Reconhecimento e/ou classificação de padrões:** Esta aplicação consiste em basicamente associar um padrão de entrada para uma das classes previamente definidas de saídas, é frequentemente utilizado em reconhecimento de voz, imagens, escrita, entre outros.
- **Agrupamento de dados:** Esta aplicação consiste em identificar e detectar similaridades e particularidades entre diversos padrões de entrada com o objetivo de possibilitar seu agrupamento.
- **Sistemas de previsão:** Consiste na aplicação da RNA para estimar o comportamento de determinado sistema, a partir de valores previamente observados dentro de seu domínio; esta aplicação é mais utilizada nas áreas do mercado financeiro, previsões climáticas, etc.
- **Otimização de sistemas:** Consiste em minimizar ou maximizar uma função objetivo, obedecendo critérios impostos para o correto mapeamento do


problema, entre as utilizações estão problemas de otimização restrita, programação dinâmica, entre outros.

- **Memórias associativas:** Utilizado para recuperar padrões de sistemas que estejam com seus elementos imprecisos ou incertos, aplica-se principalmente em processamento de imagens, transmissão de sinais, etc.

2.3.1 Neurônio Artificial

O neurônio é uma unidade de processamento fundamental para o funcionamento operacional de uma rede neural. O modelo de um neurônio artificial é que forma a base para o projeto de redes neurais artificiais (HAYKIN, 2001). Deve-se ressaltar que os modelos computacionais são versões bem simplificadas de um neurônio biológico. Os modelos de neurônios artificiais utilizados em redes neurais artificiais são não-lineares e fornecem saídas tipicamente contínuas, além de realizar funções simples, como coletar os sinais disponíveis em suas entradas, associá-los de acordo com sua função de operação e produzir uma resposta, levando em consideração sua função de ativação inerente (SILVA; SPATTI e FLAUZINO, 2010). A Figura 6 ilustra um modelo de neurônio artificial.

Figura 6 - Neurônio Artificial



Fonte: Autoria própria.

Observando a Figura 6, pode-se perceber que o neurônio artificial é composto por basicamente sete elementos básicos, como (SILVA; SPATTI e FLAUZINO, 2010):

- 1) Sinais de entrada $\{x_1, x_2, \dots, x_n\}$, são dados advindos do meio externo que tem representatividade no problema estudado em específico, variáveis usualmente

normalizadas (valores entre -1 e 1), com a finalidade de diminuir o esforço computacional;

- 2) Pesos sinápticos $\{W_1, W_2, \dots, W_n\}$, são valores responsáveis por ponderar cada dado de entrada da rede, ou seja, atribuir a cada dado a sua importância com relação a funcionalidade de seu respectivo neurônio;
- 3) Combinador linear $\{\Sigma\}$, tem como função agrupar os dados de entrada ponderados por seus respectivos pesos sinápticos para produzir o potencial de ativação;
- 4) Limiar de ativação $\{\theta\}$, é um valor responsável por delimitar o potencial de ativação mínimo para o disparo do potencial de ativação em direção a saída do neurônio;
- 5) Potencial de ativação $\{u\}$, é a diferença produzida entre combinador linear e o potencial de ativação, se $u \geq \theta$ então o neurônio produz potencial excitatório, caso contrário o neurônio produzira potencial inibitório;
- 6) Função de ativação $\{g\}$, tem por objetivo limitar a saída do neurônio, normalmente entre valores mínimo de -1 e máximo 1;
- 7) Sinal de saída $\{y\}$, representa os valores de saídas dos neurônios para determinados dados de entrada, pode representar a saída da rede, ou podem servir de dados de entradas a outros neurônios interligados em sequência.

O potencial de ativação de um neurônio artificial pode ser representado pela equação (1) e a saída do neurônio é representada pela equação (2).

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

$$y = g(u) \quad (2)$$

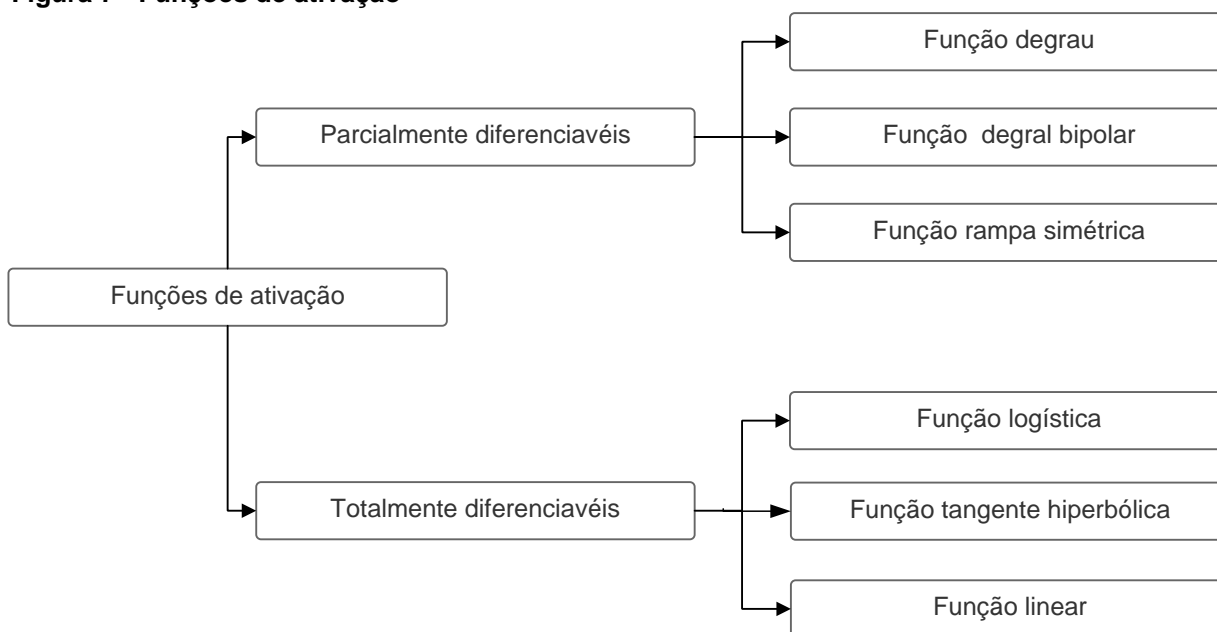
Desta forma, resume-se o princípio de funcionamento de um neurônio artificial da seguinte forma, segundo Silva, Spatti e Flauzino (2010).

- Apresentação do conjunto de entrada ao neurônio;
- Multiplicação de cada dado de entrada por seu respectivo peso sináptico;
- Obtenção do potencial de ativação, como na equação (1);
- Aplicação da função de ativação;
- Saída do neurônio definida a partir da aplicação da função de ativação em relação ao potencial de ativação, como mostra a equação (2).

2.3.2 Função de ativação

Segundo Silva; Spatti e Flauzino (2010), as funções de ativação podem ser divididas em dois grupos principais, como ilustra a Figura 7.

Figura 7 - Funções de ativação



Fonte: Autoria própria.

2.3.2.1 Funções de ativação parcialmente diferenciáveis


As funções de ativação parcialmente diferenciáveis são definidas desta forma por possuírem pontos cuja derivada de primeira ordem não existe. Em seguida serão apresentadas as principais funções de ativação parcialmente diferenciáveis.

A função degrau: tem por característica que os valores produzidos em suas saídas sempre assumiram valores unitários positivos quando o potencial de ativação do neurônio for maior ou igual a zero. Caso o potencial de ativação seja inferior a zero, a saída assumirá valores nulos, como (Silva, Spatti e Flauzino, 2010):

$$g(u) = \begin{cases} 1, & \text{se } (u \geq 0) \\ 0, & \text{se } (u < 0) \end{cases} \quad (3)$$

A representação gráfica da função de ativação degrau é mostrada na Figura 8.

Figura 8 - Função de ativação degrau




Fonte: Silva; Spatti e Flauzino (2010).

A função de ativação degrau bipolar: assumirá em sua saída valores unitários positivos quando o potencial de ativação do neurônio for superior a zero, valor nulo quando o potencial de ativação for nulo também e negativos unitários quando o potencial de ativação for menor que zero (Silva, Spatti e Flauzino, 2010). A representação matemática desta função pode ser observada na equação (4).

$$g(u) = \begin{cases} 1, & \text{se } (u > 0) \\ 0, & \text{se } (u = 0) \\ -1, & \text{se } (u < 0) \end{cases} \quad (4)$$

A representação gráfica da função de ativação degrau é mostrada na Figura 9.

Figura 9 - Função de ativação degrau bipolar



Fonte: Silva; Spatti e Flauzino (2010).

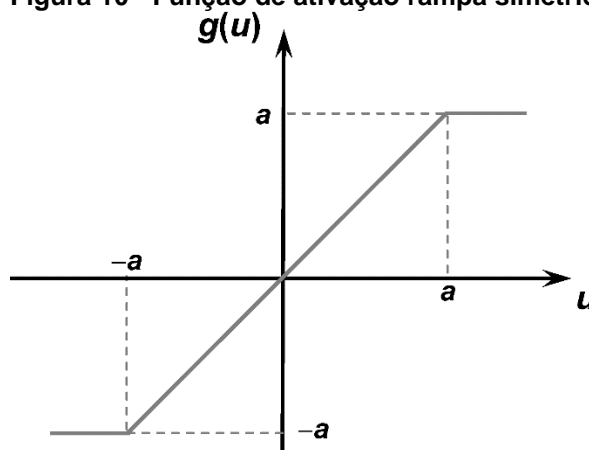
A última função de ativação parcialmente diferenciável é a rampa simétrica: onde neste caso, as saídas da função de ativação são os próprios valores assumidos pelo potencial de ativação quando estes estão definidos no intervalo $[-a, a]$. Caso

contrário, os valores são definidos como sendo os valores limites (Silva, Spatti e Flauzino, 2010). A representação matemática pode ser observada na equação (5).

$$g(u) = \begin{cases} a, & \text{se } (u > a) \\ u, & \text{se } (-a \leq u \leq a) \\ -a, & \text{se } (u < -a) \end{cases} \quad (5)$$

A representação gráfica da função de ativação degrau é mostrada na Figura 10.

Figura 10 - Função de ativação rampa simétrica



Fonte: Silva; Spatti e Flauzino (2010).

2.3.2.2 Funções de ativação totalmente diferenciáveis

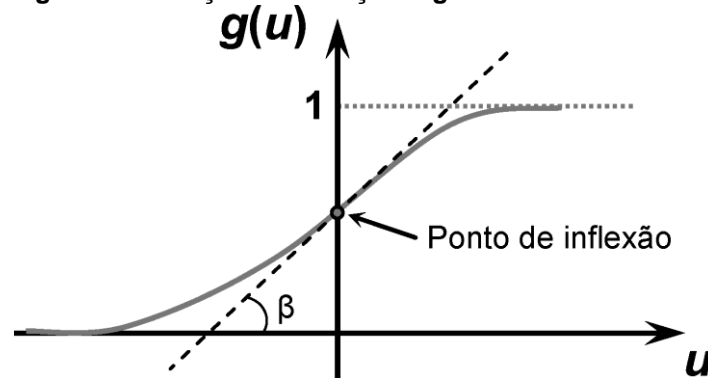
As funções de ativação totalmente diferenciáveis podem ser definidas como sendo aqueles que a derivada de primeira ordem existe e é conhecida para todos os pontos de seu domínio. As principais funções de ativação totalmente diferenciáveis serão descritas a seguir.

A função logística: tem por característica que sua saída assumirá sempre valores reais entre zero e um (0 e 1) (COPPIN, 2012). A expressão matemática que representa a função logística está descrita na equação (6).

$$g(u) = \frac{1}{1 + e^{-\beta u}} \quad (6)$$

Onde β é uma constante real relacionada a inclinação da função logística ao seu ponto de inflexão, como mostra a Figura 11.

Figura 11 - Função de ativação logística




Fonte: Silva; Spatti e Flauzino (2010).

A função de ativação tangente hiperbólica: possui como saída valores reais entre menos um e um (-1 e 1) (COPPIN, 2012). A expressão que representa esta função de ativação é a equação (7).

$$g(u) = \frac{1 - e^{-\beta u}}{1 + e^{-\beta u}} \quad (7)$$

A curva que representa a função de ativação tangente hiperbólica é apresentada na Figura 12.

Figura 12 - Função de ativação tangente hiperbólica




Fonte: Silva; Spatti e Flauzino (2010).

A função de ativação linear ou identidade, gera valores idênticos aos do potencial de ativação, a expressão que representa matematicamente esta função é a equação (8).

$$g(u) = u \quad (8)$$

A representação gráfica da função de ativação linear é mostrada na Figura 13.

Figura 13 - Função de ativação linear
 $g(u)$




Fonte: Silva; Spatti e Flauzino (2010).

2.3.3 Rede *Perceptron* Multicamadas (PMC)

Os algoritmos de redes neurais PMC são compostos por um conjunto de sensores responsáveis por receber os dados de entrada da rede, além de ser caracterizada pela presença de pelo menos uma camada de neurônio intermediária (escondida) entre a camada de entrada e a respectiva camada de saída, por consequência disto os PMC possuem ao menos duas camadas de neurônios. Uma característica muito importante do PMC são suas grandes possibilidades de aplicações, entre elas a classificação de padrões e aproximação de funções, entre outros (HAYKIN, 2001).

O PMC pertence a arquitetura *feedforward* de múltiplas camadas, ou seja, o sentido do fluxo de informações é sempre da entrada para a saída da rede, cujo treinamento é realizado de forma supervisionada (HAYKIN, 2001). Como ilustra a Figura 14.

Figura 14 - Perceptron Multicamadas (PMC)



Fonte: Autoria própria.

Como pode ser observado na Figura 14 cada uma das entradas que representam dados advindos de um sistema em estudo será propagada em direção a camada neural de saída (*feedforward*). Neste caso, cada camada subsequente receberá como entrada a saída da camada anterior, ou seja, para a rede apresentada na Figura 14, a entrada dos neurônios da camada escondida dois será a saída dos neurônios da camada escondida um, e a saída da camada escondida dois será a entrada dos neurônios da camada neural de saída.

O número de neurônios em cada camada, ou a quantidade de camadas que irão compor uma rede neural, não está relacionada a quantidade de dados de entrada da rede. Mas dependem da classe de problema a ser resolvido pelo PMC, a disposição espacial das amostras de treinamento, além, dos valores iniciais dos parâmetros de treinamentos como matrizes de pesos sinápticos (SILVA; SPATTI; FLAUZINO, 2010).

Como mencionado anteriormente, o processo de treinamento do PMC é realizado de forma supervisionada, ou seja, o ajuste dos pesos sinápticos de cada neurônio da rede é feito de modo que para cada dado de entrada se obtém uma saída desejada. Este algoritmo utilizado para o treinamento do PMC é chamado de

backpropagation ou algoritmo de retropropagação de erro (RUMELHART; HINTON; WILLIAMS, 1986).

2.3.4 Processo de treinamento do PMC

O processo de treinamento através do algoritmo de retropropagação de erro (*backpropagation*) consiste em dois passos através das camadas neurais da rede, sendo, um passo para frente (propagação), e um passo para trás, chamado de retropropagação. No passo adiante, dados são entregues à camada de entrada da rede neural, e seu efeito se propaga através da rede camada por camada. Por consequência, um grupo de saída é produzido na camada de saída da rede, onde durante este passo, os pesos sinápticos da RNA são todos fixos. No passo para trás ou retropropagação, os pesos sinápticos são ajustados de acordo com a teoria de correção de erros MSE (*Mean Squared Error*), ou seja, a resposta da rede é subtraída de uma resposta “alvo” desejada, de modo a diminuir o sinal de erro. Este sinal é direcionado para trás através de toda rede neural na contração das conexões sinápticas. Os pesos sinápticos são ajustados de modo a fazer com que a resposta da rede seja o mais próximo possível da resposta desejada (HAYKIN, 2001). Portanto, para aplicação do PMC são necessários três grupos de dados, um primeiro grupo contendo as entradas que representam um problema específico, o segundo são as respostas desejadas (alvo), referente a cada entrada, e, por fim, um grupo de entradas com respostas desconhecidas para validação da rede.

O algoritmo *backpropagation* possui algumas versões otimizadas para reduzir o esforço computacional. Neste trabalho resolveu-se por utilizar o algoritmo *Levenberg-Marquardt* que é baseado no método *backpropagation*. Devido ao esforço computacional reduzido por conta de mudanças algébricas entre o algoritmo *backpropagation* e o algoritmo *Levenberg-Marquardt*, este se torna geralmente de 10 a 100 vezes mais rápido que o *backpropagation* (HAGAN; MENHAJ, 1994).

2.3.4.1 Algoritmo de *Levenberg-Marquardt*

O algoritmo *backpropagation* previamente discutido possui apenas derivadas de primeira ordem e utiliza-se do método gradiente descendente como método de aproximação do mínimo da função erro. Por outro lado, o algoritmo de

Levenberg-Marquardt (LM) faz uso das informações sobre a derivada de segunda ordem da função custo e aproximação do mínimo da função erro utilizando o método iterativo de *Gauss-Newton* (OLIVEIRA, 2016).

Um exemplo de aplicação do algoritmo de *Levenberg-Marquardt* será apresentado. O objetivo é encontrar um ponto mínimo para determinada função $F(x)$ qualquer. O exemplo tem como base o trabalho de (MAFFRA e GATTASS, 2008).

O método de *Levenberg-Marquardt* é iterativo, como os métodos de *Newton* e *Gauss-Newton*. Deste modo, dado um ponto inicial x_0 , o algoritmo tende a gerar uma série de vetores x_1, x_2, \dots, x_n que há de se esperar que irá convergir para x^* , ou seja, um mínimo local para uma função em estudo.

O método de *Newton* baseia-se no fato de que se x^* é um ponto crítico da função F , logo $F'(x^*) = 0$. Quando se expande F em uma série de *Taylor* tem-se a equação (9).

$$F(x + h) = F(x) + F'(x)h + O(\|h\|)^2 \quad (9)$$

Quando os valores de $\|h\|$ são demasiadamente pequenos, desconsidera este valor e obtém-se a representação matemática da equação (10):

$$F'(x + h) = F'(x) + F''(x)h \quad (10)$$

Sabe-se que: $F'(x^*) = 0$ e a equação (19), pode-se obter o valor do sentido de busca de h_n no método de *Newton*, para tal, deve-se resolver o sistema exposto na equação (11):

$$Hh_n = -F'(x) \quad (11)$$

$$\text{Onde, } H = F''(x) = H(x) = \begin{bmatrix} \frac{\partial^2 f}{\partial x_1^2}(x) & \frac{\partial^2 f}{\partial x_1 \partial x_2}(x) & \dots & \frac{\partial^2 f}{\partial x_1 \partial x_n}(x) \\ \frac{\partial^2 f}{\partial x_2 \partial x_1}(x) & \frac{\partial^2 f}{\partial x_2^2}(x) & \dots & \frac{\partial^2 f}{\partial x_2 \partial x_n}(x) \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial^2 f}{\partial x_n \partial x_1}(x) & \frac{\partial^2 f}{\partial x_n \partial x_2}(x) & \dots & \frac{\partial^2 f}{\partial x_n^2}(x) \end{bmatrix},$$

Onde H é conhecida como matriz Hessiana.

Em alguns casos a matriz Hessiana pode ser demasiadamente complexa. No intuito de minimizar este problema, podem ser utilizados métodos propostos para aproximações para a matriz Hessiana, tais métodos são conhecidos como *Quasi-Newton*, dentre eles estão os métodos de *Gauss-Newton* e *Levenberg-Marquardt*.

O método de *Gauss-Newton* baseia-se nos valores de componentes aproximados de f em um vizinhança x . Desta forma, encontra-se a equação (12) utilizando a expansão em série de *Taylor*.

$$f(x + h) \approx l(h) \equiv f(x) + j(x)h \quad (12)$$

Onde $J \in \mathbf{R}^{m \times n}$ é a matriz Jacobiana, ou seja, é a matriz composta pelas derivadas parciais de primeira ordem de elemento da função vetorial f .

Substitui-se (12) em (13) para obter a equação (14) a seguir:

$$F(x) = \frac{1}{2} f(x)^T f(x) \quad (13)$$

$$F(x + h) \approx L(h) \frac{1}{2} l(h)^T l(h) \quad (14)$$

Onde $f = f(x)$ e $j = j(x)$.

É notado que o gradiente e a matriz Hessiana de L são representados pela equação (15).

$$L'(h) = J^T f + J^T J(h) \text{ e } L''(h) = J^T J \quad (15)$$

Desta forma, a direção do passo calculada utilizando o método de *Gauss-Newton* é explicitada na equação (16).

$$(J^T J)h_{gn} = -J^T f \quad (16)$$

Após encontrar-se o valor de h_{gn} tem-se que a próxima iteração do método de *Gauss-Newton* é representada por:

$$x \leftarrow x + h_{gn}$$

Mesmo com a maior simplicidade de resolver a matriz Hessiana utilizando o método de *Gauss-Newton*, percebe-se a existência do mesmo problema encontrado anteriormente no método de *Newton*, ou seja, não se pode garantir a existência da inversa dessa matriz, que é necessária para o cálculo de h_{gn} .

Para resolver este problema, o método de *Levenberg-Marquardt* propõe somar uma porção μI à matriz Hessiana aproximada pelo método de *Gauss-Newton*, onde I é a matriz identidade e μ é valor escalar denominado parâmetro de *damping*. Com esta modificação, o sentido do passo do método de *Levenberg-Marquardt* pode ser encontrado pela equação (17):

$$(J^T J + \mu I)h_{lm} = -g \quad (17)$$

Onde $g = J^T f$ e $\mu \geq 0$.

O parâmetro de *damping* μ causa diferentes comportamentos do método, sendo que:

- Para todo $\mu > 0$ a matriz de coeficientes $(J^T J + \mu I)$ é positiva definida, implicando que h_{lm} é uma direção de descida;
- Para grandes valores de μ tem-se: $h_{lm} = -\frac{1}{\mu} g = -\frac{1}{\mu} F'(x)$, que representa um passo pequeno na direção máxima de descida;
- Para valores muito pequenos de μ , tem-se que $h_{lm} \approx h_{gn}$, o que é um ponto positivo do método, pois, nos estágios finais das iterações quando x se aproxima de x^* , o método de *Levenberg-Marquardt* garante convergência quadrática.

Alguns fatores de influência do *damping* μ , como direção e tamanho do passo, faz com que o método de *Levenberg-Marquardt* não necessite de uma busca linear para encontrar o tamanho ótimo do passo a ser dado em cada iteração, aumentando assim a velocidade de processamento. O valor inicial μ pode ter relação com o tamanho dos elementos da matriz Hessiana aproximada, isto é, μ depende da dimensão dos elementos de $A_0 = J(x_0)^T J(x_0)$, desta forma, tem-se:

$$\mu_0 = \tau \max_i \{a_{ii}^{(0)}\} \quad (18)$$

Onde τ é escolhido pelo usuário.

Em casos específicos das quais o valor de x_0 é uma aproximação boa de x^* pode ser adotado $\tau = 10^{-6}$, caso contrário recomenda-se $\tau = 1$.

O valor de μ pode ser variado durante as iterações, isto acontece em função de outro parâmetro ρ , conhecido também como *gain ratio*, representado pela equação (19):

$$\rho = \frac{F(x) - F(x + h_{lm})}{L(0) - L(h_{lm})} \quad (19)$$

Onde $L(0) - L(h_{lm})$ é ganho obtido por meio do modelo linear, assim:

$$L(0) - L(h_{lm}) = 1/2 h_{lm}^T (\mu h_{lm} - g) \quad (20)$$

Se o valor de ρ for suficientemente grande, isto torna-se um indicativo de que $L(h_{lm})$ é uma aproximação boa para $F(x + h_{lm})$ e pode-se diminuir o valor de μ de forma que o próximo passo do algoritmo de *Levenberg-Marquardt* esteja próximo do passo de *Gauss-Newton*. Caso ρ seja pequeno, implica que $L(h_{lm})$ seja uma aproximação ruim e é necessário acrescentar o valor de μ para buscar a direção máxima de descida e reduzir o tamanho do passo.

Para a alteração do valor μ a seguinte regra deve ser utilizada: caso $\rho > 0$, $v = 2$. Caso contrário $\mu = \mu v$ e $v = 2v$, onde v é inicializado com valor igual a 2.

Os critérios de parada, também chamados de critérios de convergência do método são:

- Norma infinita do gradiente seja menor que um valor pré-definido (ε_1), ou seja, $g_\infty \leq \varepsilon_1$.
- Variação muito pequena no valor de x , ou seja, $\|x_{new} - x\| \leq \varepsilon_2(|x| + \varepsilon_2)$.
- Determinação de um número máximo de iterações, ou seja, $k \geq k_{máx}$.

2.4 Processamento dos dados

2.4.1 Seleção dos dados de entrada

Quando se trabalha com redes neurais artificiais, a escolha das entradas e saídas adequadas ao problema é de suma importância para que a RNA consiga reconhecer os padrões da aplicação em questão.

Geralmente os algoritmos de localização de faltas utilizam como dados de entrada amostras de tensão e corrente medidos no terminal local, ou terminal remoto ou ainda em ambos terminais no instante da falta em registradores. Quando se detecta uma ocorrência de falta pelos relés, os valores armazenados na memória são congelados e utilizados na estimação da distância da falta (RAYBOLT, 2011).

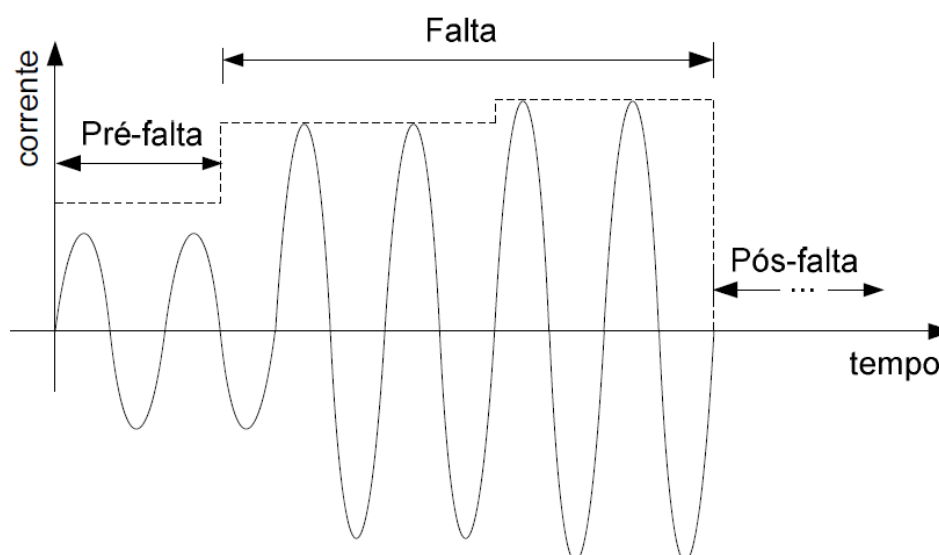
Os dados registrados numa situação de faltas em linhas de transmissão podem ser distinguidos em três, levando-se em conta os intervalos de tempo, são eles (RAYBOLT, 2011):

- Intervalo pré-falta: intervalo desde o início da aquisição até o momento da falta;
- Intervalo de falta: período desde o momento do incidente até que o mesmo seja extinguido;
- Intervalo pós-falta: período que se inicia no momento da extinção da falta.

A Figura 15 ilustra um registro oscilográfico de uma situação de falta, onde tem-se cada etapa acima descrita. Após a determinação dos períodos que serão utilizados pelo método e tratamento desejado de dados é possível aplicar os dados registrados como entrada para as topologias RNA. Para este trabalho optou-se por

utilizar os fasores trifásicos em 60Hz de tensão e corrente registrados no terminal local e também no terminal remoto.

Figura 15 - Oscilografia de uma corrente de uma linha em falta, definindo os diferentes períodos



Fonte: RAYBOLT, 2011.

2.4.2 Estimação dos fasores fundamentais

Os valores de tensões e correntes podem frequentemente conter componentes CC (corrente contínua) com amplitude inicial e constante de tempo desconhecidas, ou transitórios de variadas frequências. Portanto, é de grande importância extrair precisamente os fasores fundamentais de modo que este problema não interfira na localização da falta (OLIVEIRA, 2016).

O método matemático utilizado com mais frequência para extração dos fasores fundamentais é a Transformada Discreta de *Fourier*. A equação (21) mostra a forma geral da equação do filtro de *Fourier* para a estimação fasorial (OLIVEIRA, 2016).

$$V^k = \frac{2}{N} \times \sum_{n=1}^N v_n \times \left[\cos\left(\frac{2\pi nk}{N}\right) + j \sin\left(\frac{2\pi nk}{N}\right) \right] \quad (21)$$

Onde:

V^k é fasor representativo;

k representa a ordem do harmônico considerado ($k = 1, 2, 3, \dots$);

N é o número de amostras por ciclo;

v_n representa a n -ésima amostra dentro da janela de observação escolhida para o algoritmo, onde $n = 1, 2, \dots, N$.


2.5 Sistema de potência analisado

Com o objetivo de treinar e validar as redes neurais artificiais, aplicadas como localizadores de faltas para linhas de transmissão, utilizou-se a simulação de um sistema de transmissão em condição de falta. Para a realização das simulações o *software* ATP (*Alternative Transient Program*) (PRIKLER e HOIDALEN, 2009) foi utilizado. Vale salientar que a técnica descrita é baseada em simulações computacionais e que considerações práticas foram adicionadas às simulações, fazendo com que a obtenção dos dados se aproxime ao máximo dos reais. Vale ressaltar que as características dos condutores, bem como suas respectivas disposições geográficas nas torres de transmissão foram levadas em consideração.

2.5.1 Configuração do sistema de potência


Na Figura 16 pode ser observado o sistema elétrico analisado, o mesmo é proposto por OLESKOVICZ (2001), com especificações das fontes, barramentos (D, E, F e G) e comprimento das linhas de transmissão. Porém, para efeito do estudo deste trabalho o sistema teve sua configuração, quantidade de barras e dimensões alterados conforme mostra a Figura 17, mas vale salientar que os parâmetros e grandezas do sistema foram mantidos.

Figura 16 - Representação do sistema elétrico original



Fonte: Adaptado de (OLESKOVICZ, 2001).

Figura 17 - Sistema elétrico analisado



Fonte: Autoria própria

2.5.2 Modelagem da linha de transmissão

A estrutura da linha de transmissão de 440kV (Figura 16), empregada entre as cidades de Araraquara – Bauru e Jupiá – Ilha Solteira. Apresentam-se, no que se segue, as especificações referentes aos condutores, com as suas principais características, bem como resistividade do solo considerada (OLESKOVICZ, 2001).

- Condutores de fase: Cabo Grosbeak
 - Raio externo do condutor: 12,57mm;
 - Raio interno do condutor: 4,635mm;
 - Resistência em corrente contínua: 0,08998 Ω /km.

- Cabos para-raios: EHS 3/8"
 - Raio externo do condutor: 4,572mm;
 - Resistência em corrente contínua: 4,188 Ω /km.


- Resistividade do solo:
 - R_{solo} : 1000 Ω .km

- Flecha a meio vão
 - Fase: 13,43m;
 - Para-raios: 6,4m.

2.5.3 Parâmetros do sistema elétrico

Para realizar as simulações do sistema elétrico proposto, utilizando o *software* ATP, algumas considerações foram necessárias para os cálculos dos parâmetros da linha de transmissão, levando-se em consideração as características dos condutores e suas respectivas disposições geométricas nas torres de transmissão, como ilustrado na Figura 18. Dentre as considerações, optou-se por linhas transpostas, pois a transposição compensa os desequilíbrios dos campos magnéticos entre fases, cabo de cobertura, ferragens e solo sob a linha de transmissão. (OLESKOVICZ, 2001).

Figura 18 - Silhueta de torre da linha de 440kV



Fonte: OLESKOVICZ, 2001.

Após todas as considerações, os parâmetros da linha de transmissão foram calculados através da rotina *Line Constant* do ATP, onde é levado em consideração toda a topologia do sistema analisado, como: espaçamento e alturas relativas entre condutores, número de condutores por fase, resistividade do solo, frequência em que os parâmetros foram calculados, condições da linha, entre outros. Após a execução da rotina *Line Constant* do ATP, e a obtenção dos parâmetros da linha de transmissão que estão expostos na Tabela 3, os dados dos barramentos D e G e dos equivalentes de geração estão expostos na Tabela 4 e Tabela 5, respectivamente.

Tabela 3 - Parâmetros da linha de transmissão de 440kV

Sequência positiva			Sequência negativa		
R(Ω /km)	L(mH/km)	C(μ F/km)	R(Ω /km)	L(mH/km)	C(μ F/km)
3,853E-0,2	7,410E-0,1	1,570E-0,2	1,861E+00	2,230E+00	9,034E-0,3

Fonte: SILVA, 2003.

Tabela 4 - Parâmetros dos equivalentes de geração das barras D e G

	Gerador 1 – Barra D		Gerador 2 – Barra G	
	Sequência positiva	Sequência negativa	Sequência positiva	Sequência negativa
R(Ω/km)	1,6982	0,358	1,7876	0,4052
L(mH/km)	5,14E+01	1,12+E01	5,41E+01	1,23E+01

Fonte: SILVA, 2003.

Tabela 5 - Dados das barras de geração D e G

	Gerador 1 – Barra D	Gerador 2 – Barra G
Pot. (GVA)	10	9
Tensão (pu)	1,05	0,95
Ângulo (graus)	0	-10

Fonte: SILVA, 2003.

3 ASPECTOS DA METODOLOGIA UTILIZADA

Neste capítulo serão apresentados os métodos e ferramentas que foram utilizados para o desenvolvimento deste trabalho.

3.1 Banco de dados de entrada das redes neurais artificiais

3.1.1 Variações nas simulações no sistema de potência


Para os dados dos sinais faltosos foi utilizado o *software* ATP, considerando vários tipos de falta em diferentes localizações ao longo da linha entre os barramentos A e B (sistema da Figura 17), com diferentes ângulos de incidência de falta e resistências de falta. A seguir serão descritas as variações consideradas nas simulações:

- Tipos de faltas aplicadas:
 - Fase-terra: fase A-terra;
 - Fase-fase-terra: fases AB-terra;
 - Fase-fase: fases AB;
 - Trifásica: ABC.
- Distância em que as faltas foram aplicadas entre os barramentos A e B, sempre tendo o barramento A como referência:
 - 5, 10, 20, 30, 40, 50, 60, 70, 80, 90, 100, 110, 120, 130, 140, 150, 160, 170, 180, 190 e 195 km.
- Ângulo de incidência de falta:
 - 0 e 90 graus.
- Resistências de faltas consideradas:
 - 0,01, 14, 40 e 100 ohms.
- Total de casos testados:
 - 672 casos.

Os sinais obtidos com as simulações das situações de falta no *software* ATP foram os valores de tensão e corrente trifásicos amostrados dos barramentos A e B. Os dados obtidos a partir da simulação foram tomados a uma frequência amostral de 960Hz (sendo a frequência do sistema 60Hz), resultando em 16 pontos por ciclo completo.


A Figura 19 e a 20 ilustram as formas de onda de tensão e corrente trifásicos respectivamente, obtidos no barramento A, para uma falta fase-fase-terra com ângulo de incidência de 90° e resistência de falta de $0,01\Omega$ a uma distância de 100 km da barra A.

Figura 19 - Formas de onda de tensão de uma falta fase-fase-terra aplicada a 100 km da barra A



Fonte: Autoria própria.

Figura 20 - Formas de onda de corrente de uma falta fase-fase-terra aplicada a 100 km da barra A



Fonte: Autoria própria.

3.1.2 Estimação dos fasores fundamentais

Os dados obtidos a partir das simulações realizadas no *software* ATP são apresentados em forma de vetores contendo os valores instantâneos das tensões e correntes das três fases dos dois terminais da linha de transmissão, e mais um vetor contendo os dados de tempo. Um exemplo do arquivo de sinal de saída do ATP segue na Figura 21, onde Va1, Vb1 e Vc1 são valores de tensão medidos no terminal local, Va2, Vb2 e Vc2 são os valores de tensão medidos no terminal remoto, Ia1, Ib1 e Ic1 são as correntes medidas no terminal local e Ia2, Ib2 e Ic2 são as correntes medidas no terminal remoto.

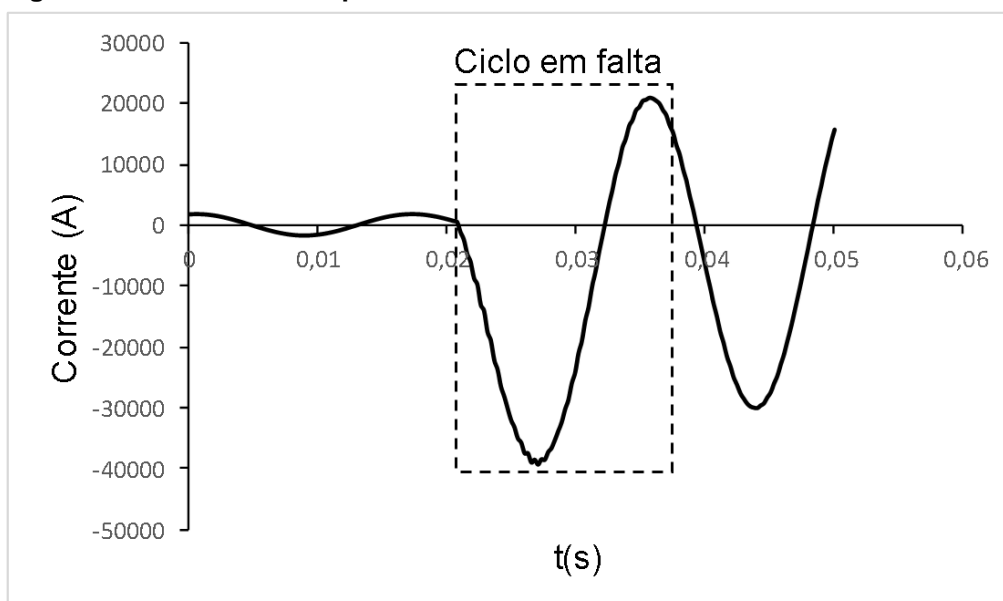
Figura 21 - Arquivo de dados de saída do software ATP

Tempo	Va1	Vb1	Vc1	Va2	Vb2	Vc2	Ia1	Ib1	Ic1	Ia2	Ib2	Ic2
0.0	373440.	-.189E6	-.185E6	341435.	-.221E6	-.12E6	1702.1	-1249.1	-452.98	-1641.4	1835.81	-194.45
.0010419	345964.	-51205.	-.295E6	337638.	-.102E6	-.236E6	1748.41	-677.73	-1070.7	-1965.	1376.23	588.785
.0020838	265792.	94290.6	-.36E6	282414.	32399.4	-.315E6	1528.41	-3.1105	-1525.3	-1989.4	707.036	1282.33
.0031258	145137.	225424.	-.371E6	184174.	161916.	-.346E6	1075.6	671.988	-1747.6	-1710.7	-69.843	1780.56
.0041677	2375.03	322222.	-.325E6	57882.7	266769.	-.325E6	458.963	1244.73	-1703.7	-1171.5	-836.08	2007.58
.0052096	-.141E6	369941.	-.229E6	-77226.	330991.	-.254E6	-227.57	1627.87	-1400.3	-453.84	-1475.	1928.81
.0062515	-.262E6	361313.	-98879.	-.201E6	344797.	-.144E6	-879.46	1763.07	-883.61	332.945	-1889.2	1556.25
.0072934	-.344E6	297652.	46495.3	-.293E6	306087.	-12719.	-1397.4	1629.72	-232.33	1069.01	-2015.7	946.656
.0083354	-.373E6	188654.	184788.	-.341E6	220755.	120725.	-1702.5	1248.14	454.331	1642.27	-1835.1	192.862
.0093773	-.346E6	50921.9	294934.	-.338E6	101798.	235781.	-1748.3	676.455	1071.8	1965.38	-1375.1	-590.31
.0104192	-.266E6	-94567.	360158.	-.282E6	-32663.	314924.	-1527.8	1.73066	1526.02	1989.13	-705.56	-1283.6
.0114611	-.145E6	-.226E6	370525.	-.184E6	-.162E6	346100.	-1074.5	-673.26	1747.81	1709.92	71.4078	-1781.3
.012503	-2089.8	-.322E6	324456.	-57622.	-.267E6	324560.	-457.68	-1245.7	1703.39	1170.26	837.505	-2007.8
.013545	141013.	-.37E6	228967.	77483.8	-.331E6	253585.	228.897	-1628.4	1399.52	452.351	1476.05	-1928.4
.0145869	262637.	-.361E6	98603.9	200787.	-.345E6	143985.	880.614	-1763.1	882.479	-334.45	1889.76	-1555.3
.0156288	344258.	-.297E6	-46778.	293508.	-.306E6	12454.7	1398.2	-1629.2	231.032	-1070.3	2015.64	-945.33
.0166707	373444.	-.188E6	-.185E6	341524.	-.221E6	-.121E6	1702.81	-1247.2	-455.6	-1643.2	1834.51	-191.36
.0177126	345749.	-50639.	-.295E6	337520.	-.102E6	-.236E6	1748.07	-675.23	-1072.8	-1965.7	1373.96	591.749
.0187546	265391.	94842.6	-.36E6	282108.	32926.3	-.315E6	1527.07	-.40042	-1526.7	-1988.9	704.137	1284.73
.0197965	144611.	225879.	-.37E6	183726.	162383.	-.346E6	1073.47	674.489	-1748.	-1709.1	-72.929	1782.02
.0208384	1804.49	322510.	-.324E6	57360.8	267107.	-.324E6	456.37	1246.64	-1703.	-1169.	-838.89	2007.89
.0218803	41716.1	187026.	-.229E6	-64972.	318376.	-.253E6	-26275.	27673.2	-1398.7	-3294.	1366.03	1927.92
.0229222	-24429.	122758.	-98329.	-62812.	206557.	-.144E6	-56529.	57410.2	-881.29	-3789.3	2235.	1554.31
.0239642	-88757.	41695.4	47061.4	-.273E6	284798.	-12190.	-83819.	84048.4	-229.68	-6962.7	6018.78	943.946
.0250061	-.138E6	-47565.	185283.	-.316E6	194462.	121221.	-.103E6	102218.	456.923	-9905.	9715.17	189.808
.026048	-.165E6	-.131E6	295284.	-.307E6	70869.2	236168.	-.109E6	108140.	1073.93	-11995.	12588.	-593.24
.0270899	-.165E6	-.195E6	360309.	-.285E6	-30513.	315144.	-.102E6	100145.	1527.36	-10974.	12260.4	-1285.9
.0281318	-.14E6	-.23E6	370454.	-.173E6	-.173E6	346119.	-80601.	78852.5	1748.15	-11834.	13616.3	-1782.8
.0291738	-93059.	-.231E6	324173.	-51241.	-.273E6	324375.	-48744.	47040.8	1702.68	-11113.	13121.2	-2008.
.0302157	-31420.	-.197E6	228516.	88643.4	-.342E6	253224.	-10604.	9205.91	1397.87	-9027.7	10955.1	-1927.5
.0312576	35340.	-.133E6	98053.4	146249.	-.29E6	143504.	28278.2	-29158.	880.137	-5343.1	6896.42	-1553.3
.0322995	96979.3	-49635.	-47344.	272283.	-.284E6	11925.8	62189.7	-62418.	228.354	-2841.4	3784.04	-942.6
.0333414	144020.	41511.	-.186E6	321301.	-.2E6	-.121E6	86132.	-85674.	-458.21	-456.95	645.241	-188.29

Fonte: Autoria própria.

Para realizar as análises e a extração dos fasores das tensões e correntes de ambos terminais da linha, optou-se em utilizar um ciclo completo das grandezas do sistema em falta, como ilustra a Figura 22.

Figura 22 – Ciclo utilizado para extrair os fasores dos dados em falta



Fonte: Autoria própria

Após a extração dos sinais das tensões e correntes do sistema em situações distintas de falta, criou-se uma rotina no *software* Matlab® utilizando a Transformada Discreta de *Fourier* (TDF), em sua variação rápida, a FFT (*Fast Fourier Transform*) com o objetivo de extrair os componentes fundamentais de 60HZ dos sinais de tensões e correntes.

Como os fasores obtidos em frequência fundamental são números complexos, foi utilizada a equação (22) para a extração dos módulos dos valores de tensão e corrente trifásicos para serem utilizadas como entrada para as arquiteturas de redes neurais artificiais.

$$|V| = |x + jy| = \sqrt{x^2 + y^2} \quad (22)$$

Onde:

$|V|$ é o módulo;

x é a parte real do fasor;

jy é a parte imaginária do fasor.

Uma vez obtidos os módulos das tensões e correntes, estes valores devem ser normalizados, ou seja, todos os dados de tensão e corrente devem estar entre 0 e 1, para facilitar o processamento dos dados pela RNA.

3.2 Definição da melhor topologia de rede neural artificial

Aplicações de redes neurais artificiais bem-sucedidas em variadas áreas da engenharia, tem explicitado a empregabilidade desta ferramenta como uma alternativa aos métodos convencionais de resolução de problemas de maneira precisa e eficiente.

Este trabalho demonstra a seguir a implementação de uma metodologia de localização de faltas em linhas de transmissão utilizando-se as teorias de Redes Neurais Artificiais implementadas na *toolbox nntool* do Matlab®.

Com a implementação das arquiteturas RNAs o objetivo é que as redes neurais extraiam o conhecimento da atuação do localizador de faltas, por meio dos dados amostrais de tensão e corrente de falta ao longo da extensão da linha de transmissão que serão apresentados às topologias de redes durante o processo de treinamento, para que posteriormente possa trabalhar na localização de casos de faltas desconhecidos, ou seja, que não constam no banco de dados de treinamento. Desta maneira subintende-se que as redes neurais trabalham com dois bancos de dados distintos, um para treinamento e outro para teste e validação da rede em questão.

3.2.1 Algoritmo de escolha da melhor topologia RNA dependendo das entradas utilizadas

Com o intuito de se obter a topologia de RNA mais adequada para cada grupo de entradas dos algoritmos de localização de faltas, implementou-se um algoritmo que testa diversas topologias RNA de acordo com as entradas selecionadas, e determina, ao final de sua execução, a rede com o menor erro relativo médio.

Para tal, alguns parâmetros das RNAs foram fixados, de modo a variar somente o número de unidades de processamento de cada camada intermediária e a quantidade de camadas intermediárias (1 ou 2 camadas intermediárias).

A Tabela 6, a seguir mostra os parâmetros fixados, bem como o número máximo de neurônio para cada camada escondida, além das funções de ativação utilizadas. Vale lembrar também que a rede escolhia foi a *Perceptron* multicamadas e o algoritmo de treinamento o *Levenberg-Marquardt*.

Tabela 6 - Parâmetros fixados para as topologias RNA

Taxa de aprendizado (η)	0,1
Número máximo de épocas	3000
Erro final desejado (ϵ)	1×10^{-4}
Número máximo de camadas intermediárias	2
Número máximo de neurônios por camada intermediária	30
Função de ativação para camadas intermediárias	Tangente hiperbólica
Função de ativação para camada de saída	Linear

O algoritmo de escolha da melhor rede de acordo com as entradas funciona em duas etapas distintas. A primeira etapa considera para topologia RNA somente uma camada neural intermediária com no máximo 30 (trinta) neurônios. Na segunda etapa o algoritmo considera para topologia RNA até duas camadas com no máximo 30 (trinta) neurônios em cada.

Na primeira etapa, o algoritmo atribui à topologia de RNA somente uma camada intermediária, que vai de 1 a 30 neurônios em sua composição. Para cada rede executada são calculados os erros relativo (equação (23)) e erro relativo médio (equação (24)) e o erro absoluto (equação (25)), sendo, estes valores armazenados em um banco de dados. Na segunda etapa, é atribuída à RNA duas camadas intermediárias, das quais ambas podem ter de 1 a 30 neurônios artificiais, de modo que todas as combinações de topologia são testadas. Desta maneira, para cada caso, são testadas 930 topologias distintas de redes neurais artificiais.

$$\epsilon_{rel}(\%) = \left| \frac{(D_{real} - D_{estimada})}{l_{LT}} \right| \times 100\% \quad (23)$$

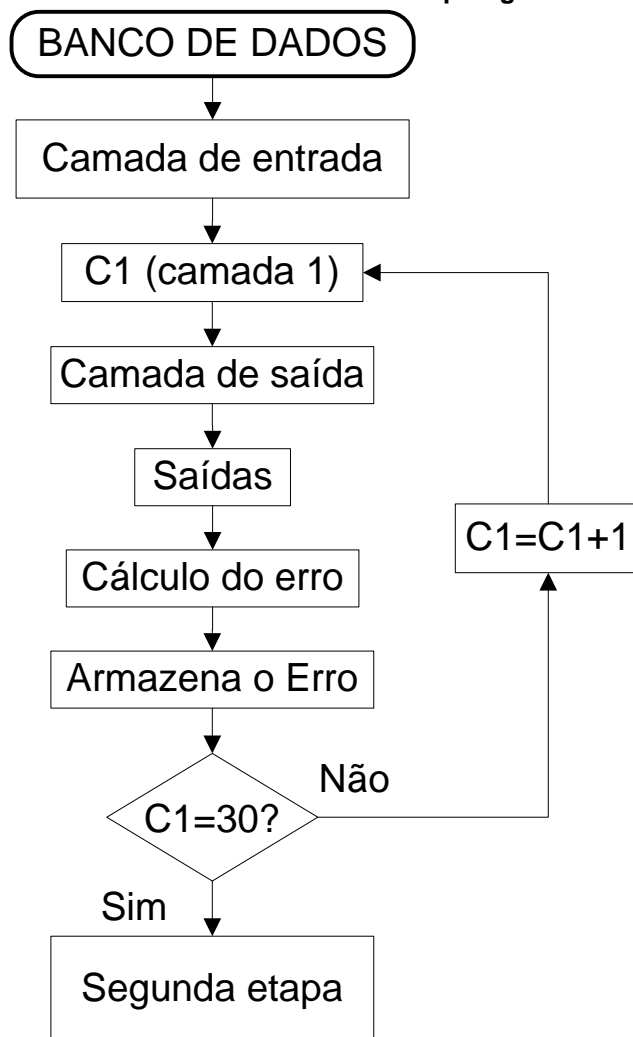
$$\epsilon_{médio}(\%) = \frac{\sum_1^N \epsilon_{rel}(\%)}{N} \quad (24)$$

$$\epsilon_{abs}(km) = |D_{real} - D_{estimada}| \quad (25)$$

Onde, N é o número de situações testadas, D_{real} é a distância real da falta, $D_{estimada}$ é a distância estimada pelo algoritmo e l_{LT} é o comprimento total da linha de transmissão.

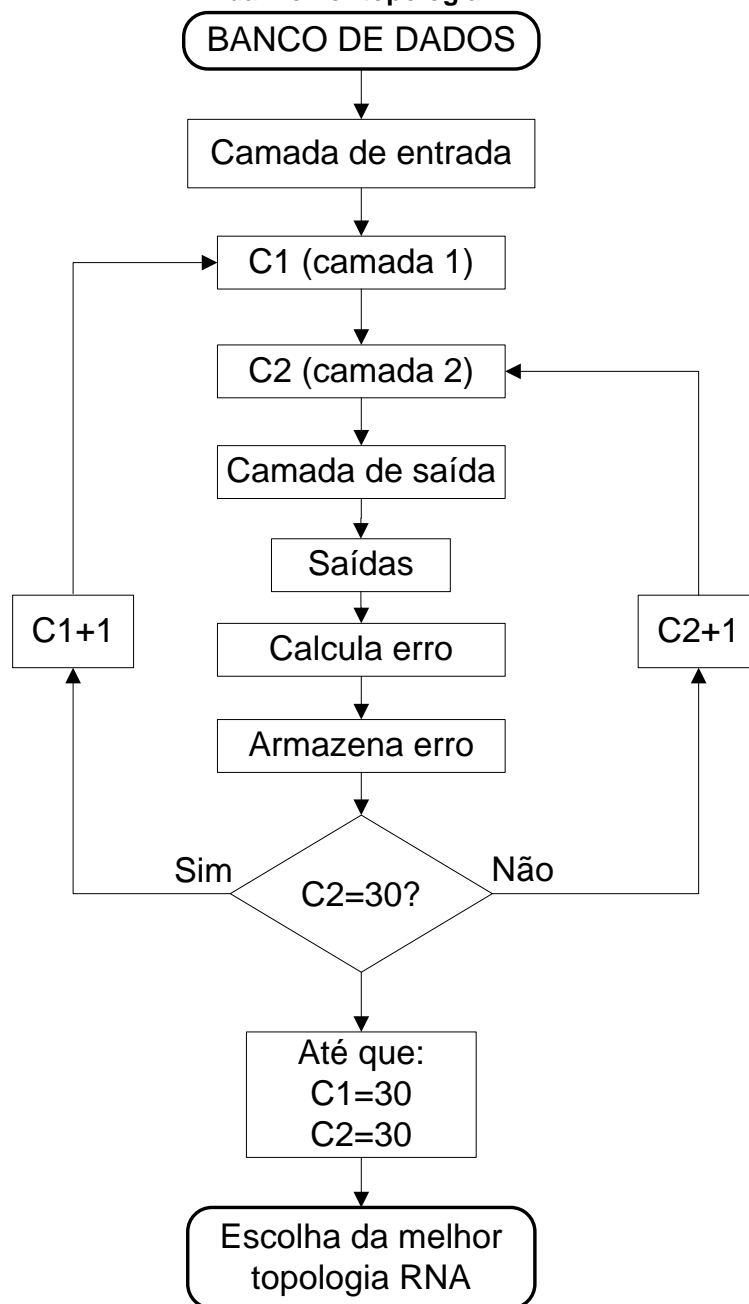
Os fluxogramas da primeira e segunda etapa de execução do algoritmo de definição da melhor topologia RNA podem ser vistas na Figura 23 e Figura 24, respectivamente.

Figura 23 - Fluxograma de execução da primeira etapa do algoritmo de busca da melhor topologia RNA



Fonte: Autoria própria.

Figura 24 - Fluxograma de execução da segunda etapa do algoritmo de busca da melhor topologia RNA



Fonte: Autoria própria.

3.3 Localizador de faltas utilizando redes neurais artificiais

Os algoritmos de localização de faltas completos foram implementados no *software* Matlab® por meio de sub-rotinas da *Neural Network Toolbox (nntool)*, os dados utilizados para compor o banco de dados de entrada das arquiteturas RNA foram adquiridos através de simulações realizadas no *software* ATP/EMTP. Como

descrito no capítulo (3.1.1 Variações nas simulações no sistema de potência), foram considerados diversos tipos de faltas, com diferentes localizações ao longo da linha de transmissão em questão, sempre tendo como referência o barramento “A”, considerando também diferentes ângulos de incidência de falta e resistência de falta, além das fases envolvidas em cada distúrbio.

Os algoritmos de localização de faltas propostos neste trabalho, serão divididos em dois métodos distintos, são eles:

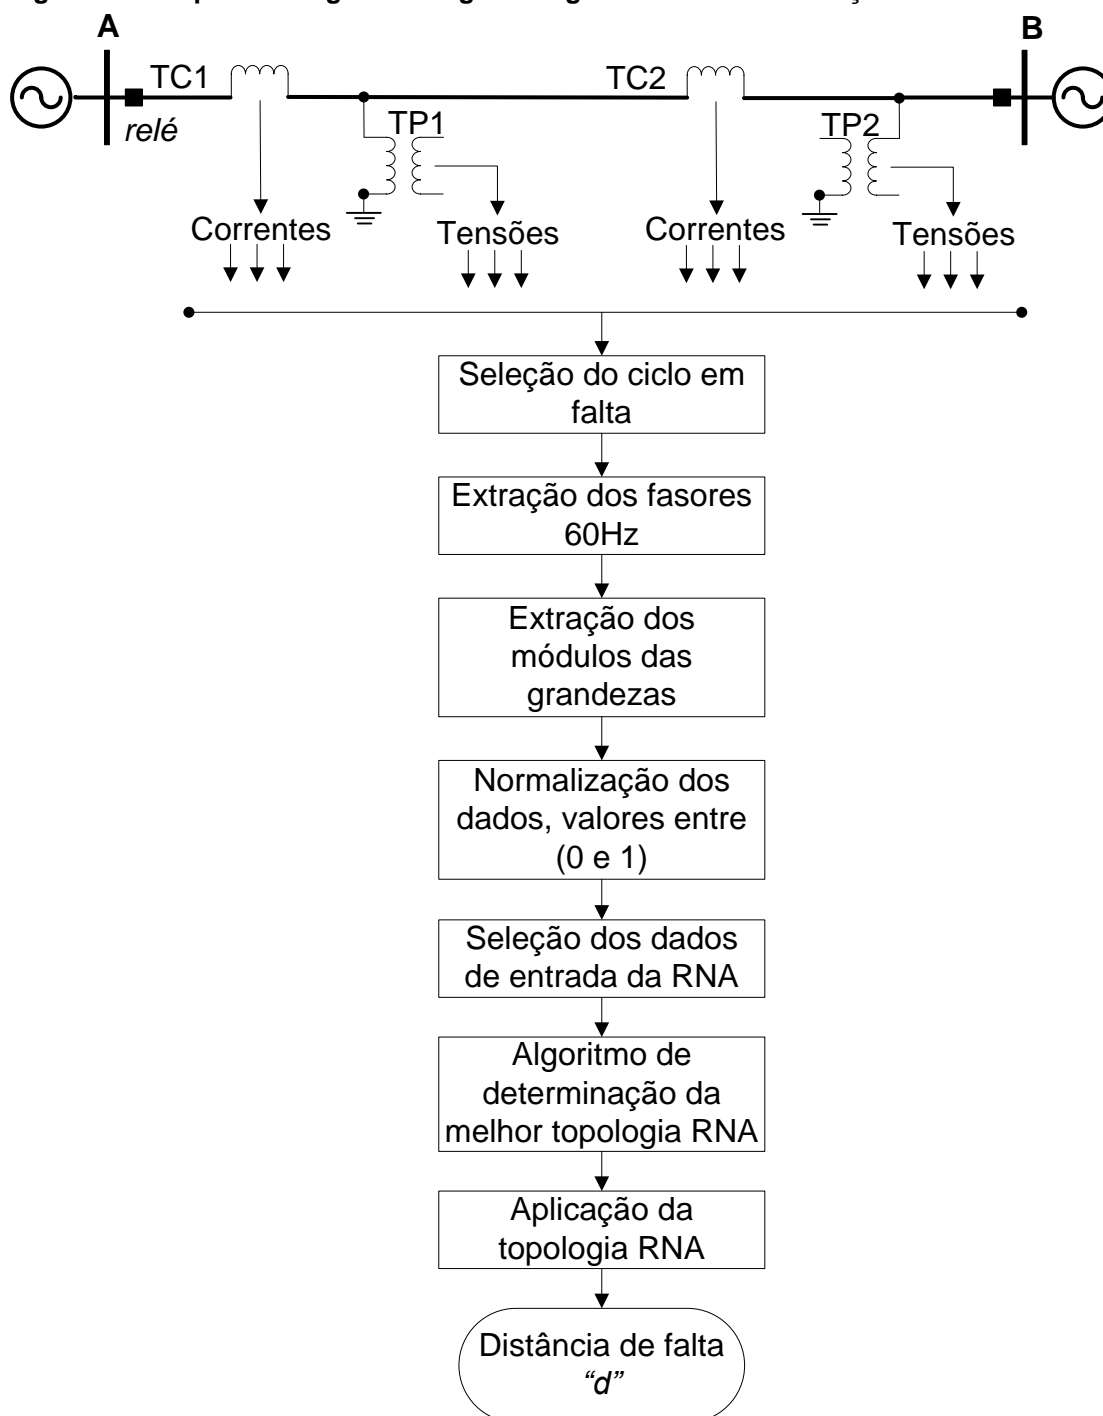
1. Trabalhando como uma arquitetura neural generalista, ou seja, uma única topologia de rede neural empregada para estimar a distância de todos os tipos de falta, sendo, portanto, independente do tipo de falta, da resistência de falta e também do ângulo de incidência de falta.
2. Este método trabalhará com duas topologias de redes neurais, uma das topologias será empregada para classificar as faltas com relação às fases envolvidas no curto-circuito (fase-terra, fase-fase, fase-fase-terra, fase-fase-fase). Após a classificação e determinação de cada caso de falta, estes serão encaminhados para uma segunda topologia neural que será utilizada para estimar a distância de ocorrência da falta com relação ao barramento local.

3.3.1 Algoritmo RNA 1

Os algoritmos de localização de faltas, geralmente, são divididos em três sub-rotinas, a de detecção de falta, classificação de falta e por fim localização de falta, sendo que este algoritmo atua única e exclusivamente na localização de faltas em linhas de transmissão. Para tal, parte-se do pressuposto que a falta já foi detectada pelo relé de proteção do sistema, de modo que o sistema já esteja *off-line*. Já o módulo de classificação não se faz necessário pois a proposta do algoritmo é justamente localizar a falta sem que haja a necessidade de classificá-la com relação às fases envolvidas.

Como mencionado anteriormente, este algoritmo trabalhará única e exclusivamente na localização de faltas do sistema em estudo, sendo que a Figura 25 mostra os passos do princípio de funcionamento deste algoritmo.

Figura 25 - Esquemático geral do algoritmo generalista de localização de faltas



Fonte: Autoria própria.

Para este método foram considerados para entradas das topologias RNA, tanto dados de tensão e corrente provenientes do barramento local da linha de transmissão, quanto dados oriundos de ambos terminais da linha. Desta forma, os resultados foram obtidos em quatro diferentes topologias de redes, cada uma com dados de entrada diferentes. Deste modo, os resultados serão apresentados da seguinte maneira:

- Topologia 1: utilizando como entradas somente as tensões trifásicas do barramento local;
- Topologia 2: utilizando como entradas para o algoritmo somente as correntes trifásicas medidas no barramento local;
- Topologia 3: foram utilizados como entradas da RNA as correntes trifásicas medidas em ambos terminais da linha de transmissão;
- Topologia 4: foram utilizados como entrada todas as medidas obtidas em ambos terminais da LT, ou seja, tensões e correntes trifásicas do barramento local, e tensões e correntes trifásicas medidas no barramento remoto do sistema.

A literatura aconselha utilizar entre 70 e 90% dos dados para treinamento e, conseqüentemente, entre 30 e 10% dos dados para testes. Assim, as topologias foram avaliadas, variando a relação entre o percentual do banco de dados utilizados como treinamento e o percentual utilizado para teste, estipulando-se um valor inicial de 65% dos dados como treinamento e 35% dos dados como teste, e variado de 5 em 5%, até que a relação seja de 90% dos dados de treinamento e 10% de teste. Esta relação está exposta na Tabela 7 a seguir.

Tabela 7 - Definição das relações entre % treinamento e % teste

% Treinamento (%)	% Teste (%)
65	35
70	30
75	25
80	20
85	15
90	10

3.3.2 Algoritmo RNA 2

Este algoritmo consiste em dois módulos, o módulo de classificação e o módulo de localização de faltas. Para implementação deste algoritmo foi utilizado uma proporção de 80% dos dados do banco de dados para treinamento e 20% dos dados

do banco de dados para testes, além de se utilizar como entrada para as topologias deste algoritmo as correntes trifásicas do terminal local do sistema.

O algoritmo proposto funciona em duas etapas distintas, a primeira é a classificação das faltas quanto às fases envolvidas no surto, este módulo ainda direciona para as topologias de localização correspondente para cada caso de falta.

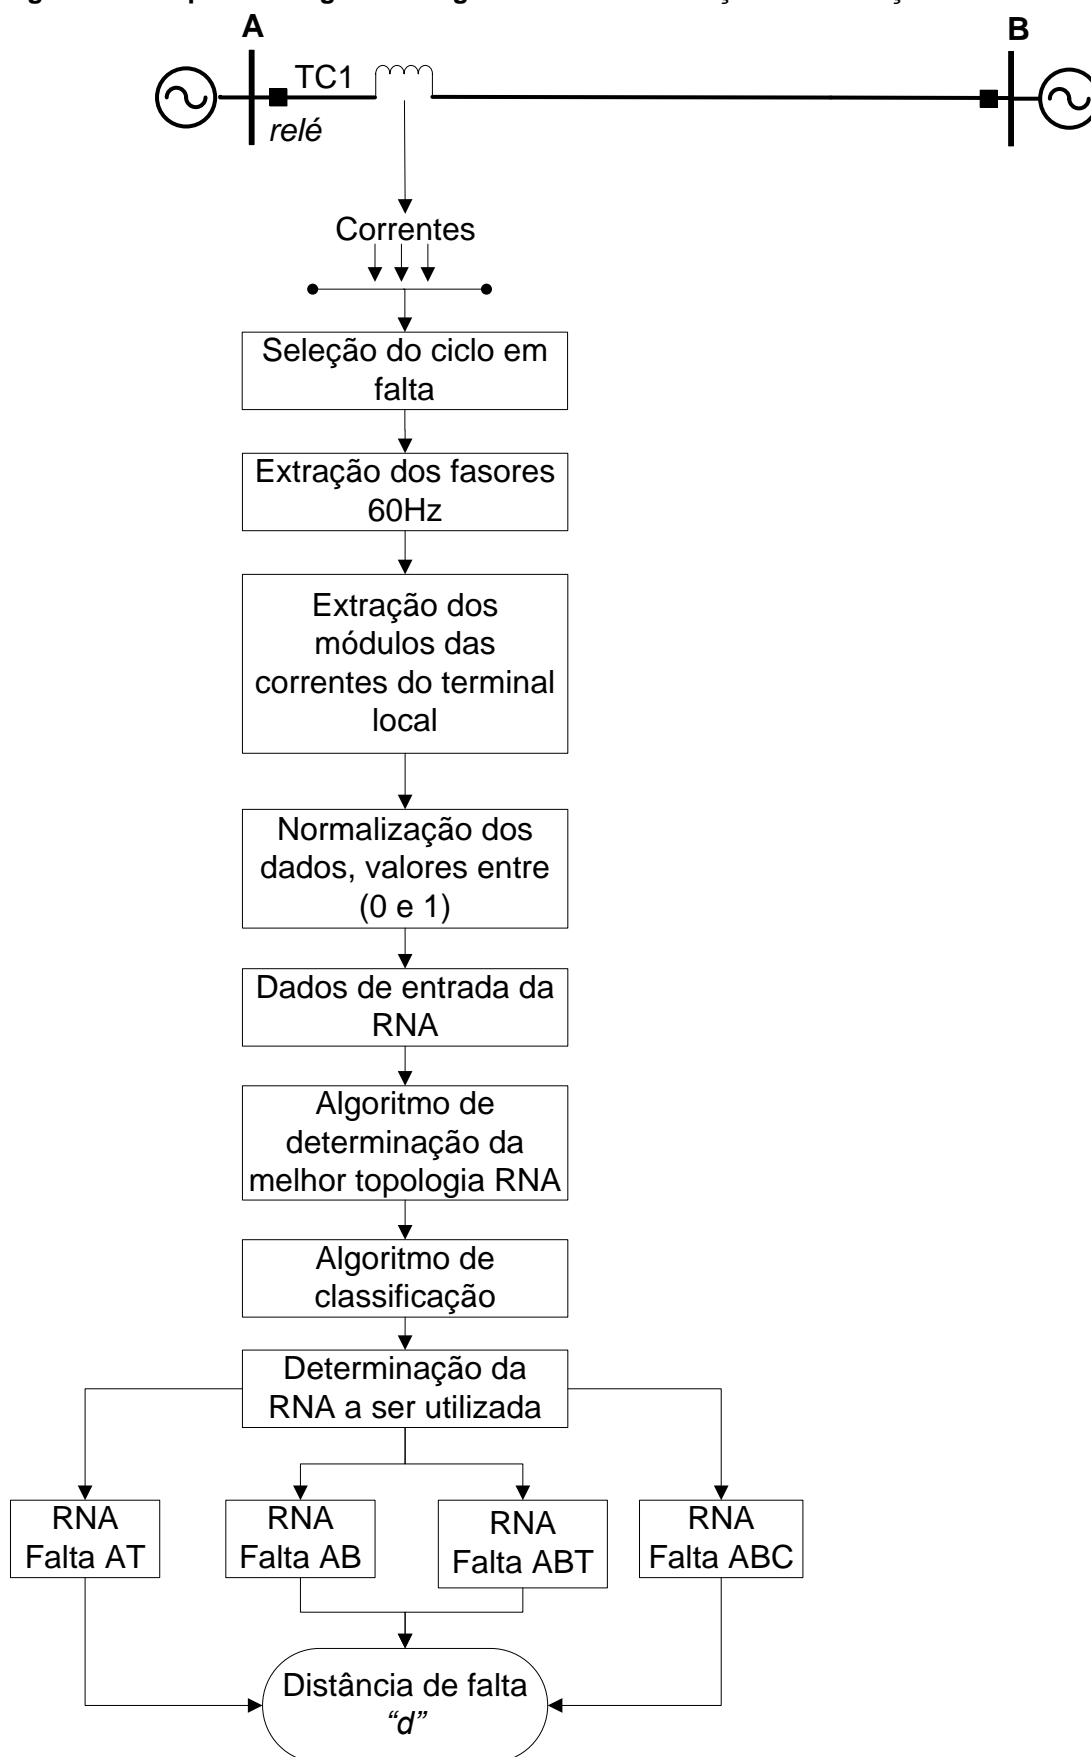
As faltas são classificadas de acordo com os códigos binários expostos na Tabela 8 a seguir, e as leituras das saídas da RNA de classificação são realizadas do *bit* mais significativo para o menos significativo, ou seja, da direita para a esquerda.

Tabela 8 - Representação binária de cada tipo de falta com relação às fases envolvidas

Tipo de falta	Saída 1	Saída 2	Saída 3	Saída 4
AT	1	0	0	0
AB	0	1	0	0
ABT	0	0	1	0
ABC	0	0	0	1

O esquemático geral dos passos do algoritmo está exposto na Figura 26 a seguir.

Figura 26 - Esquemático geral do algoritmo de classificação e localização de faltas



Fonte: Autoria própria.

4 RESULTADOS E DISCUSSÕES

Neste capítulo serão apresentados os resultados obtidos através dos métodos previamente apresentados.

4.1 Algoritmo RNA 1

Como mencionado anteriormente este método consiste em topologias de redes neurais artificiais aplicadas única e exclusivamente na localização de faltas, partindo do pressuposto de que a falta já foi detectada pelo relé, já o modulo de classificação não se faz necessário sua aplicação.

4.1.1 Topologia RNA 1

Esta topologia será utilizada para localização de faltas no sistema de transmissão, atuando como uma ferramenta generalista. A partir da aplicação do algoritmo descrito no item (3.2.1 Algoritmo de escolha da melhor topologia RNA dependendo das entradas utilizadas), tendo como entrada os módulos das tensões do terminal local, obteve-se que a melhor topologia de rede ser aplicada é a 3-27-1, ou seja, três entradas, vinte e sete neurônios na camada intermediária e uma saída. A Tabela 9 contém todas as informações da topologia RNA utilizada.

Tabela 9 - Características da topologia RNA 1

Taxa de aprendizado (η)	0,1
Número máximo de épocas	3000
Erro final desejado (ϵ)	1×10^{-4}
Entradas	3
Número de neurônios na camada intermediária	27
Número de neurônios na camada de saída	1
Função de ativação da camada intermediária	Tangente hiperbólica
Função de ativação da camada de saída	Linear

Para avaliar o desempenho desta topologia, foi dividido o banco de dados em duas partes, sendo a primeira de treinamento e a segunda a teste. Desta forma

variou-se a proporção treinamento x testes, como mostrado na Tabela 7. Os valores utilizados para testes são selecionados de forma aleatória dos valores contidos no banco de dados.

A Tabela 10 mostra os erros relativos obtidos com a aplicação desta topologia de acordo com a variação da proporção treinamento x teste. Vale salientar que para o cálculo dos erros utilizou-se as equações (23), (24) e (25). A topologia foi simulada cinco vezes e escolhido aleatoriamente os resultados de uma das simulações.

Tabela 10 - Resultados obtidos com a aplicação da topologia RNA 1

% Treinamento (%)	% Teste (%)	Erro máximo (%)	Erro mínimo (%)	Erro médio (%)
65	35	9,4776%	1,0540%	4,9142%
70	30	8,9860%	1,0102%	5,2222%
75	25	8,9178%	1,0213%	4,5144%
80	20	12,5500%	1,0120%	4,1958%
85	15	6,9260%	1,1489%	4,4741%
90	10	5,9402%	1,0086%	3,7252%

Constatou-se por meio das simulações realizadas que a proporção com maior precisão na localização de faltas, utilizando a topologia RNA 1 e como dados de entrada as tensões no barramento local, foi a de 90% dos dados para treinamento e 10% dos dados para teste. Onde o maior erro chegou a aproximadamente 6% do comprimento da linha, o menor erro atingiu cerca 1% do comprimento total da linha de transmissão e o erro médio ficou em torno dos 3,7% do comprimento da linha. Verificou-se, ainda que cerca de 21% dos resultados obtidos o erro relativo foi inferior a 2% do comprimento total da LT. A partir dos resultados obtidos observa-se que aproximadamente 48% das estimações de distâncias obtiveram erros superiores a 4% do comprimento total da LT, o que representaria 8km em erro absoluto, desta forma, evidencia que a topologia não apresentou um desempenho satisfatório.

4.1.2 Topologia RNA 2

Após a aplicação do algoritmo descrito no item (3.2.1 Algoritmo de escolha da melhor topologia RNA dependendo das entradas utilizadas), tendo como entrada os módulos dos fasores 60Hz das correntes do terminal local. Determinou-se que a

melhor topologia de rede ser utilizada é a 3-12-16-1, ou seja, três entradas, doze neurônios na camada intermediária um, dezesseis neurônios na camada intermediária dois e uma saída, a Tabela 11 contém todas as informações da topologia RNA utilizada.

Tabela 11 - Características da topologia RNA 2

Taxa de aprendizado (η)	0,1
Número máximo de épocas	3000
Erro final desejado (ϵ)	1×10^{-4}
Entradas	3
Número de neurônios na camada intermediária 1	12
Número de neurônios na camada intermediária 2	16
Número de neurônios na camada de saída	1
Função de ativação das camadas intermediárias	Tangente hiperbólica
Função de ativação da camada de saída	Linear

Com a finalidade de avaliar o desempenho desta topologia, dividiu-se o banco de dados em duas partes, sendo a primeira de treinamento e a segunda a teste. Variou-se ainda, a proporção treinamento x testes, como mostrado na Tabela 7. Os valores utilizados para testes são selecionados de forma aleatória dos valores contidos no banco de dados. A Tabela 12 a seguir mostra os erros relativos médio obtidos com a aplicação desta topologia. A topologia foi simulada cinco vezes e escolhido aleatoriamente os resultados de uma das simulações.

Tabela 12 - Resultados obtidos com a aplicação da topologia RNA 2

% Treinamento (%)	% Teste (%)	Erro máximo (%)	Erro mínimo (%)	Erro médio (%)
65	35	6,9634%	0,1988%	3,8339%
70	30	5,9753%	1,0034%	3,6211%
75	25	5,9956%	1,0467%	3,4395%
80	20	5,0000%	1,0015%	3,0749%
85	15	4,9363%	1,1110%	3,0113%
90	10	4,2314%	0,1527%	1,7077%

Constatou-se através das simulações que como ocorrido com a topologia RNA 1, os melhores resultados foram obtidos a partir da proporção de 90% treinamento e 10% do banco de dados para teste. Onde o maior erro chegou a aproximadamente 4,2% do comprimento total da LT, o menor erro próximo a 0,15% do comprimento total da LT e o erro médio próximo a 1,7% do comprimento total da linha de transmissão. Foi possível verificar que 67% das estimações obtiveram erros menores que 2%, onde cerca de 25% destes casos o erro foi inferior a 1%. Com base nos dados expostos da aplicação da topologia RNA 2, pode-se considerar que o resultado foi satisfatório, levando em consideração que em mais da metade dos casos os erros foram inferiores a 2% do comprimento total linha.

4.1.3 Topologia RNA 3

Após a aplicação do algoritmo descrito no item (3.2.1 Algoritmo de escolha da melhor topologia RNA dependendo das entradas utilizadas), tendo como entrada os módulos dos fasores 60Hz das correntes do terminal local e das correntes do terminal remoto, determinou-se que a melhor topologia de rede ser utilizada é a 6-18-27-1, ou seja, seis entradas, dezoito neurônios na camada intermediária um, vinte e sete neurônios na camada intermediária dois e uma saída. A Tabela 13 contém todas as informações da topologia RNA utilizada.

Tabela 13 - Características da topologia RNA 3

Taxa de aprendizado (η)	0,1
Número máximo de épocas	3000
Erro final desejado (ϵ)	1×10^{-4}
Entradas	6
Número de neurônios na camada intermediária 1	18
Número de neurônios na camada intermediária 2	27
Número de neurônios na camada de saída	1
Função de ativação das camadas intermediárias	Tangente hiperbólica
Função de ativação da camada de saída	Linear

Com a finalidade de avaliar o desempenho desta topologia, dividiu-se o banco de dados em duas partes, sendo a primeira de treinamento e a segunda a teste. Variando a proporção treinamento x testes, como mostrado na Tabela 7. Os valores

utilizados para testes são selecionados de forma aleatória dos valores contidos no banco de dados. A Tabela 14 a seguir mostra os erros relativos médio obtidos com a aplicação desta topologia. A topologia foi simulada cinco vezes e escolhido aleatoriamente os resultados de uma das simulações.

Tabela 14 - Resultados obtidos com a aplicação da topologia RNA 3

% Treinamento (%)	% Teste (%)	Erro máximo (%)	Erro mínimo (%)	Erro médio (%)
65	35	3,9836%	1,0119%	2,4549%
70	30	4,2684%	1,0041%	2,5481%
75	25	2,9954%	0,1111%	1,4847%
80	20	2,3686%	0,2029%	1,3697%
85	15	2,9948%	0,3119%	1,5696%
90	10	1,9780%	0,1156%	1,0030%

Por meio das simulações realizadas, pode-se constatar que o menor erro relativo médio se deu quanto a proporção era de 90% dos dados para treinamento e 10% para testes. Observa-se que o maior erro relativo observado foi de 1,9%, o menor erro relativo cerca de 0,1% e o erro relativo médio 1% do comprimento total da linha de transmissão. Verificou-se ainda que 100% dos resultados obtidos tiveram seus respectivos erros relativos inferiores a 2% e que em 55% dos resultados os erros relativos foram inferiores à 1%. Com base no exposto pode-se concluir que os resultados obtidos pela topologia RNA 3 foram satisfatórios.

4.1.4 Topologia RNA 4

Esta topologia teve como entradas todos os valores registrados do sistema de transmissão estudado, ou seja, os módulos dos fasores fundamentais (60Hz) das correntes e das tensões trifásicas dos dois terminais da linha de transmissão. Com a aplicação do algoritmo descrito no item (3.2.1 Algoritmo de escolha da melhor topologia RNA dependendo das entradas utilizadas), obteve-se que a melhor topologia para esta aplicação é a 12-22-17-1, ou seja, doze entradas, vinte e dois neurônios na camada intermediária um, dezessete neurônios na camada intermediária

dois e uma saída, a Tabela 15 contém todas as informações da topologia RNA utilizada.

Tabela 15 - Características da topologia RNA 4

Taxa de aprendizado (η)	0,1
Número máximo de épocas	3000
Erro final desejado (ϵ)	1×10^{-4}
Entradas	12
Número de neurônios na camada intermediária 1	22
Número de neurônios na camada intermediária 2	17
Número de neurônios na camada de saída	1
Função de ativação das camadas intermediárias	Tangente hiperbólica
Função de ativação da camada de saída	Linear

Para avaliar o desempenho desta topologia, dividiu-se o banco de dados em duas partes, sendo a primeira de treinamento e a segunda a teste. Variou-se também a proporção treinamento x testes, como mostra do na Tabela 7. Os valores utilizados para testes são selecionados de forma aleatória dos valores contidos no banco de dados. A Tabela 16 mostra os erros relativos médio obtidos com a aplicação desta topologia. A topologia foi simulada cinco vezes e escolhido aleatoriamente os resultados de uma das simulações.

Tabela 16 - Resultados obtidos com a aplicação da topologia RNA 4


% Treinamento (%)	% Teste (%)	Erro máximo (%)	Erro mínimo (%)	Erro médio (%)
65	35	4,9942%	1,0017%	3,0555%
70	30	4,9426%	0,9135%	3,0433%
75	25	4,9947%	1,0026%	2,9912%
80	20	3,9989%	0,2082%	2,0554%
85	15	3,9434%	0,1044%	1,9979%
90	10	3,9303%	0,3031%	1,9774%

Com os resultados obtidos utilizando a topologia RNA 4, constatou-se que a proporção 90% dos dados para treinamento e 10% dos dados para teste obteve a

melhor resposta perante as demais proporções. Onde o erro máximo foi 3,9%, o erro mínimo 0,3% e o erro médio aproximadamente 2% do comprimento total da linha de transmissão. A topologia RNA 4 apresentou aproximadamente 53% de suas estimações com erro inferior a 2% e cerca de 22% dos erros inferiores a 1% e 9% das saídas com erros inferiores a 0,5%. Os resultados obtidos com a aplicação desta topologia foram satisfatórios, mesmo com precisão um pouco inferior às apresentadas com a aplicação das topologias RNA 2 e RNA 3.

A fim de comparar as quatro topologias acima dispostas, a Figura 27 mostra a relação entre o erro relativo médio o percentual do banco de dados utilizados para testes das topologias.

Figura 27 - Comparação do desempenho das quatro topologias testadas




Fonte: Autoria própria.

Observando a Figura 27 pode-se concluir que a rede que obteve o melhor desempenho foi a topologia neural RNA 3, seguida pela topologia RNA 2, logo após vem o desempenho da topologia RNA 4 e por último a topologia RNA 1. De modo geral a aplicação de topologias de redes neurais artificiais como um algoritmo de localização de faltas generalista apresentaram resultados bastante promissores, principalmente quando se utilizam como entrada os dados de correntes, como foi o caso da topologia RNA 3 que utilizou as correntes trifásicas de ambos terminais da

linha de transmissão e a topologia RNA 2 que utilizou os dados de correntes trifásica do terminal local do sistema estudado.

A Figura 28 apresenta uma relação entre o erro relativo e a distância das faltas. Observando a Figura 28 abaixo, pode-se constatar que a distância da falta pode influenciar na precisão do método discutido, observa-se que geralmente os maiores erros percentuais relativos ocorrem próximo aos terminais da linha de transmissão.

Figura 28 - Relação entre o erro relativo e a distância de faltas na linha de transmissão



Fonte: Autoria própria.

4.2 Algoritmo RNA 2

A partir da confirmação da ocorrência de uma falta, este algoritmo pode ser empregado para classificar o tipo de falta em relação às fases envolvidas, bem como estimar a distância de ocorrência do distúrbio tendo como referência o barramento “A” do sistema em estudo. Após a classificação da falta, uma rede neural artificial denominada topologia RNA 5, será empregada para cada uma das faltas separadamente, ou seja, a mesma topologia RNA 5 será utilizada em quatro versões diferentes, uma para localizar as faltas do tipo AT, outra rede com as mesmas características para faltas AB, outra para faltas ABC e uma última para faltas ABT, tendo como única diferença o banco de dados utilizado para o treinamento e teste.

Desta maneira a topologia RNA 5 utilizada para estimar as faltas do tipo AT serão treinadas e testadas utilizando o banco de dados de faltas do tipo AT, e o mesmo acontece com as demais redes utilizadas para o restante dos tipos de faltas.

Para esta aplicação decidiu-se em utilizar como entrada para RNA de classificação e para a RNA de estimação de distância, os módulos dos fasores fundamentais (60Hz) das correntes do barramento local. Outro ponto foi a definição da relação 80% dos dados para treinamento e 20% dos dados para testes.

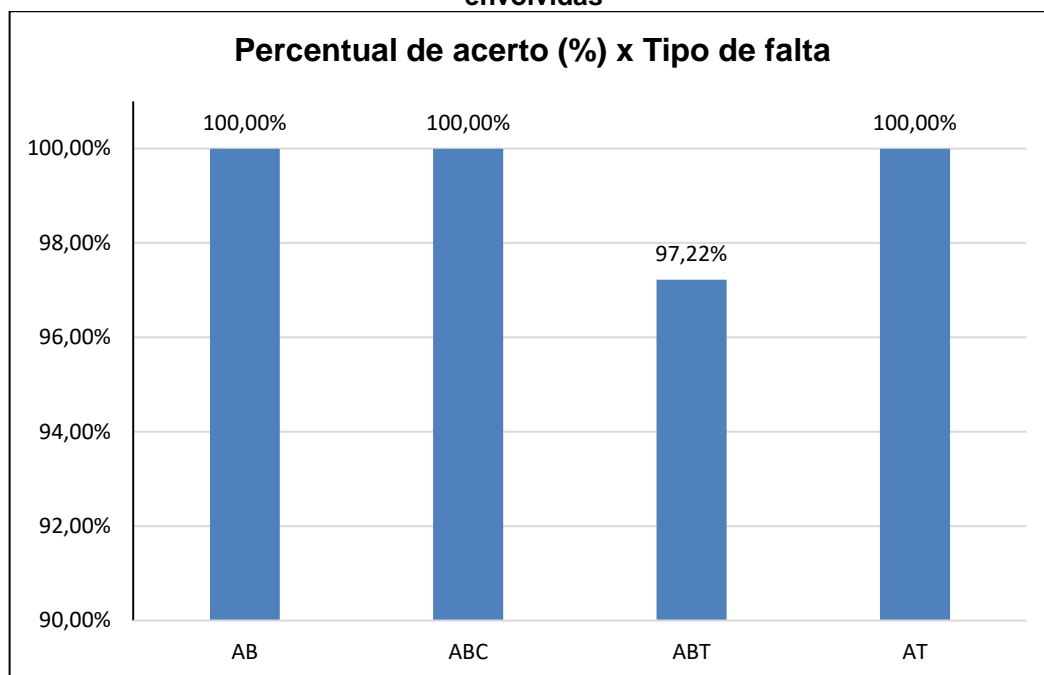
Com a aplicação do algoritmo descrito no item (3.2.1 Algoritmo de escolha da melhor topologia RNA dependendo das entradas utilizadas), definiu-se que a melhor topologia para rede neural de classificação de faltas foi a 3-14-23-4, ou seja, três entradas, quatorze neurônios na camada intermediária um, vinte e três neurônios na camada intermediária dois e quatro saídas, a Tabela 17 contém todas as informações da topologia RNA utilizada.

Tabela 17 - Características da topologia RNA para classificação de faltas

Taxa de aprendizado (η)	0,1
Número máximo de épocas	3000
Erro final desejado (ϵ)	1×10^{-4}
Entradas	3
Número de neurônios na camada intermediária 1	14
Número de neurônios na camada intermediária 2	23
Número de neurônios na camada de saída	4
Função de ativação das camadas intermediárias	Tangente hiperbólica
Função de ativação da camada de saída	Linear

A Figura 29 a seguir contém os resultados obtidos com a aplicação desta topologia de classificação, vale salientar que as saídas binárias que representam cada tipo de falta estão dispostas na Tabela 8, e que as leituras das saídas da RNA de classificação foram realizadas do *bit* mais significativo para menos significativos.

Figura 29 - Resultados obtidos com a topologia de classificação de faltas quanto às fases envolvidas



Fonte: Autoria própria.

Observando os resultados obtidos através da utilização da RNA para classificação de faltas, verificou-se que dos 134 casos utilizados como teste, somente um dos casos foi classificado como sendo a falta errada, o algoritmo obteve, portanto 97,22% de acertos nos casos de faltas ABT, para os demais tipos de faltas a precisão de 100% e 99,25% de acertos em um cenário que avalia todos os tipos de faltas. Com base nos dados obtidos a partir do emprego desta topologia, pode-se concluir que o seu resultado foi satisfatório, tendo em vista que a rede classificou incorretamente um único caso de ocorrência de faltas, do tipo ABT.

Com a aplicação do algoritmo exposto no item (3.2.1 Algoritmo de escolha da melhor topologia RNA dependendo das entradas utilizadas), definiu-se que a melhor topologia RNA para ser aplicada neste caso foi a 3-22-1, ou seja, três entradas, vinte e dois neurônios na camada intermediária e uma saída. Como entrada serão utilizados os módulos dos fasores fundamentais das correntes obtidas no terminal local do sistema em questão. A Tabela 18 contém todas as informações da topologia RNA utilizada.

Tabela 18 - Características da topologia RNA 5

Taxa de aprendizado (η)	0,1
Número máximo de épocas	3000
Erro final desejado (ϵ)	1×10^{-4}
Entradas	3
Número de neurônios na camada intermediária 2	22
Número de neurônios na camada de saída	1
Função de ativação das camadas intermediária	Tangente hiperbólica
Função de ativação da camada de saída	Linear

A Tabela 19 mostra os resultados obtidos a partir da aplicação da topologia RNA 5 nos casos classificados como faltas AB, ABC, ABT e AT.

Tabela 19 - Resultados obtidos com a aplicação da topologia RNA 5

Tipo de falta	Erro máximo (%)	Erro mínimo (%)	Erro médio (%)
AB	1,4536%	0,1041%	0,5291%
ABC	1,1958%	0,1075%	0,6378%
ABT	1,3216%	0,1018%	0,6393%
AT	0,9744%	0,1218%	0,5607%

Constata-se através das simulações, que o maior erro não chega a 1,5% do comprimento total da linha de transmissão, erros acima de 1% não chegam a 3% dos casos, erros inferiores a 1% representam 97% de todos os casos, e ainda 42% dos casos representam erro menor 0,5%. Observa-se ainda que os erros relativos médios para cada tipo de falta não superam 0,7% do comprimento total da linha de transmissão.

A partir dos dados obtidos, pode-se considerar que os algoritmos utilizados apresentaram resultados satisfatórios, vale salientar que não houve impacto com as interferências dos tipos de faltas, resistência de faltas, ângulos de incidência bem como a distância das faltas na estimação de distância das faltas. Com uma breve comparação entre os resultados obtidos pelo algoritmo RNA 1 e os resultados obtidos com a aplicação do algoritmo RNA 2, pode-se observar a maior eficácia do algoritmo RNA 2, pois após a classificação das faltas e com a separação das mesmas para topologias específicas há uma redução na complexidade do problema de aplicação.

5 CONCLUSÃO

Este trabalho apresentou a aplicação de redes neurais artificiais para localização de faltas em linhas de transmissão. Desta maneira o objetivo foi atingido de duas maneiras distintas, a primeira delas foi empregando topologias de redes neurais artificiais atuando diretamente na localização das faltas na LT, sem distinguir nenhum tipo de falta. A outra forma foi aplicando um algoritmo de classificação de faltas baseado em uma topologia RNA e a partir destas classificações a localização das faltas com topologias separadas e dedicadas à cada tipo de falta.

O método generalista, definido anteriormente como algoritmo RNA 1, mostrou-se bastante satisfatório frente aos diversos tipos de faltas, sem a necessidade de informações como, tipo de falta, resistência de falta ou ângulo de incidência de falta. Com a aplicação de diversos grupos de entradas diferentes, a utilização das correntes de ambos os terminais da linha de transmissão se mostrou a mais eficiente ante aos demais grupos de entrada.

Já o método de localização de faltas com módulo de classificação mostrou-se com resultados satisfatórios em ambas aplicações, tanto para o módulo de classificação, que obteve índice de acerto superior aos 99%, quanto às topologias utilizadas para localização de faltas, que mantiveram grande precisão estimativa de distância das faltas. Vale ressaltar que este método independe de informações como resistência de falta e ângulo de incidência de falta.

A partir dos testes realizados e resultados obtidos pelas topologias RNA, pode-se confirmar o bom desempenho de redes neurais artificiais aplicadas na localização de faltas em linhas de transmissão.

6 PERSPECTIVAS PARA TRABALHOS FUTUROS

Os resultados obtidos neste trabalho, mostram o bom desempenho das redes neurais artificiais aplicadas na localização de faltas em linhas de transmissão. Tendo em vista a continuação dos estudos relacionados a esta aplicação, maiores estudos podem ser realizados, como:

- Aumentar o banco de dados, visando aumentar os casos de faltas, alterando as fases envolvidas na falta, resistência de falta e ângulos de incidência de falta.
- Utilizar para obtenção dos dados de treinamento e testes um Sistema de transmissão com mais de dois terminais, e/ou sistemas com derivações.
- Utilizar como entrada para as topologias de redes neurais artificiais dados a partir de janelamentos.

REFERÊNCIAS

SILVA, M. **Implementação de um localizador de faltas híbrido para linhas de transmissão com três terminais baseado na Transformada *Wavelet***. Tese de Doutorado. Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2008.

COURY, Denis V.; OLESKOVICZ, Mário; GIOVANINI, Renan. **Proteção Digital de Sistemas Elétricos de Potência: dos Relés Eletromecânicos aos Microprocessadores Inteligentes**. São Carlos, SP: EESC-USP, 2007.

JORGE, D. C.; COURY, D. V.; CARVALHO, A. C. P. L. F. de. **Localização de faltas em linhas de transmissão de energia elétrica utilizando reconhecimento de padrões**. IV Congresso Brasileiro de Redes Neurais. São José dos Campos, SP, p.61-66, jul. 1999.

GRACIA, J.; MAZÓN, A. J.; ZAMORA, I. **Best ANN Structures for Fault Location in Single and Double-Circuit Transmission Lines**. IEEE Transactions on Power Delivery, v. 20, n. 4, out. 2005.

ABDOLLAHI, A.; SEYEDTABAI, S. **Transmission line fault location estimation by Fourier & Wavelet transforming using ANN**. The 4th International Power Engineering and Optimization Conf. (PEOCO2010), p. 573-578, jun. 2010.

Ministério de Minas e Energia. **Boletim Mensal de Energia**. Janeiro, 2017.

Operador Nacional do Sistema Elétrico. **Sobre o SIN: O SIN em números**. 2017.

MAMEDE FILHO, João; MAMEDE, Daniel R. **Proteção de Sistemas Elétricos de Potência**. Rio de Janeiro: LTC, 2011.

GOMES, A. de S. **Detecção e Classificação de faltas em linhas de transmissão utilizando análise funcional e inteligência computacional**. Dissertação de Mestrado, Escola de Engenharia, Universidade Federal de Minas Gerais, Belo Horizonte – MG, 2011.

MAGALHÃES, C. H. N.; GOUVÊA, M. R.; SILVA, F. A. T.; TAHAN, C. M. V.; ARAUJO FILHO, L. G. C. **Avaliação do custo social de interrupção do fornecimento de energia elétrica do lado da demanda no estado de São Paulo**. XVI – Seminário Nacional de Produção e Transmissão de Energia Elétrica, GPC/019, Campinas-SP, 2001.

ENERGISA. **NORMA DE DISTRIBUIÇÃO UNIFICADA – NDU-017: PROTEÇÃO DA DISTRIBUIÇÃO**. Julho, 2012.

SILVA, M. **Localização de faltas em linhas de transmissão utilizando a teoria de ondas viajantes e transformada *wavelet***. Dissertação de Mestrado. Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2003.

GIRGIS, A. A.; HART, D. G.; PETERSON, W. L. ***Fault location technique for two- and three-terminal lines.*** Department of Electrical and Computer Engineering, Clemson University, South Carolina, 1992.

LAIN, B. and SALAMA, M. M. A. ***An overview of digital fault location algorithms for the power transmission line protection based on steady-state phasor approaches.*** Electric Machines and Power Systems, v.24, p.83-115, Taylor & Francis, (1996).

LIMA, D. A. C. ***Localização de faltas em sistemas de transmissão de energia elétrica baseada na impedância aparente: algoritmo utilizando dados de um terminal.*** Dissertação de Mestrado. Universidade Federal do Rio Grande do Sul, Porto Alegre, 2013.

DI SANTO, S. G.; PEREIRA, C. E.M.; ZANETTA JR. L.C. ***Localização de faltas em linhas de transmissão com múltiplas derivações utilizando dados de somente dois terminais.*** Revista Controle & Automação, v.22, n.2, p.144-156, março e abril, 2011.

RAYBOLT, A. C. S. ***Localização de faltas em linhas de transmissão em circuito duplo utilizando redes neurais artificiais.*** Dissertação de Mestrado. Universidade Federal do Rio de Janeiro, Rio de Janeiro-RJ, 2011.

OLIVEIRA, D. S. ***Classificação e localização de faltas em sistemas de transmissão com compensação série utilizando redes neurais artificiais.*** Dissertação de Mestrado. Universidade Federal do Rio de Janeiro, Rio de Janeiro-RJ, 2016.

VON ZUBEN, F. J.; CASTRO, L. N. ***Redes Neurais Artificiais.*** Unicamp, Campinas. Disponível em:<ftp.dca.fee.unicamp.br>, último acesso: 18 de agosto de 2017.

SILVA, Ivan N.; SPATTI, Danilo H.; FLAUZINO, Rogério A. ***Redes Neurais Artificiais para engenharia e ciências aplicadas.*** São Paulo: Artliber Editora Ltda. 2010.

HAYKIN, Simon. ***Redes Neurais: Princípios e prática.*** 2ª ed. Porto Alegre: ARTMED® Editora S/A, 2001.

COPPIN, Ben. ***Inteligência artificial.*** Rio de Janeiro: LTC, 2012.

RUMELHART, D. E.; HINTON, G. E.; WILLIAMS, R. J. ***Learning Internal representations by error propagation.*** In: Parallel Distributed Processing, vol. 1, chapter 8. MIT Press, Cambridge, Massachusetts, USA, 1986.

HAGAN, M. T.; MENHAJ, M. B. ***Training Feedforward networks with the Marquardt algorithm.*** IEEE. v.5, n. 6, p. 989-993, 1994.

MAFFRA, Fabíola. A.; GATTASS, Marcelo. ***Uma implementação do método de Levenberg-Marquardt em C.*** PUC-Rio, Rio de Janeiro, 2008.

PRIKLER, L.; HOIDALEN, H. K. ***ATPDraw: Users Manual.*** Norwegian University of technology Trondheim, Norway, november, 2009.

OLESCOVICZ, M. **Aplicação de redes neurais artificiais na proteção de distância.** Tese de Doutorado, Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos-SP, 2001.