

INSTITUTO FEDERAL DE MINAS GERAIS
CURSO DE ENGENHARIA ELÉTRICA
SAMIR WALKER FERNANDES

REDES NEURAIS ARTIFICIAIS APLICADAS NA ANÁLISE DE FALTAS EM LINHAS
DE TRANSMISSÃO

FORMIGA – MG
2015

SAMIR WALKER FERNANDES

REDES NEURAS ARTIFICIAIS APLICADAS NA ANÁLISE DE FALTAS EM LINHAS
DE TRANSMISSÃO

Trabalho de Conclusão de Curso
apresentado ao Curso de Engenharia Elétrica
do Instituto Federal de Minas Gerais como
requisito para obtenção do título de bacharel
em Engenharia Elétrica.

Orientador: Prof. Msc. Renan Souza Moura

FORMIGA – MG

2015

Samir Walker Fernandes

Redes neurais artificiais aplicadas na análise de faltas em linhas de transmissão

Trabalho de Conclusão de Curso
apresentado ao Curso de Engenharia Elétrica
do Instituto Federal de Minas Gerais como
requisito para obtenção do título de bacharel
em Engenharia Elétrica.

BANCA EXAMINADORA

Prof. MSc. Renan Souza Moura

Prof. MSc. José Antônio Moreira de Rezende

Prof. MSc. Diego Melo da Silva

Formiga, Julho de 2015.

Dedico este trabalho aos meus familiares.

AGRADECIMENTOS

Agradeço a Deus.

Aos meus pais, Ângela e Ademir, e à minha irmã, Samira, pelo apoio, compreensão, incentivo e amor incondicional durante toda minha vida acadêmica.

Ao meu professor orientador, Msc. Renan Souza Moura, pelo apoio e contribuição durante a realização deste trabalho.

A todos os professores do curso de Engenharia Elétrica, e a todos os funcionários do Instituto Federal, Ciência e Tecnologia de Minas Gerais, pela contribuição em minha formação. Em especial ao professor Msc. André Roger Rodrigues pelos conselhos durante a realização deste trabalho.

A CAPES, pelo apoio financeiro para a realização do intercâmbio no programa Ciência sem Fronteiras na *Ohio Northern University*, Ada-OH, Estados Unidos.

Aos professores do colégio de engenharia da *Ohio Northern University*. Em especial ao professor Dr. Khalid Al-Olimat pela orientação durante o intercâmbio e pela influência na escolha de minha carreira profissional.

A todos meus amigos e familiares pelo apoio e incentivo durante todo o período da faculdade. Em especial ao meu primo, Luís Eduardo, pelos valiosos conselhos durante minha vida acadêmica.

RESUMO

O Sistema Elétrico de Potência é o responsável pelo fornecimento de energia elétrica a todos os tipos de consumidores a ele conectados, deve apresentar alto grau de confiabilidade, garantindo continuidade no fornecimento da energia elétrica dentro dos padrões de qualidade estabelecidos por normas. Qualquer sistema elétrico está sujeito à ocorrência de faltas, e dentre os vários componentes do mesmo, a linha de transmissão é o mais vulnerável. Faltas em linhas de transmissão podem ocasionar em desligamentos não programados de consumidores a ela conectados, impactando negativamente na confiabilidade do sistema e ocasionando em penalidades para a empresa transmissora. Para mitigar este problema, sistemas de proteção são empregados. Relés digitais vêm sendo amplamente utilizados em sistemas de proteção de linhas de transmissão, nestes, podem ser utilizados métodos baseados em sistemas inteligentes, tais como lógica *fuzzy*, redes neurais artificiais e redes *neurofuzzy*. Redes neurais artificiais têm apresentado excelentes resultados quando utilizadas em métodos de análise de faltas, pois possuem capacidade de aprendizado, generalização e robustez. Este trabalho apresenta um estudo da arte de redes neurais aplicadas na análise de faltas em linhas de transmissão, e demonstra a aplicabilidade das mesmas através da análise de três trabalhos sobre o tema, os quais apresentaram resultados satisfatórios por meio de dados reais e simulados.

Palavras chave: Análise de faltas; linhas de transmissão; redes neurais artificiais.

ABSTRACT

Power System's purpose is to delivery energy to all types of costumers that are linked to it; it must be reliable in order to deliver energy continually in certain levels established by quality standards. Energy systems are susceptible to faults, and among their components, transmission lines are the most vulnerable one. Faults in transmission lines may lead to unexpected outages, which have negative impact at the system reliability, and can cause penalties for the utility. In order to mitigate this problem, protection systems are applied. Digital relays have been applied in transmission lines protection systems; methods using intelligent systems, such as fuzzy logic, artificial neural networks and neurofuzzy systems can be applied in digital relaying. Fault analysis using artificial neural networks have shown great results due their strength, learning and generalization capabilities. This work presents artificial neural networks applied on fault analysis in transmission lines, and shows their applicability through the analysis of three papers about the subject, which have shown satisfactory results with real and simulated data.

Keywords: Fault analysis; transmission lines; artificial neural networks.

LISTA DE FIGURAS

Figura 2.1: Torre de linha de transmissão aérea.....	16
Figura 2.2: Quadripolo de uma linha de transmissão.....	17
Figura 2.3: Modelo de linha curta.....	17
Figura 2.4: Modelo de linha média.....	18
Figura 2.5: Modelo de linha longa.....	19
Figura 2.6: Diagrama simplificado de uma falta trifásica balanceada.....	21
Figura 2.7: Diagrama simplificado de uma falta fase-terra (AT).....	21
Figura 2.8: Diagrama simplificado de uma falta fase-fase (AB).....	21
Figura 2.9: Diagrama simplificado de uma falta fase-fase-terra (ABT).....	22
Figura 2.10: Neurônio humano.....	26
Figura 2.11: Modelo do neurônio artificial.....	29
Figura 2.12: Função Linear.....	31
Figura 2.13: Função rampa.....	31
Figura 2.14: Função degrau.....	32
Figura 2.15: Função sigmoideal.....	32
Figura 2.16: Rede direta de camada única.....	33
Figura 2.17: Rede direta de camadas múltiplas.....	35
Figura 2.18: Rede neural recorrente com neurônios ocultos.....	36
Figura 2.19: Aprendizado supervisionado.....	38
Figura 2.20: Aprendizado não supervisionado.....	38
Figura 3.1: Método proposto.....	41
Figura 3.2: Topologia do sistema elétrico analisado.....	41
Figura 3.3: Diagrama de blocos do método proposto.....	47
Figura 3.4: Representação simplificada do sistema analisado.....	48
Figura 3.5: Sistema de transmissão de dois terminais.....	52
Figura 3.6: Sistema de transmissão modelado no ATP.....	53
Figura 3.7: EMQ para diferentes topologias de RNA.....	54
Figura 3.8: Arquitetura da RNA utilizada.....	54
Figura 4.1: Sistema avaliado no estudo de caso.....	60
Figura 4.2: Tempo de propagação da primeira e segunda onda viajante.....	61

LISTA DE TABELAS

Tabela 2.1: Classificação das linhas de transmissão em função do comprimento....	16
Tabela 3.1: Respostas esperadas por parte das RNAs.	44
Tabela 3.2: Esquema de codificação da saída desejada da RNA.....	51
Tabela 4.1: Respostas corretas e tempo de processamento para os módulos de detecção, classificação e localização integrados.	56
Tabela 4.2: Registros simulados para avaliação do método.	57
Tabela 4.3: Resultados para LTs de 138 kV.	58
Tabela 4.4: Resultados para LTs de 230 kV.	58
Tabela 4.5: Resultados para LTs de 500 kV.	59
Tabela 4.6: Erros obtidos na fase de teste da RNA em diferentes localizações em 10 rodadas de treinamento.	62
Tabela 4.7: Erros obtidos na fase de teste da RNA em diferentes localizações em 10 rodadas de treinamento.	62
Tabela 4.8: Condições de faltas simuladas.....	63
Tabela 4.9: Erros obtidos considerando as faltas simuladas.	63

SUMÁRIO

1. INTRODUÇÃO	12
1.1. OBJETIVOS.....	13
1.2. JUSTIFICATIVA.....	13
1.3. ESTRUTURA DO TRABALHO	14
2. REFERENCIAL TEÓRICO	15
2.1. LINHAS DE TRANSMISSÃO	15
2.1.1. INTRODUÇÃO	15
2.1.2. MODELAGEM.....	16
2.2. FALTAS EM LINHAS DE TRANSMISSÃO	20
2.2.1. INTRODUÇÃO	20
2.2.2. CAUSAS	22
2.2.3. DIAGNÓSTICO DE FALTAS EM LINHAS DE TRANSMISSÃO	23
2.3. REDES NEURAIS ARTIFICIAIS.....	25
2.3.1. INTRODUÇÃO	25
2.3.2. O CÉREBRO HUMANO	25
2.3.3. HISTÓRICO	27
2.3.4. O MODELO DO NEURÔNIO	29
2.3.5. FUNÇÕES DE ATIVAÇÃO.....	30
2.3.6. ARQUITETURAS DE REDES.....	33
2.3.7. APRENDIZADO	36
3. ANÁLISE DE FALTAS EM LINHAS DE TRANSMISSÃO ATRAVÉS DE RNAS ...	40
3.1. PRIMEIRO MÉTODO ANALISADO.....	40
3.1.1. CONSIDERAÇÕES INICIAIS.....	40
3.1.2. IMPLEMENTAÇÃO	43
3.2. SEGUNDO MÉTODO ANALISADO.....	46
3.2.1. CONSIDERAÇÕES INICIAIS.....	46
3.2.2. IMPLEMENTAÇÃO	49
3.3. TERCEIRO MÉTODO ANALISADO	51
3.3.1. CONSIDERAÇÕES INICIAIS.....	51
3.3.2. IMPLEMENTAÇÃO	53
4. RESULTADOS E DISCUSSÕES	55
4.1. ANÁLISE DOS RESULTADOS DO PRIMEIRO MÉTODO	55

4.2. ANÁLISE DOS RESULTADOS DO SEGUNDO MÉTODO.....	57
4.2. ANÁLISE DOS RESULTADOS DO TERCEIRO MÉTODO	61
5. CONCLUSÕES	65
5.1. TRABALHOS FUTUROS	66
REFERÊNCIAS.....	67

1. INTRODUÇÃO

O Sistema Elétrico de Potência (SEP) é o responsável pelo fornecimento da energia elétrica consumida em todo o país; é composto por vários componentes, como usinas geradoras de energia elétrica, subestações, transformadores, linhas de transmissão, linhas de distribuição, dentre outros, cada qual com uma função específica e definida. O objetivo de um SEP é fornecer energia com um determinado padrão de qualidade aos consumidores, sejam consumidores industriais, comerciais ou residenciais (INÁCIO, 2010).

Penalidades podem ser impostas às empresas transmissoras de energia, caso certos padrões não sejam atendidos. Sendo assim, é esperado que um SEP apresente alto índice de confiabilidade na continuidade do fornecimento da energia elétrica, garantindo então, qualidade no fornecimento de energia ao consumidor e evitando descontos na receita anual da empresa transmissora. No entanto, faltas em um SEP podem ocasionar em desligamentos não programados de seus componentes, o que pode afetar sua confiabilidade (INACIO, 2010; ROCHA DE OLIVEIRA, 2005).

Todo SEP é susceptível à ocorrência de faltas, e dentre todos os elementos que constituem o mesmo, a linha de transmissão (LT) é o mais vulnerável. Faltas permanentes em LTs podem provocar interrupção no fornecimento de energia (INÁCIO, 2010; OLESKOVICZ et al., 2003). Os sistemas de proteção e seus componentes são os responsáveis por proteger as LTs, estes, tem como objetivo realizar a remoção imediata do trecho com falta, através da atuação apropriada de seus disjuntores, minimizando a interrupção do fornecimento de energia elétrica e limitando os danos aos equipamentos (OLESKOVICZ et al., 2003).

Disjuntores, transdutores e relés são exemplos dos elementos que compõe um sistema de proteção. O desenvolvimento de sistemas de proteção vem acontecendo ao longo dos anos; relés eletromecânicos, de estado sólido, e recentemente digitais, vêm sendo utilizados para a proteção de LTs (INÁCIO, 2010; OLESKOVICZ, 2003).

Relés digitais executam algoritmos que processam sinais de entrada com o intuito de produzir uma saída digital. Com o avanço dos estudos sobre algoritmos utilizados em relés digitais para análise de faltas em LTs, métodos baseados em análise de sinais e métodos baseados em sistemas inteligentes vêm se destacando. Dentre os métodos de análise de faltas por sistemas inteligentes, incluem-se as Redes Neurais Artificiais (RNAs). A análise de faltas, incluindo sua detecção, classificação e localização em LTs por meio de RNAs têm apresentado excelente desempenho, devido sua capacidade de aprendizado, generalização e robustez (INÁCIO, 2010).

1.1. OBJETIVOS

Este trabalho tem como objetivo demonstrar a aplicabilidade das redes neurais artificiais na análise de faltas em linhas de transmissão e servir como referencial para trabalhos futuros envolvendo o tema. Especificamente, métodos de detecção, classificação e localização de faltas em linhas de transmissão são abordados através da análise de três trabalhos sobre o tema.

1.2. JUSTIFICATIVA

Visto que, o SEP deve apresentar um alto grau de confiabilidade, e as redes neurais vem se mostrando cada vez mais capazes de realizar tarefas como detecção, classificação e localização de faltas em linhas de transmissão, de maneira rápida e precisa, este trabalho se fundamenta na necessidade do entendimento da metodologia de redes neurais para a implementação de métodos de análise de faltas baseados em sistemas inteligentes.

1.3. ESTRUTURA DO TRABALHO

Além deste capítulo de introdução, este trabalho contém mais quatro capítulos.

No Capítulo 2 são apresentadas as fundamentações teóricas sobre linhas de transmissão, faltas em linhas de transmissão e redes neurais artificiais.

No Capítulo 3 são apresentadas as considerações iniciais e implementações dos trabalhos escolhidos para demonstrar a aplicabilidade das redes neurais na análise de faltas.

No Capítulo 4 são apresentados os resultados e discussões referentes às análises dos trabalhos descritos no capítulo anterior.

Por fim, no Capítulo 5 são apresentadas as conclusões, bem como as sugestões para trabalhos futuros.

2. REFERENCIAL TEÓRICO

Neste capítulo são apresentados de maneira detalhada, tópicos referentes a linhas de transmissão, incluindo seu modelamento, faltas e suas causas, e análise de faltas. Redes neurais artificiais e sua metodologia também são abordadas.

2.1. LINHAS DE TRANSMISSÃO

2.1.1. INTRODUÇÃO

Linhas de transmissão (LTs) são importantes elementos dos Sistemas Elétricos de Potência (SEP), são responsáveis pela transferência de energia elétrica entre centros de produção e centros de consumo, e também pela interligação entre centros de produção (FUCHS, 1977). LTs são os elementos do SEP mais susceptíveis à ocorrência de faltas, devido suas características físicas (LOPES et al., 2014; OLESKOVICZ et al., 2003).

A prática demonstra que faltas entre um só condutor e a terra representam cerca de 70% a 80% das faltas nas linhas de transmissão, e as faltas trifásicas representam algo em torno de 5% (OLESKOVICZ et al., 2003). A maioria das faltas nas LTs é transitória, porém, caso uma falta perdure, esta pode se tornar permanente (GOMES, 2006). Sistemas de proteção eficientes são essenciais para que ocorra rapidamente o isolamento das faltas nas LTs, garantindo assim, a continuidade de funcionamento do sistema (INÁCIO, 2010).

Linhas de transmissão são basicamente divididas em dois grupos: linhas aéreas de cabos nus ou linhas subterrâneas de cabos isolados. As linhas aéreas de cabos nus ainda se dividem em: linhas de circuito simples ou circuito duplo. A transmissão de energia elétrica pode ser em corrente contínua (CC) ou corrente alternada (CA). Na maioria dos casos, quando em corrente alternada, as linhas de transmissão são trifásicas (INÁCIO, 2010).

As linhas de transmissão aéreas, que são objetos de estudo deste trabalho, são basicamente constituídas por: cabos condutores, que são os elementos ativos de uma LT; cabos para-raios, que são os cabos localizados acima dos cabos condutores, conectados à torre e ao potencial terra, que tem como objetivo proteger os condutores das fases contra descargas atmosféricas; isoladores, que são os elementos responsáveis por isolar os cabos de fase da estrutura da torre, o número de isoladores a ser utilizado é determinado pela tensão da linha; e a torre, que basicamente, é a estrutura de sustentação (GOMES, 2006; INÁCIO, 2010). A Figura 2.1 representa uma torre de linha de transmissão aérea.




Figura 2.1: Torre de linha de transmissão aérea.

Fonte: (SAADAT, 2010)

2.1.2. MODELAGEM

Linhas de transmissão podem ser modeladas através dos modelos de linha curta, linha média ou linha longa. A classificação do modelo da linha depende do comprimento da mesma, como pode ser observado na Tabela 2.1.

Tabela 2.1: Classificação das linhas de transmissão em função do comprimento.

Classe	Comprimento (L)
Curta	$L \leq 80 \text{ km}$
Média	$80 \text{ km} \leq L \leq 250 \text{ km}$
Longa	$L \geq 250 \text{ km}$

Fonte: (INÁCIO, 2010).

Uma LT pode ser representada como um quadripolo, Figura 2.2. Sua solução é representada pela Equação 2.1 e apresentada na forma matricial na Equação 2.2.




Figura 2.2: Quadripolo de uma linha de transmissão

Fonte: (SAADAT, 2010)

$$\begin{cases} V_S = AV_R + BI_R \\ I_S = CV_R + DI_R \end{cases} \quad \text{Equação 2.1}$$

$$\begin{pmatrix} V_S \\ I_S \end{pmatrix} = \begin{pmatrix} A & B \\ C & D \end{pmatrix} \begin{pmatrix} V_R \\ I_R \end{pmatrix} \quad \text{Equação 2.2}$$

Os valores das variáveis A, B, C e D dependem do modelo de linha utilizado.

- MODELO DE LINHA CURTA

O modelo de linha de transmissão curta é apresentado na Figura 2.3. Neste, a resistência série e indutância série são considerados, e a capacitância é desconsiderada. As Equações 2.3 e 2.4 representam a solução para o circuito da Figura 2.3 (SAADAT, 2010).




Figura 2.3: Modelo de linha curta

Fonte: (SAADAT, 2010)

$$\begin{cases} V_S = V_R + ZI_R \\ I_S = I_R \end{cases} \quad \text{Equação 2.3}$$

$$\begin{pmatrix} V_S \\ I_S \end{pmatrix} = \begin{pmatrix} \mathbf{1} & \mathbf{Z} \\ \mathbf{0} & \mathbf{1} \end{pmatrix} \begin{pmatrix} V_R \\ I_R \end{pmatrix} \quad \text{Equação 2.4}$$

Onde,

V_S Tensão no transmissor;

V_R Tensão no receptor;

I_S Corrente no transmissor;

I_R Corrente no receptor;

Z Impedância total da linha (produto da impedância série e do comprimento total da linha).

- MODELO DE LINHA MÉDIA

O modelo de linha média é apresentado na Figura 2.4. O mesmo difere-se do modelo de linha curta pela inserção da capacitância; para tal, metade da admitância *shunt* é adicionada em cada um de seus terminais. As Equações 2.5 e 2.6 representam a solução para o circuito da Figura 2.4. O modelo de linha média é conhecido como π -nominal (SAADAT, 2010).




Figura 2.4: Modelo de linha média.

Fonte: (SAADAT, 2010).

$$\begin{cases} V_S = \left(1 + \frac{ZY}{2}\right) V_R + Z I_R \\ I_S = Y \left(1 + \frac{ZY}{4}\right) V_R + \left(1 + \frac{ZY}{2}\right) I_R \end{cases} \quad \text{Equação 2.5}$$

$$\begin{pmatrix} V_S \\ I_S \end{pmatrix} = \begin{pmatrix} \left(1 + \frac{ZY}{2}\right) & Z \\ Y \left(1 + \frac{ZY}{4}\right) & \left(1 + \frac{ZY}{2}\right) \end{pmatrix} \begin{pmatrix} V_R \\ I_R \end{pmatrix} \quad \text{Equação 2.6}$$

Onde,

V_S Tensão no transmissor;

V_R Tensão no receptor;

- I_S Corrente no transmissor;
 I_R Corrente no receptor;
 Z Impedância total da linha (produto da impedância série e do comprimento total da linha).
 Y Admitância *shunt* total da linha (produto da admitância *shunt* e do comprimento total da linha).

- MODELO DE LINHA LONGA

O modelo de linha longa é apresentado na Figura 2.5. Neste, para obtenção de resultados mais precisos, os parâmetros de linhas não são considerados como sendo concentrados, e sim distribuídos uniformemente ao longo do comprimento da linha. A solução para o circuito da Figura 2.5 é obtida através da solução das Equações 2.7 e 2.8, o passo-a-passo pode ser encontrado em Saadat (2010), a solução é apresentada na Equação 2.9.




Figura 2.5: Modelo de linha longa.

Fonte: (SAADAT, 2010).

$$\frac{dV(x)}{dx} = zI(x) \quad \text{Equação 2.7}$$

$$\frac{dI(x)}{dx} = yV(x) \quad \text{Equação 2.8}$$

$$V(x) = \frac{e^{\gamma x} + e^{-\gamma x}}{2} V_R + Z_C \frac{e^{\gamma x} - e^{-\gamma x}}{2} I_R$$

$$I(x) = \frac{1}{Z_C} \frac{e^{\gamma x} - e^{-\gamma x}}{2} V_R + \frac{e^{\gamma x} + e^{-\gamma x}}{2} I_R$$

$$\begin{pmatrix} V_S \\ I_S \end{pmatrix} = \begin{pmatrix} \cosh \gamma l & Z_C \sinh \gamma l \\ \frac{1}{Z_C} \sinh \gamma l & \cosh \gamma l \end{pmatrix} \begin{pmatrix} V_R \\ I_R \end{pmatrix} \quad \text{Equação 2.9}$$

Onde,

V_S Tensão no transmissor;

V_R Tensão no receptor;

I_S Corrente no transmissor;

I_R Corrente no receptor;

Z_C Impedância característica da linha ($Z_C = \sqrt{\frac{z}{y}} \Omega$)

γ Constante de propagação ($\gamma = \sqrt{zy} \text{ m}^{-1}$)

2.2. FALTAS EM LINHAS DE TRANSMISSÃO

2.2.1. INTRODUÇÃO

As faltas no SEP são divididas em dois grupos: faltas trifásicas balanceadas e faltas desbalanceadas. As faltas desbalanceadas, por sua vez, podem ser divididas em: fase-terra (*single line-to-ground*), fase-fase (*line-to-line*) e fase-fase-terra (*double line-to-ground*). O problema de análise de faltas consiste basicamente na determinação de tensões nos barramentos e correntes de linha durante os vários tipos de faltas. O estudo de faltas em um SEP auxilia na seleção e determinação dos dispositivos de proteção e na coordenação da mesma (SAADAT, 2010).

As Figuras 2.6 a 2.9 representam o diagrama simplificado para cada tipo de falta citado anteriormente, onde Z_f representa a impedância da falta.

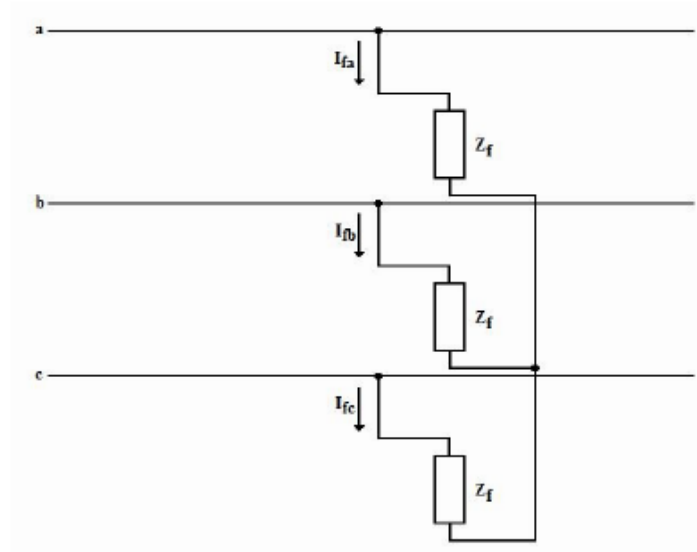


Figura 2.6: Diagrama simplificado de uma falta trifásica balanceada.

Fonte: (INÁCIO, 2010).




Figura 2.7: Diagrama simplificado de uma falta fase-terra (AT).

Fonte: (INÁCIO, 2010).




Figura 2.8: Diagrama simplificado de uma falta fase-fase (AB).

Fonte: (INÁCIO, 2010).

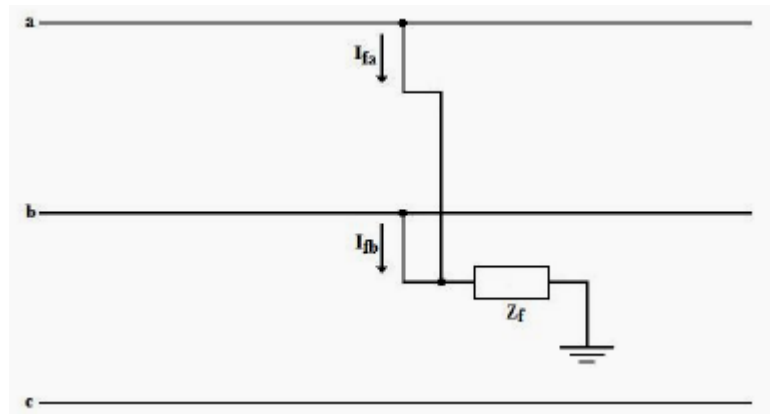


Figura 2.9: Diagrama simplificado de uma falta fase-fase-terra (ABT).

Fonte: (INÁCIO, 2010).

2.2.2. CAUSAS

Descargas atmosféricas, queimadas nas proximidades das linhas, árvores de grande porte nas proximidades das linhas, perda de isolamento e falhas mecânicas são algumas das causas de faltas em linhas de transmissão.

As faltas provenientes de descargas atmosféricas são a maior causa de desligamentos não programados em linhas de transmissão (LESSA, 2012). Sobretensões geradas pela descarga atmosférica são suficientemente elevadas a ponto de provocar falhas nos isoladores da linha, ou entre os condutores da mesma, o que acarreta no rompimento de seu isolamento. Descargas atmosféricas podem ocorrer de forma direta, quando caem sobre o equipamento, ou de forma indireta, quando caem nas proximidades das linhas de transmissão (GOMES, 2006; LESSA, 2012).

Quando acontece um incêndio nas proximidades das linhas de transmissão, o calor decorrente do mesmo faz com que a rigidez dielétrica do ar situado entre os condutores e entre os condutores e o solo diminua, podendo ocasionar faltas fase-fase e fase-terra (GOMES, 2006).

Árvores de grande porte nas proximidades das linhas de transmissão também podem causar faltas, permanentes ou transitórias. Faltas permanentes podem ser provocadas por quedas de árvores sobre os condutores da linha, e faltas transitórias

podem ser provocadas pela aproximação e contato de árvores pela ação do vento (LESSA, 2012).

As perdas de isolamento das linhas podem ocorrer devido à poluição, quando resíduos ficam impregnados na superfície dos isoladores, o que acarreta em um caminho de baixa impedância até a estrutura metálica da linha, também podem ocorrer por vandalismo e pela ação de animais (LESSA, 2012).

As falhas mecânicas podem ser causadas principalmente pelos os seguintes fatores: rompimento dos condutores, ocasionado por sobrecargas, descargas elétricas ou fadiga; rompimento da cadeia de isoladores, ocasionado pela eletrocorrosão dos pinos; encaixe inadequado; deterioração das cadeias de isoladores; sobrecarga mecânica e queda da estrutura da linha (LESSA, 2012).

2.2.3. DIAGNÓSTICO DE FALTAS EM LINHAS DE TRANSMISSÃO

Diversos métodos de diagnóstico de faltas em linhas de transmissão foram criados ao longo do desenvolvimento das tecnologias de proteção de SEP. Estes métodos podem ser divididos em: métodos convencionais, métodos baseados em análise de sinais e métodos baseados em sistemas inteligentes.

- MÉTODOS CONVENCIONAIS

Os métodos convencionais utilizam diversos parâmetros para analisar a ocorrência de uma falta em uma LT, sendo tensão e corrente da linha os mais utilizados (INACIO, 2010).

Em geral, na ocorrência de faltas de curto-circuito, as magnitudes das correntes tendem a aumentar e das tensões tendem a diminuir. Além da mudança das magnitudes de corrente e tensão, também podem ocorrer mudanças em outros parâmetros, tais como: ângulo de fase entre tensão e corrente, componentes harmônicas, potência ativa e reativa, frequência, etc. Princípios de operações de relés são baseados na detecção destas mudanças (HOROWITZ; PHADKE, 2008).

Os métodos convencionais são amplamente utilizados em sistemas de proteção de linhas de transmissão. Entretanto, a precisão deste modelo é afetada

por fatores como: distância da falta, resistência da falta, efeitos de reatância, influência de efeitos mútuos nas componentes de sequência zero em linhas paralelas, imprecisão do modelo de linha, dentre outros (INACIO, 2010).

- MÉTODOS BASEADOS EM ANÁLISE DE SINAIS

Os métodos baseados em análise de sinais utilizam os transitórios provocados pela falta na linha de transmissão para realizar o diagnóstico da mesma. A análise no domínio da frequência, das mudanças nos sinais de tensão e corrente devido a uma falta, permite observar que estas mudanças ocorrem tanto na componente fundamental, quanto nas componentes de alta frequência dos sinais. Também é possível observar que a mudança nas componentes de alta frequência acontece de forma mais rápida do que na frequência fundamental, e depende das características da falta. Assim, extraindo-se o espectro dos sinais, torna-se possível o diagnóstico da falta (INACIO, 2010).

Informações como o tipo da falta, localização, direção e duração podem ser encontradas nas componentes de alta frequência dos sinais gerados pela falta. Após a extração e os sinais passarem por filtragem analógica, algoritmos rápidos de processamento de sinais são utilizados para a realização de identificação da falta, os mais utilizados são a Transformada de Fourier e a Transformada *Wavelet* (TW) (INACIO, 2010).

- MÉTODOS BASEADOS EM SISTEMAS INTELIGENTES

Os métodos baseados em sistemas inteligentes se fundamentam no reconhecimento de padrões (LOPES et al., 2014). Esses métodos utilizam dados extraídos da linha como padrões de entrada para o sistema inteligente. Redes Neurais Artificiais, Lógica *Fuzzy* ou Lógica Nebulosa e Redes *Neurofuzzy* são exemplos de sistemas inteligentes (INACIO, 2010). Redes Neurais Artificiais serão abordadas com detalhes no próximo item deste capítulo, uma vez que, a análise de faltas por meio de redes neurais é o foco deste trabalho.

2.3. REDES NEURAIS ARTIFICIAIS

2.3.1. INTRODUÇÃO

Redes neurais artificiais (RNAs) ou redes neurais como são comumente chamadas, são modelos computacionais baseados nos neurônios naturais e na estrutura do cérebro humano. RNAs são caracterizadas por serem sistemas paralelos distribuídos e serem compostas por nodos ou unidades de processamento simples, os quais são responsáveis pelos cálculos de determinadas funções matemáticas, geralmente não lineares. Os nodos podem ser dispostos em uma ou mais camadas e interligados por um grande número de conexões, na maioria dos casos unidirecionais. Estas conexões podem estar associadas a pesos, os quais são responsáveis por armazenar o conhecimento do modelo e por ponderar a entrada recebida por cada neurônio na rede (BRAGA et al., 2000).

RNAs possuem capacidade computacional adquirida através de aprendizado e generalização. O aprendizado das redes neurais se dá de maneira iterativa; o mesmo está relacionado com a capacidade de adaptação de seus parâmetros como consequência da interação com o meio externo. Por meio desse aprendizado, o desempenho da RNA deve melhorar de maneira gradativa. A generalização de uma rede neural está relacionada à sua capacidade de dar respostas coerentes para dados não apresentados anteriormente. Aprendizado e generalização caminham juntos, uma vez que a generalização é uma consequência do aprendizado (REZENDE, 2005).

2.3.2. O CÉREBRO HUMANO

Estima-se que no cérebro humano contenha algo em torno de 10 bilhões de neurônios, sua célula fundamental, e 60 trilhões de sinapses (BRAGA et al., 2010; HAYKIN, 1999). As sinapses são unidades estruturais e funcionais elementares que medeiam às interações entre os neurônios (HAYKIN, 1999). A estrutura dos

neurônios, topologia de suas conexões e comportamento formam a base para o estudo das RNAs (BRAGA et al., 2010). A sinapse pode impor ao neurônio que a recebe, um sinal de excitação ou inibição, mas não ambos.

Há uma grande variedade de formas e tamanhos de neurônios em diferentes partes do cérebro. A Figura 2.10 representa uma célula piramidal, um dos tipos mais comuns de neurônio do córtex. Este tipo de neurônio recebe seus estímulos através de espinhas dendritais e pode receber dez mil ou mais contatos sinápticos e também se projetar sobre milhares de células-alvo (HAYKIN, 1999).

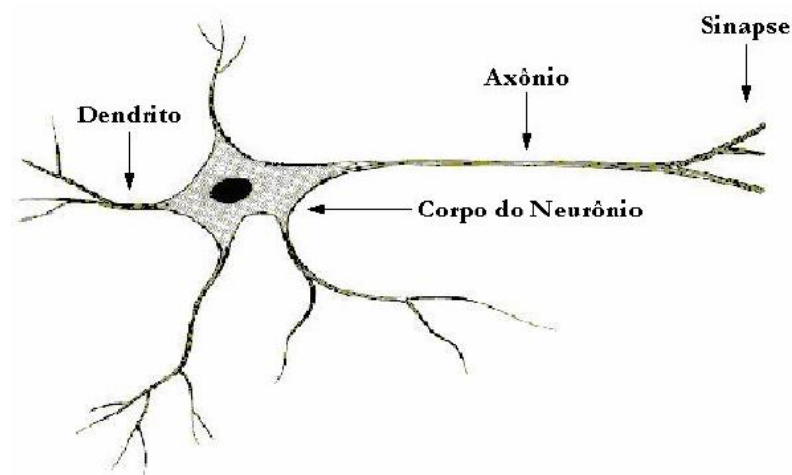


Figura 2.10: Neurônio humano.

Fonte: (ROCHA DE OLIVEIRA, 2005),

Os dendritos recebem os impulsos nervosos, ou informações, que chegam de outros neurônios e os conduzem até o corpo celular, onde serão processados e novos impulsos serão gerados. Os novos impulsos gerados serão transmitidos através do axônio até os dendritos dos neurônios seguintes, pelo meio de contato conhecido como sinapse (BRAGA et al., 2010). O axônio é o meio de transmissão do impulso até a outra extremidade do neurônio. Os axônios podem ser considerados como linhas de transmissão, uma vez que são finos, longos, possuem alta resistência e alta capacitância distribuídas uniformemente ao longo de sua extensão (HAYKIN, 1999).

É válido ressaltar que os neurônios artificiais de uma rede neural são bastante primitivos quando comparados aos neurônios biológicos.

2.3.3. HISTÓRICO

O estudo de redes neurais se deu início devido ao pioneiro trabalho de Warren McCulloch e Walter Pitts (1943), no qual os mesmos desenvolveram o primeiro modelo artificial de um neurônio biológico. Redes lógicas de nodos, novas ideias de máquinas de estados finitos, representações lógicas de várias formas de memória e comportamento, e elementos de decisão limiar, são exemplos de temas que foram abordados no trabalho. McCulloch e Pitts se concentraram mais no desenvolvimento de um modelo de neurônio artificial e na apresentação de suas capacidades computacionais do que em abordar e apresentar técnicas de aprendizado (BRAGA et al, 2010).

Estudos envolvendo o aprendizado foram desenvolvidos alguns anos depois do trabalho de McCulloch e Pitts, o primeiro trabalho foi apresentado por Donald Hebb em 1949. Hebb (1949) mostrou que a plasticidade das redes neurais pode ser obtida através da variação dos pesos na entrada de cada nodo. E propôs uma teoria para explicar o aprendizado em nodos biológicos com base no reforço das ligações sinápticas entre nodos excitados. A regra Hebb foi interpretada do ponto de vista matemático e atualmente é utilizada em diversos algoritmos de aprendizado. Widrow e Hoff (1960) propuseram outra regra de aprendizado conhecida como regra Widrow-Hoff ou regra delta, baseada no método do gradiente para minimização do erro na saída de um neurônio com resposta linear (BRAGA et al., 2010).

Rosenblatt (1958) apresentou uma nova abordagem para o reconhecimento de padrões, o modelo *perceptron*. Este modelo é composto por três camadas: a primeira, responsável por receber as entradas do exterior e possui conexões fixas; a segunda, responsável por receber os impulsos da primeira e possui pesos ajustáveis; a terceira e última é a camada de resposta, responsável por receber as saídas da segunda camada. Rosenblatt também propôs um algoritmo para o ajuste dos pesos do *perceptron* e demonstrou a capacidade de classificar padrões do mesmo em sistemas linearmente separáveis (BRAGA et al, 2010).

Em 1960, Widrow e Hoff apresentaram o algoritmo do mínimo quadrado médio (LMS, *Least Mean-Square*) e o usaram para a formulação do *Adaline* (*adaptive linear element*, elemento linear adaptativo), alguns anos depois fora proposto o *Madaline* (*multiple-adaline*) umas das primeiras redes neurais em

camadas treináveis com múltiplos elementos adaptativos (HAYKIN, 1999). Nos anos 60 o *perceptron* estava em seu período clássico, e parecia que as redes neurais poderiam realizar qualquer tarefa. Porém, Minsky e Papert (1969) mostraram através de meios matemáticos, as limitações do *perceptron*. Como o *perceptron* só solucionava problemas linearmente separáveis, ou seja, a solução pode ser obtida dividindo-se o espaço de entrada através de uma reta, o mesmo não detectava paridade, simetria e conectividade. Minsky e Papert brevemente abordaram *perceptrons* de múltiplas camadas, e afirmaram que as limitações encontradas em *perceptrons* de camada única não seriam superadas na versão de múltiplas camadas (BRAGA et al, 2010; HAYKIN, 1999).

Nos anos 70 poucos pesquisadores continuaram trabalhando na área, boa parte devido à repercussão do trabalho de Minsky e Papert (BRAGA et al, 2010; HAYKIN, 1999) e também por razão tecnológica, pois não existiam computadores pessoais ou estações de trabalho para a experimentação. Uma atividade importante que emergiu nos anos 70 foram os mapas auto-organizáveis por meio de aprendizagem competitiva. Von der Marlsburg (1973) apresentou um trabalho em simulação computacional que possivelmente foi o primeiro a demonstrar à auto-organização. Willshaw juntamente com von der Marlsburg (1976) publicou o primeiro artigo sobre a formação de mapas auto-organizáveis. Nos anos 80 surgiram importantes contribuições para a teoria e design de redes neurais, e com isso ressurgia o interesse nas redes neurais (HAYKIN, 1999).

Em 1980, Grossberg introduziu a teoria da ressonância adaptativa (ART, *Adaptative Resonance Theory*) baseada em um novo princípio de auto-organização. A teoria proposta por Grossberg engloba uma camada de reconhecimento de baixo para cima (*bottom-up*) e uma camada generativa de cima para baixo (*top-down*). Caso o padrão realimentado aprendido coincida com o padrão de entrada, ocorre um estado dinâmico chamado de “ressonância adaptativa”. Este princípio foi também redescoberto por outros pesquisadores (HAYKIN, 1999).

Em 1982, um artigo publicado por John Hopfield chamou a atenção para as propriedades associativas das redes neurais, e foi responsável por boa parte da retomada das pesquisas na área. Hopfield (1982) mostrou a relação entre redes recorrentes auto associativas e sistemas físicos, o que desencadeou grande interesse da física teórica pela modelagem neural, transformando assim, a área de redes neurais (BRAGA et al, 2010; HAYKIN, 1999). Alguns anos mais tarde, a

introdução do algoritmo *backpropagation* provou que o ponto de vista de Minsky e Papert em relação ao *perceptron* era bastante pessimista. As redes neurais artificiais de múltiplas camadas se mostraram capazes de solucionar problemas não linearmente separáveis. Houve então uma nova explosão de interesse na área de redes neurais no mundo todo.

2.3.4. O MODELO DO NEURÔNIO

O neurônio é um elemento fundamental no funcionamento e operação de uma rede neural. O mesmo é composto por três elementos básicos, como ilustrado na Figura 2.11 (HAYKIN, 1999).

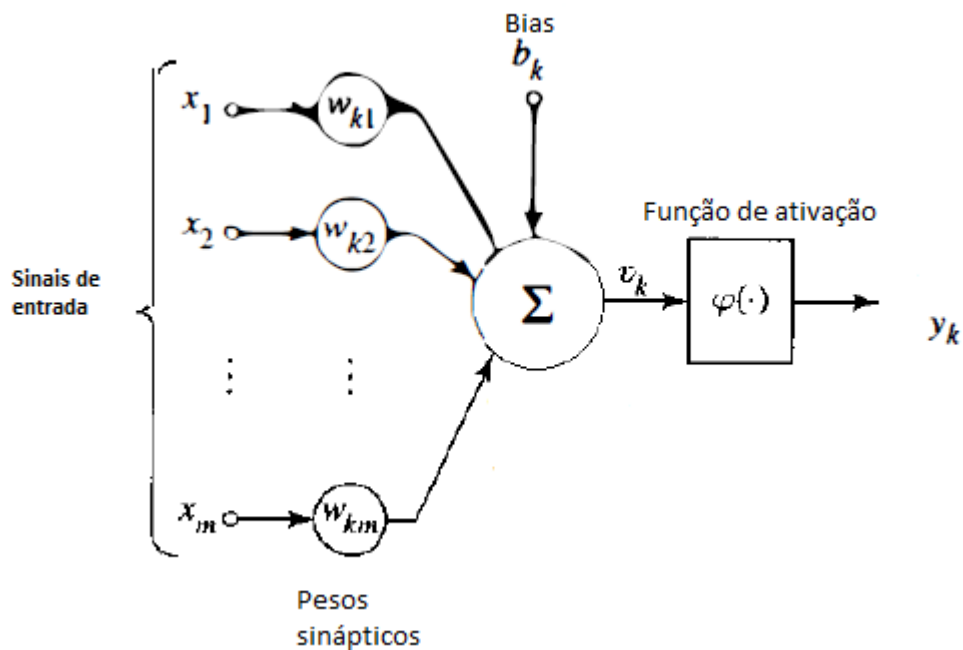


Figura 2.11: Modelo do neurônio artificial.

Fonte: (HAYKIN, 1999).

Os três elementos básicos que constituem o neurônio são: Sinapses, somador e função de ativação. A sinapse é caracterizada por um “peso” ou “força própria”. Uma sinapse x_m , conectada ao neurônio k é multiplicada por um peso sináptico w_{km} . O peso sináptico de um neurônio artificial pode ser positivo, no caso

de sinapses de excitação, ou pode ser negativo, em casos de sinapses de inibição. O somador é um combinador linear responsável por somar os sinais de entradas após os mesmos serem ponderados pelas respectivas sinapses do neurônio. A função de ativação também conhecida como função restritiva é a responsável por limitar, a um valor finito, o intervalo permissível de amplitude do sinal de saída, tipicamente os intervalos de normalização são [0,1] e [-1,1] (HAYKIN, 1999).

O modelo de neurônio artificial também apresenta um *bias*, \mathbf{b}_k , aplicado externamente, o mesmo tem o efeito de aumentar ou diminuir a entrada líquida da função de ativação.

Um neurônio k pode ser descrito em termos matemáticos, como:

$$v_k = \sum_{j=1}^m w_{kj} x_j \quad \text{Equação 2.10}$$

$$y_k = \varphi(v_k + \mathbf{b}_k) \quad \text{Equação 2.11}$$

Onde:

$x_1, x_2, x_3, \dots, x_m$ representam os sinais de entrada.

$w_{k1}, w_{k2}, \dots, w_{km}$ representam os pesos sinápticos do neurônio k .

v_k representa a saída do somador.

\mathbf{b}_k representa o bias.

$\varphi()$ representa a função de ativação .

y_k representa a saída do neurônio k .

2.3.5. FUNÇÕES DE ATIVAÇÃO

As Funções de ativação derivaram-se a partir do modelo de neurônio de McCulloch e Pitts, as mesmas permitem a produção de uma saída qualquer, e não necessariamente zero ou um. Os quatro tipos básicos de função de ativação são: linear, rampa, degrau (*step*) e sigmoidal (BRAGA et al., 2010).

A função de ativação linear é mostrada na Figura 2.12 e definida pela Equação 2.12.




Figura 2.12: Função Linear.

Fonte: (BRAGA et al., 2010).

$$y = \alpha x$$

Equação 2.12

Onde x é a entrada, α é um número real que define a saída linear para os valores da entrada, e y é a saída.

A função linear também pode ser restringida para produzir valores constantes em uma faixa $[-Y, +Y]$, passando assim a ser uma função rampa, ilustrada na Figura 2.13 e definida pela Equação 2.13 (BRAGA et al., 2010).




Figura 2.13: Função rampa.

Fonte: (BRAGA et al., 2010).

$$y = \begin{cases} +Y & x \geq +Y \\ x & |x| < +Y \\ -Y & x < -Y \end{cases}$$

Equação 2.13

A função degrau (*step*) é ilustrada na Figura 2.14 e definida pela Equação 2.14.




Figura 2.14: Função degrau.

Fonte: (BRAGA et al., 2010).

$$y = \begin{cases} +Y & x > 0 \\ -Y & x \leq 0 \end{cases}$$

Equação 2.14

A função sigmoidal, também conhecida como *S-shape* é ilustrada na Figura 2.15 e definida pela Equação 2.15.




Figura 2.15: Função sigmoidal.

Fonte: (BRAGA et al., 2010).

$$y = \frac{1}{1 + e^{-x/T}}$$

Equação 2.15

Onde o parâmetro T determina a suavidade da curva.

2.3.6. ARQUITETURAS DE REDES

O tipo de problema que pode ser tratado pela RNA está intimamente conectado à sua arquitetura. Por exemplo, redes de camada única de nodos, só conseguem solucionar problemas linearmente separáveis.

A definição da arquitetura de uma RNA envolve os seguintes parâmetros: número de camadas de rede, número de nodos em cada camada, tipo de conexão entre os nodos e topologia da rede (HAYKIN, 1999). Os três tipos básicos de arquiteturas são descritos a seguir:

- REDES DIRETAS DE CAMADA ÚNICA

Uma rede direta de camada única é a forma mais simples de uma rede em camadas, a camada de nós de fonte se projeta sobre uma camada de saída de neurônios. Esta rede é acíclica, ou seja, não ocorre *feedback*, a Figura 2.16 ilustra a mesma (HAYKIN, 1999).




Figura 2.16: Rede direta de camada única.

Fonte: (HAYKIN, 1999).

A definição “camada única” se dá pelo fato de a rede possuir apenas uma camada de neurônios.

- REDES DIRETAS DE CAMADAS MÚLTIPLAS

As redes diretas de camadas múltiplas são unidirecionais assim como as de camada única. Porém, esta rede se difere da rede direta de camada única pelo fato da inserção de uma ou mais camadas de neurônios. Estas camadas são denominadas camadas ocultas e seus nodos são denominados neurônios ocultos, cuja função é intervir entre a entrada externa e a saída da rede. Como neste tipo de rede ocorrem mais conexões sinápticas, as camadas ocultas se tornam capazes de extrair características complexas do ambiente no qual estão inseridas (HAYKIN, 1999).

A Figura 2.17 ilustra uma rede direta de camadas múltiplas. A camada de neurônios de entrada da rede fornece os sinais de ativação ou sinais de entrada à camada de neurônios oculta. Os sinais de saída da camada oculta são utilizados como entrada para os neurônios da camada de saída. A rede da Figura 2.17 é também denominada como uma rede 10-4-2, pois possui 10 neurônios de fonte, 4 neurônios ocultos e 2 neurônios de saída. Também é referida como sendo totalmente conectada, uma vez que cada nodo de uma camada está conectado a todos os nodos da próxima camada (HAYKIN, 1999).




Figura 2.17: Rede direta de camadas múltiplas.

Fonte: (HAYKIN, 1999).

- REDES RECORRENTES

A principal diferença entre uma rede neural recorrente e as demais, é que na rede neural recorrente há a presença de pelo menos um laço de realimentação. Uma rede neural recorrente pode consistir de uma única camada de neurônios alimentando seu sinal de saída de volta para as entradas de todos os outros neurônios, pode possuir ou não camadas ocultas. A Figura 2.18 ilustra uma rede neural recorrente com neurônios ocultos. Os laços de realimentação deste modelo causam profundo impacto na capacidade de aprendizagem da rede e no seu desempenho. Além disso, o uso dos elementos de atraso unitário nos laços de repetições resulta em um comportamento dinâmico não linear, admitindo-se que a rede contenha unidades não lineares (HAYKIN, 1999).




Figura 2.18: Rede neural recorrente com neurônios ocultos.

Fonte: (HAYKIN, 1999).

2.3.7. APRENDIZADO

Redes Neurais Artificiais são capazes de aprender por exemplos e realizar interpolações e extrapolações do que aprenderam. O algoritmo de aprendizado é o responsável por isso, o mesmo deve adaptar os parâmetros de uma RNA para que a mesma possa aprender uma determinada função. Existem atualmente, diversos tipos de algoritmos de aprendizado, a maioria se difere basicamente pela forma em que o ajuste dos pesos é realizado (BRAGA et al., 2010).

A solução de uma tarefa por meio de uma RNA passa inicialmente pela etapa de aprendizagem, é nesta etapa que acontece a extração de informações relevantes dos padrões de informação apresentados à RNA. É um processo iterativo onde ocorre o ajuste dos pesos das conexões entre os neurônios e o ajuste dos

parâmetros da rede (BRAGA et al., 2010). Uma definição geral do conceito de aprendizagem em uma rede neural descrita por Mendel e McLaren (1970) e adaptada por Haykin (1999, p. 50) é apresentada a seguir:

Aprendizagem é um processo pelo qual os parâmetros livres de uma rede neural são adaptados através de um processo de estimulação pelo ambiente no qual a rede está inserida. O tipo de aprendizagem é determinado pela maneira pela qual a modificação dos parâmetros ocorre.

Os diversos métodos de treinamento de redes neurais podem ser divididos em dois grupos principais: aprendizado supervisionado e aprendizado não supervisionado.

- APRENDIZADO SUPERVISIONADO

O método de aprendizado supervisionado, ou aprendizado com professor, é um dos mais utilizados em treinamentos de RNAs. O mesmo consiste, basicamente, na inserção da entrada e saída desejadas por meio de um “supervisor” ou “professor” (BRAGA et al., 2010). A Figura 2.19 representa o mecanismo de aprendizado supervisionado. O professor indica a saída esperada, a rede neural calcula a saída real, desta forma, um sinal de erro é gerado e realimentado na rede neural, assim, os pesos sinápticos são ajustados de forma a minimizar o erro da saída da rede.

O desempenho da rede é normalmente obtido através da soma dos erros quadráticos de todas as saídas. Uma grande desvantagem do aprendizado supervisionado é que sem um “professor”, a rede não conseguirá obter as soluções para problemas não cobertos durante o treinamento (BRAGA et al., 2010). A regra delta, apresentada por Widrow e Hoff (1960) e sua generalização para redes de múltiplas camadas, o algoritmo *backpropagation* descrito em Rumelhart et al. (1986) são os exemplos mais conhecidos de algoritmos para aprendizado supervisionado (BRAGA et al, 2010).

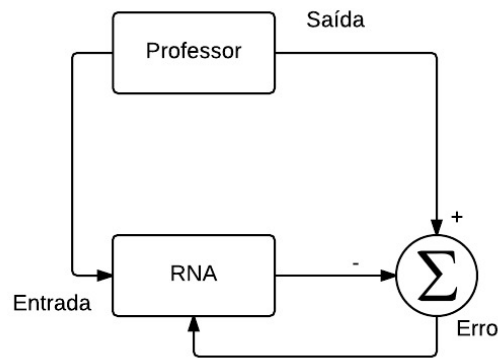


Figura 2.19: Aprendizado supervisionado.

Há duas maneiras para a implementação do aprendizado supervisionado, *online* e *offline*. No aprendizado *offline*, os dados de treinamento não se alteram, e uma vez obtida solução para a rede, esta deve ser mantida como fixa. Por outro lado, no treinamento *online* os dados podem ser alterados continuamente, e a rede deve estar em contínuo processo de adaptação (BRAGA et al., 2010).

- APRENDIZADO NÃO SUPERVISIONADO

No aprendizado não supervisionado não há um “professor” para supervisionar o processo de aprendizado (BRAGA et al, 2010; HAYKIN, 1999). Em algoritmos de aprendizado não supervisionado, apenas os dados de entrada estão disponíveis. A partir de dados de entrada redundantes, a rede desenvolve uma habilidade de criar novas classes e formar representações internas. O aprendizado só ocorre se houver redundância nos dados de entrada, uma vez que, sem redundância seria impossível para a rede encontrar padrões e características dos dados de entrada (BRAGA et al., 2010). A Figura 2.20 representa o mecanismo de aprendizado não supervisionado.




Figura 2.20: Aprendizado não supervisionado.

Alguns métodos para implementação de aprendizado não supervisionado são: O aprendizado Hebbiano (HEBB, 1949); o modelo de Linsker (LINSKER, 1988); a regra de Oja (OJA, 1982); a regra de Yuille (YUILLE, 1989); e os casos particulares, como o aprendizado por competição e aprendizado por reforço (BRAGA et al., 2010).

3. ANÁLISE DE FALTAS EM LINHAS DE TRANSMISSÃO ATRAVÉS DE RNAS

Este capítulo apresenta com detalhes as considerações iniciais e implementações de Oleskovicz et al. (2003), Melo e Silva et al. (2007) e Souza et al. (2014) que foram os trabalhos selecionados para demonstrar a aplicabilidade das redes neurais artificiais na análise de faltas em linhas de transmissão.

3.1. PRIMEIRO MÉTODO ANALISADO

3.1.1. CONSIDERAÇÕES INICIAIS

No trabalho de Oleskovicz et al. (2003), intitulado “*O emprego de redes neurais artificiais na detecção, classificação e localização de faltas em linhas de transmissão*”, foi proposto um método alternativo para proteção de linhas de transmissão através da aplicação de RNAs. O método é baseado em modelos que realizem as suas funções em menor tempo quando comparados aos dispositivos convencionais, e que sejam imunes a mudanças operacionais do sistema. Seu diagrama é apresentado na Figura 3.1, e será abordado com detalhes no próximo item.

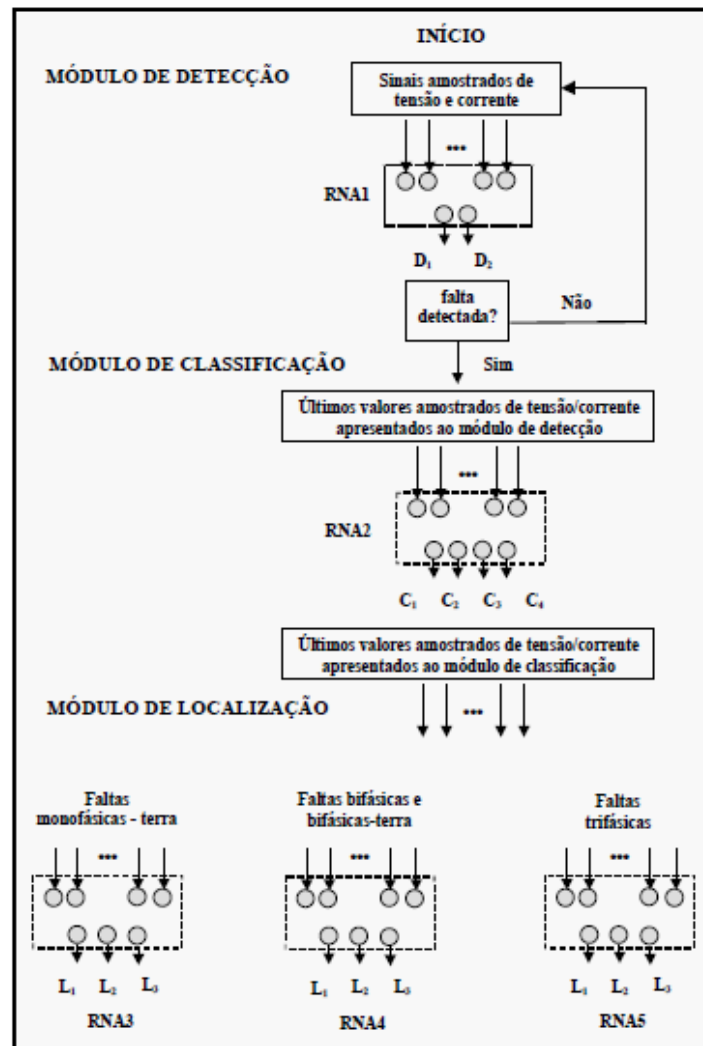


Figura 21: Método proposto.

Fonte: (OLESKOVICZ et al., 2003).

O sistema elétrico utilizado em todo o trabalho é uma típica linha de 440 kV da CESP (Companhia Energética de São Paulo), sua topologia é apresentada na Figura 3.2.




Figura 22: Topologia do sistema elétrico analisado.

Fonte: (OLESKOVICZ et al., 2003).

O sistema elétrico apresentado na Figura 3.2 foi implementado no *software* ATP e todas as condições faltosas foram simuladas no mesmo. Os autores levaram em consideração as seguintes variáveis durante as simulações das faltas:

- Distância em quilômetros de aplicação da falta, em relação ao barramento E;
- Resistência da falta entre fases e fase e terra;
- Ângulo de incidência da falta;
- Tipo da falta;
- Condição de operação do sistema elétrico.

As seguintes considerações práticas também foram incluídas:

- Transformador de potencial capacitivo;
- Amostragem do sinal (frequência de 1 kHz);
- Filtro *anti-aliasing* (frequência de corte de 300 Hz);
- Erros de quantização da conversão analógica/digital.

As características dos condutores, suas respectivas disposições geométricas na torre de transmissão, acoplamento mutuo e linhas transpostas também foram levadas em consideração nas simulações.

As RNAs foram implementadas através do *software NeuralWorks* com o intuito de se obter as matrizes de pesos fixas, as quais contêm todas as informações sobre as operações presentes no sistema de transmissão. O algoritmo de aprendizado supervisionado utilizado foi “*Norm-Cum-Delta Learning Rule*”, que é uma variação do algoritmo *backpropagation*. A função de transferência hiperbólica foi utilizada como uma alternativa para a função de transferência sigmoidal.

Um algoritmo computacional em linguagem de programação “C” foi desenvolvido com o intuito de realizar a conexão entre todos os módulos de redes neurais implementados. Foram desenvolvidas cinco topologias de RNAs, que serão abordadas no próximo item.

3.1.2. IMPLEMENTAÇÃO

Os autores dividiram a implementação do modelo em três módulos distintos: detecção, classificação e localização da falta. Um conjunto de dados foi gerado para cada módulo, onde, cada um fora subdividido em um conjunto de treinamento e um de validação, contendo 80% e 20% do conjunto total de dados, respectivamente.

O módulo de detecção da falta tem como objetivo reconhecer se a falta está ocorrendo à frente ou em sentido reverso ao barramento E, e também reconhecer as situações de operações normais do sistema.

Para formar o conjunto de dados, os autores selecionaram 37 localizações da falta, três resistências de falta (0, 50 e 100 Ω para faltas fase-terra; 0, 0,5 e 1,0 Ω para faltas entre fase-fase), três ângulos de incidência da falta (0°, 45° e 90°), três janelas de dados, 10 tipos distintos de falta, totalizando em 9990 padrões, que descrevem as características do sistema sob falta, também foram incluídos 2006 padrões para descrever as características normais do sistema, totalizando em 12006 padrões.

Para a implementação do módulo de detecção, várias arquiteturas de RNAs do tipo *perceptron* multicamadas foram avaliadas através da variação de parâmetros, como por exemplo, o número de neurônios na camada intermediária, taxa de aprendizagem, número de ciclos de treinamento, dentre outros. A RNA1 apresenta uma arquitetura 24-9-2, ou seja, 24 unidades de processamento (neurônios) em sua camada de entrada, 9 neurônios em sua camada intermediária e 2 elementos na camada de saída (D1 e D2). Esta arquitetura alcançou um erro RMS mínimo para o conjunto de validação de 0,0569 para todas as unidades na camada de saída. A arquitetura da RNA1, bem como as situações e respostas esperadas para a mesma são apresentadas na Tabela 3.1.

Tabela 3.2: Respostas esperadas por parte das RNAs.

Módulo de Detecção			Módulo de Classificação RNA2 (24-16-4)					Módulo de Localização			
Situação	D1	D2	Tipo de falta	C1	C2	C3	C4	Localização da falta	L1	L2	L3
Normal	0	0	AT	1	0	0	1	Zona 1	1	0	0
Falta reversa	1	0	BT	0	1	0	1	Zona 2	0	1	0
Falta à frente	0	1	CT	0	0	1	1	Zona 3	0	0	1
RNA1 (24-9-2)			AB	1	1	0	0	RNA3 (24-48-40-3) RNA4 (24-42-40-3) RNA5 (24-24-20-3)			
			AC	1	0	1	0				
			BC	0	1	1	0				
			ABT	1	1	0	1				
			ACT	1	0	1	1				
			BCT	0	1	1	1				
			ABC	1	1	1	0				

Fonte: (OLESKOVICZ et al., 2003).

Para o módulo de classificação de falta, os autores geraram um conjunto de dados com 1380 situações de faltas e 5 janelas de dados, totalizando em 6900 padrões. A arquitetura da RNA2 é apresentada na Tabela 3.1, bem como suas respostas relacionadas às fases A (C1), B (C2), C (C3), e a conexão com a terra (C4), para todas as condições de faltas consideradas.

Os autores definiram que a RNA2 deve apresentar valores iguais ou próximos a um (1) ou zero (0), mostrando se a falta envolveu as fases A (C1), B (C2) e C (C3) ou não. A saída (C4) foi designada para indicar se a falta envolveu uma conexão a terra.

Diferentes topologias de RNAs do tipo *perceptron* multicamadas foram avaliadas pelos autores, buscando a que melhor representasse o problema de classificação. A arquitetura escolhida foi do tipo 24-16-4, ou seja, 24 neurônios em sua camada de entrada, 16 neurônios em sua camada intermediária e 4 elementos na camada de saída. Esta arquitetura alcançou um erro RMS mínimo para o conjunto de validação de 0,10 para todas as unidades na camada de saída.

Para o módulo de localização, baseados no circuito da Figura 3.2 e consideradas as incertezas do alcance da zona de proteção, os autores designaram

as zonas de proteção, sendo todas a partir do barramento E, com as seguintes proporções:

- Zona de proteção primária: até 142,5 km;
- Primeira zona de transição: $142,5 \pm 2,85$ km;
- Zona de proteção secundária: até 195 km;
- Segunda zona de transição: $195 \pm 3,9$ km;
- Zona de proteção terciária: até 240 km.

As zonas de transição são consideradas devido a alteração dos valores próximos ou iguais a 0 (zero) para valores próximos ou iguais a 1 (um), ou vice-versa, que devem ser apresentados pela RNA quando ocorrem mudanças entre zonas de proteção. Assim, como há alteração entre os valores esperados como respostas, há uma pequena área onde valores ou localizações errôneas são esperadas.

Para o módulo de localização de falta os autores implementaram três RNAs. A RNA3 é responsável por localizar as faltas do tipo fase-terra (A-terra, B-terra e C-terra). A RNA4 designa-se a localizar as faltas do tipo fase-fase (AB, AC e BC) e fase-fase-terra (AB-terra, AC-terra e BC-terra). Por último, a RNA5 refere-se às faltas trifásicas (fases ABC).

As RNAs do módulo de localização possuem três saídas, onde, cada uma delas se relaciona a uma zona de proteção. A saída L1 relaciona-se à zona de proteção primária, e as saídas L2 e L3 às zonas de proteção secundária e terciária, respectivamente. Saídas com valores próximos ou iguais a 0 (zero) indicam o não envolvimento da área de proteção e saídas com valores próximos ou iguais a 1 (um) indicam a ocorrência de falta na zona de proteção indicada. As respostas esperadas estão ilustradas na Tabela 3.1.

Para o treinamento e validação da RNA3 foi gerado um conjunto de dados com 14700 padrões. Os autores avaliaram 63 arquiteturas de RNAs do tipo *perceptron* multicamadas, a arquitetura escolhida foi do tipo 24-48-44-3, ou seja, 24 neurônios em sua camada de entrada, duas camadas intermediárias com 48 e 44 neurônios cada e 3 elementos na camada de saída. Esta arquitetura alcançou um erro RMS mínimo para o conjunto de validação de 0,08 para todas as unidades na camada de saída.

Para a implementação da RNA4 foi gerado um conjunto de dados com 31800 padrões. A topologia escolhida pelos autores para a RNA4 foi do tipo 24-42-40-3, ou seja, 24 neurônios em sua camada de entrada, duas camadas intermediárias com 42 e 40 neurônios cada e 3 elementos na camada de saída. O erro RMS mínimo alcançado por esta arquitetura para o conjunto de validação foi de 0,15 para todas as unidades na camada de saída.

Um conjunto de dados com 6100 padrões foi criado para a implementação da RNA5. Os autores analisaram 25 arquiteturas de RNAs do tipo *perceptron* multicamadas, para encontrar a que melhor representasse o problema. A arquitetura escolhida foi do tipo 24-24-20-3, ou seja, 24 neurônios em sua camada de entrada, duas camadas intermediárias com 24 e 20 neurônios cada e 3 elementos na camada de saída, esta arquitetura apresentou um erro RMS mínimo para o conjunto de validação de 0,04 para todas as unidades na camada de saída.

A análise dos resultados obtidos por Oleskovicz et al. (2003) será abordada no Capítulo 4.

3.2. SEGUNDO MÉTODO ANALISADO

3.2.1. CONSIDERAÇÕES INICIAIS

No trabalho de Melo e Silva et al. (2007), foi proposto um método de detecção e classificação de faltas em linhas de transmissão através da análise de registros oscilográficos via transformada *wavelet* e RNAs.

Os registros oscilográficos são produtos do monitoramento das grandezas elétricas do sistema de potência por meio de um registrador digital de perturbação (RDP). Um RDP é capaz de armazenar dados via rede WAN (*wide area network*), o que possibilita a concepção de redes de monitoramento de grande porte, denominadas redes oscilográficas. As informações registradas pelos RDPs são coletadas automaticamente e organizadas em registros padronizados, para então serem transferidas ao servidor central da oscilografia.

Devido à possibilidade de se utilizar RDPs com uma alta taxa de amostragem, os mesmos se tornam capazes de, além de faltas, capturar distúrbios relacionados à qualidade de energia elétrica (QEE). Em muitos casos, os RDPs são ativados por distúrbios relacionados à QEE, como afundamentos de tensão e manobras de chaveamento, o que ocasiona no armazenamento de uma grande quantidade de dados não relacionados à análise de faltas. A proposta dos autores é que somente os dados com relação às faltas sejam transferidos para a central de oscilografia.

O diagrama em blocos do método proposto é ilustrado na Figura 3.3, este, foi implementado em linguagem de programação “C++” utilizando recursos de programação orientada a objetos. O método foi dividido em dois módulos, um de detecção e outro de classificação.

A detecção da falta e de sua duração é realizada por meio da análise dos sinais de corrente nos domínios do tempo e *wavelet*, é neste módulo que ocorre a separação entre faltas e distúrbios relacionados à QEE, sendo que para este trabalho, somente registros que caracterizam faltas são relevantes. A classificação da falta é realizada por meio de RNAs, do tipo *perceptron* multicamadas (MLP), cujos valores de entrada são as tensões e correntes na linha de transmissão no domínio do tempo.

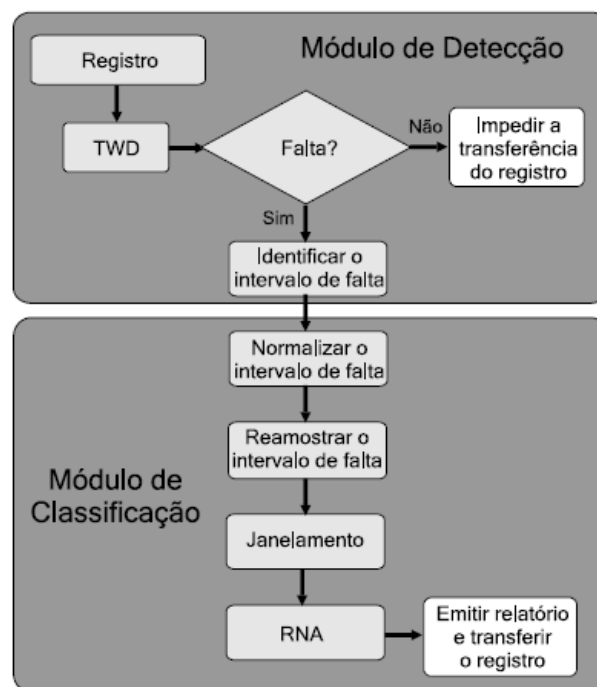


Figura 23: Diagrama de blocos do método proposto.

Fonte: (MELO E SILVA et al., 2007).

Na implementação do método, registros capturados por RDPs em linhas de transmissão de 138, 230 e 500 kV do sistema Chesf foram consideradas. No entanto, para a criação da base de dados da RNA também foram realizadas simulações de faltas na LT 04V4 do sistema Chesf, ilustrada na Figura 3.4.

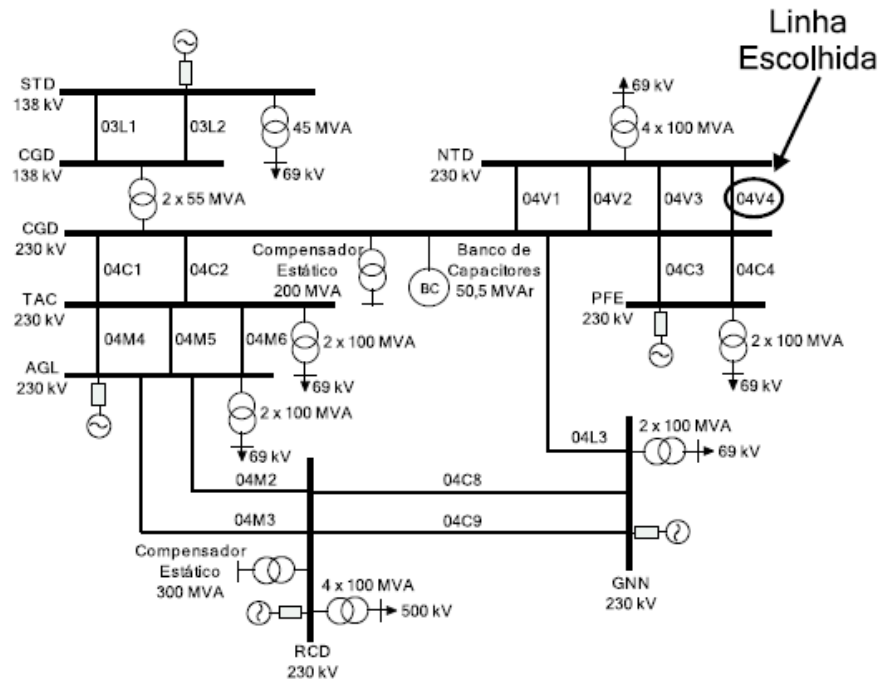


Figura 24: Representação simplificada do sistema analisado.

Fonte: (MELO E SILVA et al., 2007).

O sistema elétrico foi implementado no software ATP considerando parâmetros do sistema distribuídos e independentes da frequência, as simulações de faltas foram realizadas na LT 04V4, levando em consideração os seguintes parâmetros:

- Localização da falta;
- Ângulo de incidência da falta;
- Resistência da falta entre fases e entre fase-terra;
- Tipo da falta.

Um software de análise de registros oscilográficos foi desenvolvido baseado no método proposto pelos autores. Até a data de publicação do trabalho, o software encontrava-se implantado em escala piloto, no concentrador da subestação (SE) Campina Grande II (CGD) realizando a análise dos registros da LT 04V4 de 230 kV e 188 km entre as SEs CGD e Natal II (NTD), pertencentes ao subsistema Leste da

Chesf. A implementação do método será abordada com mais detalhes no próximo item.

3.2.2. IMPLEMENTAÇÃO

Como mencionado no item anterior, os autores dividiram o método em dois módulos, detecção e classificação. A detecção foi realizada através da aplicação da transformada *wavelet* discreta (TWD) apenas nos sinais de corrente. Para o módulo de classificação, uma rede neural foi treinada, validada e testada com dados simulados e reais.

O módulo de detecção consiste de duas etapas, uma para realizar a detecção da falta, e outra para identificar a duração da falta. Na etapa de detecção, os autores utilizaram apenas coeficientes *wavelet* de detalhes referentes à primeira escala de resolução, neste, a *wavelet* Daubechies 4 foi aplicada nos sinais de corrente. E para a constatação de uma falta, o seguinte conjunto de regras foi criado:

1. Se $C_{max} < C^*$, então não é um registro de uma falta.
2. Se $C_{max} \geq C^*$, $I_{pre} < 0, 2I_{pos}$ e $I_{pos} > I_m$, então não é um registro de falta.
3. Se $C_{max} \geq C^*$, $|I_{pre} - I_{pos}|$ e $I_{pos} > I_m$, então não é um registro de falta.
4. Se $C_{max} \geq C^*$, e se as demais regras não foram satisfeitas, então o registro corresponde a uma falta.

Onde, C_{max} corresponde ao máximo valor absoluto dos coeficientes *wavelet* da primeira escala das correntes; C^* é um limiar estabelecido a partir da observação dos coeficientes *wavelet* das correntes para diversos registros reais; I_{pre} e I_{pos} são os valores de pico das correntes no primeiro e último ciclo registrado, respectivamente; I_m é um limiar estabelecido de acordo com a corrente de carga típica no sistema.

Após a constatação da ocorrência de uma falta, a determinação da duração desta é realizada por meio da análise dos coeficientes *wavelets* das correntes de fase e de neutro na primeira escala de resolução da TWD. Para a determinação dos

instantes iniciais e finais do intervalo da falta, os autores filtraram os coeficientes *wavelet* através da técnica *hard wavelet threshold* e então aplicaram um algoritmo.

A classificação das faltas é realizada através de uma RNA, cujos valores de entrada são as tensões e correntes no domínio do tempo. O módulo de classificação de faltas foi dividido em quatro etapas, sendo elas: normalização, reamostragem, janelamento e classificação.

Na etapa de normalização, as amostras de tensões e correntes do intervalo da falta em análise são normalizadas por seus respectivos valores máximos. Esta estratégia permite que os padrões de entrada da RNA, tanto reais quanto simulados, sejam uniformizados mesmo quando são advindos de diferentes níveis de tensão.

A etapa de reamostragem é responsável pela conversão da frequência de amostragem original, frequência do RDP, para uma frequência padrão. A frequência padrão escolhida pelos autores foi de 1200 Hz.

No processo de janelamento foram agrupadas 5 amostras consecutivas das tensões e correntes de fase e de neutro em um único padrão de entrada da RNA. Cada padrão possui 40 entradas, sendo 5 amostras de 4 tensões e 4 correntes.

Durante a etapa de classificação, cada janela obtida é apresentada a uma RNA do tipo MLP responsável por identificar o tipo de falta correspondente à amostra. 20160 padrões foram simulados pelos autores, sendo 11200 utilizados para treinamento, 4480 para validação e 4480 para a fase de testes da RNA, 9407 dados reais também foram incorporados aos padrões de entrada da RNA, sendo 3316 utilizados para treinamento, 2163 para validação e 3928 para a fase de testes.

Os autores testaram várias topologias de RNAs, a escolhida foi do tipo 40-30-4, ou seja, 40 neurônios em sua camada de entrada, 30 neurônios em sua camada intermediária e 4 elementos na camada de saída. O algoritmo utilizado foi o *resilient backpropagation* (RPROP), e o erro médio quadrático encontrado para o conjunto de validação foi de 0,02%.

As respostas esperadas pela RNA estão ilustradas na Tabela 3.2, onde as saídas S1, S2 e S3 correspondem às fases A, B e C, respectivamente, e a saída S4 corresponde à conexão com a terra.

Tabela 3.3: Esquema de codificação da saída desejada da RNA

Tipo de Falta	Fases Envolvidas	Sigla	Saídas			
			S1	S2	S3	S4
Monofásica	A	AT	1	0	0	1
	B	BT	0	1	0	1
	C	CT	0	0	1	1
Bifásica	A e B	AB	1	1	0	0
	A e C	AC	1	0	1	0
	B e C	BC	0	1	1	0
Bifásica para Terra	A e B	ABT	1	1	0	1
	A e C	ACT	1	0	1	1
	B e C	BCT	0	1	1	1
Trifásica	A, B e C	ABC	1	1	1	0

Fonte: (MELO E SILVA et al., 2007).

A análise dos resultados obtidos por Melo e Silva et al. (2007) será abordada no Capítulo 4.

3.3. TERCEIRO MÉTODO ANALISADO

3.3.1. CONSIDERAÇÕES INICIAIS

No trabalho de Souza et al. (2014), foi proposto um método de localização de faltas em linhas de transmissão através de RNA e da Teoria de Ondas Viajantes (TOVs).

O sistema elétrico utilizado em todo trabalho é uma LT de 500 kV, 200 km ilustrada na Figura 3.5, o mesmo foi implementado no *software* ATP com parâmetros distribuídos e dependentes da frequência. A topologia da LT utilizada é de dois terminais, A e B, representando o terminal de medição e o terminal remoto, respectivamente.




Figura 25: Sistema de transmissão de dois terminais.

Fonte: (SOUZA et al., 2014).

Os autores simularam apenas faltas monofásicas do tipo AT, alegando que, estas representam a maioria dos casos de ocorrência de faltas em LTs. Foi utilizada uma taxa de amostragem de 100 kHz, e as seguintes variáveis foram levadas em consideração durante as simulações:

- Distância em quilômetros de aplicação da falta, em relação ao barramento A;
- Ângulo de incidência da falta;
- Resistência de falta.

A disposição dos condutores na torre de transmissão e suas características também foram levadas em consideração durante as simulações. O modelo de torre de transmissão adotado corresponde a um modelo de torre típico do sistema da CHESF utilizado na linha de transmissão que interliga as subestações de Presidente Dutra, no estado do Maranhão e Boa Esperança, no estado do Piauí.

Como os autores consideraram a transposição da LT e o mesmo carregamento para todas as fases, a realização das simulações apenas com a fase A não invalida a abordagem apresentada. Pois, sob estas condições, são obtidos os mesmos sinais faltosos considerando apenas a defasagem entre as fases.

Para a implementação do método, os autores utilizaram a TOVs para realizar a extração dos tempos de propagação das ondas viajantes de tensão, das faltas do tipo AT aplicadas até a metade do comprimento total da LT. Os tempos de propagação das ondas viajantes são utilizados como entrada para a RNA.

Para a implementação RNA do tipo perceptron multicamadas (MLP), os autores utilizaram a *toolbox* do *software* MATLAB. O algoritmo de aprendizado utilizado foi o *Levenberg-Marquardt*, as funções de ativação utilizadas foram do tipo sigmoide logística, para a camada intermediária, e linear, para a camada de saída. A topologia da RNA, bem como mais detalhes sobre a implementação do método proposto serão abordados no próximo item.

3.3.2. IMPLEMENTAÇÃO

A etapa de pré-localização da falta, consiste em identificar a metade faltosa da LT e o tipo de falta ocorrida, para tal, foram realizadas simulações no circuito da Figura 3.6.




Figura 26: Sistema de transmissão modelado no ATP.

Fonte: (SOUZA et al., 2014).

Para a modelagem da linha de transmissão os autores utilizaram o bloco LCC do ATP e o modelo JMarti, devido à sua precisão na análise de transitórios eletromagnéticos. A LT foi dividida em dois trechos: O Trecho 1 está compreendido entre os pontos T1 e T2 e representa a distância do terminal de medição até a falta. O Trecho 2 está compreendido entre os pontos T2 e T3 e representa a distância da falta até o terminal remoto. Para alterar a distância de aplicação da falta, modifica-se o comprimento da linha nas propriedades de cada bloco.

Foram aplicadas faltas monofásicas do tipo AT em seis distâncias ao longo da primeira metade da LT, sendo: 8 km, 16 km, 35 km, 50 km, 75 km e 90 km. As faltas foram aplicadas em 98 ângulos de incidência, contidos no intervalo $[3,89^\circ, 360^\circ]$ com passo de $3,67^\circ$, a resistência de falta utilizada durante todas as simulações foi de valor nulo, totalizando em 588 amostras de falta.

Para a etapa de localização da falta através do uso do MATLAB, os autores testaram diferentes tipos de topologias para a RNA, como mostra a Figura 3.7; a escolhida foi a que apresentou menor erro quadrático médio (EMQ) de acordo com o

número de neurônios na camada intermediária, sendo esta do tipo 3-5-1, ou seja, 3 neurônios em sua camada de entrada, 5 neurônios em sua camada intermediária e 1 elemento na camada de saída.

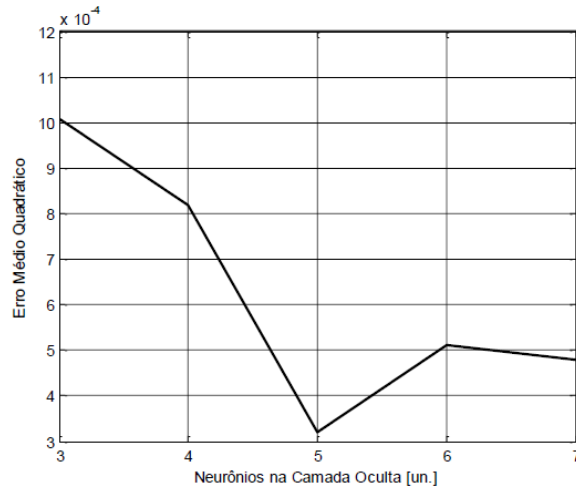


Figura 27: EMQ para diferentes topologias de RNA.

Fonte: (SOUZA et al., 2014).

A Figura 3.8 apresenta a topologia da RNA implementada no MATLAB. Esta RNA possui como entrada as seguintes variáveis: tempo de propagação da primeira onda viajante (t_1); tempo de propagação da segunda onda reversa (t_2); ângulo de incidência da falta (θ).

Dentre as 588 amostras de faltas obtidas nas simulações, 528 foram utilizadas na etapa de treinamento da RNA e 60 foram utilizadas na etapa de teste. Visando um bom ajuste dos pesos os autores realizaram 10 etapas de treinamento,




Figura 28: Arquitetura da RNA utilizada.

Fonte: (SOUZA et al., 2014).

4. RESULTADOS E DISCUSSÕES

Neste capítulo são apresentadas as análises dos resultados de Olevskovicz et al. (2003), Melo e Silva et al. (2007) e Souza et al. (2014) abordados no Capítulo 3, os quais foram utilizados para exemplificação do uso de redes neurais artificiais aplicadas na análise de faltas em linhas de transmissão.

4.1. ANÁLISE DOS RESULTADOS DO PRIMEIRO MÉTODO

Os resultados referentes ao trabalho de Oleskovicz et al. (2003) foram obtidos através do algoritmo computacional em linguagem de programação “C” implementado pelos autores. Para o mesmo, foram gerados 4050 novos casos de prováveis situações que possam a vir a ocorrer sobre o sistema de transmissão em análise.

A Tabela 4.1 apresenta em síntese todos os resultados registrados. Pode-se observar pela Tabela 4.1 que os índices de R.C. apresentados para os módulos de detecção e classificação estão muito próximos a 100%. Porém, a percentagem de respostas corretas para o módulo de localização apresenta valores não tão próximos de 100% devido às duas áreas de transição adotadas, onde valores incorretos na localização da falta são esperados.

Tabela 4.4: Respostas corretas e tempo de processamento para os módulos de detecção, classificação e localização integrados.

Percentagem (%) de Respostas Corretas (R.C.) e o Tempo de Processamento (T.P.) para cada módulo					
Módulo	T.P. (ms)	Faltas fase-terra	Faltas fase-fase	Faltas fase-fase-terra	Faltas trifásicas
Detecção 4050 padrões testados	R.C.	100	100	100	100
	2	71,94	76,46	82,14	84,44
	3	23,29	22,63	16,79	15,56
	4-5	4,77	0,91	1,07	-
Classificação 4050 padrões testados	R.C.	99,92	100	99,26	99,52
	4	24,20	-	-	-
	5	37,94	4,44	6,18	-
	6	31,36	21,89	12,92	-
	7	5,60	17,12	31,28	30,37
	8	0,58	31,93	35,48	26,91
	9	0,24	13,58	10,54	24,70
	10-17	-	11,04	2,86	17,54
Localização 3240 padrões testados	R.C.	94,65	88,78	95,97	92,84
	8	0,61	-	0,31	-
	9	4,12	2,06	6,50	-
	10	14,10	6,38	15,53	5,03
	11	19,60	22,02	27,01	17,61
	12	21,13	18,11	23,46	21,07
	13	17,39	20,06	13,89	28,63
	14	12,34	8,54	5,02	13,59
	15	4,42	7,41	2,76	3,72
	16-18	0,94	4,20	1,49	3,19

Fonte: (OLESKOVICZ et al., 2003).

O modelo proposto por Oleskovicz et al. (2003) atua como um identificador direcional de faltas, um classificador de faltas e também como um localizador da mesma. Os resultados obtidos pela implementação do modelo mostram que o desempenho global das arquiteturas das RNAs alcançou um índice altamente

satisfatório, com percentagem de respostas corretas de 100% para o módulo de detecção, acima de 99,26% para o módulo de classificação e acima de 88,78% para o módulo de localização.

De acordo com os casos testados para o módulo de detecção, pode-se observar uma rápida convergência para a grande maioria dos casos, com níveis corretos de até 3 ms após a ocorrência da falta. Em relação ao módulo de classificação, este foi capaz de definir as fases envolvidas nas faltas apresentadas, em um tempo entre 4 e 9 ms após a ocorrência da falta. Por último, considerando as três zonas de proteção, o módulo de localização foi capaz de localizar as faltas em um tempo entre 8 e 15 ms após sua ocorrência.

O modelo proposto por Oleskovicz et al. (2003) se mostrou altamente preciso e com alta velocidade de atuação, características essas, muito desejadas em um sistema de proteção moderno.

4.2. ANÁLISE DOS RESULTADOS DO SEGUNDO MÉTODO

O método proposto em Melo e Silva et al. (2007) foi avaliado por meio de registros reais e simulados. Para os registros simulados, apresentados na Tabela 4.2, os autores mencionaram um índice de acerto de 100% na classificação do tipo de falta. Os registros reais utilizados na avaliação do método são provenientes de RDPs com diferentes frequências de amostragem em diferentes LTs do sistema de transmissão da Chesf. As tabelas 4.3, 4.4 e 4.5 apresentam os resultados para as LTs de 138, 230 e 500 kV, respectivamente.

Tabela 4.5: Registros simulados para avaliação do método.

Variáveis de Simulação	Situações de Falta
Locais de falta (km)	10-20-...-170-180
Resistência de falta (Ω)	Fase-Fase: 0,1 e 5
	Fase-Terra: 30 e 80
Ângulo de Incidência ($^\circ$)	30-120
Tipos de falta	AT-BT-CT-AB-AC-BC-ABT-ACT-BCT-ABC

Fonte: (MELO E SILVA et al., 2007).

Tabela 4.6: Resultados para LTs de 138 kV.

Diagnóstico		Número de Registros	Diagnósticos Corretos
Real	Esperado		
Sem defeito perceptível	Sem falta	184	184
Variações de carga	Sem falta	10	10
Afundamentos de tensão	Sem falta	16	16
Transitórios	Sem falta	28	28
Desligamentos de LTs	Sem falta	14	14
Energizações de LTs	Sem falta	25	25
Falta AT	Falta AT	1	1
Falta BT	Falta BT	5	5
Falta CT	Falta CT	2	2
		285	285

Fonte: (MELO E SILVA et al., 2007).

Tabela 4.7: Resultados para LTs de 230 kV.

Diagnóstico		Número de Registros	Diagnósticos Corretos
Real	Esperado		
Sem defeito perceptível	Sem falta	213	213
Variações de carga	Sem falta	24	24
Afundamentos de tensão	Sem falta	156	156
Transitórios	Sem falta	80	80
Desligamentos de LTs	Sem falta	44	43
Energizações de LTs	Sem falta	43	43
Falta AT	Falta AT	4	3
Falta BT	Falta BT	15	14
Falta CT	Falta CT	13	13
Falta AB	Falta AB	1	1
Falta BC	Falta BC	1	1
Falta ACT	Falta ACT	1	1

Falta BCT	Falta BCT	2	1
		597	593

Fonte: (MELO E SILVA et al., 2007).

Tabela 4.8: Resultados para LTs de 500 kV.

Diagnóstico		Número de Registros	Diagnósticos Corretos
Real	Esperado		
Sem defeito perceptível	Sem falta	3	3
Afundamentos de tensão	Sem falta	27	27
Transitórios	Sem falta	2	2
Desligamentos de LTs	Sem falta	2	2
Energizações de LTs	Sem falta	1	1
Falta AT	Falta AT	1	1
Falta BT	Falta BT	5	5
Falta CT	Falta CT	1	1
		42	42

Fonte: (MELO E SILVA et al., 2007).

Para avaliar a aplicabilidade do método, os autores também realizaram um estudo de caso de registros oscilográficos capturados devido a ocorrência de uma falta monofásica do tipo CT, proveniente de queimadas em plantações de cana-de-açúcar, na LT 05L9 de 500 kV e 170 km, situada entre as SEs Angelim II (AGD) e Recife II (RCD) do subsistema Leste da Chesf (Figura 4.1).




Figura 29: Sistema avaliado no estudo de caso.

Fonte: (MELO E SILVA et al., 2007).

Os registros oscilográficos foram capturados pelos RDPs dos terminais da LT em análise, e pelos RDPs dos outros terminais do sistema. No entanto, o método deve ser capaz de distinguir entre distúrbios e faltas, e classificar apenas a falta CT ocorrida na LT 05L9. Índices de acerto de 100% para este estudo de caso foram apresentados pelos autores.

O método proposto por Melo e Silva et al. (2007) atua na detecção e classificação de faltas em LTs. O mesmo apresentou excelentes resultados na detecção e classificação das faltas em LTs com diferentes níveis de tensão, tanto para os casos de simulação, quanto para os casos reais do sistema de transmissão da Chesf.

Uma contribuição relevante do método proposto, em relação aos métodos existentes, é distinção de registros referentes à faltas de registros referentes à QEE. Para tornar o método mais robusto, novas regras podem ser incorporadas ao mesmo, como sugerido pelos autores.

Para o módulo de detecção da falta, o algoritmo de delimitação do intervalo da mesma foi bem sucedido na indicação de seu instante inicial, porém, em alguns registros reais foram apresentados erros na indicação de seu instante final, devido a transitórios de alta frequência que podem ocorrer nas correntes de fase. No entanto, a classificação da falta não foi comprometida e o sistema se mostrou altamente preciso.

4.2. ANÁLISE DOS RESULTADOS DO TERCEIRO MÉTODO

Através da TOVs e da análise do sinal de tensão da fase A durante a falta, torna-se possível identificar e extrair os tempos de propagação das ondas viajantes de tensão, representados por t_1 e t_2 na Figura 4.2.




Figura 30: Tempo de propagação da primeira e segunda onda viajante.

Fonte: (SOUZA et al., 2014).

As variáveis t_1 e t_2 fazem parte da camada de entrada da RNA, no entanto, os autores também as utilizaram para realizar a estimativa do local da falta através da TOVs por meio da Equação 4.1, com o objetivo de comparar estes resultados com os resultados obtidos pela RNA.

$$d = \frac{v(t_2 - t_1)}{2} \quad \text{Equação 4.1}$$

Onde, v é velocidade de propagação das ondas; t_1 é o tempo de propagação da primeira frente de onda originada no ponto de falta até o terminal de medição; t_2 é o tempo de propagação considerando-se o tempo de retorno dessa primeira onda até o ponto de falta e desse ponto novamente ao terminal de origem.

A implementação da RNA consistiu no treinamento e teste da mesma. Foram realizadas 10 rodadas de treinamento, os valores de erros obtidos nas fases de teste da RNA são apresentados nas Tabelas 4.6 e 4.7. Observando as tabelas, pode-se notar que à medida que a falta se aproxima do terminal de medição, os erros se tornam mais expressivos.

Tabela 4.9: Erros obtidos na fase de teste da RNA em diferentes localizações em 10 rodadas de treinamento.

Treino RNA	8 km			16 km			35 km		
	Erro [%]			Erro [%]			Erro [%]		
	Máx.	Min.	Med.	Máx.	Min.	Med.	Máx.	Min.	Med.
T1	1,48	0,00	0,56	4,45	0,00	0,20	0,48	0,01	0,14
T2	7,08	3,74	5,92	4,13	1,07	2,46	0,47	0,01	0,12
T3	6,95	0,82	6,45	4,50	1,06	1,84	0,58	0,03	0,32
T4	1,94	0,04	0,39	0,82	0,12	0,45	0,29	0,10	0,17
T5	4,92	1,22	2,13	3,53	0,11	2,36	0,52	0,02	0,14
T6	7,22	1,41	2,27	3,47	0,80	1,66	1,23	0,06	0,75
T7	3,26	0,04	0,82	4,07	0,02	0,82	0,55	0,01	0,20
T8	6,07	0,69	1,79	4,20	0,98	3,15	1,34	0,29	0,51
T9	5,56	3,19	4,45	4,33	1,87	2,95	0,48	0,01	0,31
T10	5,96	3,83	4,31	3,92	2,24	3,63	1,13	0,57	0,84

Fonte: (SOUZA et al., 2014).

Tabela 4.10: Erros obtidos na fase de teste da RNA em diferentes localizações em 10 rodadas de treinamento.

Treino RNA	50 km			75 km			90 km		
	Erro [%]			Erro [%]			Erro [%]		
	Máx.	Min.	Med.	Máx.	Min.	Med.	Máx.	Min.	Med.
T1	0,34	0,07	0,19	0,30	0,04	0,10	0,32	0,02	0,06
T2	0,51	0,03	0,19	0,47	0,09	0,22	0,34	0,03	0,09
T3	0,56	0,02	0,20	0,63	0,00	0,27	0,46	0,01	0,05
T4	0,16	0,11	0,13	0,11	0,01	0,06	0,13	0,02	0,06
T5	0,19	0,01	0,09	0,26	0,01	0,08	0,43	0,01	0,06
T6	0,53	0,03	0,26	0,73	0,01	0,09	0,62	0,02	0,09
T7	0,32	0,01	0,10	0,41	0,00	0,13	0,25	0,01	0,05
T8	0,58	0,01	0,14	0,51	0,02	0,29	0,45	0,02	0,10
T9	0,65	0,01	0,11	0,67	0,17	0,32	0,39	0,02	0,11
T10	0,61	0,06	0,33	0,52	0,18	0,42	0,30	0,02	0,16

Fonte: (SOUZA et al., 2014).

Como em casos reais uma falta nem sempre ocorre nas condições em que a RNA foi treinada, os autores realizaram cinco simulações de faltas não inclusas no treinamento, com o objetivo de testar sua capacidade de generalização. As condições de faltas simuladas são apresentadas na Tabela 4.8.

Tabela 4.11: Condições de faltas simuladas.

Simulação	D_{REAL} (km)	RF (Ω)	Θ (graus)	t₁ (ms)	t₂ (ms)
1	8,20	3,40	341,64	15,88	15,93
2	23,60	9,33	47,94	0,96	1,12
3	44,20	9,88	158,08	7,50	7,80
4	58,70	8,34	84,66	4,14	4,54
5	83,10	14,10	286,57	13,58	14,14

Fonte: (SOUZA et al., 2014).

Para fins de comparação, os autores realizaram a estimativa da distância da falta através da TOVs. As distâncias e os erros referentes à localização da falta por TOVs e RNA são apresentados na Tabela 4.9.

Tabela 4.12: Erros obtidos considerando as faltas simuladas.

D_{REAL} (km)	D_{TOV} (km)	D_{RNA} Méd (km)	Erro TOVs		Erro RNA	
			Abs (km)	Rel [%]	Abs (km)	Rel [%]
8,20	7,49	8,38	0,71	8,66	0,18	2,16
23,60	23,98	23,50	0,38	1,61	0,11	0,46
44,20	44,97	44,15	0,77	1,74	0,08	0,19
58,70	59,96	58,73	1,26	2,15	0,07	0,13
83,10	83,94	83,42	0,84	1,01	0,32	0,39

Fonte: (SOUZA et al., 2014).

O método proposto por Souza et al. (2014) possui algumas diferenças em relação aos outros métodos analisados neste trabalho, sendo as principais a realização da análise parcial da LT, limitando-se a localizar apenas faltas na primeira metade da LT, e a realização da análise de apenas faltas monofásicas do tipo AT.

No entanto, realiza a estimativa da distância da falta, em localizações já conhecidas, através da TOVs e RNA e apresenta os resultados (Tabela 4.9), fato bastante relevante, uma vez que, pode-se realizar a comparação entre os métodos e observar os erros de cada um. O método proposto apresentou resultados satisfatórios e boa precisão tanto na utilização da TOVs quanto de RNA, sendo os menores erros obtidos com a RNA.

5. CONCLUSÕES

A análise de faltas em linhas de transmissão por meio de redes neurais artificiais foi abordada neste trabalho. Ao longo do mesmo, tópicos referentes à LTs, como descrição dos parâmetros, modelamento, faltas e suas possíveis causas, análise de faltas por meio de métodos convencionais, métodos baseados em análise de sinais e métodos inteligentes foram abordados.

Dentre os métodos inteligentes de análise de faltas estão as RNAs. A metodologia utilizada nas RNAs, bem como demais detalhes também foram tópicos abordados neste trabalho. Para exemplificar a análise de faltas através de RNAs e sua aplicabilidade, três trabalhos foram selecionados e apresentados no Capítulo 3, bem como as análises de seus resultados, apresentadas no Capítulo 4.

Os trabalhos apresentaram excelentes resultados, com alto índice de acertos. Oleskovicz et al. (2003), abordou a detecção, classificação e localização de faltas em LTs utilizando apenas dados simulados. Melo e Silva et al. (2007), abordou a detecção e classificação de faltas em LTs utilizando dados reais e simulados. Por fim, Souza et al. (2014), abordou a localização de faltas em LTs utilizando dados simulados.

Nos resultados apresentados por Oleskovicz et al. (2003), pôde-se observar boa precisão e velocidade das respostas para todos os módulos do método proposto. A percentagem de respostas corretas foi apresentada por cada módulo, sendo o módulo de localização da falta, o que apresentou a menor delas, porém, ainda melhor que métodos convencionais.

Em Melo e Silva et al. (2007) foi proposto um método de detecção e classificação de faltas em LTs por meio de TWD e RNAs, diferindo-o assim de Oleskovicz et al. (2003), Souza et al. (2014) e de outros métodos existentes. Outro diferencial deste método é a distinção entre faltas e distúrbios relacionados à QEE. O método apresentou ótimos resultados, tanto para dados reais, quanto para dados simulados.

Em Souza et al. (2014) foi proposto um método de localização de faltas em LTs por meio de TOVs e RNA, diferindo-o assim dos outros métodos analisados neste trabalho. O método apresentou resultados satisfatórios para a localização das faltas por meio da TOVs e RNA, apresentando maior precisão na utilização da RNA.

Através dos resultados apresentados neste trabalho, pôde-se observar o alto desempenho das RNAs na detecção, classificação e localização de faltas em LTs. No entanto, é válido ressaltar que, o alto desempenho das RNAs está intimamente ligado às etapas de treinamento, validação e teste das mesmas. Para isso, é necessária uma grande quantidade de dados, fato este, que dificulta o processo, pois em muitos dos casos, dados reais não são disponibilizados e simulações podem ser bastante complexas. Ainda assim, os métodos de análise de faltas em LTs baseados em redes neurais têm se mostrado bastante promissores, devido sua precisão e velocidade, que são características esperadas em um sistema de proteção eficiente.

Espera-se, por fim, que este trabalho sirva como referencial teórico e guia para trabalhos futuros envolvendo análise de faltas em linhas de transmissão através de métodos inteligentes. Algumas indicações para trabalhos futuros são apresentadas no próximo item.

5.1. TRABALHOS FUTUROS

Visando aperfeiçoar o trabalho apresentado aqui, propõem-se as seguintes sugestões a serem realizadas em trabalhos futuros:

- Levantamento teórico e abordagem detalhada de métodos convencionais e de métodos baseados em análise de sinais;
- Levantamento teórico e abordagem detalhada de outros métodos baseados em sistemas inteligentes, tais como lógica *fuzzy* e *neurofuzzy*;
- Comparação entre diferentes métodos de análise de faltas em LTs;
- Desenvolvimento de um método completo para análise de faltas em LTs;
- Simulação de faltas em LTs através de *softwares*, como por exemplo, o ATP;
- Validação da metodologia a partir de estudos de casos reais.

REFERÊNCIAS

- BRAGA, A. de P.; LUDEMIR, T. B.; LEON FERREIRA CARVALHO, A. C. P. **Redes Neurais Artificiais – Teoria e Aplicações**. 2. ed., LTC. Rio de Janeiro, 2007.
- FUCHS, R. D. **Transmissão de energia elétrica: Linhas Aéreas**. 1. ed. Livros Técnicos e Científicos. Rio de Janeiro, 1977.
- GOMES, C. R. **Localização de falhas em linhas de transmissão utilizando decomposição harmônica e redes neurais artificiais**. 2006. 106 f. Dissertação de Mestrado - Universidade Federal do Pará, Instituto de Tecnologia, Belém, 2006. Programa de Pós-Graduação em Engenharia Elétrica.
- HAYKIN, S. **Neural Networks – A Comprehensive Foundation**. 2. ed. Prentice-Hall, 1999.
- HEBB, D. O. **The Organization of Behavior**. Wiley, 1949.
- HOPFIELD, J. J. **Neural networks and physical systems with emergent collective properties**. Proc. Nat. Acad. Sci., 79:2554-8, 1982.
- HOROWITZ, S. H.; PHADKE, A. G. **Power system relaying**. 3. ed. John Wiley & Sons Ltd, West Sussex, England, 2008.
- INÁCIO, M. J. **Detecção e classificação de faltas em linhas de transmissão utilizando transformada wavelet e rede lógica neurofuzzy com aprendizado participativo**. Dissertação de Mestrado - Universidade Federal de Minas Gerais, Belo Horizonte, 2010.
- LESSA, L. **Avaliação de um método de localização de faltas em linhas de transmissão**. 2012. 106 f. Monografia (Engenharia Elétrica) – Universidade Federal do Rio de Janeiro, Escola Politécnica, Rio de Janeiro, 2012.
- LINSKER, R. **Self-organization in perceptual network**. Computer, 21(3):105-117, 1988.
- LOPES, F. V.; FERNANDES Jr, D; NEVES, W. L. **Localização de faltas em linhas de transmissão: revisão da literatura e tendências recentes**. Anais do V Simpósio Brasileiro de Sistemas Elétricos. 22 a 25 de abril de 2014. Foz do Iguaçu – PR, 2014.

McCULLOCH, W.S.; PITTS, W. **A logical calculus of the ideas immanent in nervous activity**. Bulletin of Mathematical Biophysics, 5:115-133, 1943.

MENDEL, J. M.; McLAREN, R. W. **Reinforcement-learning control and pattern recognition systems**. Adaptive, Learning, and Pattern Recognition Systems: Theory and Applications, vol 66, MENDEL, J.M. FU, K.S. eds., pp. 287-318, New York: Academic Pres, 1970.

MINSKY, M.; PAPERT, S. **Perceptrons: an introduction to computational geometry**. MIT Press, Massachusetts, 1969.

OJA, E. **A simplified neuron model as a principal component analyzer**. Journal of Mathematical Biology. 15:267-273, 1982.

OLESKOVICZ, M.; COURRY, D. V.; AGGARWAL, R. K. O emprego de redes neurais artificiais na detecção, classificação e localização de faltas em linhas de transmissão. **Sba Controle & Automação**, Campinas, v. 14, n. 2, p. 138-150, Junho 2003. Disponível em: <http://www.scielo.br/scielo.php?script=sci_arttext&pid=S0103-17592003000200006&lng=en&nrm=iso>. Acesso em: 16 de março de 2015.

REZENDE, S. O. **Sistemas Inteligentes – Fundamentos e Aplicações**. Manole, São Paulo, 2005.

ROCHA DE OLIVEIRA, A. **Redes neurais artificiais aplicadas na detecção, classificação e localização de defeitos em linhas de transmissão**. Dissertação de Mestrado - Universidade Federal de Juiz de Fora, Juiz de Fora, 2005. Programa de Pós-Graduação em Engenharia Elétrica.

ROSENBLATT, F. **The perceptron: A probabilistic model for information storage and organization in the brain**. Psychol. Rev.,65:386-408, 1958.

RUMELHART, D. E.; HINTON, G. E.; WILLIAMS, R. J. **Learning representations by back-propagating errors**. Nature, 323:533-536, 1986.

SAADAT, H. **Power system analysis**. 3. ed. PSA Publishing, 2010.

SOUZA, S. C. A. et al. **Localização de faltas em linhas de transmissão usando redes neurais artificiais e ondas viajantes.** Anais do XX Congresso Brasileiro de Automática. 20 a 24 de setembro de 2014. Belo Horizonte – MG, 2014.

von der MALSBERG, C. **Self-organization of orientation sensitive cells in the striate cortex.** Kybernetik, vol. 14, pp. 85-100, 1973.

WIDROW, B.; HOFF, M. E. **Adaptative switching circuits.** Institute of Radio Engineers, Western Electronic Show and Convention, 1960.

WILLSHAW, D. J.; von der MALSBERG, C. **How patterned neural connections can be set up by self-organization.** Proceedings of the Royal Society of London Series B, vol. 194, pp. 431-445, 1976.

YUILLE, A. L.; KAMMEN, D. M.; COHEN, D. S. **Quadrature and development of orientation selective cortical cells by hebb rules.** Biological Cybernetics, 61:183-194, 1989.