UNIVERSIDADE DE SÃO PAULO
ESCOLA DE ENGENHARIA DE SÃO CARLOS
DEPARTAMENTO DE ENGENHARIA ELÉTRICA E DE COMPUTAÇÃO

Luís Fernando Navarro

Redes Neurais Artificiais Aplicadas à Detecção, Classificação e Localização de Faltas em Sistemas de Distribuição de Energia Elétrica

São Carlos
2014

Luís Fernando Navarro

Redes Neurais Artificiais Aplicadas à Detecção, Classificação e Localização de Faltas em Sistemas de Distribuição de Energia Elétrica

Trabalho de Conclusão de Curso
apresentado à Escola de Engenharia de
São Carlos, da Universidade de São Paulo

Curso de Engenharia Elétrica com ênfase
em Sistemas de Energia e Automação

ORIENTADOR: Prof. Dr. Rogério Andrade Flauzino

São Carlos
2014

AUTORIZO A REPRODUÇÃO TOTAL OU PARCIAL DESTE TRABALHO, POR QUALQUER MEIO CONVENCIONAL OU ELETRÔNICO, PARA FINS DE ESTUDO E PESQUISA, DESDE QUE CITADA A FONTE.

N322r

Navarro, Luís Fernando
Redes neurais artificiais aplicadas à detecção, classificação e localização de faltas em sistemas de distribuição de energia elétrica / Luís Fernando Navarro; orientador Rogério Andrade Flauzino. São Carlos, 2014.

Monografia (Graduação em Engenharia Elétrica com ênfase em Sistemas de Energia e Automação) -- Escola de Engenharia de São Carlos da Universidade de São Paulo, 2014.

1. Proteção de Sistemas Elétricos de Potência. 2. Sistemas de Distribuição de Energia Elétrica. 3. Redes Neurais Artificiais. 4. Sistemas Inteligentes . 5. MATLAB. 6. Transformada Discreta de Fourier. I. Título.

FOLHA DE APROVAÇÃO

Nome: **Luis Fernando Navarro**

Título: "Redes neurais artificiais aplicadas à detecção, classificação e localização de faltas em sistemas de distribuição de energia elétrica"

Trabalho de Conclusão de Curso defendido e aprovado
em 12 / 09 / 2014,

com NOTA 9,5 (Nove, cinco), pela Comissão Julgadora:

Prof. Dr. Rogério Andrade Flauzino - (Orientador - SEL/EESC/USP)

Mestre Lucas Assis de Moraes - (SEL/EESC/USP)

Mestre Oureste Elias Batista - (SEL/EESC/USP)

Coordenador da CoC-Engenharia Elétrica - EESC/USP:
Prof. Associado Homero Schiabel

A Grande Conquista é o resultado de pequenas vitórias que passam despercebidas.

Paulo Coelho

Agradecimentos:

A conclusão desta etapa acadêmica representada através deste Trabalho de Conclusão de Curso teve a colaboração, direta ou indireta, de diversas pessoas.

Em primeiro lugar aos meus pais **Walmir Fernandes Navarro** e **Soraia Serafim Navarro** que me ensinaram os primeiros passos e me ajudaram ao longo de toda caminhada até aqui. À minha irmã **Gabriela Serafim Navarro** pelo companheirismo ao longo destes doze anos.

Ao meu orientador **Rogério Andrade Flauzino** por todo suporte dado no decorrer do desenvolvimento deste trabalho.

A todas as pessoas que conheci e convivi ao longo destes seis anos, superando com elas os desafios dia após dia e compartilhando bons momentos que sempre serão lembrados.

Por fim, ao Departamento de Engenharia Elétrica e Computação da Escola de Engenharia de São Carlos e a todos os professores e funcionários que o integram pela excelência no ensino.

Sumário:

Capítulo 1 - Introdução. **23**
1.1 Justificativas e Objetivos 23
1.2 Organização do Trabalho 24
Capítulo 2 - Revisão Bibliográfica **27**
2.1 Sistemas de Distribuição de Energia Elétrica 27
2.2 Proteção em Sistemas Elétricos de Potência (SEPs) 29
2.3 Redes Neurais Artificiais (RNAs) 32
2.4 RNAs aplicadas aos SEPs 43
2.5 O MATLAB e as ferramentas computacionais aplicadas à simulação de SEPs e RNAs 46
Capítulo 3 - Aspectos da Metodologia Desenvolvida **49**
3.1 Esquemático Geral do Trabalho 49
3.2 Sistema de Distribuição de Energia Elétrica Simulado 54
3.3 Módulo de Detecção 65
3.4 Módulo de Classificação 67
3.5 Módulo de Localização 70
Capítulo 4 - Validação das Redes Neurais Artificiais **73**
4.1 Validação do Módulo de Detecção 73
4.2 Validação do Módulo de Classificação 76
4.3 Validação do Módulo de Localização 79
4.3.1 Rede Neural Artificial 1 79
4.3.2 Rede Neural Artificial 2 81
4.3.3 Rede Neural Artificial 3 83
Capítulo 5 - Conclusão **87**
Referências Bibliográficas **88**
Anexos **93**

Lista de Figuras:

Figura 2.1: Diagrama Unifilar representando a Geração, Transmissão e Distribuição nos SEPs.....27
Figura 2.2: Sistema Elétrico de Potência (SEP).....28
Figura 2.3: Sistema de proteção típico e suas zonas de proteção primárias.....30
Figura 2.4: Esquemático do sistema de proteção de um SEP 31
Figura 2.5: Neurônio Artificial proposto no trabalho de McCulloch e Pitts 35
Figura 2.6: Função Degrau e Degrau Bipolar.....36
Figura 2.7: Funções Sigmoides.....36
Figura 2.8: Função Rampa Simétrica, Gaussiana e Linear.....37
Figura 2.9: Rede *feedforward* de múltiplas camadas.....39
Figura 2.10: Rede PCM adaptada para o seu equacionamento 39
Figura 2.11: Trabalhos publicados no IEEE entre 2000 e 2005 relacionados às aplicações das RNAs em SEPs.....44
Figura 3.1: Diagrama de blocos do trabalho desenvolvido 49
Figura 3.2: Diagrama de blocos com a aquisição e análise pelas RNAs dos dados obtidos do sistema simulado.....50
Figura 3.3: Exemplo do registro oscilográfico da corrente na ocorrência de uma falta.....50
Figura 3.4: Janela móvel de dados com dados de entrada das RNAs.....51
Figura 3.5: Principais sub-sistemas de um relé digital.....52
Figura 3.6: Fluxograma dos algoritmos implementados neste trabalho.....53
Figura 3.7: Sistema de distribuição utilizado para a obtenção de dados para as RNAs.....54
Figura 3.8: Modelo no *SimPowerSystems* do sistema de distribuição utilizado (Parte 1).....55
Figura 3.9: Modelo no *SimPowerSystems* do sistema de distribuição utilizado (Parte 2).....55
Figura 3.10: Modelo no *SimPowerSystems* do sistema de distribuição utilizado (Parte 3)....55
Figura 3.11: Terminal de aquisição de dados dos sinais de tensão e corrente (nó N) do sistema de distribuição utilizado no *SimPowerSystems*.....56
Figura 3.12: Sinal com amostragem adequada e Sinal com *aliasing*.....57
Figura 3.13: Representação de um filtro passa-baixa ideal do tipo *Butterworth*.....57
Figura 3.14: Representação de um filtro passa-baixa de ordem 2, 4 e 6 do tipo *Butterworth*.....57
Figura 3.15: Resposta em frequência do filtro *Butterworth* de ordem 2 deste trabalho.....58
Figura 3.16: Fluxograma do processo de formação das matrizes de entrada para o treinamento das RNAs.....59
Figura 3.17: Bloco do *SimPowerSystems* responsável pela simulação das faltas.....60

Figura 3.18: Bloco do *SimPowerSystems* responsável pela simulação das cargas do sistema.....60
Figura 3.19: Bloco do *SimPowerSystems* responsável por realizar a simulação.....60
Figura 3.20: Figura relacionada com a Tabela 3.3.....61
Figura 3.21: Quantidade de simulações efetuadas com o sistema apresentando uma falta.....62
Figura 3.22: Exemplo de arquivo gerado pelo *SimPowerSystems* e correspondente à entrada do RNA do módulo de detecção com janela de dados de 3 amostras.....65
Figura 3.23: Detecção de falta através do método comparativo.....66
Figura 3.24: Detecção de falta através do estimativo (esquerda) e de retificação da onda (direito).....66
Figura 3.25: Sinal das Correntes Trifásicas (direita) e das Tensões Trifásicas (esquerda) no caso de ocorrência de falta AT na localização ‘2’ de acordo com a tabela 3.3 com resistência de falta de 0,001[Ω] e ângulo de incidência de 0º.....67
Figura 3.26: Sinal das Correntes Trifásicas (direita) e das Tensões Trifásicas (esquerda) no caso de ocorrência de falta AT na localização ‘10’ de acordo com a tabela 3.3 com resistência de falta de 0,001[Ω] e ângulo de incidência de 0º.....67
Figura 3.27: Esquema de localização de falta sincronizando dois terminais através de GPS.....71
Figura 4.1: Relação entre quantidade de neurônios na camada intermediária e porcentagem de acertos no módulo de detecção.....74
Figura 4.2: RNA eleita para o módulo de detecção.....75
Figura 4.3: Relação entre comprimento da janela de dados, porcentagem de acertos e tempo de processamento no módulo de classificação.....77
Figura 4.4: RNA eleita para o módulo de classificação.....78
Figura 4.5: RNA 1 do módulo de localização.....80
Figura 4.6: RNA 2 do módulo de localização.....82
Figura 4.7: RNA 3 do módulo de localização.....84

Lista de Tabelas:

Tabela 2.1: Incidência de faltas elétricas em sistema de transmissão.....32
Tabela 2.2: Estatística para os tipos de faltas ocorrentes em sistemas de distribuição.....32
Tabela 3.1: Parâmetros das linhas de distribuição empregadas na simulação.....54
Tabela 3.2: Parâmetros do Conversor Analógico Digital (CAD) e do filtro *Butterworth* deste trabalho.....58
Tabela 3.3: 10 diferentes localizações das faltas simuladas.....61
Tabela 3.4: Respostas esperadas da RNA do módulo de detecção de falta.....66
Tabela 3.5: Classificação da falta quanto ao tipo se falta ocorrer entre os nós N e O/P/Q.....68
Tabela 3.6: Classificação da falta quanto ao tipo se falta ocorrer entre os nós L e N.....69
Tabela 3.7: Respostas esperadas da RNA do módulo de classificação de falta.....69
Tabela 3.8: Respostas esperadas da RNA do módulo de localização de falta.....72
Tabela 4.1: Divisão do total de amostras em conjunto de treinamento e teste para os três grupos do módulo de detecção.....74
Tabela 4.2: Características da RNA do módulo de detecção de falta.....75
Tabela 4.3: Parâmetros de Treinamento da RNA do módulo de detecção de falta.....75
Tabela 4.4: Validação Cruzada da RNA eleita para o módulo de detecção.....76
Tabela 4.5: Divisão do total de amostras em conjunto de treinamento e teste para os três grupos do módulo de classificação.....76
Tabela 4.6: Características da RNA do módulo de classificação de falta.....77
Tabela 4.7: Parâmetros de Treinamento da RNA do módulo de detecção de falta.....78
Tabela 4.8: Validação Cruzada da RNA eleita para o módulo de classificação.....78
Tabela 4.9: Divisão do total de amostras em conjunto de treinamento e teste para os três grupos da RNA 1 módulo de localização.....79
Tabela 4.10: Características da 1ª RNA do módulo de localização de falta.....79
Tabela 4.11: Parâmetros de Treinamento da 1ª RNA do módulo de localização de falta.....80
Tabela 4.12: Validação Cruzada da 1ª RNA eleita para o módulo de localização.....81
Tabela 4.13: Divisão do total de amostras em conjunto de treinamento e teste para os três grupos da RNA 2 módulo de localização.....81
Tabela 4.14: Características da 2ª RNA do módulo de localização de falta.....82
Tabela 4.15: Parâmetros de Treinamento da 2ª RNA do módulo de localização de falta.....82
Tabela 4.16: Validação Cruzada da 2ª RNA eleita para o módulo de localização.....83

Tabela 4.17: Divisão do total de amostras em conjunto de treinamento e teste para os três grupos da RNA 3 módulo de localização.....83
Tabela 4.18: Características da 3ª RNA do módulo de localização de falta.....84
Tabela 4.19: Parâmetros de Treinamento da 3ª RNA do módulo de localização de falta.....84
Tabela 4.20: Validação Cruzada da 3ª RNA eleita para o módulo de localização.....85

Lista de Siglas:

AC *Alternating Current*

ANEEL Agência Nacional de Energia Elétrica

ASPEN *Advanced Systems Control*

ATP *Alternative Transient Program*

CAD Conversor Analógico Digital

CAPE *Computer-Aided Protection Engineering*

DIgSILENT *Digital Simulator for Electrical Networks*

DC *Direct Current*

DFT *Discrete Fourier Transform*

EMTP *Electromagnetic Transient Program*

GPS *Global Positioning System*

IEEE *Institute of Electrical and Electronics Engineers*

LVD *Learning Vector Quantization*

MATLAB *Matrix Laboratory*

MLP *MultiLayer Perceptron*

OPGW O*ptic Overhead Ground Wire*

PMC Perceptron Multicamadas

Prodist Procedimentos de Distribuição

PSAF *Power System Analysis Framework*

PSCAD *Power System Computer Aided Design*

PSS/E *Power System Simulation/Engineering*

RNA Rede Neural Artificial

RTDS *Real Time Digital Simulator*

SCADA *Supervisory Control and Data Acquisition*

SEP Sistemas Elétricos de Potência

SPICE *Simulation Programs for Integrated Circuits*

TC Transformador de Corrente

TDF Transformada Discreta de Fourier

TDNN *Time Delay Neural Network*

TP Transformador de Potencial

Resumo:

NAVARRO, L. F. (2014) "**Redes Neurais Artificiais Aplicadas à Detecção, Classificação e Localização de Faltas em Sistemas de Distribuição de Energia Elétrica**". Trabalho de Conclusão de Curso – Escola de Engenharia de São Carlos, Universidade de São Paulo, 2014.

Com o aumento da demanda e importância da energia elétrica no Brasil e no mundo, a crescente complexidade e quantidade de informações a serem tratadas dos Sistemas Elétricos de Potência, e a maior diversidade e exigência do mercado consumidor na garantia da continuidade e confiabilidade no fornecimento de energia elétrica, é cada vez mais necessária, dentre outras medidas, a melhoria das técnicas de proteção dos sistemas de distribuição de energia elétrica. Com base nisso, diversas metodologias são desenvolvidas e aprimoradas, dentre elas algumas utilizando redes neurais artificiais. Baseado na literatura disponível deste setor, se busca através deste trabalho o estudo e desenvolvimento de ferramentas inteligentes cruciais para o restabelecimento do fornecimento de energia elétrica aos consumidores, sendo elas voltadas para a detecção, classificação e localização de curtos-circuitos em linhas de distribuição de energia elétrica, contanto com o auxílio do MATLAB e da Transformada Discreta de Fourier. Ao final deste trabalho será possível concluir que as redes neurais artificiais se apresentam como uma alternativa viável e confiável aos métodos convencionais de proteção de curtos-circuitos em linhas de distribuição de energia elétrica.

Palavras-chave: Redes Neurais Artificiais, Sistemas de Distribuição de Energia Elétrica, Proteção de Sistemas Elétricos de Potência, Sistemas Inteligentes, MATLAB, Transformada Discreta de Fourier.

Abstract:

NAVARRO, L. F. (2014) "***Artificial Neural Networks Applied to Detection, Classification and Localization of Faults in Power Distribution Systems***". *Undergraduate Final Project* – Escola de Engenharia de São Carlos, Universidade de São Paulo, 2014.

Considering the increasing and importance of electricity in Brazil and around the world, the growing complexity and quantity of information to be treated of Electric Power Systems, and the greatest diversity and demands of the consumer market to ensure the continuity and reliability of electricity supply, it is increasingly necessary, among other things, the improvement of techniques for the protection of electrical power distribution systems. According to this, various methodologies are developed and improved, some of them using artificial neural networks. Based on the literature available of this sector, this Undergraduate Final-Project will study and develop crucial intelligent tools for restoring the supply of electric energy to consumers, focused on the detection, classification and localization of short circuits in distribution lines, using MATLAB and Discrete Fourier Transform (DFT). At the end of this monograph it will be able to conclude that artificial neural networks are presented as a viable and reliable alternative to conventional methods of protection from short circuits in electric power distribution systems.

Keywords: Neural Networks, Electrical Distribution Systems, Power-System Protection, Intelligent Systems, MATLAB, Discrete Fourier Transform.

Capítulo 1

Introdução

1.1 Justificativas e Objetivos

A energia elétrica é um recurso fundamental para o desenvolvimento econômico de um país e para o bem estar de sua população, com sua importância aumentando a cada dia, e está presente nos setores industrial, agrícola, comercial e doméstico. Neste contexto, os Sistemas Elétricos de Potência (SEPs) devem ser projetados com a finalidade de entregar energia elétrica ao consumidor com confiabilidade e continuidade. No entanto, os SEP estão sujeitos a descargas atmosféricas, catástrofes naturais, falhas operacionais ou em seus dispositivos, como geradores, transformadores, cabos, disjuntores, chaves de manobra, relés e motores, e podem prejudicar todos os sistemas que estejam interligados, portanto é necessário o isolamento da parte afetada com a finalidade de minimizar os efeitos negativos e manter a maior parte possível do sistema elétrico em funcionamento. Sendo assim, é necessário um sistema de proteção seletivo e eficaz para assegurar a confiabilidade e a continuidade no suprimento de energia, ao mesmo tempo em que isola o mais rápido possível a região afetada visando à diminuição de danos materiais, instabilidade do sistema, efeito cascata, dentre outros efeitos negativos. Com relação às regiões isoladas se busca integrá-las novamente ao SEP o mais rápido possível para que os consumidores sejam afetados o mínimo possível [1].

Com o constante crescimento da demanda de energia elétrica no Brasil, a crescente complexidade dos SEPs, o aumento da diversidade do mercado consumidor, da quantidade de informações a serem tratadas e da exigência da confiabilidade no fornecimento de energia elétrica, é cada vez maior a necessidade de melhoria nos sistemas de proteção dos SEPs [2]. Os sistemas de transmissão e de distribuição de energia elétrica estão crescendo à medida que aumentam os núcleos populacionais e o desenvolvimento industrial. Este crescimento apresenta maior reflexo nos sistemas de distribuição, já que correspondem aos circuitos terminais do fornecimento de energia elétrica [3].

Nas linhas de distribuição primárias, cuja classe de tensão pode ser de 13.8[kV], por exemplo, estão a maioria dos consumidores e a ocorrência de faltas é muito grande. No sistema de transmissão, onde a classe de tensão é da ordem de dez ou mais vezes maior quando comparado ao sistema de distribuição, estes inconvenientes também ocorrem, no entanto o restabelecimento de energia é mais rápido primeiro devido à sua configuração e

segundo porque os relés de proteção destas linhas possuem a função de localização de falta [2]. Além disso, nos SEPs, a medida que se diminui os níveis de tensão, os elementos que conformam essa grandeza elétrica aumentam em quantidade e diversidade, e na operação deles a influência humana se torna mais significativa, e a presença de ferramentas que auxiliem na análise das diferentes faltas que ocorrem em tais redes elétricas se tornam ainda mais importantes [4]. Por essas razões este trabalho foi desenvolvido para redes de distribuição, embora a ideia possa ser aplicada também aos sistemas de transmissão.

Uma descontinuidade no fornecimento de energia elétrica além de gerar perdas financeiras por parte das empresas, agricultura e comércio e desconforto por parte também dos consumidores residenciais, podem implicar em multas para os responsáveis pelo fornecimento de energia elétrica pela agência de regulação do setor elétrico ANEEL. Além disso, podem haver prejuízos em virtude de processos judiciais devido a perdas e danos causados a grandes e pequenos consumidores e ao mesmo tempo insatisfação por parte destes consumidores. A regulamentação do setor tem levado as empresas de energia elétrica a investirem em equipamentos modernos, permitindo melhor gerenciamento e proteção dos sistemas elétricos [5].

Nas últimas décadas, a utilização de dispositivos baseados em microprocessadores para problemas relacionados aos SEPs está cada vez mais frequente e estudada por engenheiros e cientistas. Isso se deve ao rápido avanço desta tecnologia por parte de *hardware* e *software*, além do desenvolvimento da área de proteção de SEPs [1].

Este trabalho tem como objetivo o estudo e desenvolvimento de técnicas aplicadas à detecção, classificação e localização de faltas em sistemas de distribuição de energia elétrica que sejam confiáveis, eficientes na obtenção dos resultados e de fácil implementação prática. Serão apresentadas ao decorrer deste trabalho as diferentes alternativas que foram encontradas ao longo da revisão bibliográfica. Pode-se listar como objetivos secundários a definição de um sistema de distribuição de energia elétrica, o estudo do MATLAB, que se apresenta como uma excelente alternativa para a resolução dos mais diversos problemas que possam aparecer no âmbito da engenharia, das redes neurais artificiais (RNAs) e do processamento do sinal de entrada para que fosse possível a aplicação desta técnica.

1.2 Organização do Trabalho

Este Trabalho de Conclusão de Curso está organizado em cinco capítulos que mostram o seu processo de desenvolvimento e os resultados finais obtidos.

O capítulo 1 apresenta o contexto em que está inserido este trabalho, assim como sua relevância, seus objetivos e as justificativas de seu desenvolvimento.

No capítulo 2 é apresentada uma revisão bibliográfica com relação, a princípio, aos sistemas de distribuição de energia elétrica e aos tópicos principais da proteção de SEPs. Em seguida os tópicos abordados são as RNAs com enfoque no Perceptron Multicamadas (PMC), que foi a arquitetura de rede escolhida, e de suas aplicações na proteção dos SEPs, e por fim, a discussão gira em torno dos *softwares* utilizados neste trabalho, com o *Simulink* responsável pela obtenção dos dados da rede de distribuição e o *software* MATLAB como um todo para a simulação das RNAs e a manipulação destes dados.

No capítulo 3 é apresentado um esquemático geral do trabalho desenvolvido e o sistema de distribuição utilizado para a simulação, além do tratamento do sinal obtido com o uso de filtros *anti-aliasing*, da conversão analógica digital e dos algoritmos para adequar os dados para a sua posterior entrada nas RNAs desenvolvidas. No decorrer deste capítulo serão mostrados também os três módulos do conjunto criado para a obtenção pelos dispositivos de proteção das informações referentes às faltas que podem ocorrer no sistema de distribuição de energia elétrica, que no caso são os módulos de detecção, classificação e localização da falta.

No capítulo 4 se apresentam os resultados obtidos no treinamento e validação das RNAs presentes no trabalho, sendo os tópicos divididos em módulos de acordo com o que foi discutido no capítulo 3.

No capítulo 5 é apresentada uma conclusão sobre os efeitos deste algoritmo desenvolvido no contexto do tema abordado, e são feitas propostas para a continuação deste trabalho.

Capítulo 2

Revisão Bibliográfica

2.1 Sistemas de Distribuição de Energia Elétrica

Os Sistemas Elétricos de Potências (SEPs) são conjuntos de equipamentos que operam de maneira coordenada com o objetivo de fornecer energia elétrica aos consumidores respeitando certos padrões de qualidade, segurança, custo e com o mínimo de impacto ambiental. Eles são compostos pela geração, transmissão e distribuição de energia, conforme diagrama unifilar da figura 2.1, e estão condicionados ao fato de que geração e demanda devem estar em equilíbrio instantâneo e permanente. O dimensionamento dos SEPs é elaborado baseado no pico de consumo, portanto de um modo geral deve haver a subutilização do sistema [6].

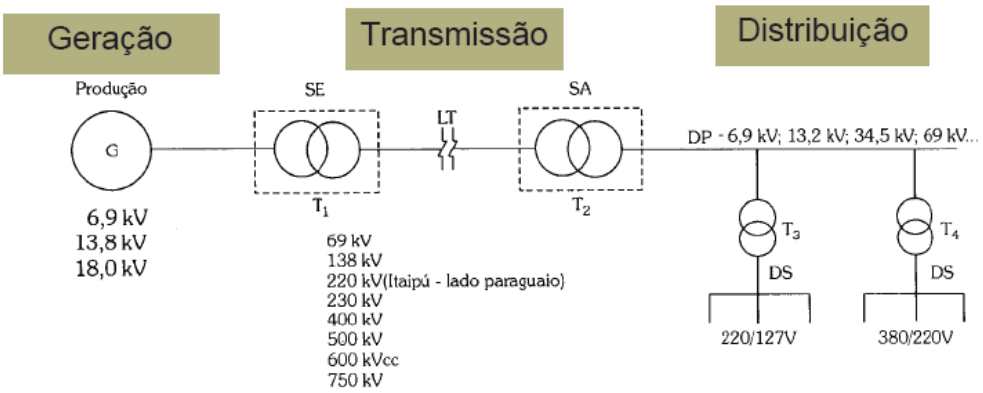

Figura 2.1: Diagrama Unifilar representando a Geração, Transmissão e Distribuição nos SEPs

A energia elétrica é gerada mediante as mais variadas tecnologias, e as principais delas usam do movimento rotatório para gerar corrente alternada em um alternador, e este movimento pode ser realizado mediante energia mecânica direta, como no caso das quedas d'água ou vento, ou através de um ciclo termodinâmico. É importante destacar também a energia gerada através dos raios solares. Na geração a tensão elétrica está geralmente entre 6[kV] e 20[kV], e em seguida há transformadores que elevam essa tensão para a ordem dos 220[kV] a 750[kV]. Este aumento faz com que seja possível transportar uma alta potência elétrica através das linhas de transmissão em longas distâncias usando cabos de baixo custo com perdas mínimas nas linhas. Geralmente no transporte da energia elétrica se

emprega a corrente alternada já que ela possibilita que a magnitude da tensão possa ser variada através de transformadores. Porém nas últimas décadas se mostrou possível esse transporte através de corrente contínua para longas distâncias [6]. No Brasil a frequência da rede elétrica é de 60[Hz], e é comum também o uso de 50[Hz] em alguns outros países, como Argentina, Chile e Paraguai e também no continente europeu. Ao longo da transmissão de energia elétrica, a tensão elétrica é abaixada mediante transformadores para que a energia elétrica possa percorrer os sistemas de distribuição e ser entregue aos consumidores como ocorre, por exemplo, no SEP da figura 2.2 [7].

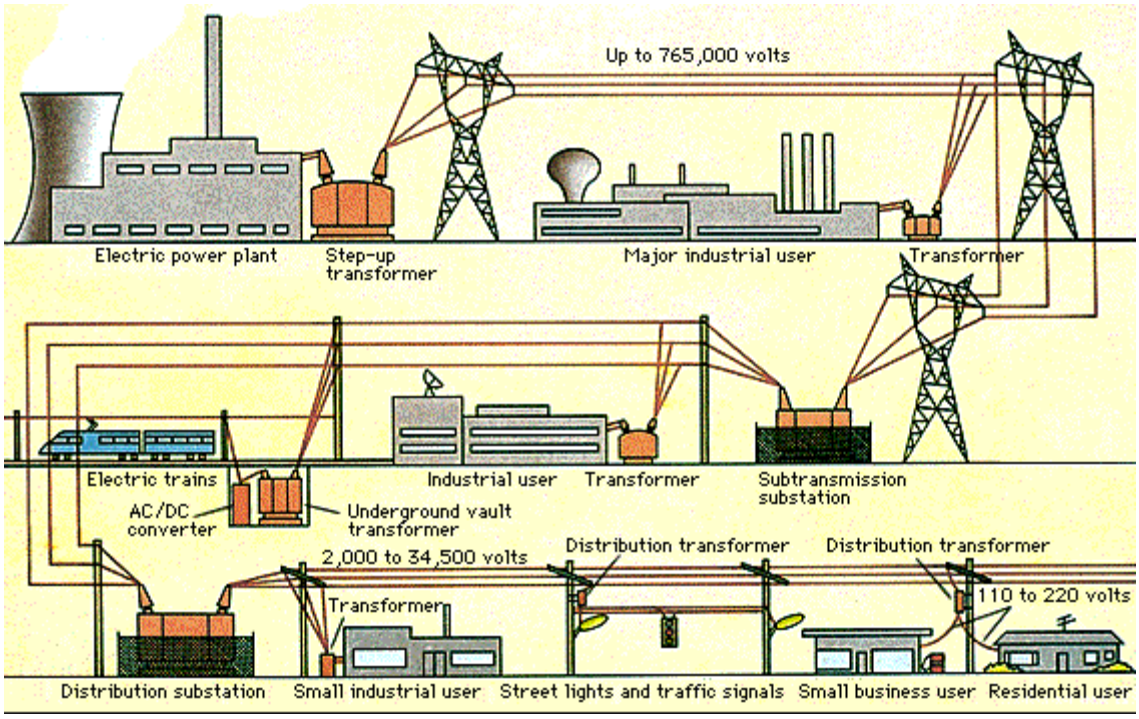

Figura 2.2: Sistema Elétrico de Potência (SEP) (Fonte: [8])

O sistema de sub-transmissão trabalha com níveis de tensão de 35[kV] e 160[kV] e recebe a energia elétrica da rede de transmissão com o intuito de transportá-la a pequenas cidades ou importantes consumidores industriais [7].

O sistema de distribuição, assim como o de transmissão, é composto por fios condutores, transformadores e diferentes equipamentos de medição, controle e proteção. No entanto, o sistema de distribuição é muito mais ramificado e extenso já que ele deve chegar aos vários endereços de seus consumidores, sejam eles domicílios, indústrias e estabelecimentos comerciais e agrícolas [7]. Além das redes de subtransmissão, as distribuidoras operam linhas de média e baixa tensão, também chamadas de redes primária e secundária, respectivamente. As linhas de média tensão são aquelas com tensão elétrica entre 1[kV] e 69[kV], e são vistas frequentemente nas cidades, compostas por três fios

condutores aéreos, são sustentados por cruzetas de madeira em postes de concreto. As redes de baixa tensão, com tensão elétrica abaixo de 1[kV], geralmente 127[V], 220[V] e 440[V], são aquelas que também estão presentes nos postes de concreto que sustentam as redes de média tensão, porém localizam-se a uma altura inferior. As redes de baixa tensão levam energia elétrica até as residências e pequenos comércios e indústrias por meio dos chamados ramais de ligação. Os supermercados, comércios e indústrias de médio porte adquirem energia elétrica diretamente das redes de média tensão, devendo transformá-la internamente para níveis de tensão menores, sob sua responsabilidade [6].

O setor de distribuição de energia elétrica é um dos mais regulamentados e fiscalizados do setor elétrico, tendo a Agência Nacional de Energia Elétrica (ANEEL) como a responsável pela criação de resoluções, portarias e outras normas para o seu funcionamento. Os Procedimentos de Distribuição (Prodist), por exemplo, contêm importantes responsabilidades, penalidades, condições e regras que devem ser respeitadas na distribuição de energia, além de estabelecer critérios e indicadores de qualidade [7].

2.2 Proteção em Sistemas Elétricos de Potência (SEPs)

As concessionárias de energia elétrica devem garantir que o transporte de energia ocorra de modo que as instalações e os equipamentos elétricos interligados ao sistema não tenham sua vida útil reduzida, além de assegurar a qualidade da energia entregue. No entanto, os sistemas elétricos responsáveis por esse transporte estão sujeitos a descargas atmosféricas, catástrofes naturais, falhas operacionais ou em seus dispositivos, podendo comprometer o funcionamento destes sistemas. Segundo a NBR5460 uma falta elétrica pode ser definida como "*ocorrência acidental e súbita, ou defeito, em um elemento de um sistema elétrico, que pode resultar em falha do próprio elemento e/ou de outros elementos associados*" [9].

Os equipamentos de proteção são responsáveis por detectar a ocorrência destas faltas e, com a máxima rapidez possível, devem agir apropriadamente de modo a isolar somente a parte defeituosa do sistema, característica conhecida como seletividade. O restabelecimento do sistema deve ocorrer o mais breve possível, com a finalidade de se evitar danos aos consumidores e à empresa fornecedora, portanto é essencial que a ocorrência dos eventos que produzirem uma determinada sequência de alarmes ocorra de forma rápida, precisa e segura [1].

Com isso se têm as quatro características funcionais básicas de um sistema de proteção, que são:

Sensibilidade: se refere à capacidade do sistema de proteção em responder aos distúrbios ocorrentes no SEP e, por conseguinte, aos curtos-circuitos pelo qual foi projetado [1].

Seletividade: propriedade do sistema de proteção de reconhecer e determinar para quais condições são necessárias a imediata atuação deste sistema, ou a ausência desta atuação e até mesmo o seu retardo, conforme as zonas de proteção. As zonas de proteção correspondem às regiões limitadas do SEP em que cada um dos sistemas de proteção tem a responsabilidade de atuar, podendo ser classificadas como primárias, secundárias ou terciárias conforme o retardo de tempo intencional estabelecido para a atuação de determinado sistema de proteção, sendo este retardo menor para a zona de proteção primária, e maior para a terciária [1]. Na figura 2.3 observa-se um SEP com suas zonas de proteção primária.

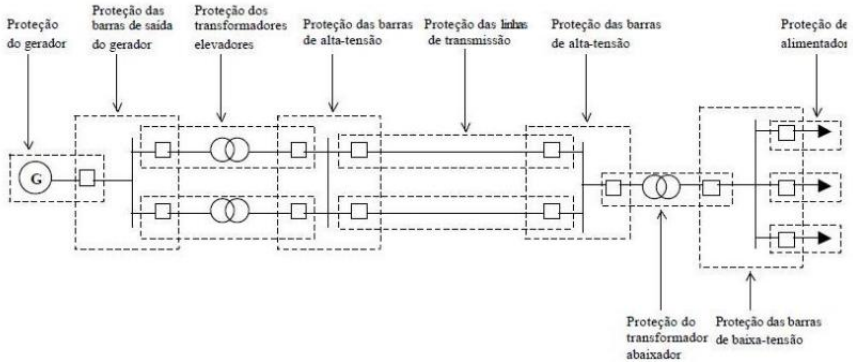

Figura 2.3: Sistema de proteção típico e suas zonas de proteção primárias

Velocidade de atuação: corresponde à capacidade de um sistema de proteção de tomar a decisão de atuar ou não, através do relé, sobre determinada região do sistema, removendo-o o mais rápido possível de uma possível situação de falta [1].

Confiabilidade: se define como a probabilidade de um equipamento ou sistema em satisfazer a função prevista. Neste caso, se considera um sistema de proteção confiável se ele opera apenas nas condições no qual foi projetado. Por sua vez, este mesmo sistema será também classificado como seguro, se ele não opera em qualquer outra situação que possa ocorrer no SEP [1].

Um sistema de proteção, para ser considerado robusto, deve apresentar as características de seletividade, rapidez, sensibilidade e confiabilidade. Um exemplo de sistema de supervisão e controle com a capacidade de processar as informações advindas do sistema de aquisição de dados e controlar remotamente os equipamentos do sistema de proteção é o SCADA. Além da utilização destes mecanismos de supervisão, com o avanço dos sistemas de automação baseados na tecnologia digital, se tornou mais comum a

presença de relés e medidores digitais. Relés baseados em tecnologia digital podem agregar uma ampla gama de funções em um único dispositivo, com as mais comuns sendo relé de sobrecorrente instantâneo e temporizador de fase e neutro, relé de sobrecarga, relé de subtensão e sobretensão, relé de falta e inversão de fases, relé de religamento e relé diferencial de barra [9].

O sistema de proteção de um SEP consiste em quatro diferentes componentes, como se pode observar na figura 2.4 e que são:

Transdutores: apresentam como função reduzir as grandezas envolvidas obtidas do sistema a ser protegido, no caso tensão e corrente, para níveis aceitáveis para os equipamentos do sistema de proteção. Para o caso da tensão, o transdutor correspondente é o TP, e para a corrente, o TC [1].

Relé: corresponde ao componente que controla o sistema de proteção. Normalmente respondem às grandezas de tensão e correntes obtidas do sistema mediante os transdutores acusando a abertura ou não dos disjuntores [1].

Banco de Baterias: referente à fonte de energia reserva do sistema de proteção, e deve ser independente do sistema a ser protegido [1].

Disjuntor: tem como função isolar o trecho do sistema elétrico sobre condição de falta, interrompendo uma corrente quando ela está próxima de zero. É operado através de um disparador energizado pelo banco de baterias e que é comandado pelo relé. [1].

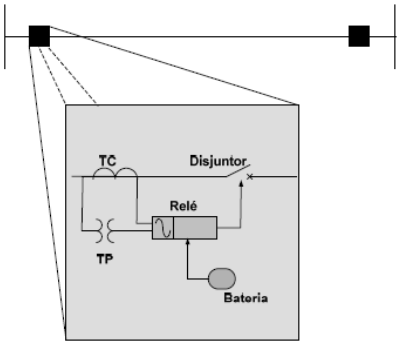

Figura 2.4: Esquemático do sistema de proteção de um SEP (Fonte: [1])

As faltas elétricas que podem ocorrer nas linhas do sistema de distribuição de energia elétrica são os curto-circuitos do tipo [10]:

Monofásicos com aterramento: fase A-terra, fase B-terra e fase C-terra.

Bifásicos: fase A-fase B, fase A-fase C e fase B-fase C.

Bifásicos com aterramento: fase A-fase B-terra, fase A-fase C-terra e fase B-fase C-terra

Trifásicos: fase A-fase B-fase C

De acordo com dados coletados pelas concessionárias *Bonneville Power Administration* entre 09 de Dezembro de 1967 e 30 de Junho de 1973 e pela *Swedish State Power Board* no período de 1951 a 1953, mostrados na tabela 2.1, as faltas monofásicas são largamente predominantes nos sistemas de transmissão de energia elétrica [11].

Tabela 2.1: Incidência de faltas elétricas em sistema de transmissão (Fonte: [11])

Tipo da falta	*Bonneville Power Administration*	*Swedish State Power Board*	
	500[kV]	400[kV]	200[kV]
Fase-Terra	93%	70%	56%
Fase-Fase	4%	23%	27%
Fase-Fase-Terra	2%		
Fase-Fase-Fase	1%	7%	17%

Como se pode ver na tabela 2.2, que corresponde à análise de um sistema de distribuição durante um período de tempo para o estudo dos tipos de faltas ocorrentes nele, as faltas que predominantemente ocorrem no circuito de distribuição, como no de transmissão, são do tipo fase-terra [7].

Tabela 2.2: Estatística para os tipos de faltas ocorrentes em sistemas de distribuição (Fonte: [7])

Tipo da falta	% de Ocorrência	% de Permanentes	% de Transitórias
Trifásicas	2%	95%	5%
Bifásicas	11%	70%	30%
Fase-Terra	79%	20%	80%
Outros	8%	-	-

Em [9] se relata que os principais tipos de faltas em sistemas de distribuição são curto-circuito do tipo fase-terra, com 70% de ocorrência, curto-circuito bifásico, com 15%, curto-circuito bifásico à terra, 10% e curto-circuito trifásico, menos de 1%.

2.3 Redes Neurais Artificiais (RNAs)

As RNAs (Redes Neurais Artificiais) são modelos computacionais inspirados na estrutura neural dos organismos inteligentes e que adquirem conhecimento através da experiência [12].

As principais características das RNAs são:

Capacidade de Aprendizagem: através de um conjunto de dados usados para o processo de treinamento da RNA se consegue ajustar os pesos sinápticos e se permite que a rede se adapte ao processo, extraindo assim o relacionamento existente entre as variáveis que compõem a aplicação [12].

Habilidade de Generalização: por meio de um conjunto de amostras entregues para o treinamento da RNA, a rede é capaz de generalizar o conhecimento adquirido, permitindo a estimação de soluções que até então eram desconhecidas [12].

Organização de Dados: as RNAs são capazes de extrair informações importantes dos dados de entrada a fim de realizar sua organização interna para o agrupamento de amostras que são similares, formando classes separadas ou padrões [12].

Capacidade de Adaptação: se refere à capacidade das RNAs de se adequarem em sistemas variantes no tempo sem que haja nenhuma alteração estrutural interna, como, por exemplo, a quantidade de neurônios, sendo para isso necessário apenas a apresentação de um novo conjunto de dados [12].

Facilidade de Prototipagem: após o processo de treinamento da rede, os seus resultados são normalmente obtidos através de algumas operações matemáticas elementares, podendo ser facilmente embarcada em um *hardware* dedicado a ela. As redes também são facilmente implementadas em questão de *software* para a maioria das arquiteturas neurais [12].

Armazenamento Distribuído: o conhecimento contido na rede é obtido de forma distribuída entre as sinapses dos neurônios artificiais conferindo à rede robustez perante neurônios que porventura fiquem inoperantes [12].

Tolerância a Falhas: há entre os neurônios artificiais das RNAs alto grau de interconexão, permitindo a uma rede operar informações mesmo que tenha parte de sua estrutura sensivelmente comprometida como, por exemplo, com a perda de um neurônio, evidenciando a robustez das RNAs [12].

As redes neurais artificiais se apresentam em diversas áreas de aplicação despontando das mais variadas vantagens que justificam assim o seu uso. As principais áreas de aplicações das RNAs são:

Aproximação de Funções: as RNAs neste caso são treinadas com o intuito de mapear o relacionamento existente entre as variáveis de entrada e saída, generalizando as suas respostas. Geralmente são utilizadas para mapear processos que apresentam modelagem complexa através das técnicas convencionais. Neste caso necessitam de um domínio específico para as variáveis de entrada [12].

Controle de Processos: correspondente à identificação de ações de controle que permitam o alcance de requisitos de qualidade, eficiência e segurança de determinado processo. Alguns exemplos de aplicação são em controles empregados em robótica, aeronaves, elevadores, eletrodomésticos, satélites, dentre outros [12].

Classificação de Padrões: consiste em associar a cada padrão de entrada da rede uma classe previamente definida. É geralmente aplicado no reconhecimento de imagens, voz e escrita [12].

Agrupamento de Dados: o objetivo neste caso é detectar e identificar similaridades e particularidades entre as diversas amostras de entrada do processo com o intuito de agrupá-las. Conhecido também como *clustering* são aplicados na identificação automática de classes, compressão e mineração de dados (*data mining*) [12].

Sistemas de Previsão: a rede consegue estimar valores futuros de determinado processo com base em diversas medidas observadas anteriormente em seu domínio. As redes neste caso são utilizadas para, por exemplo, prever mercado financeiro, estimar demanda de energia ou previsão climática [12].

Otimização de Sistemas: consiste na minimização ou maximização de determinada função objetivo, também denominada função custo, obedecendo a restrições do problema. São utilizadas, por exemplo, em problemas de otimização combinatorial, otimização restrita, programação dinâmica ou sequenciamento de produção [12].

Memórias Associativas: o objetivo da rede neste caso é recuperar padrões corretos mesmo que os elementos que o constituem estejam incompletos ou distorcidos. A identificação de caracteres manuscritos, o processamento de imagens e a transmissão de sinais são alguns dos exemplos de aplicação das redes neste tópico [12].

As RNAs são formadas pelos neurônios artificiais, que são unidades de processamento, e estão ligados entre si através das conexões sinápticas. Cada uma destas conexões entre dois neurônios está associada a um peso sináptico. O treinamento da rede ocorre através do ajuste dos pesos sinápticos de cada neurônio a cada iteração, até que se atinjam resultados em sua saída que sejam compatíveis com os dados de entrada [12].

A modelagem matemática de funcionamento de um neurônio artificial foi proposta em 1943 pelo neurologista Warren McCulloch e pelo matemático Walter Pitts. Neste modelo o neurônio como sendo a unidade básica de processamento da rede neural recebe vários estímulos de entrada e a sua saída é ativada através de uma função do somatório destas entradas ponderadas [13].

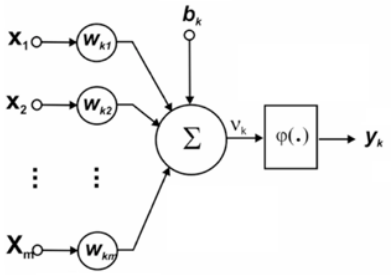

Figura 2.5: Neurônio Artificial proposto no trabalho de McCulloch e Pitts (Fonte: [13])

Com base na figura 2.5 tem-se no neurônio artificial:

Sinais de Entrada: { x_1 , x_2 , ... , x_m };

Pesos Sinápticos: { w_{k1} , w_{k2} , ... , w_{km} };

Combinador Linear: { $\sum$ };

Limiar de Ativação (bias): { b_k };

Potencial de Ativação: { v_k };

Função de Ativação: { $\varphi(.)$ };

Sinal de Saída: { y_k }

$$v_k = \sum_{i=1}^{m} w_{ki} x_i - b_k \tag{2.1}$$

$$y_k = \varphi(v_k) \tag{2.2}$$

Os sinais de entrada consistem em estímulos que o neurônio recebe do meio externo como, por exemplo, dados de leitura de tensão e corrente de um trecho de um sistema elétrico de distribuição. Enquanto isso os pesos sinápticos representam as conexões sinápticas e têm como finalidade ponderar os sinais de entrada. Diferentes pesos sinápticos para cada sinal de entrada confere diferente grau de importância na determinação do sinal de saída. O combinador linear corresponde à junção dos sinais de entrada ponderados na etapa anterior, fazendo assim a combinação linear dos sinais ponderados. O limiar de ativação, também conhecido como bias, é usado para melhorar a adaptação, por parte da rede neural, ao conhecimento a ela fornecido. O potencial de ativação corresponde à soma ponderada de todas as entradas juntamente com o limiar de ativação e constitui no sinal aplicado à função de ativação associada ao neurônio [12].

As funções de ativação podem ser do tipo degrau (*heavyside*), degrau bipolar, rampa simétrica, logística, tangente hiperbólica, gaussiana ou linear [12].

As funções degrau e degrau bipolar são descontínuas e não diferenciáveis ao longo de todo o seu período, retornando valores iguais a 0 para o primeiro caso e -1 para o segundo para potenciais de ativação negativos, ou seja, v_k<0. Para o caso de potenciais de

ativação positivos, v_k>0, estas funções retornam 1. Elas são geralmente empregadas como classificador de padrões.

$$\varphi_{\text{degrau}}\,(v_k) = \begin{cases} 1, \text{se } v_k \geq 0 \\ 0, \text{se } v_k < 0 \end{cases} \tag{2.3}$$

$$\varphi_{\text{degrau_bipolar}}\,(v_k) = \begin{cases} 1, \text{se } v_k > 0 \\ 0, \text{se } v_k = 0 \\ -1, \text{se } v_k < 0 \end{cases} \tag{2.4}$$

(a) Função Degrau (b) Função Degrau Bipolar

Figura 2.6: Função Degrau e Degrau Bipolar

Por outro lado, as funções sigmoides, nome advindo da forma S do gráfico, são diferenciáveis ao longo de todo o seu domínio, retornando valores entre 0 e 1 no caso da função logística e entre -1 e 1 nas função tangente hiperbólica. O parâmetro β está relacionado com a inclinação da função sigmoide frente ao ponto de inflexão e quando apresenta valores elevados faz com que o formato geométrico da função logística seja muito semelhante ao da função degrau, e o da tangente hiperbólica, com o da função degrau bipolar.

$$\varphi_{\text{logística}}\,(v_k) = \frac{1}{1+\,e^{-\beta v_k}} \tag{2.5}$$

$$\varphi_{\text{tangente_hiperbólica}}\,(v_k) = \frac{1-\,e^{-\beta v_k}}{1+\,e^{-\beta v_k}} \tag{2.6}$$

(a) Função Logística (b) Função Tangente Hiperbólica

Figura 2.7: Funções Sigmoides

No caso da função rampa simétrica aplicada às RNAs, os valores retornados são iguais aos próprios potenciais de ativação quando os mesmos estão definidos no intervalo [-a,a], limitando-se aos valores limites caso contrário. Estes valores limites são -1 e 1.

$$\varphi_{\text{rampa_simétrica}}(v_k) = \begin{cases} a, \text{se } v_k > a \\ v_k, \text{se } -a \leq v_k \leq a \\ -a, \text{se } v_k < -a \end{cases} \tag{2.7}$$

Para a função gaussiana temos que o parâmetro c define o centro da função, ou seja, sua respectiva média. Já a variância dela é representada pelo parâmetro σ^2.

$$\varphi_{\text{gaussiana}}(v_k) = e^{\frac{(v_k - c)^2}{2\sigma^2}} \tag{2.8}$$

Por fim há também a função linear, que produz resultados idênticos aos valores do potencial de ativação no caso de aplicação nas redes.

$$\varphi_{\text{linear}}(v_k) = v_k \tag{2.9}$$

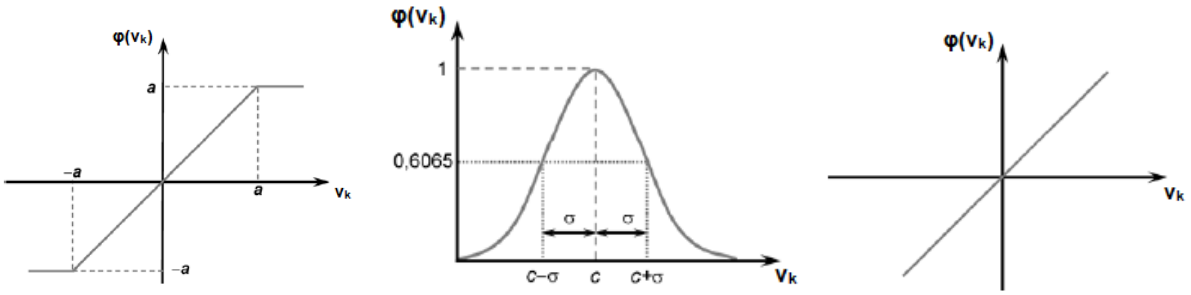

(a) Função Rampa Simétrica (b) Função Gaussiana (c) Função Linear

Figura 2.8: Função Rampa Simétrica, Gaussiana e Linear

As RNAs podem ser formadas por um ou mais neurônios distribuídos em uma ou mais camadas. A arquitetura de uma RNA define a forma com que os neurônios que a constituem estarão arranjados um com relação aos outros através do direcionamento do fluxo sináptico. Enquanto isso, a topologia de uma rede se refere às diferentes formas de composição estruturais que ela poderá assumir dentro de uma arquitetura. Por exemplo, em uma mesma arquitetura pode haver redes compostas por 5 neurônios e outra por 15. O que representa essa diferença na quantidade de neurônios é a sua topologia [12].

O aprendizado de uma rede neural ocorre quando ela atinge uma solução generalizada para uma classe de problemas. A propriedade mais importante das redes é a

capacidade de aprender em um ambiente e melhorar seu desempenho através de um processo iterativo de ajustes de seus pesos sinápticos e limiares. Esse processo consiste no treinamento da rede, e o algoritmo de aprendizado está condicionado a um conjunto de regras bem definidas, e os diferentes tipos de algoritmos diferem uns com relação aos outros principalmente pela forma como os pesos são modificados. O aprendizado das redes pode ser supervisionado ou não supervisionado. No primeiro, é utilizado um agente externo que indica à rede a resposta desejada para determinada entrada, e no segundo, quando não existe este agente e, portanto, não há a indicação à rede desta resposta. O aprendizado pode ainda ser por reforço, em que o comportamento da rede é avaliado somente baseado em algum critério numérico, fornecido em instantes de tempo diferentes [14].

A forma mais simples de configuração de uma rede neural artificial é a Rede Perceptron, constituída apenas de uma camada, tendo ainda somente um neurônio nesta camada, tipicamente usados em problema de Classificação de Padrões, com funções de ativação do tipo degrau ou degrau bipolar. Por esta razão a saída é do tipo binário, para entradas do tipo reais ou binárias. Os pesos sinápticos são do tipo real e são inicializados aleatoriamente, assim como seu limiar. O processo de treinamento é supervisionado e a regra de aprendizado é a Regra de Hebb, em que se a saída produzida pela rede está coincidente com a saída desejada, os pesos sinápticos e limiares são incrementados proporcionalmente, e se a saída produzida é diferente ao valor desejado, ocorre o decremento. Para esta rede ser utilizada como classificador de padrões é necessário que as classes do problema sejam linearmente separáveis. A sua arquitetura é do tipo *feedforward* de camada única pelo fato do fluxo de informação ser dado sempre adiante [12].

Outra configuração simples de RNA é a Rede Adaline (*Adaptive Linear Element*) idealizado em 1960 pelo professor Bernard Widrow e seu aluno Ted Hoff na Universidade de Stanford. Esta configuração também é formada por apenas uma camada de um neurônio, com várias entradas reais advindas do exterior, e uma saída binária. Os pesos sinápticos e o limiar são do tipo real, inicializados aleatoriamente, e a função de ativação segue sendo do tipo degrau ou degrau bipolar, além do processo de treinamento ser supervisionado. No entanto, a regra de aprendizagem é a Regra Delta, o que a distingue das Redes Perceptron, onde aqui se busca minimizar a diferença entre a saída desejada e a resposta do combinador linear, que no caso é o potencial de ativação v_k, sendo essa diferença representada pelo erro quadrático entre esses dois parâmetros, ajustando assim os pesos sinápticos e o limiar da rede. Com relação às redes Perceptron, a rede Adaline tem maior imunidade a eventuais ruídos que possam afetar o processo em que está sendo mapeado já que a inclinação do hiperplano que classificam as amostras é ajustada por intermédio do método dos mínimos quadrados [12].

Este trabalho foi desenvolvido utilizando as redes Perceptron Multicamadas (PMC), que são constituídas de vários neurônios interconectados pelas conexões sinápticas na presença de pelo menos uma camada intermediária de neurônios como, por exemplo, a rede apresentada na figura 2.9. Graças a sua versatilidade, pode ser usada em problemas de aproximação universal de funções, classificação de padrões, identificação e controle de processos, previsão de séries temporais e otimização de sistemas, como já discutido anteriormente. O PMC faz parte do grupo de redes de arquitetura *feedforward* e o processo de treinamento é supervisionado [12].

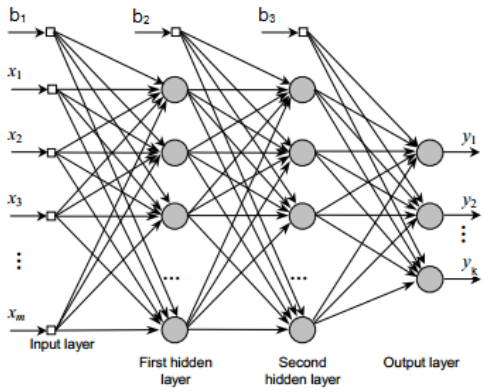

Figura 2.9: Rede *feedforward* de múltiplas camadas (Fonte: [14])

As camadas neurais podem ser divididas em três tipos:

Camada de Entrada: camada responsável por receber os sinais de entrada advindos do meio externo e repassá-los para todos os neurônios da primeira camada intermediária sendo, portanto, responsável apenas pelo repasse dos sinais, sem operar sobre esses dados.

Camada Intermediária ou Escondida: camadas responsáveis por processar os dados advindos da camada de entrada extraindo suas características. Em um PMC deve haver pelo menos uma camada deste tipo.

Camada de Saída: camada responsável por apresentar os resultados finais da rede.

A quantidade de camadas de neurônios de um PMC corresponde à quantidade de camadas escondidas somadas a um, referente à camada de saída da rede, portanto um PMC deve apresentar no mínimo duas camadas de neurônios. Com respeito ao funcionamento do PMC temos que os sinais chegam à camada de entrada e são repassados para todos os neurônios da primeira camada intermediária, onde são processados utilizando os pesos sinápticos referentes às conexões sinápticas que ligam os neurônios presentes na camada de entrada até a primeira camada intermediária, aplicando-se posteriormente a combinação linear e a função de ativação da primeira camada intermediária. Em seguida estes sinais vão para a próxima camada intermediária seguindo o

mesmo processo. Os sinais, portanto, vão sendo transportados de camada em camada, sofrendo as alterações conforme os pesos sinápticos, combinações lineares e funções de ativação que vão encontrando pelo caminho, até chegarem à camada de saída da rede, que processa as informações obtidas da última camada escondida e fornece a resposta da rede aos estímulos de entrada [14]. Na figura 2.10 se pode observar e refletir a respeito do discutido neste parágrafo.

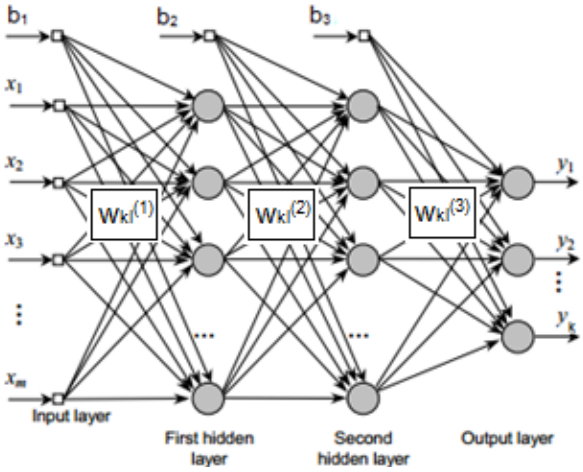

Figura 2.10: Rede PCM adaptada para o seu equacionamento (Fonte: [14])

Considerando:

$v_k^{(C)}$: potencial de ativação do k-ésimo neurônio da camada (C).

$b_k^{(C)}$: limiar de ativação do k-ésimo neurônio da camada (C).

$y_k^{(C)}$:saída do k-ésimo neurônio da camada (C).

$w_{kl}^{(C)}$: matriz cujos elementos denotam o valor do peso sináptico que conecta o k-ésimo neurônio da camada (C) ao l-ésimo neurônio da camada (C-1)

x_l: entrada do l-ésimo neurônio

N: quantidade de neurônios da camada (C-1)

φ(.): função de ativação da camada (C)

$$v_k^{(1)} = \sum_{l=1}^{N} w_{kl}^{(1)} . x_l - b_k^{(1)} \tag{2.10}$$

$$v_k^{(2)} = \sum_{l=1}^{N} w_{kl}^{(2)} . y_l^{(1)} - b_k^{(2)} \tag{2.11}$$

$$v_k^{(3)} = \sum_{l=1}^{N} w_{kl}^{(3)} . y_l^{(2)} - b_k^{(3)} \tag{2.12}$$

$$y_k^{(1)} = \varphi(v_k^{(1)}) \tag{2.13}$$

$$y_k^{(2)} = \varphi(v_k^{(2)}) \tag{2.14}$$

$$y_k^{(3)} = \varphi(v_k^{(3)}) \tag{2.15}$$

Com relação ao processo de treinamento de uma rede PMC há duas fases a serem consideradas, no caso, a fase *forward* e a fase *backward*. No decorrer da fase *forward* o fluxo de dados é levado de camada em camada da entrada até a saída da rede, e durante a fase *backward* ocorre justamente o contrário, onde este fluxo percorre exatamente o trajeto oposto, ou seja, é levado da camada de saída até a de entrada. O objetivo da fase *forward* é a obtenção das respostas da rede. Neste caso são considerados os valores de pesos sinápticos e limiares de seus neurônios no momento em que se está executando essa fase em determinada iteração e no decorrer desta fase estes parâmetros permanecem inalterados. Por sua vez, na fase *backward*, são ajustados os pesos sinápticos e os limiares dos neurônios do PMC com base nos erros obtidos entre as respostas desejadas e aquelas produzidas pelos neurônios de saída na fase *forward*. Com as aplicações sucessivas dessas duas fases se tem um ajuste gradativo em cada iteração dos pesos sinápticos e limiares dos neurônios que constituem o PMC, com uma diminuição da soma dos erros produzidos pelas respostas da rede em cada iteração em comparação com as desejadas. Este processo iterativo encerra quando essa soma já estiver dentro dos valores requeridos [12].

No processo de implementação de uma RNA o primeiro passo é a coleta de dados relacionados com o problema através, por exemplo, de uma simulação ou sensores presentes fisicamente no sistema em estudo. Os dados neste caso devem cobrir amplamente o domínio do problema, considerando exceções e as condições nos limites do domínio do problema, e se deve evitar ambiguidade nestas amostras.

Em seguida, no segundo passo, deve-se separar essas amostras em conjunto de treinamento e conjunto de testes. Os dados de treinamento são utilizados no decorrer da aprendizagem da RNA, e os dados de teste, para verificar o desempenho da RNA frente a condições reais de utilização. Do conjunto total de amostras cerca de 60% a 90% em geral são aleatoriamente escolhidos como conjunto de treinamento, enquanto que o restante fica alocado para o conjunto de testes. Vale ressaltar que as amostras de testes são todas diferentes das amostras de treinamento. Essa sistemática de divisão aleatória em conjunto de treinamento e de teste é conhecida como validação cruzada [12].

O terceiro passo consiste na definição da configuração da rede, com a determinação da topologia da rede a ser utilizada e dos parâmetros do algoritmo de treinamento, como taxa de aprendizagem e precisão requerida, além das funções de ativação de cada

neurônio. Uma grande quantidade de neurônios ou camadas intermediárias em um PMC não garante uma generalização adequada da rede. Quando uma rede treinada apresenta um erro quadrático baixo durante a fase de treinamento, porém um alto erro quadrático na fase de testes significa que ocorreu uma memorização excessiva da rede ou também conhecido como *overfitting*, ou seja, ela não foi capaz de generalizar as respostas para casos desconhecidos e acabou decorando as suas respostas frente aos estímulos introduzidos em suas entradas na fase de treinamento. A especificação da topologia de uma rede PMC é realizada de maneira empírica de um modo geral já que tal dimensionamento depende de diversas variantes, como o algoritmo de aprendizado, a maneira como as matrizes de pesos sinápticos são inicializadas, a disposição espacial das amostras, a complexidade do problema a ser mapeado e a qualidade do conjunto de treinamento disponível. Vale ressaltar com relação à topologia que para a maioria dos problemas, uma camada intermediária é suficiente [12]. Com relação à determinação da quantidade adequada de neurônios nas camadas intermediárias de uma RNA, embora empírica, existem algumas propostas:

1. Pode-se definir a quantidade de neurônios na camada escondida como sendo a média aritmética ou ainda a média geométrica entre o número de neurônios da camada de entrada e de saída da rede [15].

2. Se o número de exemplos disponíveis para treinamento for muito maior que o número de sinapses, é improvável que ocorra *overfitting*, porém não isenta a rede da ocorrência de *underfitting*, quando a rede não é treinada suficientemente para se tornar capaz de produzir resultados satisfatórios podendo ocorrer com a baixa quantidade de neurônios ou camadas para o problema abordado, ou pela quantidade de épocas abaixo do necessário [15].

O quarto passo corresponde ao processo de treinamento da rede, em que baseado nas três etapas anteriores se ajustam os pesos sinápticos e os limiares de cada um dos neurônios que constituem a rede. De um modo geral os valores iniciais destes parâmetros são obtidos aleatoriamente, porém dependendo deste conjunto, pode haver uma diminuição do tempo necessário para o treinamento. Esta etapa deve ser interrompida quando a rede apresentar uma boa capacidade de generalização e uma taxa de erro quadrático menor do que a admissível. A generalização da rede será máxima quando o erro quadrático for mínimo [12].

O quinto passo se refere a fase de testes da rede, onde se utiliza o conjunto de testes para avaliar o desempenho da RNA.

Por fim, com a rede treinada e avaliada se pode integrá-la em um sistema do ambiente operacional da aplicação e se deve periodicamente monitorar seu desempenho,

fazendo sua respectiva manutenção quando necessário ou indicar aos projetistas a necessidade de retreinamento ou de uma possível melhoria da rede [12].

Outras duas configurações de PMC podem ser citadas:

Configuração TDNN: a rede PMC apresenta entradas atrasadas no tempo para determinada variável [14].

Configuração recorrente: a arquitetura com saídas recorrentes às entradas permite a recuperação das respostas passadas já que apresenta realimentação de sinais produzidos em instantes anteriores. Pode-se dizer que esta configuração possui memória capaz de obter saídas passadas a fim de produzir respostas atuais ou futuras [14].

Outras arquiteturas de redes que podem ser citadas e que são muito empregadas na resolução de problemas envolvendo SEPs, como se pode ver em [16], são as redes neurais Hopfield, que contém camadas com neurônios completamente conectados, ou seja, cada neurônio é conectado a todos os outros da rede, as redes neurais Kohonen e também as redes LVQ, com o aprendizado competitivo, em que os neurônios são inibidos por outros de modo que a competição entre eles leva apenas um neurônio a ficar excitado por vez [12].

2.4 RNAs aplicadas aos SEPs

Com o aumento do uso de computadores e o contínuo crescimento dos SEPs tanto em tamanho quanto em complexidade, tornou-se possível e necessário o armazenamento de grande volume de dados e a execução repetida de programas capazes de se ajustar a distintos modelos e cenários modificando apenas os seus dados de entrada. Sendo assim, as RNAs se apresentam como uma alternativa aos modelos computacionais por serem uma técnica de reconhecimento de padrões mais eficiente e são úteis em uma grande diversidade de aplicações em sistemas de potência, seja na operação, no planejamento, no monitoramento ou no controle destes sistemas elétricos, e várias pesquisas estão sendo desenvolvidas para a resolução de problemas em SEPs usando-se as RNAs. Um dos grandes atrativos das RNAs neste contexto é a habilidade de aprendizado de relações não lineares, com suas estruturas modulares permitindo um processamento paralelo. Além disso, a obtenção das saídas das RNAs é muito rápida devido à série de operações simples que ela executa, se adaptando facilmente em caso de alterações das condições de um SEP, sendo necessário apenas um novo treinamento da rede [17].

Uma visão geral a respeito do uso das RNAs na área de operação e controle de sistemas de potência é dada em [16]. Graças ao grande avanço nas pesquisas relacionadas à aplicação de RNAs nos sistemas de energia elétrica, os autores deste artigo destacam a

utilização dessa técnica nas áreas de diagnóstico e localização de faltas, despacho econômico, avaliação de segurança e estabilidade transitória. Por sua vez em [4] temos exemplos de aplicação das RNA no setor de planejamento dos SEPs, com a previsão de perdas em circuitos de distribuição e a previsão de carga.

No gráfico da figura 2.11 é possível observar a relação entre os trabalhos publicados no IEEE entre os anos de 2000 e 2005 referentes ao uso das RNAs nas diferentes aplicações voltadas para os SEPs. A partir dele se pode refletir em quais destas aplicações as RNAs são mais adequadas para substituírem os métodos convencionais.

Figura 2.11: Trabalhos publicados no IEEE entre 2000 e 2005 relacionados às aplicações das RNAs em SEPs (Fonte: [16])

Com base nos artigos [4] e [16], algumas das aplicações a serem descritas são:

Diagnóstico e Localização de Faltas: o progresso na área de comunicações e tecnologia digital tem aumentado a quantidade de informações disponíveis para os sistemas de controle e aquisição de dados, como o SCADA. Embora estas informações sejam importantes, o operador pode se sobrecarregar com as excessivas informações de alerta operando simultaneamente, além de retardar o processo de restauração do sistema [16], tornando a experiência e habilidade do operador fator determinante para detectar as faltas no sistema e evitar que um número excessivo de operações seja efetuado [4]. Sendo esta a aplicação que este trabalho está atrelado, a detecção, classificação e localização de faltas simplifica a vida do operador no diagnóstico de faltas e no restabelecimento do sistema, deixando o processo mais ágil e confiável.

Despacho Econômico: consiste em minimizar os custos de operação de acordo com a demanda e algumas restrições, ou seja, o modo com que se aloca a carga requerida entre as unidades disponíveis de geração. A Rede Neural de Hopfield tem demonstrado a

capacidade de resolver estes problemas de otimização substituindo técnicas convencionais, como o método de Newton-Raphson e o método de relaxação Lagrangiana [16].

Avaliação de Segurança e Estabilidade Transitória: uma das tarefas dos SEPs é entregar a energia requerida pelos consumidores sem exceder níveis aceitáveis de tensão e frequência, e esta tarefa executada em tempo real deve ser segura, confiável e econômica. Os estados operacionais definidos para o sistema elétrico podem ser classificados em três tipos: estado normal ou seguro, em que todas as demandas dos consumidores estão sendo supridas dentro dos limites exigidos, estado de alerta ou crítico, em que as variáveis estão ainda dentro dos limites, porém uma instabilidade pode causar distúrbio e estado de emergência, em que essas variáveis já estão fora do limite, violando regras de segurança. As redes neurais mais utilizadas neste caso são as do tipo PMC [16].

Previsão de Perdas em Circuitos de Distribuição: variam conforme a resistência dos condutores dos circuitos de distribuição, que por sua vez dependem do material que os constituem, da sua área transversal, do seu comprimento e outros fatores como temperatura, carga do circuito, dentre outros. As RNAs se apresentam como uma alternativa à resolução destes problemas que através de métodos convencionais seriam muito mais complexos [4].

Previsão de Carga: corresponde às necessidades energéticas futuras em determinada região e deve ser o mais ajustado possível. O consumo de uma região está diretamente relacionado com parâmetros meteorológicos como a temperatura, a umidade relativa, as chuvas e se o período em estudo corresponde a momentos de trabalho ou se é um feriado ou época de férias escolares, por exemplo [4]. Redes simples já podem ser capazes de resolver problemas de previsão de carga em curto prazo, em que se trabalha com horas e semanas, caso em que mais as empregam. Para as previsões em médio prazo, em que se trabalha com o período de um mês a cinco anos, há como exemplo de uso a estipulação da necessidade de energia a ser produzida neste período uma vez estabelecida a sua tarifa. Para as previsões em longo prazo, de cinco a vinte anos ou mais, essas previsões são necessárias para que engenheiros e economistas determinem o tipo e o tamanho das plantas de geração que minimizem os seus custos fixos e variáveis [16].

Além das RNAs temos a Lógica *Fuzzy* e os Algoritmos Genéticos como técnicas de Inteligência Artificial presentes na resolução de problemas na área de SEPs [1].

2.5 O MATLAB e as ferramentas computacionais aplicadas à simulação de SEPs e RNAs

O MATLAB consiste em um *software* cujos elementos básicos são as matrizes, que não requerem dimensionamento pelo usuário. Através dele é possível fazer análises numéricas, cálculos com matrizes, construção de gráficos, processamento de sinais e as mais diferentes simulações, com o auxílio neste último caso, do *Simulink*. Esse sistema permite a resolução de muitos problemas numéricos de modo mais rápido quando comparados com programas semelhantes, porém construídos em linguagens como Fortran, Basic ou Linguagem C, evidenciando seu alto desempenho. Portanto o MATLAB proporciona ao usuário uma fácil prototipagem na tarefa de resolução de algum problema, sendo ajudada pela grande presença de *toolboxes*, com grandes coleções de funções voltadas para as mais variadas aplicações, como para as áreas de controle, otimização, manipulação algébrica, redes neurais, sistemas *fuzzy*, processamento de sinais, sistemas dinâmicos, dentre outros.

Os simuladores de SEPs são usados para as mais diferentes finalidades, como, por exemplo, estudos de fluxo de potência, curto circuito, análise DC, estabilidade, proteção e coordenação. Para a simulação dos SEPs podemos contar com as mais diferentes ferramentas, e se pode citar: ATP, EMTP, SPICE, RTDS *Simulador*, *PowerWorld Simulator*, *SimPowerSystems*, PSS/E, PSCAD, WindMil, PSAF, ASPEN, *EasyPower*, *PowerFactory*, CAPE, DIgSILENT, dentre outros. Os modelos matemáticos em que estão baseados estes simuladores podem ser classificados em linear ou não linear, de parâmetros agrupados ou distribuídos, contínuo ou discreto, determinístico ou estocástico e dinâmico ou estático [18].

Alguns métodos de análises destes simuladores para os SEPs são:

Análise Estática: se assume tensão e corrente senoidais como componentes lineares do sistema, geralmente utilizados para se obter fluxo de potência, perfis de tensão, perdas ativas e reativas, compensação de potência reativa e determinação da posição do *tap* do transformador [18].

Análise Quase Estática: usados para condições anormais no sistema, como para a análise de sistemas elétricos na presença de curtos-circuitos ou harmônicos [18].

Análise Dinâmica: usados para verificar se o SEP irá ficar instável ou entrará em colapso durante distúrbios de maiores dimensões, e para determinar as condições limites do sistema [18].

Análise Transitória: simula sistemas de potências reais, incluindo modelos com componentes não lineares e impedâncias desbalanceadas [18].

O *Simulink* é uma ferramenta para modelagem, simulação e análise de sistemas dinâmicos. Sua interface primária é uma ferramenta de diagramação gráfica por blocos e bibliotecas customizáveis de blocos, e apresenta alta integração com o restante do ambiente MATLAB, sendo os dois desenvolvidos pela *MathWorks*. O *Simulink* é amplamente usado em teoria de controle, comunicação, processamento digital de sinais, sistemas elétricos de potência, redes neurais artificiais, lógica *fuzzy* e modelagem aeroespacial, por exemplo [19]. O *SimPowerSystems* corresponde a um simulador de sistemas elétricos de potência pertencente ao domínio *Simulink*/MATLAB. Contendo mais de 130 blocos de componentes e dispositivos frequentemente encontrados em SEPs, apresenta uma poderosa capacidade de modelar sistemas de geração, transmissão e distribuição de energia distribuídos em seis bibliotecas, dentre elas as correspondentes a fontes, máquinas elétricas, elementos elétricos, eletrônicos, de controle e de medida, e estão baseados em equações eletromagnéticas e eletromecânicas dos componentes reais [18].

O MATLAB juntamente com o *SimPowerSystems* se mostraram uma ferramenta capaz de simular eficientemente o sistema de distribuição e as redes neurais estudadas, além de permitirem a manipulação dos dados necessária, como se pode ver no próximo capítulo. Para que se usasse o MATLAB também não foi exigido em termos de *hardware* nada mais do que um simples *notebook*. Por estas características, são as ferramentas computacionais utilizadas neste trabalho.

Capítulo 3

Aspectos da Metodologia Desenvolvida

3.1 Esquemático Geral do Trabalho

No contexto da proteção de sistemas elétricos de potência, se busca a implementação de um modelo completo para a proteção de linhas de distribuição. Para o esquema das redes neurais deste trabalho se propõe a criação de três módulos distintos:

Detecção da falta: módulo que sinaliza que uma falta ocorreu no SEP [20].

Classificação da falta: módulo que indica o tipo de falta ocorrido e as fases envolvidas [20].

Localização da falta: módulo que determina onde a falta ocorreu, informando o trecho ou a que distância em relação a um algum ponto do SEP [20].

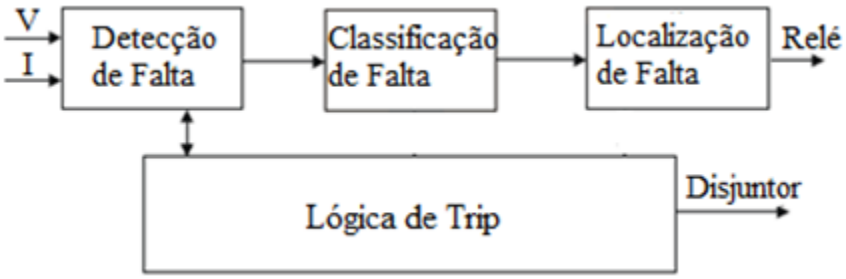

Figura 3.1: Diagrama de blocos do trabalho desenvolvido (Fonte: adaptado de [10])

As entradas das redes neurais artificiais propostas correspondem a valores amostrados de tensão e corrente obtidos do sistema de distribuição em estudo e, para qualquer distúrbio que ocorra nessas formas de onda em virtude de curtos-circuitos no sistema de distribuição estudado, se propõe que as redes sejam capazes de, primeiramente, detectar essa falta, e caso ela ocorra informe também o seu tipo e o trecho de sua ocorrência no sistema. O módulo de detecção deverá sempre receber dados de entrada em condição de falta ou não e analisar estes dados enquanto as linhas de distribuição estejam energizadas e somente no caso de falta detectada por este módulo que também o de classificação e o de localização os receberá, entrando em atuação. Na prática, as informações de entrada das redes chegariam do TC e TP de cada fase para o caso de corrente e tensão respectivamente, e as saídas iriam para o responsável pela lógica de

controle do sistema de proteção, que é o relé. Com essas informações, o relé deveria ser capaz de executar ou não a abertura do disjuntor e informar ao operador o status do sistema de distribuição e também da possível falta ocorrente.

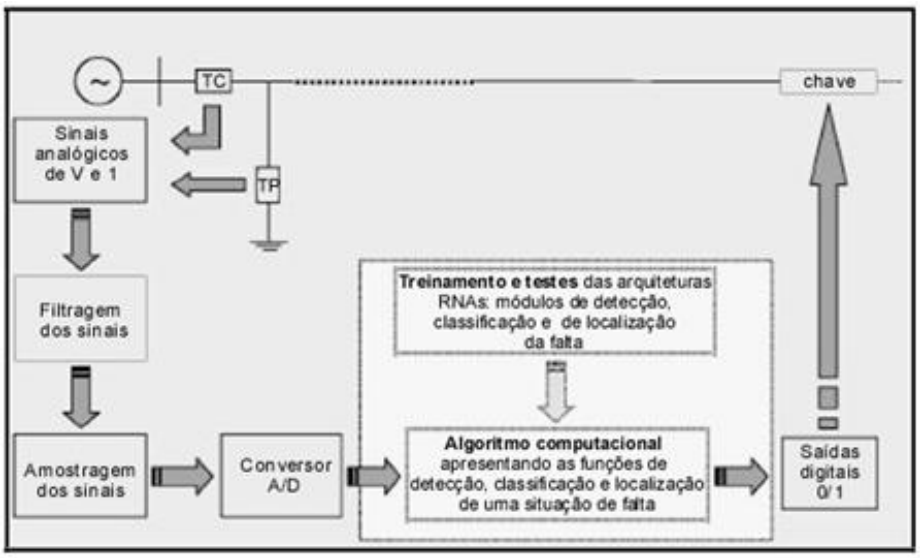

Figura 3.2: Diagrama de blocos com a aquisição e análise pelas RNAs dos dados obtidos do sistema simulado (Fonte: [21])

Baseado no parágrafo anterior, para o treinamento das redes se utiliza dados de pré-falta e pós-falta apenas para o módulo de detecção. Para os módulos de classificação e localização somente são considerados dados de pós-falta.

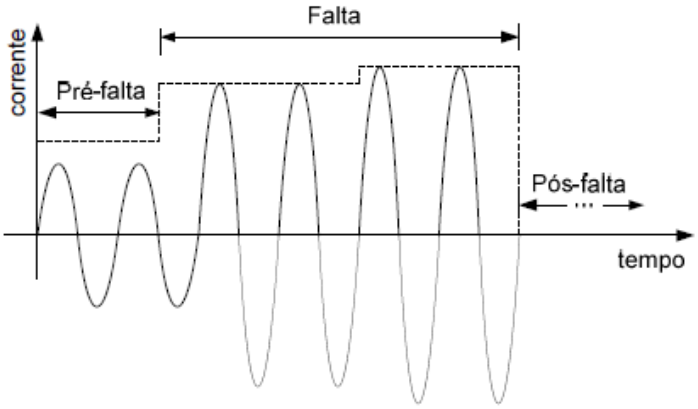

Figura 3.3: Exemplo do registro oscilográfico da corrente na ocorrência de uma falta (Fonte: [17])

As janelas móveis de dados, como se pode observar na figura 3.4, correspondem aos valores amostrados de tensão ou corrente do sistema de distribuição e que ao mesmo tempo são as entradas das RNAs criadas. Essa janela é móvel com a finalidade de se

percorrer o sinal ao longo do tempo e engloba valores atuais e passados destas duas grandezas elétricas.

Um ponto importante a ser discutido com relação às janelas de dados se refere com o seu comprimento. Uma vez que ela seja mais longa, o tempo de processamento necessário para que a rede neural convirja para uma resposta será maior, uma vez que haverá mais entradas, e uma decisão obviamente será tomada mais rapidamente por elas por uma janela mais curta. Porém, a habilidade de um algoritmo de analisar corretamente estes dados de entrada é uma função do comprimento da janela de dados. Sendo assim, se pode estabelecer uma relação inversamente proporcional entre a velocidade de atuação e precisão do algoritmo que tomará as decisões do sistema de proteção [1].

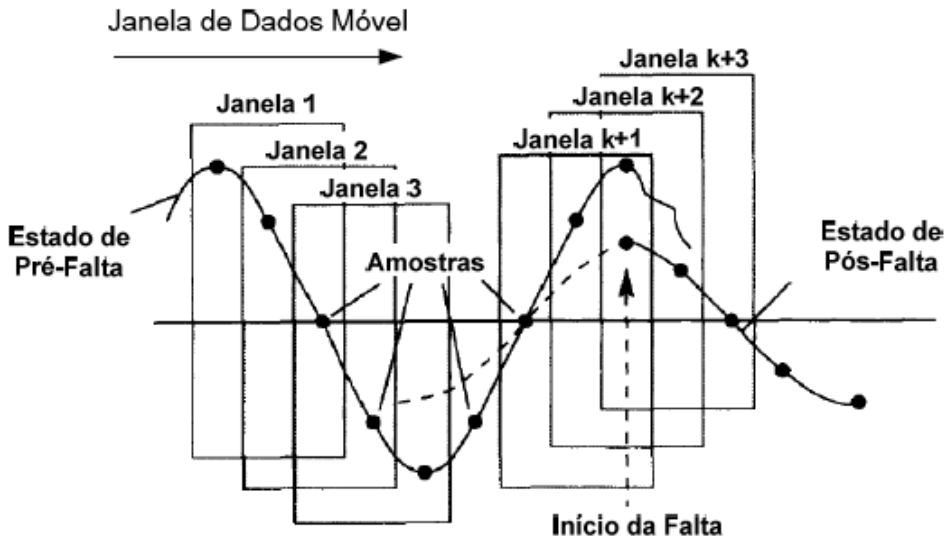

Figura 3.4: Janela móvel de dados com dados de entrada das RNAs (Fonte: [17])

Este sistema proposto pode operar como:

Dispositivo *Stand-Alone*: neste caso, possuindo *hardware* similar ao de um relé digital [2].

Como parte de um relé de proteção: neste caso se inclui o sistema juntamente com o algoritmo do relé de proteção [2].

Como um algoritmo independente: neste caso se dispõe de dados obtidos através de registradores digitais de faltas e o *software* poderia ser instalado em diversos computadores, como *notebooks*, *desktops* e servidores [2].

O *hardware* básico deste sistema consiste em:

Módulo de Interface: são os transformadores de corrente e tensão e filtros passa-baixa com o intuito de atenuar as altas frequências e o efeito *aliasing* [2].

Módulo de Sincronização: contêm os dispositivos *Sample and Hold* (S/H), que amostram as entradas analógicas em um mesmo instante, minimizando a deformação provocada pela amostragem não sequencial, e o multiplexador, que selecionará as entradas advindas dos S/H [2].

Conversor Analógico-Digital (CAD): a partir do sinal analógico adquirido na etapa anterior se forma outro sinal, porém digital.

Dispositivos de Memória: apresenta a função de registrar os dados de falta após o processo da conversão analógica-digital [2].

Microprocessador: dispositivo que irá operar os algoritmos construídos após receber o registro de faltas [2].

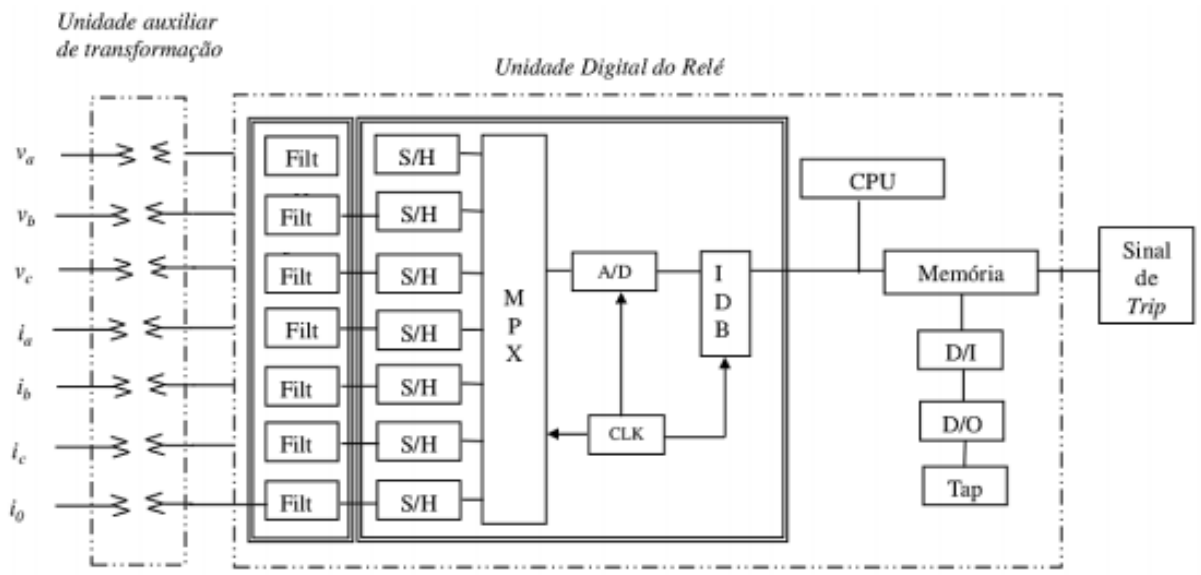

Figura 3.5: Principais sub-sistemas de um relé digital (Fonte: [1])

No fluxograma da figura 3.6 há uma visão geral de todos os algoritmos implementados no decorrer do desenvolvimento deste trabalho de conclusão de curso, bem como o relacionamento existente entre eles. Vale destacar que para que seja de fato um sistema de proteção completo seria necessária a construção de um algoritmo que junte cada um desses módulos, o que não foi contemplado neste trabalho.

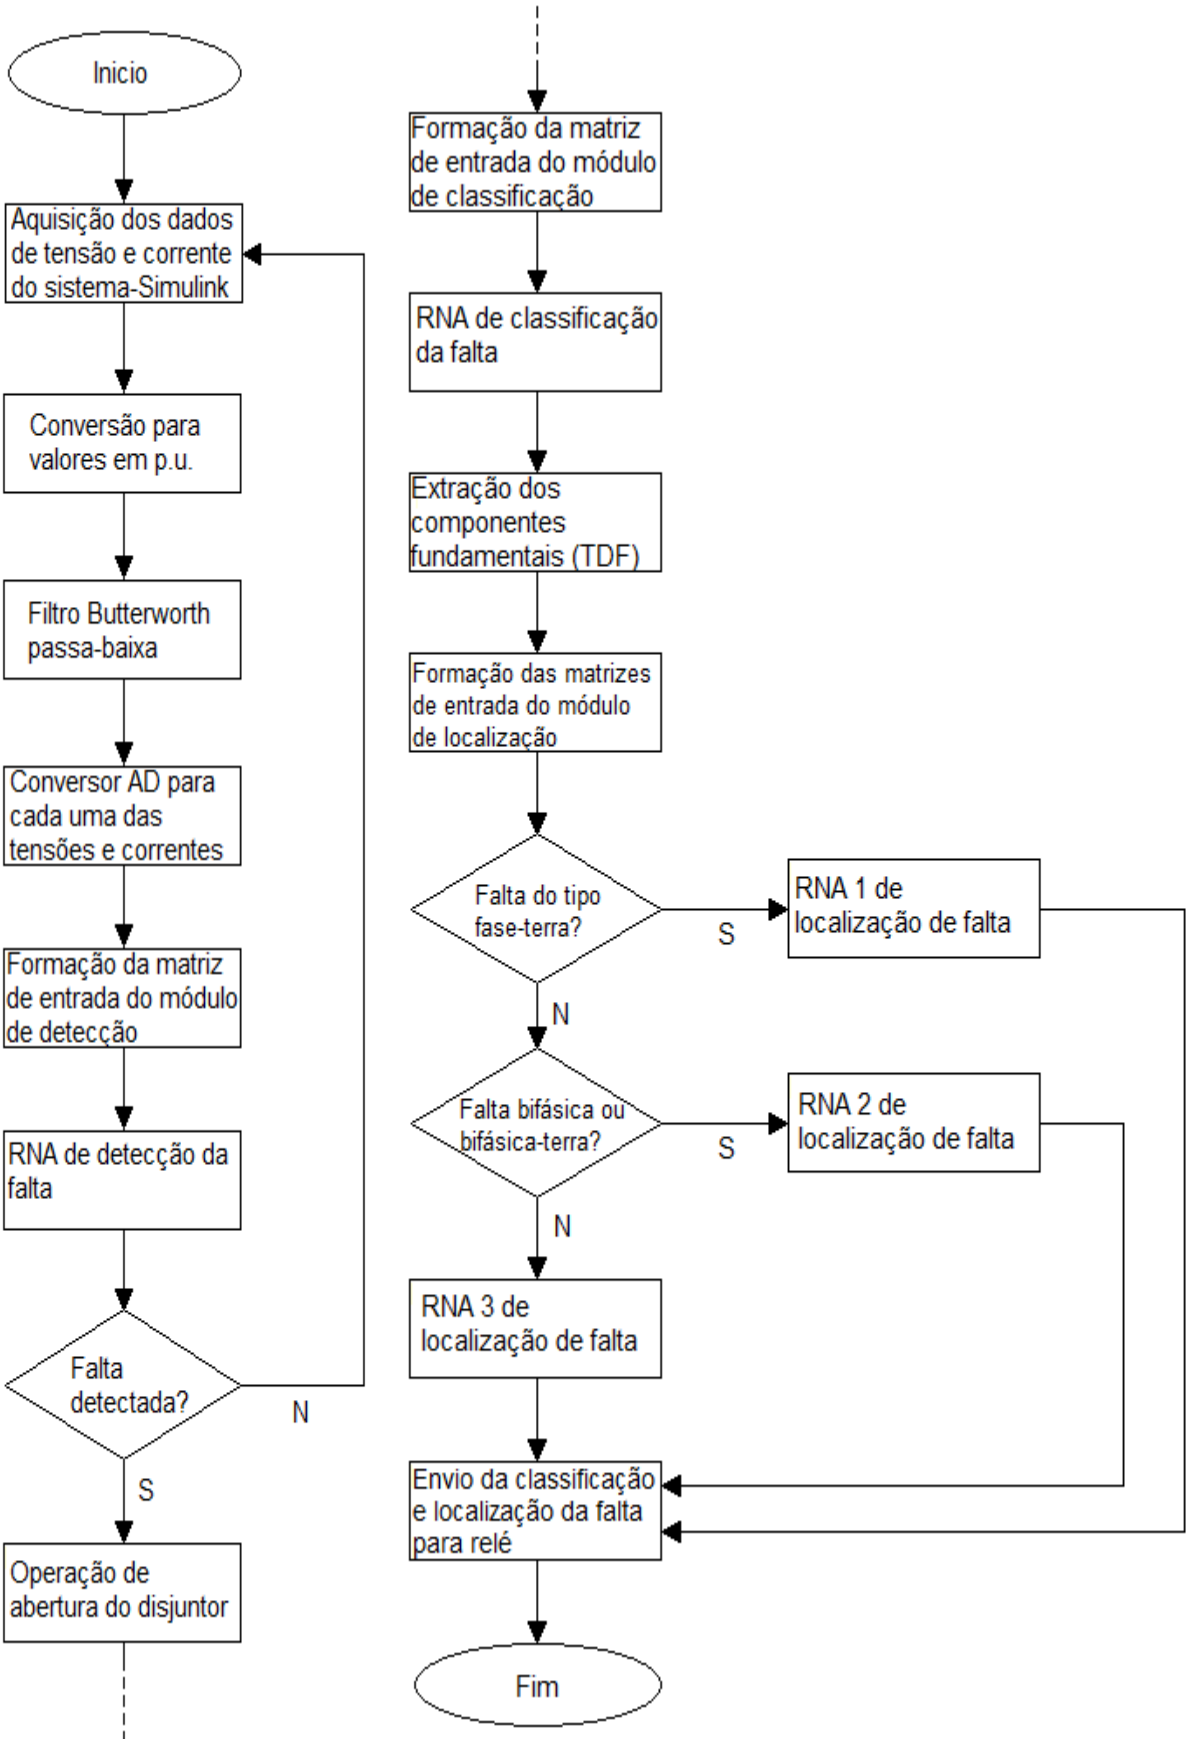

Figura 3.6: Fluxograma dos algoritmos implementados neste trabalho

3.2 Sistema de Distribuição de Energia Elétrica Simulado

Para que fosse possível iniciar o processo de treinamento das RNAs implementadas, foi necessária a coleta de dados através de simulações efetuadas no *SimPowerSystems* de um sistema de distribuição de energia elétrica. Vale lembrar que o sistema em estudo corresponde à rede primária de distribuição, com 13,8[kV], que são aquelas encontradas sobre as cruzetas dos postes. As cargas neste caso corresponderiam aos bairros de um determinado município.

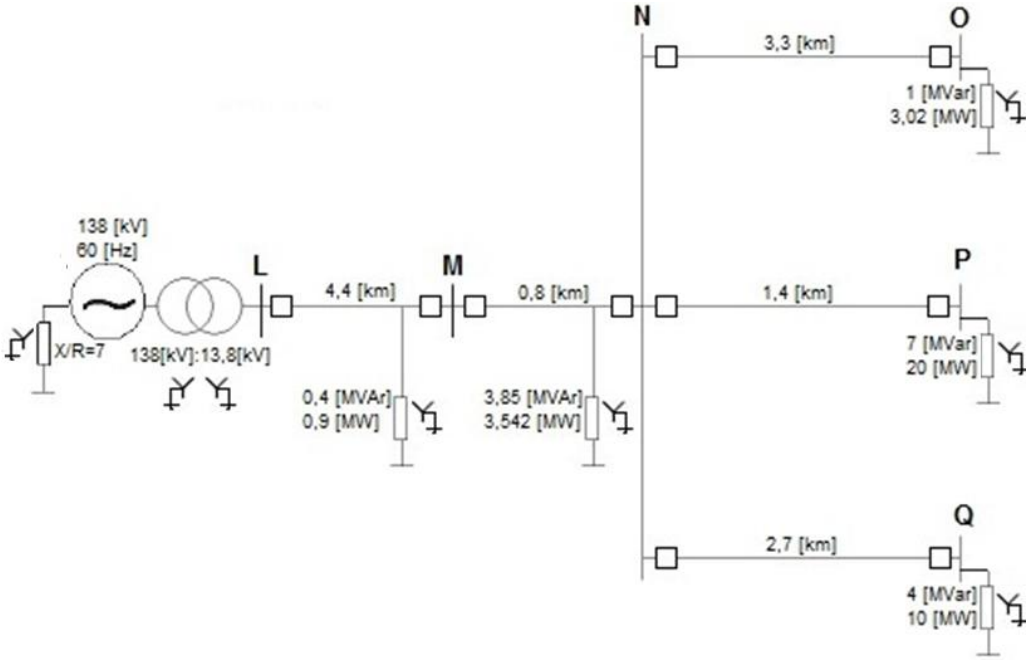

Figura 3.7: Sistema de distribuição utilizado para a obtenção de dados para as RNAs

O sistema de distribuição da figura 3.7 já apresenta os comprimentos de cada linha e os valores de potência ativa e reativa de cada uma das cargas. Com relação ao modelo de linha empregado na simulação, se utilizou o modelo de linha com parâmetros distribuídos, com os dados presentes na tabela 3.1.

Tabela 3.1: Parâmetros das linhas de distribuição empregadas na simulação

	Sequência Positiva	Sequência Zero
Resistência por unidade de comprimento	0,01273 [Ω/km]	0,3864 [Ω/km]
Indutância por unidade de comprimento	$0,9337 \times 10^{-3}$ [H/km]	$4,1264 \times 10^{-3}$ [H/km]
Capacitância por unidade de comprimento	$12,74 \times 10^{-9}$ [F/km]	$7,751 \times 10^{-9}$ [F/km]

Este sistema de distribuição também pode ser observado nas figuras 3.8, 3.9 e 3.10 sendo neste caso o modelo implementado no *SimPowerSystems*.

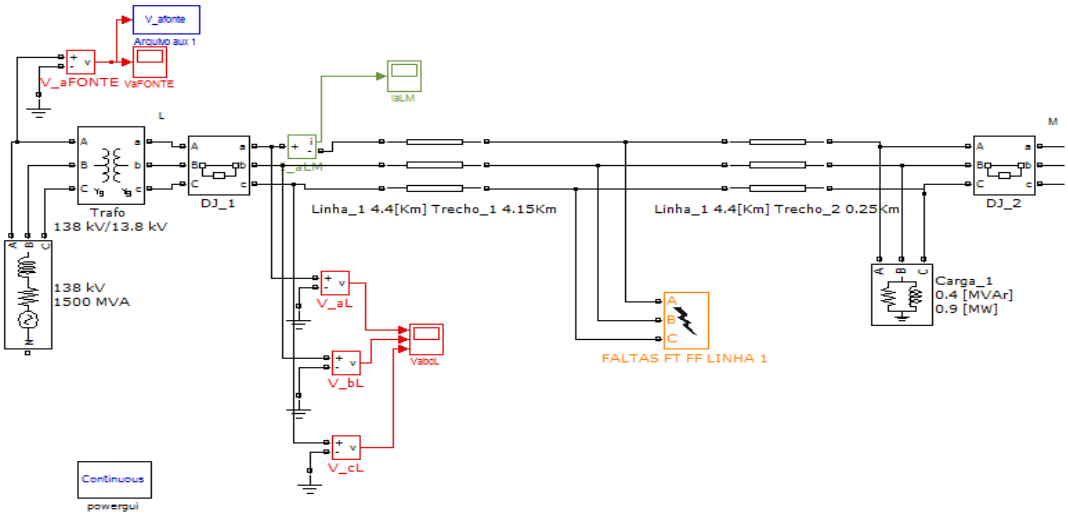

Figura 3.8: Modelo no *SimPowerSystems* do sistema de distribuição utilizado (Parte 1)

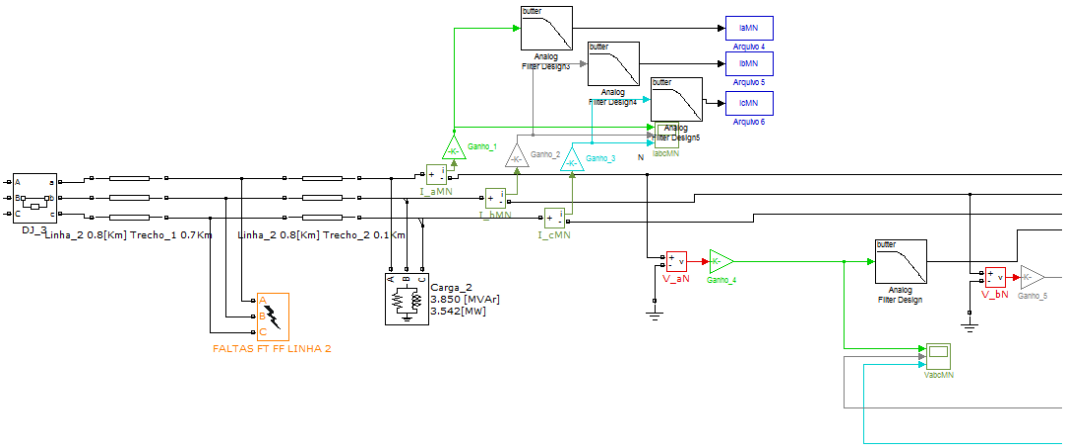

Figura 3.9: Modelo no *SimPowerSystems* do sistema de distribuição utilizado (Parte 2)

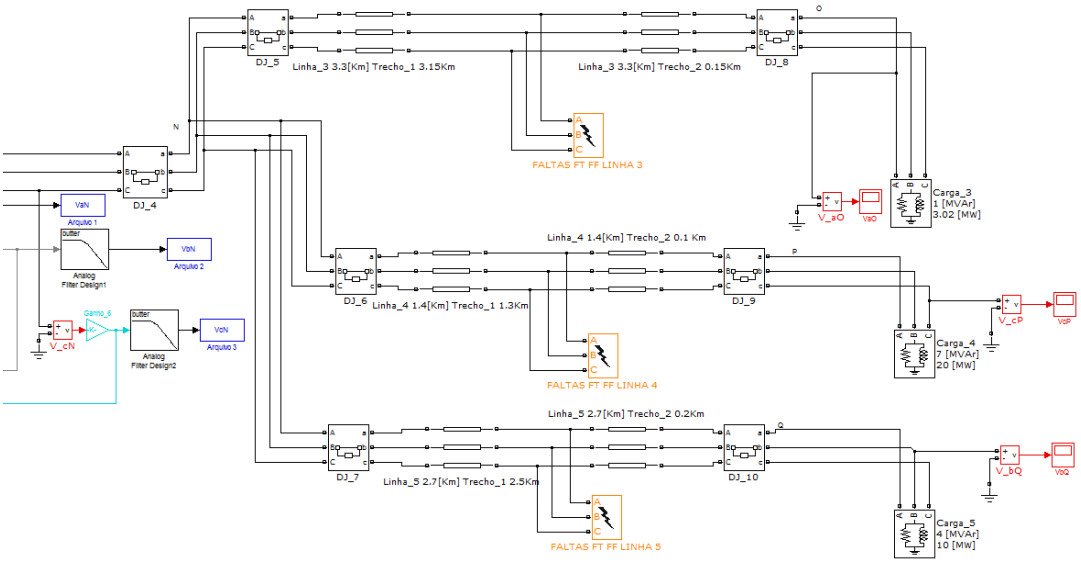

Figura 3.10: Modelo no *SimPowerSystems* do sistema de distribuição utilizado (Parte 3)

Importante observar que todas as medidas de tensão e corrente foram tomadas no nó N do sistema, e delas foram gerados os arquivos do bloco de notas para que a partir destes valores se construísse o conjunto de treinamento e teste das RNAs. Os seis blocos responsáveis pela aquisição dos dados que formarão as matrizes contendo os valores das formas de ondas para cada uma das três tensões e correntes deste sistema trifásico estão em azul e um deles está justamente ao lado do numeral 3 na figura 3.11. Os blocos triangulares da figura 3.11, onde um deles está justamente ao lado do numeral 1, se refere ao ganho dado a cada uma das variáveis para que se obtivesse seus valores em p.u. (por unidade). Para cada uma das variáveis foi necessária a implementação de um filtro *Butterworth* passa-baixa, um deles ao lado do numeral 2 na mesma figura em questão.

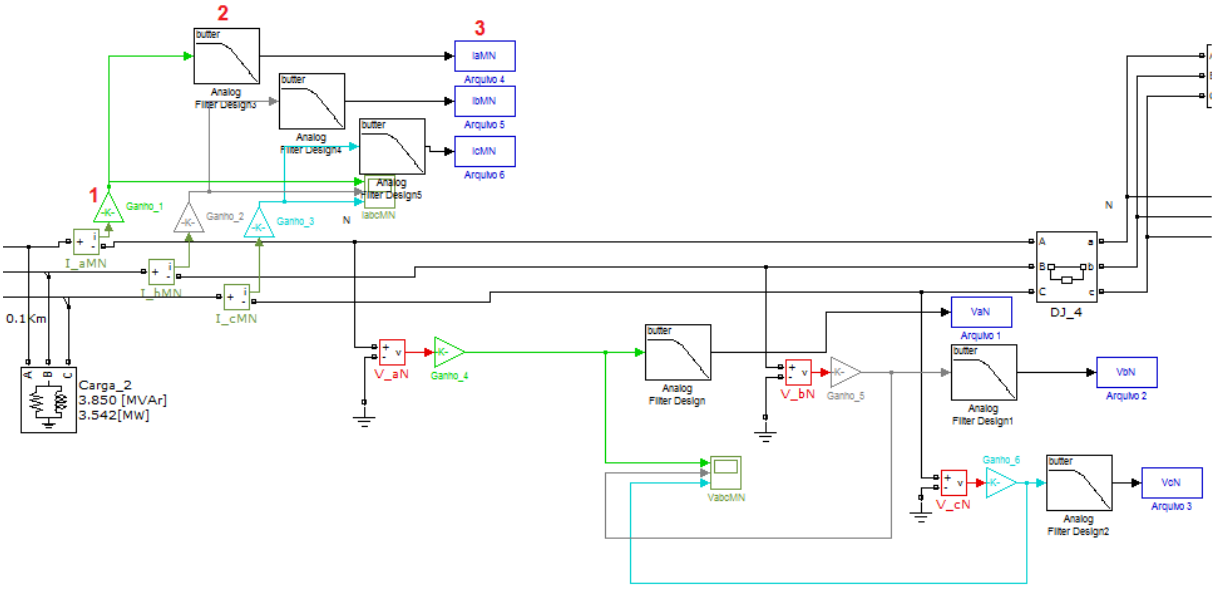

Figura 3.11: Terminal de aquisição dos sinais de tensão e corrente (Nó N) do sistema de distribuição utilizado no *SimPowerSystems*

$$Z_{base} = \frac{V_{base}{}^2}{S_{base}} \;//\; V_{pu} = \frac{V_{medido}}{V_{base}} \;//\; K_{tensão} = \frac{1}{V_{base}} \tag{3.1}$$

$$I_{base} = \frac{S_{base}}{\sqrt[2]{3}.V_{base}} \;//\; I_{pu} = \frac{I_{medido}}{I_{base}} \;//\; K_{corrente} = \frac{1}{I_{base}} \tag{3.2}$$

Considerando V_{base}=13,8[kV] e S_{base}=866[MVA] teremos Z_{base}= 0,2199[Ω] e I_{base}=36,232x10^3[A].

$$K_{tensão}=1/(13{,}8x10^3)$$

$$K_{corrente}=1/(36{,}232x10^3)$$

A finalidade dos filtros é permitir a passagem de componentes de sinal na faixa selecionada de frequência, rejeitando ou atenuando assim os componentes não desejados. A importância da aplicação dos filtros nos SEPs se deve ao fato de se selecionar apenas as frequências com a finalidade de se evitar um efeito indesejado conhecido como *aliasing*, ou sobreposição de espectros. O filtro passa-baixa do tipo *Butterworth* de segunda ordem foi o modelo escolhido para esse trabalho pela sua simplicidade e também porque já que é comum o seu uso em aplicações práticas neste caso uma vez que satisfazem os requisitos dos relés digitais e de suas respostas em frequência [1].

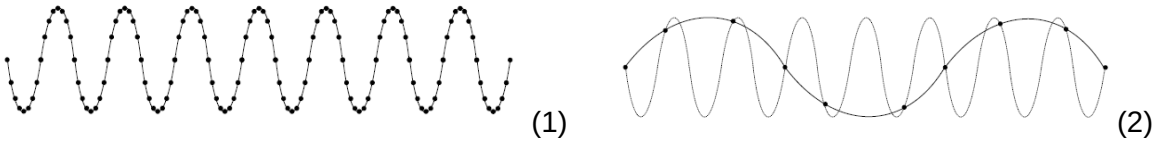

Figura 3.12: Sinal com amostragem adequada e Sinal com *aliasing* (Fonte: [17])

Na figura 3.13 se observa o comportamento da resposta ideal em frequência do filtro adotado, e que praticamente se anula as componentes de frequência maiores que a frequência de corte (W_c), e não há atenuação para componentes de frequência menores que ela, ou seja, temos na região de passagem, em que $0<W<W_c$, atenuação de 0[dB]. A região em que $W>W_c$ é conhecida como faixa rejeitada [22].

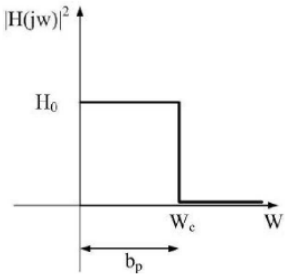

Figura 3.13: Representação de um filtro passa-baixa ideal do tipo *Butterworth*

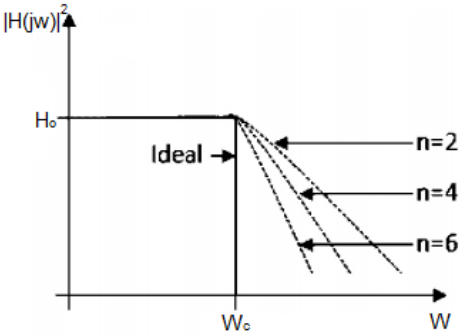

Figura 3.14: Representação de um filtro passa-baixa de ordem 2, 4 e 6 do tipo *Butterworth* (Fonte: adaptado de [22])

A equação geral da resposta em frequência que representa um filtro Butterworth passa-baixa de ordem n é [23]:

$$H_n(jW) = \frac{1}{\sqrt[2]{1+\varepsilon^2\left(\frac{W}{W_c}\right)^{2n}}} \tag{3.3}$$

$$\varepsilon = \frac{H_o}{H_1} = \frac{\text{ganho máximo da banda de passagem}}{\text{ganho mínimo da banda de passagem}} \tag{3.4}$$

Após a passagem pelo filtro o sinal se converte de natureza contínua para discreta, e quem faz o papel de conversor analógico digital (CAD) são os mesmos blocos azuis um deles apresentado pelo numeral 3 na figura 3.11, também responsável por obter as amostras de tensão e corrente de cada uma das fases que irá constituir a matriz de dados de entrada para cada uma das RNAs desenvolvidas.

Na tabela 3.2 temos a frequência de amostragem adotada por este conversor e a frequência de corte do filtro *Butterworth* implementado e anteriormente comentado, considerando o Teorema de Nyquist, em que a taxa de amostragem deve ser de no mínimo duas vezes o valor da frequência máxima alcançada pelo sinal analógico para possibilitar o registro digital de todas as frequências analisadas e evitar assim o *aliasing*. A resposta em frequência deste filtro está presente na figura 3.15.

Tabela 3.2: Parâmetros do Conversor Analógico Digital (CAD) e do filtro *Butterworth* deste trabalho

Taxa de Amostragem do CAD	1920[Hz]
Frequência de Corte do filtro *Butterworth*	800[Hz]

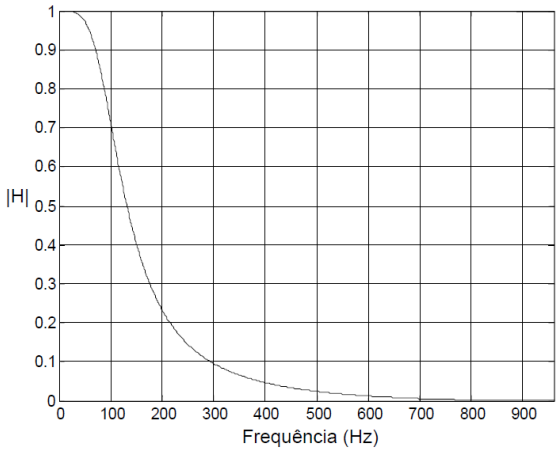

Figura 3.15: Resposta em frequência do filtro *Butterworth* de ordem 2 deste trabalho

Será discutida ainda neste tópico a formação dessas matrizes através de códigos construídos no MATLAB para cada uma das RNAs. No caso, como será observado na sequência, como há particularidades nas entradas de cada um dos módulos foram construídos cinco arquivos no MATLAB distintos para cada uma das RNAs lembrando que há uma rede para o módulo de detecção e outra para o de classificação e três para o de localização.

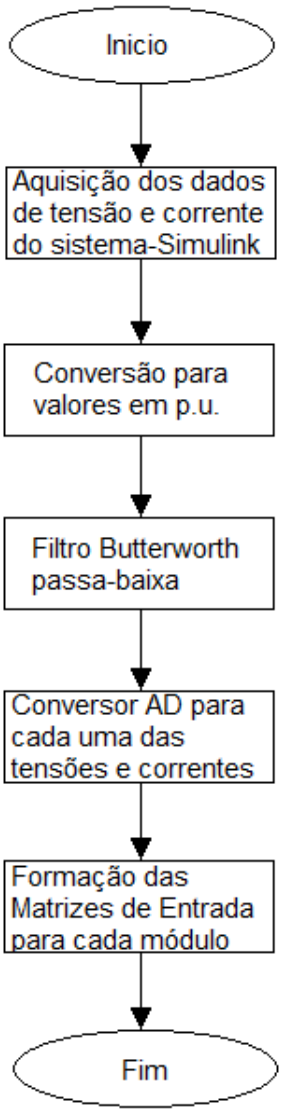

Figura 3.16: Fluxograma do processo de formação das matrizes de entrada para o treinamento das RNAs

O Bloco responsável pela simulação dos 10 tipos de curtos-circuitos está apresentado na figura 3.17. Com ele se pode além de selecionar as fases envolvidas e a inclusão ou não do terra, também se pode determinar a resistência de falta Fase-Fase ou Fase-Terra.

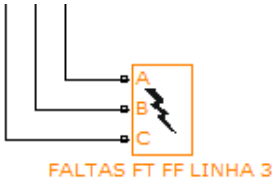

Figura 3.17: Bloco do *SimPowerSystems* responsável pela simulação das faltas

Enquanto isso, o bloco presente na figura 3.18 tem a finalidade de simular as cargas interligadas ao circuito primário do sistema de distribuição através do circuito secundário. Esse bloco ao mesmo tempo representa na simulação todo o circuito secundário do sistema de distribuição, juntamente com os transformadores que abaixam o valor da tensão que vem do primário e vai para o secundário e em seguida para os consumidores. Essa representação não compromete o intuito desta simulação, pois fornece as amostras desejadas para o desenvolvimento das RNAs, que são as de tensão e corrente das três fases do circuito primário apenas. As cargas representariam na prática bairros de um município.

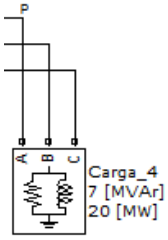

Figura 3.18: Bloco do *SimPowerSystems* responsável pela simulação das cargas do sistema

O bloco *Powergui* da figura 3.19 é essencial para que se possa executar as simulações através do *SimPowerSystems*. Através dele também se pode selecionar o método que se deseja para que seja efetuada a simulação. No caso foi escolhido o método contínuo, porém diversas outras análises poderiam ser escolhidas mediante este bloco, e todas elas estão descritas na página da *Mathworks* na internet.

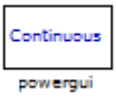

Figura 3.19: Bloco do *SimPowerSystems* responsável por realizar a simulação

As variáveis que se alteram em cada simulação são:

Ângulo de Incidência da falta: 0º e 90º

Tipo de falta: AT, BT, CT, AB, AC, BC, ABT, ACT, BCT e ABC

Resistência de falta FF e FT: 0.001[Ω], 10[Ω], 40[Ω] e 80[Ω]

Localização: conforme tabela 3.3 e figura 3.20

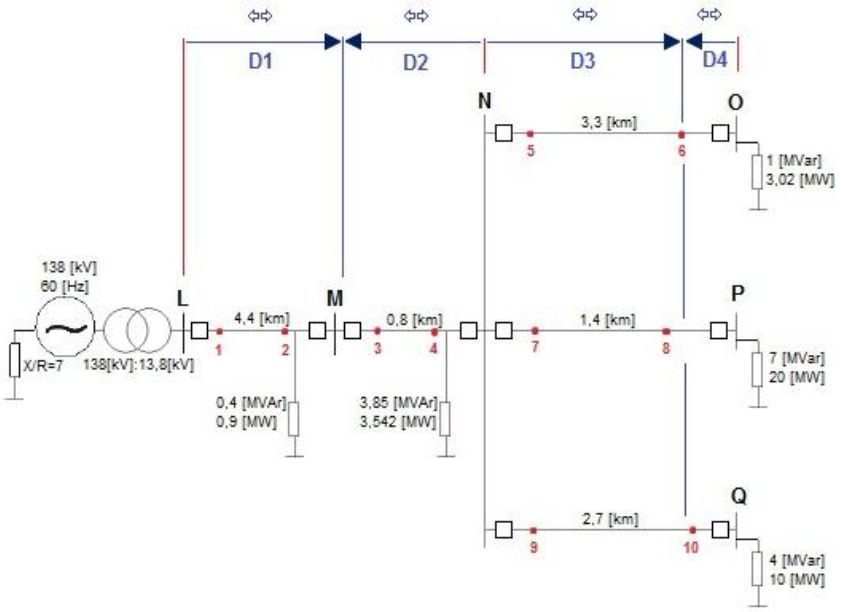

Figura 3.20: Figura relacionada com a Tabela 3.3

Tabela 3.3: 10 diferentes localizações das faltas simuladas

Localização	D1	D2	D3	D4
1	0,10[km]	5,10[km]	-	-
2	4,15[km]	1,05[km]	-	-
3	4,50[km]	0,70[km]	-	-
4	5,10[km]	0,10[km]	-	-
5	-	-	0,30[km]	3,00[km]
6	-	-	3,15[km]	0,15[km]
7	-	-	0,30[km]	1,10[km]
8	-	-	1,30[km]	0,10[km]
9	-	-	0,30[km]	2,40[km]
10	-	-	2,50[km]	0,20[km]

Para a obtenção de todos os dados necessários para o treinamento das redes foram efetuadas 800 simulações, já que foi necessário fazer todas as combinações possíveis entre as localizações apresentadas, ângulos de incidência e resistências de falta estudadas, além dos possíveis tipos de falta que poderiam acontecer em cada caso. Sem contar a simulação efetuada com o sistema operando sem ocorrência de falta para que as amostras fossem utilizadas para a RNA do módulo de detecção.

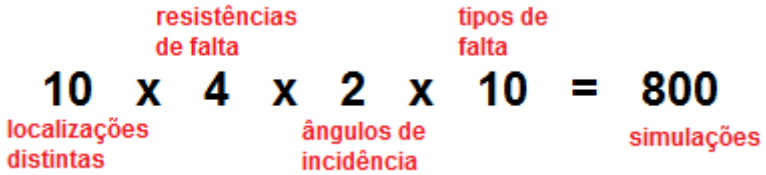

Figura 3.21: Quantidade de simulações efetuadas com o sistema apresentando uma falta

Para cada uma das simulações executadas foram extraídas 9 janelas de dados pós-falta distintas, portanto para o caso das redes de classificação e localização temos 7200 amostras correspondentes ao conjunto de treinamento somado com o conjunto de testes. Para o caso da detecção como também é necessário incluir dados de pré-falta, e nesse caso temos 190 amostras, para a RNA do módulo de detecção há 7390 amostras referentes ao conjunto de treinamento e de teste.

A formação das matrizes para o módulo de detecção a partir das amostras obtidas no processo de aquisição de dados da simulação ocorre através do algoritmo 'MentDET.m', que além de formar as matrizes atribui as saídas identificando os casos correspondentes a cada uma das entradas. As funções 'MentClass.m' e 'MentLOC.m' para os módulos de classificação e localização respectivamente, também construídas no MATLAB, adaptam as matrizes de entrada formadas pelo algoritmo de detecção, atribuindo as saídas correspondentes a cada um destes módulos e também selecionando apenas as 9 amostras pós-falta em cada uma das simulações. Além do comentado, para as entradas do módulo de localização é também aplicada a Transformada Discreta de Fourier, que produz a magnitude e o ângulo de fase dos fasores fundamentais de tensão e corrente, sendo que a sua aplicação permitiu que a RNA pudesse localizar a falta de acordo com os setores em que estava dividido o sistema de distribuição simulado. Também para o módulo de localização foi necessário o uso do algoritmo 'Separador.m', que tem como função dividir as amostras entre faltas do tipo fase-terra, bifásica-terra e bifásica, e por fim trifásica, cada um destes três grupos correspondentes a uma rede neural do módulo de localização.

As duas matrizes seguintes mostram como estão organizados os dados de entrada do módulo de detecção obtidos em cada uma das 801 simulações.

$$[\text{Variaveis de entrada}_{\text{jan4}}]_{1X26} =$$

$$[\mathrm{Va}_{t-3} \quad \mathrm{Va}_{t-2} \quad \mathrm{Va}_{t-1} \quad \mathrm{Va}_{t} \quad \mathrm{Vb}_{t-3} \quad \cdots \quad \mathrm{Ib}_{t} \quad \mathrm{Ic}_{t-3} \quad \mathrm{Ic}_{t-2} \quad \mathrm{Ic}_{t-1} \quad \mathrm{Ic}_{t} \quad \mathrm{saida}_{1} \quad \mathrm{saida}_{2}] \tag{3.5}$$

$$
M_{ent_det_jan4} = \begin{bmatrix}
[\text{Variáveis de entrada}_{jan4}]_{1x26} \\
[AB_LOC1_40_0]_{9x26} \\
[AB_LOC1_40_90]_{9x26} \\
[AB_LOC1_10_0]_{9x26} \\
[AB_LOC1_10_90]_{9x26} \\
[AB_LOC1_0001_0]_{9x26} \\
[AB_LOC1_0001_90]_{9x26} \\
[ABC_LOC1_40_0]_{9x26} \\
\vdots \\
[ABT_LOC1_40_0]_{9x26} \\
\vdots \\
[AC_LOC1_40_0]_{9x26} \\
\vdots \\
[ACT_LOC1_40_0]_{9x26} \\
\vdots \\
[AT_LOC1_40_0]_{9x26} \\
\vdots \\
[BC_LOC1_40_0]_{9x26} \\
\vdots \\
[BCT_LOC1_40_0]_{9x26} \\
\vdots \\
[BT_LOC1_40_0]_{9x26} \\
\vdots \\
[CT_LOC1_40_0]_{9x26} \\
\vdots \\
[AB_LOC2_40_0]_{9x26} \\
\vdots \\
[AB_LOC3_40_0]_{9x26} \\
\vdots \\
[AB_LOC1_80_0]_{9x26} \\
[AB_LOC1_80_90]_{9x26} \\
[ABC_LOC1_80_0]_{9x26} \\
[ABC_LOC1_80_90]_{9x26} \\
[ABT_LOC1_80_0]_{9x26} \\
\vdots \\
[AB_LOC10_80_0]_{9x26} \\
[AB_LOC10_80_90]_{9x26} \\
[normal_1]_{1x26} \\
[normal_2]_{1x26} \\
\vdots \\
[normal_{189}]_{1x26} \\
[normal_{190}]_{1x26}
\end{bmatrix}_{7390x26} \tag{3.6}
$$

Através das outras sete matrizes que serão apresentadas a seguir se pode observar a entrada de cada uma das cinco RNAs desenvolvidas para cada módulo, sendo que para os módulos de detecção e classificação também foram estudadas as variações dos comprimentos da janela de dados, portanto apresentando quatro destas sete matrizes, e para o de localização foram simuladas três RNAs sem o estudo do comprimento da janela de dados, respondendo assim pelas outras três matrizes.

$$
M_{ent_det_jan4} =
$$

$$
\begin{bmatrix}
Va_{t-3} & Va_{t-2} & Va_{t-1} & Va_t & Vb_{t-3} & \cdots & Ic_{t-3} & Ic_{t-2} & Ic_{t-1} & Ic_t & saida_1 & saida_2 \\
n_{1_1d} & n_{1_2d} & n_{1_3d} & n_{1_4d} & n_{1_5d} & \cdots & n_{1_21d} & n_{1_22d} & n_{1_23d} & n_{1_24d} & 1 & 0 \\
n_{2_1d} & n_{2_2d} & n_{2_3d} & n_{2_4d} & n_{2_5d} & \cdots & n_{2_21d} & n_{2_22d} & n_{2_23d} & n_{2_24d} & 1 & 0 \\
\vdots & \vdots & \vdots & \vdots & \vdots & \cdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots
\end{bmatrix}_{7390x26} \tag{3.7}
$$

$$M_{ent_det_jan3} = \begin{bmatrix} Va_{t-2} & Va_{t-1} & Va_t & Vb_{t-2} & \cdots & Ib_t & Ic_{t-2} & Ic_{t-1} & Ic_t & saida_1 & saida_2 \\ n_{1_2d} & n_{1_3d} & n_{1_4d} & n_{1_6d} & \cdots & n_{1_20d} & n_{1_22d} & n_{1_23d} & n_{1_24d} & 1 & 0 \\ n_{2_2d} & n_{2_3d} & n_{2_4d} & n_{2_6d} & \cdots & n_{2_20d} & n_{2_22d} & n_{2_23d} & n_{2_24d} & 1 & 0 \\ \vdots & \vdots & \vdots & \vdots & \cdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \end{bmatrix}_{7390x20} \quad (3.8)$$

$$M_{ent_class_jan4} = \begin{bmatrix} Va_{t-3} & Va_{t-2} & Va_{t-1} & Va_t & Vb_{t-3} & \cdots & Ib_t & Ic_{t-3} & Ic_{t-2} & Ic_{t-1} & Ic_t & \cdots & saida_4 \\ n_{1_1} & n_{1_2} & n_{1_3} & n_{1_4} & n_{1_5} & \cdots & n_{1_20} & n_{1_21} & n_{1_22} & n_{1_23} & n_{1_24} & \cdots & 0 \\ n_{2_1} & n_{2_2} & n_{2_3} & n_{2_4} & n_{2_5} & \cdots & n_{2_20} & n_{2_21} & n_{2_22} & n_{2_23} & n_{2_24} & \cdots & 0 \\ \vdots & \vdots & \vdots & \vdots & \vdots & \cdots & \vdots & \vdots & \vdots & \vdots & \vdots & \cdots & \vdots \end{bmatrix}_{7200x28} \quad (3.9)$$

$$M_{ent_class_jan3} = \begin{bmatrix} Va_{t-2} & Va_{t-1} & Va_t & Vb_{t-2} & \cdots & Ib_t & Ic_{t-2} & Ic_{t-1} & Ic_t & \cdots & saida_4 \\ n_{1_2} & n_{1_3} & n_{1_4} & n_{1_6} & \cdots & n_{1_20} & n_{1_22} & n_{1_23} & n_{1_24} & \cdots & 0 \\ n_{2_2} & n_{2_3} & n_{2_4} & n_{2_6} & \cdots & n_{2_20} & n_{2_22} & n_{2_23} & n_{2_24} & \cdots & 0 \\ \vdots & \vdots & \vdots & \vdots & \cdots & \vdots & \vdots & \vdots & \vdots & \cdots & \vdots \end{bmatrix}_{7200x22} \quad (3.10)$$

$$M_{ent_loc_jan4_RNA1} = \begin{bmatrix} Va_{t-3} & Va_{t-2} & Va_{t-1} & \cdots & Ic_{t-2} & Ic_{t-1} & Ic_t & \cdots & saida_5 \\ TDF(n_{1_1}) & TDF(n_{1_2}) & TDF(n_{1_3}) & \cdots & TDF(n_{1_22}) & TDF(n_{1_23}) & TDF(n_{1_24}) & \cdots & 0 \\ TDF(n_{2_1}) & TDF(n_{2_2}) & TDF(n_{2_3}) & \cdots & TDF(n_{2_22}) & TDF(n_{2_23}) & TDF(n_{2_24}) & \cdots & 0 \\ \vdots & \vdots & \vdots & \cdots & \vdots & \vdots & \vdots & \cdots & \vdots \end{bmatrix}_{2160x29} \quad (3.11)$$

$$M_{ent_loc_jan4_RNA2} = \begin{bmatrix} Va_{t-3} & Va_{t-2} & Va_{t-1} & \cdots & Ic_{t-2} & Ic_{t-1} & Ic_t & \cdots & saida_5 \\ TDF(n_{1_1}) & TDF(n_{1_2}) & TDF(n_{1_3}) & \cdots & TDF(n_{1_22}) & TDF(n_{1_23}) & TDF(n_{1_24}) & \cdots & 0 \\ TDF(n_{2_1}) & TDF(n_{2_2}) & TDF(n_{2_3}) & \cdots & TDF(n_{2_22}) & TDF(n_{2_23}) & TDF(n_{2_24}) & \cdots & 0 \\ \vdots & \vdots & \vdots & \cdots & \vdots & \vdots & \vdots & \cdots & \vdots \end{bmatrix}_{4320x29} \quad (3.12)$$

$$M_{ent_loc_jan4_RNA3} = \begin{bmatrix} Va_{t-3} & Va_{t-2} & Va_{t-1} & \cdots & Ic_{t-2} & Ic_{t-1} & Ic_t & \cdots & saida_5 \\ TDF(n_{1_1}) & TDF(n_{1_2}) & TDF(n_{1_3}) & \cdots & TDF(n_{1_22}) & TDF(n_{1_23}) & TDF(n_{1_24}) & \cdots & 0 \\ TDF(n_{2_1}) & TDF(n_{2_2}) & TDF(n_{2_3}) & \cdots & TDF(n_{2_22}) & TDF(n_{2_23}) & TDF(n_{2_24}) & \cdots & 0 \\ \vdots & \vdots & \vdots & \cdots & \vdots & \vdots & \vdots & \cdots & \vdots \end{bmatrix}_{720x29} \quad (3.13)$$

Onde:

n_{x_yd}: Valor obtido através do *SimPowerSystems* para a linha x, coluna y da matriz de entrada do módulo de detecção de falta.

n_{x_y}: Valor obtido através do *SimPowerSystems* para a linha x, coluna y da matriz de entrada do módulo de classificação de falta, que difere da detecção por conter apenas dados de pós-falta.

$TDF(n_{x_y})$: Valor obtido através do *SimPowerSystems* para a linha x, coluna y da matriz de entrada do módulo de localização de falta, que difere do módulo de classificação

por haver a necessidade da extração dos componentes fundamentais das amostras através da Transformada Discreta de Fourier.

Estando todas estas matrizes contidas em arquivos ‘.txt’ distintos, se apresenta na figura 3.22 um exemplo deles, neste caso para a matriz do módulo de detecção com janela de dados de 3 amostras.

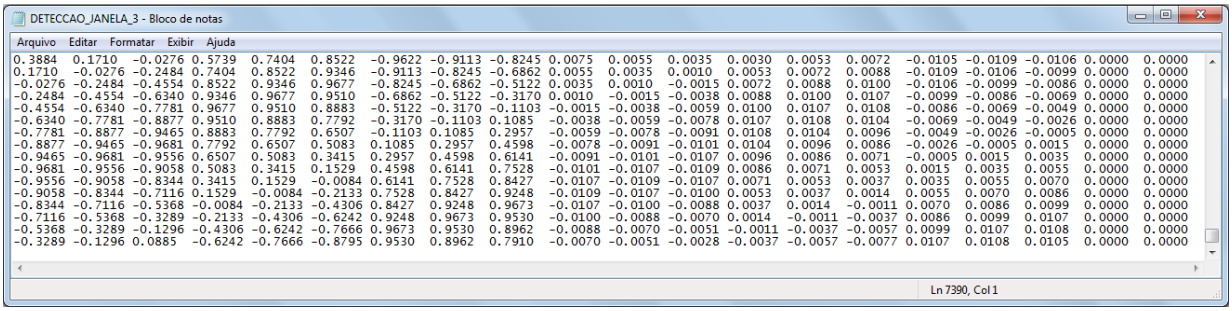
DETECCAO_JANELA_3 - Bloco de notas

Arquivo Editar Formatar Exibir Ajuda

0.3884	0.1710	-0.0276	0.5739	0.7404	0.8522	-0.9622	-0.9113	-0.8245	0.0075	0.0055	0.0035	0.0030	0.0053	0.0072	-0.0105	-0.0109	-0.0106	0.0000	0.0000
0.1710	-0.0276	-0.2484	0.7404	0.8522	0.9346	-0.9113	-0.8245	-0.6862	0.0055	0.0035	0.0010	0.0053	0.0072	0.0088	-0.0109	-0.0106	-0.0099	0.0000	0.0000
-0.0276	-0.2484	-0.4554	0.8522	0.9346	0.9677	-0.8245	-0.6862	-0.5122	0.0035	0.0010	-0.0015	0.0072	0.0088	0.0100	-0.0106	-0.0099	-0.0086	0.0000	0.0000
-0.2484	-0.4554	-0.6340	0.9346	0.9677	0.9510	-0.6862	-0.5122	-0.3170	0.0010	-0.0015	-0.0038	0.0088	0.0100	0.0107	-0.0099	-0.0086	-0.0069	0.0000	0.0000
-0.4554	-0.6340	-0.7781	0.9677	0.9510	0.8883	-0.5122	-0.3170	-0.1103	-0.0015	-0.0038	-0.0059	0.0100	0.0107	0.0108	-0.0086	-0.0069	-0.0049	0.0000	0.0000
-0.6340	-0.7781	-0.8877	0.9510	0.8883	0.7792	-0.3170	-0.1103	0.1085	-0.0038	-0.0059	-0.0078	0.0107	0.0108	0.0104	-0.0069	-0.0049	-0.0026	0.0000	0.0000
-0.7781	-0.8877	-0.9465	0.8883	0.7792	0.6507	-0.1103	0.1085	0.2957	-0.0059	-0.0078	-0.0091	0.0108	0.0104	0.0096	-0.0049	-0.0026	-0.0005	0.0000	0.0000
-0.8877	-0.9465	-0.9681	0.7792	0.6507	0.5083	0.1085	0.2957	0.4598	-0.0078	-0.0091	-0.0101	0.0104	0.0096	0.0086	-0.0026	-0.0005	0.0015	0.0000	0.0000
-0.9465	-0.9681	-0.9556	0.6507	0.5083	0.3415	0.2957	0.4598	0.6141	-0.0091	-0.0101	-0.0107	0.0096	0.0086	0.0071	-0.0005	0.0015	0.0035	0.0000	0.0000
-0.9681	-0.9556	-0.9058	0.5083	0.3415	0.1529	0.4598	0.6141	0.7528	-0.0101	-0.0107	-0.0109	0.0086	0.0071	0.0053	0.0015	0.0035	0.0055	0.0000	0.0000
-0.9556	-0.9058	-0.8344	0.3415	0.1529	-0.0084	0.6141	0.7528	0.8427	-0.0107	-0.0109	-0.0107	0.0071	0.0053	0.0037	0.0035	0.0055	0.0070	0.0000	0.0000
-0.9058	-0.8344	-0.7116	0.1529	-0.0084	-0.2133	0.7528	0.8427	0.9248	-0.0109	-0.0107	-0.0100	0.0053	0.0037	0.0014	0.0055	0.0070	0.0086	0.0000	0.0000
-0.8344	-0.7116	-0.5368	-0.0084	-0.2133	-0.4306	0.8427	0.9248	0.9673	-0.0107	-0.0100	-0.0088	0.0037	0.0014	-0.0011	0.0070	0.0086	0.0099	0.0000	0.0000
-0.7116	-0.5368	-0.3289	-0.2133	-0.4306	-0.6242	0.9248	0.9673	0.9530	-0.0100	-0.0088	-0.0070	0.0014	-0.0011	-0.0037	0.0086	0.0099	0.0107	0.0000	0.0000
-0.5368	-0.3289	-0.1296	-0.4306	-0.6242	-0.7666	0.9673	0.9530	0.8962	-0.0088	-0.0070	-0.0051	-0.0011	-0.0037	-0.0057	0.0099	0.0107	0.0108	0.0000	0.0000
-0.3289	-0.1296	0.0885	-0.6242	-0.7666	-0.8795	0.9530	0.8962	0.7910	-0.0070	-0.0051	-0.0028	-0.0037	-0.0057	-0.0077	0.0107	0.0108	0.0105	0.0000	0.0000

Ln 7390, Col 1

Figura 3.22: Exemplo de arquivo gerado pelo *SimPowerSystems* e correspondente à entrada da RNA do módulo de detecção com janela de dados de 3 amostras

3.3 Módulo de Detecção

Levando em consideração que uma situação de falta no sistema introduz alterações abruptas na amplitude e fase dos sinais de tensão e corrente, pode-se abordar a questão da detecção de uma falta como um problema de reconhecimento de padrões, onde os sinais de pré-falta e pós-falta, com os seus componentes transitórios, treinam a RNA para reconhecer a situação de falta no instante em que ela ocorre.

Há três métodos a serem destacados para a detecção de uma falta:

Método Comparativo: um dos métodos mais empregados na detecção de faltas, neste método se armazena na memória de um processador ou mediante o treinamento das RNAs amostras que sejam do sistema operando com e sem falta. Compara-se assim o valor instantâneo lido com estas amostras armazenadas, e daí quando for o caso se detecta a falta [1].

Método Estimativo: nesta análise através de uma quantidade N de amostras reais se estima outras N amostras no mesmo período de onda e se houver mudança substancial entre os valores instantâneos e os estipulados, está detectada a falta [1].

Método de Retificação da Onda: neste caso os sinais de corrente e tensão do TC e TP respectivamente são retificados e se atribui ‘1’ para o caso de variação positiva e ‘0’ para variação negativa. Caso o sistema esteja operando normalmente as ondas serão aproximadamente senoidais e a quantidade de ‘0’s e ‘1’s para um período de onda será

igual um com relação ao outro. Caso ocorra alguma falta esta condição será perturbada e em poucas amostras de pós-falta será possível detectá-la [1].

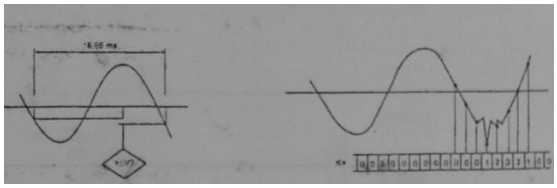

Figura 3.23: Detecção de falta através do método comparativo (Fonte: [1])

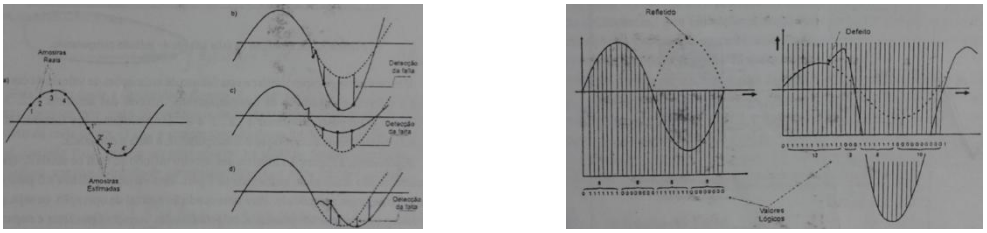

Figura 3.24: Detecção de falta através do estimativo (esquerda) e de retificação da onda (direito) (Fonte: [1])

Para o caso deste trabalho, o método utilizado foi o comparativo.

São três as possíveis saídas para a RNA deste módulo correspondente ao sistema operando sem falta, com falta entre os nós L e N, no caso uma falta reversa, ou com uma falta entre os nós N e O, P ou Q, caracterizando assim uma falta à frente. A tabela 3.4 resume essas condições citadas.

Tabela 3.4: Respostas esperadas da RNA do módulo de detecção de falta

Situação de operação do SEP	**Saída$_1$**	**Saída$_2$**
Normal	0	0
Falta reversa (entre os nós L e N)	1	0
Falta à frente (entre os nós N e O/P/Q)	0	1

A Rede Neural em questão apresentará 24 neurônios na camada de entrada no caso de janela de dados com 4 amostras ou 18, no caso desta janela de dados apresentar apenas 3 amostras, além da camada intermediária e de saída, e foi simulada através do arquivo ‘DETECCAO_RN.m’. No próximo capítulo será discutida a escolha de melhor topologia e sua validação.

3.4 Módulo de Classificação

Através dos fasores de correntes superpostos obtidos no nó N do sistema simulado I_{aN}'', I_{bN}'', I_{cN}'' e I_{oN}'', sendo cada uma das correntes relacionadas com as suas respectivas fases e a última referente a corrente de sequência zero, se pode classificar os tipos de faltas ocorrentes em cada caso. No caso das correntes, pelo fato de haver apenas um gerador presente antes do nó L, faltas ocorrentes entre L e N apresentam comportamento distinto quando a ocorrência está entre N e O, P ou Q. No caso das tensões trifásicas o mesmo não ocorre e são similares quando a falta é do mesmo tipo, resistência, ângulo de incidência, alterando assim apenas a localização. Nas figuras 3.25 e 3.26 se podem ver as formas de onda de tensão e corrente para uma falta do tipo AT, ângulo de incidência de 0º, resistência 0,001[Ω] e localizadas antes e depois respectivamente do nó N e observar o que foi discutido neste parágrafo.

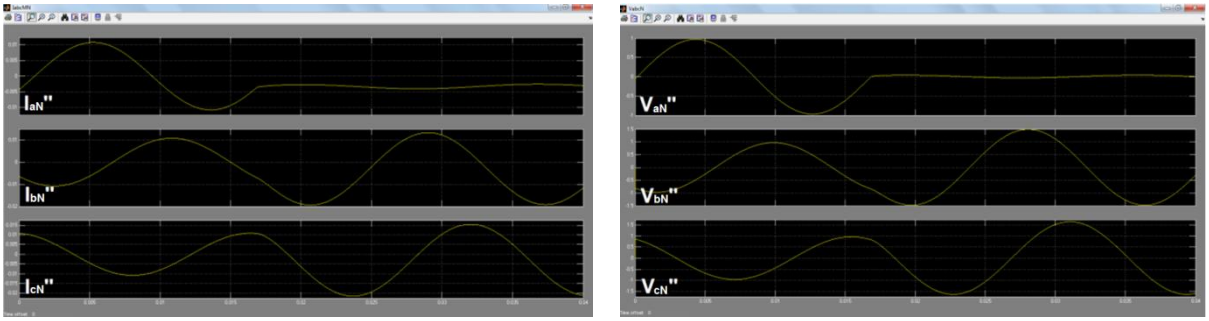

Figura 3.25: Sinal das Correntes Trifásicas (direita) e das Tensões Trifásicas (esquerda) no caso de ocorrência de falta AT na localização '2' de acordo com a tabela 3.3 com resistência de falta de 0,001[Ω] e ângulo de incidência de 0º

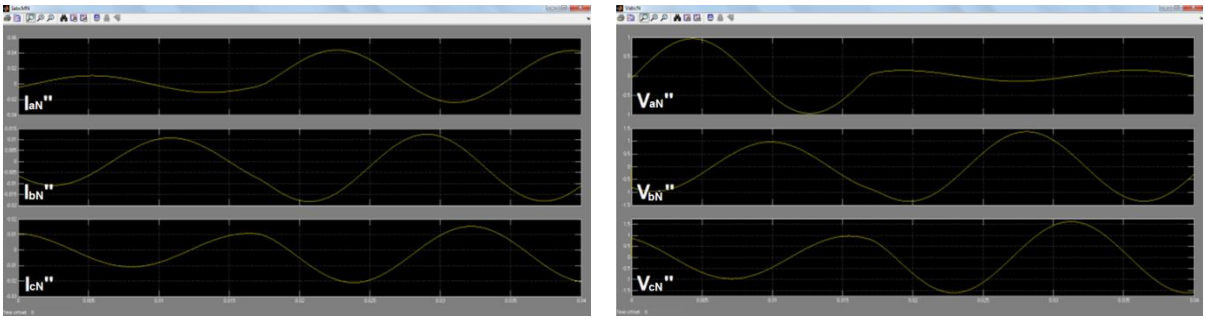

Figura 3.26: Sinal das Correntes Trifásicas (direita) e das Tensões Trifásicas (esquerda) no caso de ocorrência de falta AT na localização '10' de acordo com a tabela 3.3 com resistência de falta de 0,001[Ω] e ângulo de incidência de 0º

As tabelas 3.5 e 3.6 resumem para cada tipo de falta como se apresentam os fasores de tensão e corrente para que, a partir dessas informações, a RNA possa extrair essas informações e classificar cada uma das faltas ocorrentes no sistema elétrico. A primeira tabela se refere à ocorrência de falta entre os nós N e O, P ou Q, e a segunda, entre os nós L e N. Essa distinção se deve ao fato da falta isolar, no caso da sua ocorrência entre L e N, ou não o gerador do terminal de leitura de dados que no caso é o nó N. Se nota através das tabelas que existe um padrão entre as correntes e tensões trifásicas pós-falta conforme o tipo desta falta.

Tabela 3.5: Classificação da falta quanto ao tipo se falta ocorrer entre os nós N e O/P/Q (Fonte: adaptado de [1])

Se	**Falta do tipo**
$I_{bN}'' \leq KI_{aN}''$ e $I_{cN}'' \leq KI_{aN}''$ $V_{aN}'' \leq KV_{bN}''$ e $V_{aN}'' \leq KV_{cN}''$	Falta A-terra
$I_{aN}'' \leq KI_{bN}''$ e $I_{cN}'' \leq KI_{bN}''$ $V_{bN}'' \leq KV_{aN}''$ e $V_{bN}'' \leq KV_{cN}''$	Falta B-terra
$I_{aN}'' \leq KI_{cN}''$ e $I_{bN}'' \leq KI_{cN}''$ $V_{cN}'' \leq KV_{aN}''$ e $V_{cN}'' \leq KV_{bN}''$	Falta C-terra
$I_{cN}'' \leq KI_{aN}''$, $I_{aN}'' \approx I_{bN}''$ e $I_{oN}'' \leq I_{min}$ $V_{aN}'' \leq KV_{cN}''$ e $V_{aN}'' \approx V_{bN}''$	Falta AB-terra
$I_{cN}'' \leq KI_{aN}''$, $I_{aN}'' \approx I_{bN}''$ e $I_{oN}'' > I_{min}$ $V_{aN}'' \leq KV_{cN}''$ e $V_{aN}'' \approx V_{bN}''$	Falta AB
$I_{aN}'' \leq KI_{bN}''$, $I_{bN}'' \approx I_{cN}''$ e $I_{oN}'' \leq I_{min}$ $V_{bN}'' \leq KV_{aN}''$ e $V_{bN}'' \approx V_{cN}''$	Falta BC-Terra
$I_{aN}'' \leq KI_{bN}''$, $I_{bN}'' \approx I_{cN}''$ e $I_{oN}'' > I_{min}$ $V_{bN}'' \leq KV_{aN}''$ e $V_{bN}'' \approx V_{cN}''$	Falta BC
$I_{bN}'' \leq KI_{aN}''$, $I_{aN}'' \approx I_{cN}''$ e $I_{oN}'' \leq I_{min}$ $V_{aN}'' \leq KV_{bN}''$ e $V_{aN}'' \approx V_{cN}''$	Falta AC-Terra
$I_{bN}'' \leq KI_{aN}''$, $I_{aN}'' \approx I_{cN}''$ e $I_{oN}'' > I_{min}$ $V_{aN}'' \leq KV_{bN}''$ e $V_{aN}'' \approx V_{cN}''$	Falta AC
$I_{aN}'' \approx I_{bN}'' \approx I_{cN}''$ $V_{aN}'' \approx V_{bN}'' \approx V_{cN}''$	Falta ABC

Tabela 3.6: Classificação da falta quanto ao tipo se falta ocorrer entre os nós L e N

Se	Falta do tipo
$I_{aN}'' \leq KI_{bN}''$ e $I_{aN}'' \leq KI_{cN}''$ $V_{aN}'' \leq KV_{bN}''$ e $V_{aN}'' \leq KV_{cN}''$	Falta A-terra
$I_{bN}'' \leq KI_{aN}''$ e $I_{bN}'' \leq KI_{cN}''$ $V_{bN}'' \leq KV_{aN}''$ e $V_{bN}'' \leq KV_{cN}''$	Falta B-terra
$I_{cN}'' \leq KI_{aN}''$ e $I_{cN}'' \leq KI_{bN}''$ $V_{cN}'' \leq KV_{aN}''$ e $V_{cN}'' \leq KV_{bN}''$	Falta C-terra
$I_{aN}'' \leq KI_{cN}''$, $I_{aN}'' \approx I_{bN}''$ e $I_{oN}'' \leq I_{min}$ $V_{aN}'' \leq KV_{cN}''$ e $V_{aN}'' \approx V_{bN}''$	Falta AB-terra
$I_{aN}'' \leq KI_{cN}''$, $I_{aN}'' \approx I_{bN}''$ e $I_{oN}'' > I_{min}$ $V_{aN}'' \leq KV_{cN}''$ e $V_{aN}'' \approx V_{bN}''$	Falta AB
$I_{bN}'' \leq KI_{aN}''$, $I_{bN}'' \approx I_{cN}''$ e $I_{oN}'' \leq I_{min}$ $V_{bN}'' \leq KV_{aN}''$ e $V_{bN}'' \approx V_{cN}''$	Falta BC-Terra
$I_{bN}'' \leq KI_{aN}''$, $I_{bN}'' \approx I_{cN}''$ e $I_{oN}'' > I_{min}$ $V_{bN}'' \leq KV_{aN}''$ e $V_{bN}'' \approx V_{cN}''$	Falta BC
$I_{aN}'' \leq KI_{bN}''$, $I_{aN}'' \approx I_{cN}''$ e $I_{oN}'' \leq I_{min}$ $V_{aN}'' \leq KV_{bN}''$ e $V_{aN}'' \approx V_{cN}''$	Falta AC-Terra
$I_{aN}'' \leq KI_{bN}''$, $I_{aN}'' \approx I_{cN}''$ e $I_{oN}'' > I_{min}$ $V_{aN}'' \leq KV_{bN}''$ e $V_{aN}'' \approx V_{cN}''$	Falta AC
$I_{aN}'' \approx I_{bN}'' \approx I_{cN}''$ $V_{aN}'' \approx V_{bN}'' \approx V_{cN}''$	Falta ABC

São dez as possíveis saídas para a RNA deste módulo que representa o tipo de falta ocorrente. A tabela 3.7 contém os possíveis tipos de falta e a representação de cada uma delas nas saídas da RNA de classificação.

Tabela 3.7: Respostas esperadas da RNA do módulo de classificação de falta

Tipo da Falta	**Saída$_1$** **Fase A**	**Saída$_2$** **Fase B**	**Saída$_3$** **Fase C**	**Saída$_4$** **Terra**
Falta A-terra	1	0	0	1
Falta B-terra	0	1	0	1
Falta C-terra	0	0	1	1
Falta AB	1	1	0	0
Falta AC	1	0	1	0
Falta BC	0	1	1	0

Falta AB-terra	1	1	0	1
Falta AC-terra	1	0	1	1
Falta BC-terra	0	1	1	1
Falta ABC	1	1	1	0

Esta RNA apresentará 24 neurônios na camada de entrada no caso de janela de dados com 4 amostras ou 18, no caso desta janela de dados apresentar apenas 3 amostras, além da camada intermediária e de saída, e foi simulada através do arquivo 'CLASSIFICACAO_RN.m'. No próximo capítulo será discutida a escolha de melhor topologia e sua validação.

3.5 Módulo de Localização

Com relação à localização de faltas há abordagens que trabalham com a aquisição de dados em um, dois e até três terminais [24].

Com relação às técnicas baseadas em dados provenientes de um terminal, dentre as diferentes abordagens, a que se baseou este trabalho tem como procedimentos a serem seguidos, primeiramente, a determinação do instante de ocorrência de falta, sendo esta a responsabilidade do módulo de detecção. Em seguida se deve determinar o tipo de falta para que assim se possa selecionar a rede neural adequada para a localização da falta, esta tarefa de responsabilidade do módulo de classificação da falta. São três as redes neurais desenvolvidas para este módulo. Uma para a localização de faltas do tipo AT, BT e CT, uma segunda para o caso das faltas do tipo AB, AC, BC, ABT, ACT e BCT, e uma terceira para as faltas ABC.

Na sequência se deve extrair os fasores fundamentais das ondas de tensão e corrente da matriz de dados provenientes do terminal através da Transformada Discreta de Fourier (TDF), que são amplamente utilizados para esta finalidade devido à sua simplicidade e precisão na obtenção dos fasores fundamentais quando os sinais são periódicos e contêm apenas níveis múltiplos da frequência fundamental e nível DC [17]. Assim se obterá a matriz entrada das redes neurais do módulo de localização [25].

Sendo x(t) o sinal contínuo a ser amostrado, para a obtenção da transformada de Fourier existem os seguintes requisitos:

1. O sinal x(t) deve ser periódico, ou seja, $x(t)=x(t+\zeta)$, para qualquer t [26].
2. O sinal deve ser amostrado com um período de amostragem T_s, submúltiplo do período ζ do sinal, ou seja, $x_s(t)=x(t).d(t,T_s)$, com $T_s=\zeta/N$ [26].

3. A frequência de amostragem ω_s deve ser maior que o dobro da maior frequência contida no sinal x(t) [26].
4. Deve-se dispor de N amostras do sinal x(t), onde $x[k]=x(t_o+kT_s)$, com k=0,1,...,N-1 [26].

Os valores x[k] correspondem aos valores do sinal contínuo x(t) nos instantes referentes à amostragem deste sinal, e fisicamente correspondem aos valores obtidos na saída do Conversor Analógico-Digital (CAD) [26].

Seja x[n] uma sequência discreta periódica cujo período seja N, a TDF de x[n], resultando em $X_F(k)$, é definida como [26]:

$$X_F[k] = \frac{1}{N}\sum_{n=0}^{N-1} x[n].\, e^{-jk\frac{2\pi n}{N}} \tag{3.14}$$

A TDF de x[n] está relacionada com a transformada de Fourier do sinal x(t), sendo a frequência fundamental do sinal x(t) igual a $\omega_o=2\pi/\zeta$ e o sinal contendo apenas frequências na forma $\omega_k=p\omega_o$, com p inteiro já que estas frequências são múltiplas da fundamental [26].

Se a técnica de localização adotada utilizasse dados de dois terminais, para a sua implantação seria necessário um meio de comunicação entre os terminais para a transferência de dados além de um método de sincronização de medição destes [1].

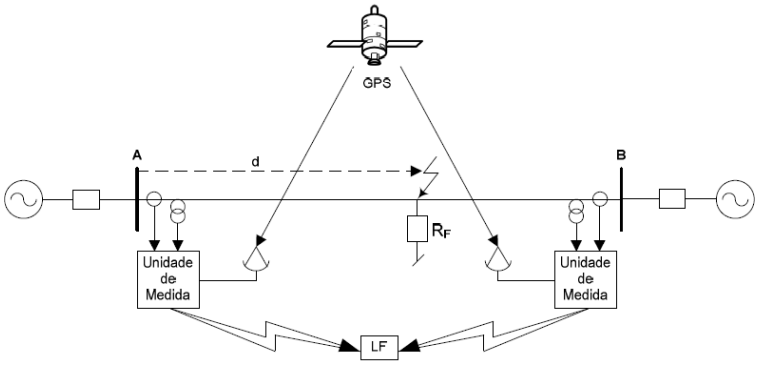

Figura 3.27: Esquema de localização de falta sincronizando dois terminais através de GPS (Fonte: [17])

A sincronização dos dados se consegue com o uso do GPS (*Global Positioning System*) em que se transmite via satélite um sinal de tempo como referência disponível em diversos pontos da rede elétrica. Cada amostra dos sinais de cada terminal pode ser armazenada em tempo real utilizando como referência o tempo obtido no GPS considerando o atraso na transmissão dos dados de um terminal remoto para local, verificando o instante em que os sinais foram obtidos [1]. Com respeito ao meio de comunicação entre os

terminais os que vêm sendo mais utilizados atualmente são fibras ópticas no interior de cabos guarda, ou OPGW (*optic overhead ground wire*), microondas, *modem*, satélite e via rádio [1].

São cinco as possíveis saídas para cada uma das três RNAs deste módulo que representa o trecho do sistema de distribuição em que a falta ocorreu. A tabela 3.8 contém cada um dos trechos do sistema e as suas respectivas representações nas saídas de cada uma das RNAs de localização da falta.

Tabela 3.8: Respostas esperadas da RNA do módulo de localização de falta

Trecho em que ocorreu a falta	**Saída$_1$**	**Saída$_2$**	**Saída$_3$**	**Saída$_4$**	**Saída$_5$**
Trecho L-M	1	0	0	0	0
Trecho M-N	0	1	0	0	0
Trecho N-O	0	0	1	0	0
Trecho N-P	0	0	0	1	0
Trecho N-Q	0	0	0	0	1

Esta RNA apresentará 24 neurônios na camada de entrada no caso de janela de dados com 4 amostras ou 18, no caso desta janela de dados apresentar apenas 3 amostras, além de duas camadas intermediárias e a de saída. Neste caso foi necessária a utilização de mais de uma camada intermediária na rede neural para que fosse possível a extração das características dos sinais para que fosse determinado o setor de ocorrência de falta. A rede foi simulada no MATLAB através dos arquivos ‘LOCALIZACAO_RN_1.m’, ‘LOCALIZACAO_RN_2.m’ e ‘LOCALIZACAO_RN_3.m’. No próximo capítulo será discutida a escolha de melhor topologia e sua validação.

Capítulo 4

Validação das Redes Neurais Artificiais

Este capítulo tem como objetivo validar as RNAs comentadas no capítulo anterior a fim de verificar o desempenho de cada uma delas.

Para a validação cruzada com amostragem aleatória temos que o conjunto total de amostras é dividido em subconjunto de treinamento e subconjunto de teste, o primeiro para treinar as topologias candidatas e o segundo para avaliar o desempenho da generalização de cada uma das topologias, e nenhuma amostra do subconjunto de treinamento está contida no de testes e vice-versa. Foram criados três grupos para cada uma das RNAs dos três módulos implementados, no caso o de detecção, o de classificação e o de localização, e neste último caso como são três RNAs, são três conjuntos contendo estes três grupos. Os algoritmos construídos no MATLAB para selecionar 1000, 1500 ou 2000 amostras aleatórias do conjunto total de amostras para constituírem o conjunto de teste estão presentes no anexo e foram denominados de:

geracao_n_det.m: Para o módulo de detecção.

geracao_n.m: Para o módulo de classificação.

geracao_n_LOC_FT.m: Para o módulo de localização.

Foram criados um algoritmo para cada módulo já que na detecção o conjunto total de amostras é de 7390 amostras, no de classificação 7200, e no de localização também 7200, porém está dividida entre as três RNAs criadas.

Os algoritmos responsáveis pela finalização do processo de constituição dos conjuntos de amostras de treinamento e de testes a partir do conjunto de amostras totais são conhecidos como ‘Mteste_trein_det.m’, ‘Mteste_trein.m’, ‘Mteste_trein_LOC_FT.m’ e são distintos pela mesma razão que os algoritmos que selecionam as amostras de testes no conjunto total de amostras.

4.1 Validação do Módulo de Detecção

Na tabela 4.1 temos a divisão das amostras de treinamento e de testes e a sua porcentagem em relação ao conjunto total de amostras para a validação da RNA do módulo de detecção.

Tabela 4.1: Divisão do total de amostras em conjunto de treinamento e teste para os três grupos do módulo de detecção

Grupo	Quantidade de Amostras de Treinamento	Quantidade de Amostras de Teste
1	6390 (86,5%)	1000 (13,5%)
2	5890 (79,7%)	1500 (20,3%)
3	5390 (72,9%)	2000 (27,1%)

Sabe-se que na maioria das resoluções de problemas envolvendo PMC uma camada intermediária já é o suficiente. A partir dessa premissa e com o que foi discutido no capítulo 2, primeiro se checa a quantidade de neurônios nessa camada que produz a maior porcentagem de acertos. Para este objetivo, se seleciona o grupo 2 e uma janela de dados de 4 amostras. O número de épocas é de 400, a taxa de aprendizado é de 0,2 e a função de ativação para a camada de saída neste caso é a degrau, e para a intermediária, a logística.

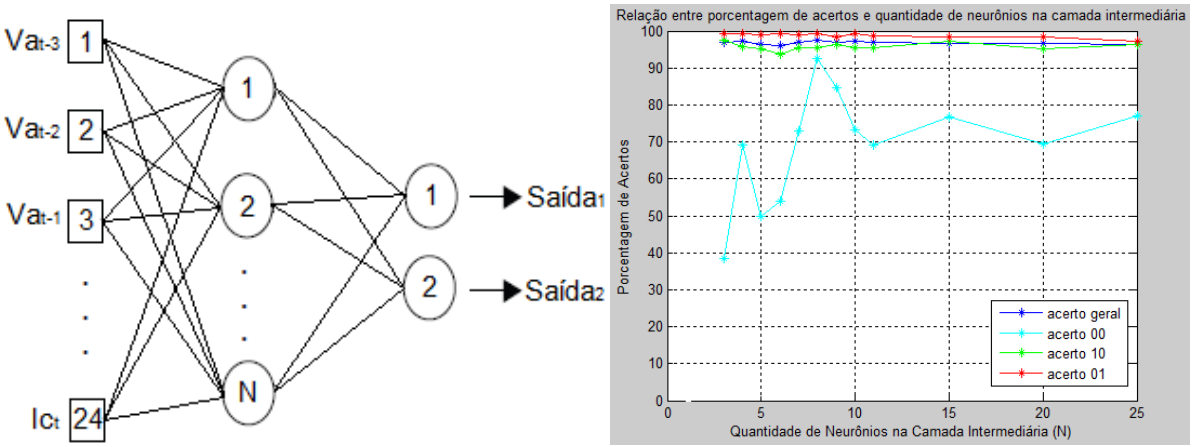

Figura 4.1: Relação entre quantidade de neurônios na camada intermediária e porcentagem de acertos no módulo de detecção

Para o módulo de detecção foi selecionada a RNA da figura 4.2, cujas características estão presentes nas tabelas 4.2 e 4.3.

Tabela 4.2: Características da RNA do módulo de detecção de falta

Característica	RNA de detecção da falta
Quantidade de amostras na janela de dados	4 amostras/janela
Quantidade de camadas intermediárias	1
Número de Neurônios da camada de entrada	24
Número de Neurônios na camada de intermediária	8
Função de Ativação da camada Intermediária	Logística
Número de Neurônios na camada de saída	2
Função de Ativação da camada de saída	Degrau

Tabela 4.3: Parâmetros de Treinamento da RNA do módulo de detecção de falta

Parâmetros	Valores estabelecidos para o RNA de detecção de falta
Número de Épocas	400
Taxa de Aprendizado	0,2
Erro final estabelecido	10^{-3}

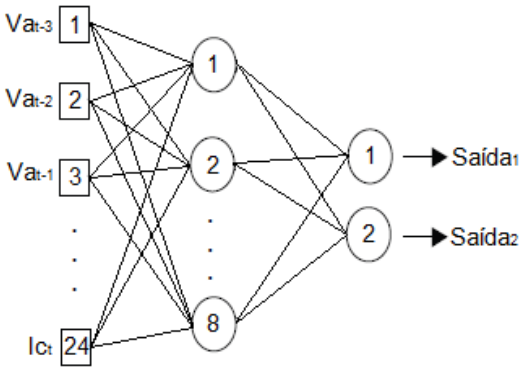

Figura 4.2: RNA eleita para o módulo de detecção

O resultado da validação cruzada para a topologia eleita considerando os três grupos criados e contidos na tabela 4.1 se encontra na tabela 4.4.

Tabela 4.4: Validação Cruzada da RNA eleita para o módulo de detecção

Grupo	Porcentagem de Acertos			
	Detectada falta à frente	**Detectada falta reversa**	**Funcionamento Normal**	**Geral**
1	98,34%	95,17%	81,48%	96,87%
2	99,17%	95,44%	92,59%	97,10%
3	98,65%	95,89%	84,62%	97,17%

A partir destes resultados se verifica que a rede obtém um bom nível de generalização e, portanto, desempenha adequadamente sua função.

4.2 Validação do Módulo de Classificação

Na tabela 4.5 temos a divisão das amostras de treinamento e de testes e a sua porcentagem em relação ao conjunto total de amostras para a validação da RNA do módulo de classificação.

Tabela 4.5: Divisão do total de amostras em conjunto de treinamento e teste para os três grupos do módulo de classificação

Grupo	Quantidade de Amostras de Treinamento	Quantidade de Amostras de Teste
1	6200 (86,1%)	1000 (13,9%)
2	5700 (79,2%)	1500 (20,8%)
3	5200 (72,2%)	2000 (27,8%)

Como no módulo de detecção, foi observada a relação entre a quantidade de neurônios na camada intermediária e a maior porcentagem de acertos por parte da RNA, considerando o grupo 2 da tabela 4.5, janela de dados de 4 amostras, número de épocas de 400, taxa de aprendizado de 0,1 e função de ativação para a camada de saída, degrau, e para a intermediária, logística.

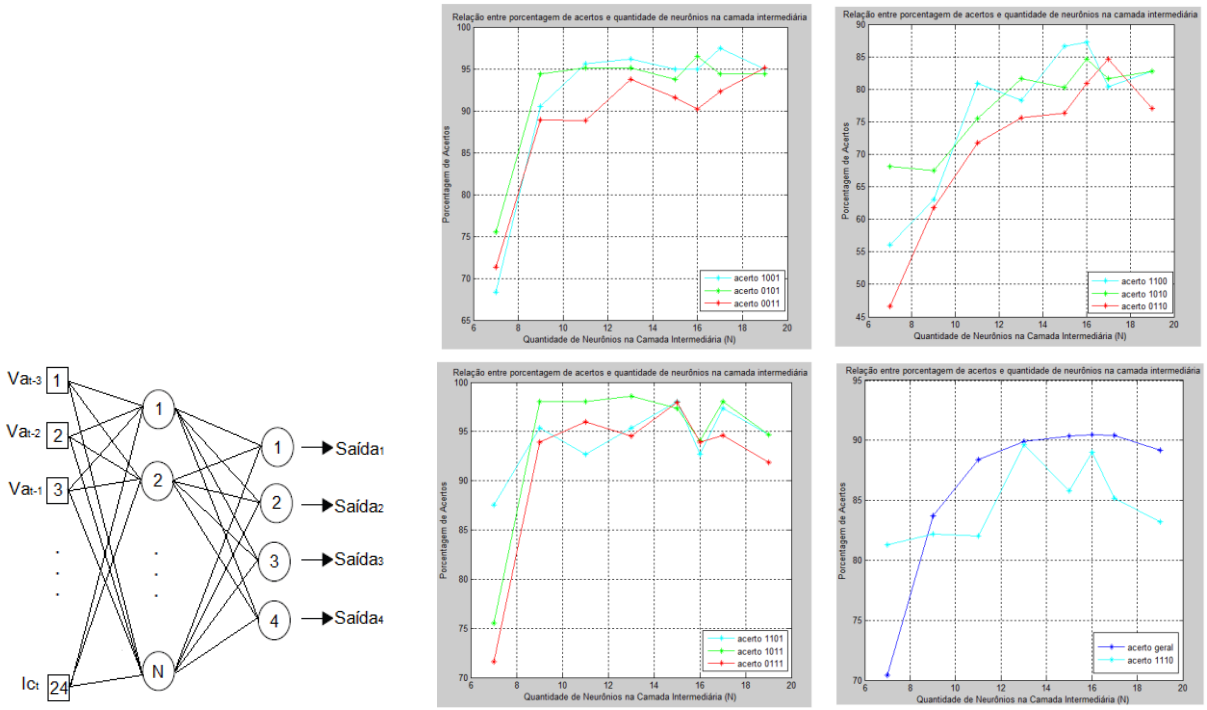

Figura 4.3: Relação entre quantidade de neurônios na camada intermediária e porcentagem de acertos no módulo de classificação

Para o módulo de classificação foi selecionada a RNA da figura 4.4, cujas características estão presentes nas tabelas 4.6 e 4.7.

Tabela 4.6: Características da RNA do módulo de classificação de falta

Característica	**RNA de classificação da falta**
Quantidade de amostras na janela de dados	4 amostras/janela
Quantidade de camadas intermediárias	1
Número de Neurônios da camada de entrada	24
Número de Neurônios na camada de intermediária	16
Função de Ativação da camada Intermediária	Logística
Número de Neurônios na camada de saída	4
Função de Ativação da camada de saída	Degrau

Tabela 4.7: Parâmetros de Treinamento da RNA do módulo de detecção de falta

Parâmetros	**Valores estabelecidos para o RNA de classificação de falta**
Número de Épocas	400
Taxa de Aprendizado	0,1
Erro final estabelecido	10^{-3}

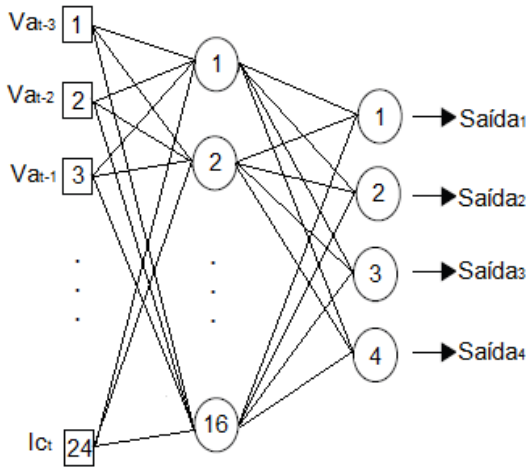

Figura 4.4: RNA eleita para o módulo de classificação

O resultado da validação cruzada para esta topologia escolhida considerando os três grupos criados e contidos na tabela 4.5 se encontra na tabela 4.8.

Tabela 4.8: Validação Cruzada da RNA eleita para o módulo de classificação

Grupo	**Porcentagem de Acertos**										
	AT	**BT**	**CT**	**AB**	**AC**	**BC**	**ABT**	**ACT**	**BCT**	**ABC**	**Geral**
1	94,6%	94,1%	87,9%	85,6%	91,8%	83,5%	96,1%	93,3%	94,7%	81,1%	90,1%
2	94,9%	96,5%	90,2%	87,3%	84,7%	80,9%	92,7%	94,0%	93,9%	89,0%	90,5%
3	92,1%	86,4%	95,3%	86,3%	85,5%	80,3%	94,8%	93,9%	93,4%	83,3%	90,0%

Para a RNA contendo uma camada intermediária já se pode observar os bons resultados obtidos. Caso se deseje melhorar ainda mais os resultados, seriam recomendadas alternativas como o aumento de camadas intermediárias ou outras topologias de RNAs.

4.3 Validação do Módulo de Localização

Levando em conta que neste módulo se trabalha com três RNAs se busca simplificar alguns estudos já que através dos módulos de detecção e classificação foi possível refletir a respeito. Para cada uma das RNAs será apresentada a rede que apresentou melhor desempenho juntamente com os resultados da validação cruzada.

4.3.1 Rede Neural Artificial 1

Esta RNA é a rede encarregada de determinar o trecho em que ocorreu a falta para as do tipo AT, BT e CT. Na tabela 4.9 temos para os três grupos em estudo a divisão das amostras de treinamento e de testes e cada uma das suas porcentagens em relação ao conjunto total de amostras para a validação desta rede neural.

Tabela 4.9: Divisão do total de amostras em conjunto de treinamento e teste para os três grupos da RNA 1 módulo de localização

Grupo	Quantidade de Amostras de Treinamento	Quantidade de Amostras de Teste
1	1910 (88,3%)	250 (11,7%)
2	1760 (81,5%)	400 (18,5%)
3	1610 (74,5%)	550 (25,5%)

Para o módulo de localização voltado para as faltas do tipo fase-terra foi selecionada a RNA da figura 4.5, cujas características estão presentes nas tabelas 4.10 e 4.11.

Tabela 4.10: Características da 1ª RNA do módulo de localização de falta

Característica	RNA 1 de localização da falta
Quantidade de amostras na janela de dados	4 amostras/janela
Quantidade de camadas intermediárias	3
Número de Neurônios da camada de entrada	24

Número de Neurônios na camada de intermediária	Primeira camada – 28 Segunda camada – 20 Terceira camada – 9
Função de Ativação da camada Intermediária	Primeira camada – Logística Segunda camada – Logística Terceira camada – Logística
Número de Neurônios na camada de saída	5
Função de Ativação da camada de saída	Degrau

Tabela 4.11: Parâmetros de Treinamento da 1ª RNA do módulo de localização de falta

Parâmetros	**Valores estabelecidos para a 1ª RNA de localização de falta**
Número de Épocas	200
Taxa de Aprendizado	0,2
Erro final estabelecido	10^{-3}

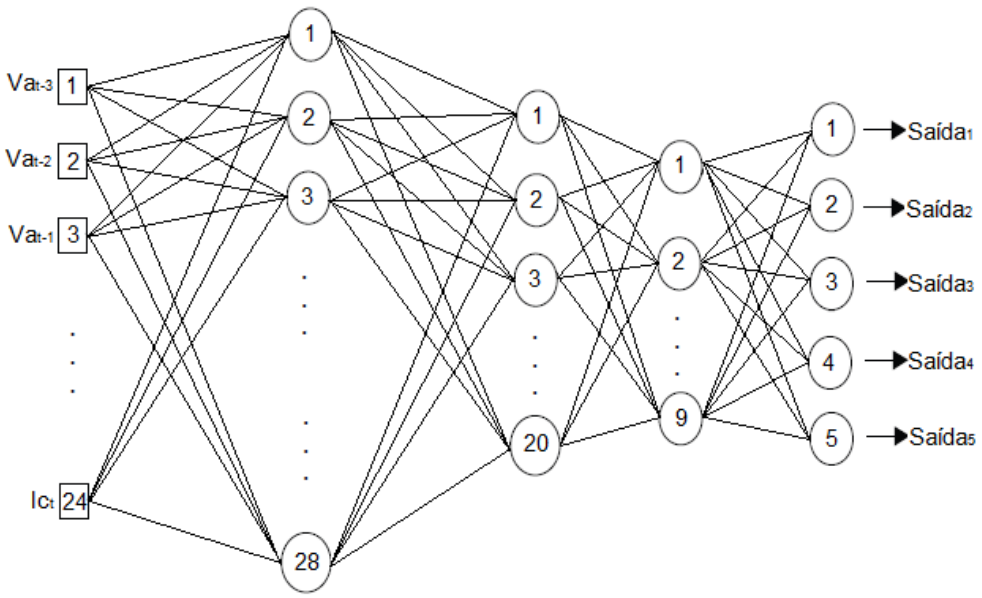

Figura 4.5: RNA 1 do módulo de localização

O resultado da validação cruzada para esta topologia escolhida considerando os três grupos criados e contidos na tabela 4.9 se encontra na tabela 4.12.

Tabela 4.12: Validação Cruzada da 1ª RNA eleita para o módulo de localização

Grupo	Porcentagem de Acertos					
	Trecho L-M	Trecho M-N	Trecho N-O	Trecho N-P	Trecho N-Q	Geral
1	95,9%	94,6%	80,0%	91,1%	87,5%	90,0%
2	93,3%	91,4%	82,1%	84,6%	83,5%	86,8%
3	84,9%	84,3%	80,2%	90,1%	80,5%	84,0%

A partir destes resultados se verifica que a rede obtém um bom nível de generalização. Importante ressaltar que se podem melhorar ainda mais estes resultados a partir da leitura de dados através de dois ou três nós, ao invés de apenas um como ocorreu neste caso.

4.3.2 Rede Neural Artificial 2

Esta RNA é a rede encarregada de determinar o trecho em que ocorreu a falta para as do tipo AB, AC, BC, ABT, ACT e BCT. Na tabela 4.13 temos para os três grupos em estudo a divisão das amostras de treinamento e de testes e cada uma das suas porcentagens em relação ao conjunto total de amostras para a validação desta rede neural.

Tabela 4.13: Divisão do total de amostras em conjunto de treinamento e teste para os três grupos da RNA 2 módulo de localização

Grupo	Quantidade de Amostras de Treinamento	Quantidade de Amostras de Teste
1	3870 (89,6%)	450 (10,4%)
2	3670 (85,0%)	650 (15,0%)
3	3420 (79,2%)	900 (20,8%)

Para o módulo de localização voltado para as faltas do tipo fase-fase e fase-fase-terra foi selecionada a RNA da figura 4.6, cujas características estão presentes nas tabelas 4.14 e 4.15.

Tabela 4.14: Características da 2ª RNA do módulo de localização de falta

Característica	**RNA 2 de localização da falta**
Quantidade de amostras na janela de dados	4 amostras/janela
Quantidade de camadas intermediárias	3
Número de Neurônios da camada de entrada	24
Número de Neurônios na camada de intermediária	Primeira camada – 35 Segunda camada – 22 Terceira camada – 9
Função de Ativação da camada Intermediária	Primeira camada – Logística Segunda camada – Logística Terceira camada – Logística
Número de Neurônios na camada de saída	5
Função de Ativação da camada de saída	Degrau

Tabela 4.15: Parâmetros de Treinamento da 2ª RNA do módulo de localização de falta

Parâmetros	**Valores estabelecidos para a 2ª RNA de localização de falta**
Número de Épocas	200
Taxa de Aprendizado	0,2
Erro final estabelecido	10^{-3}

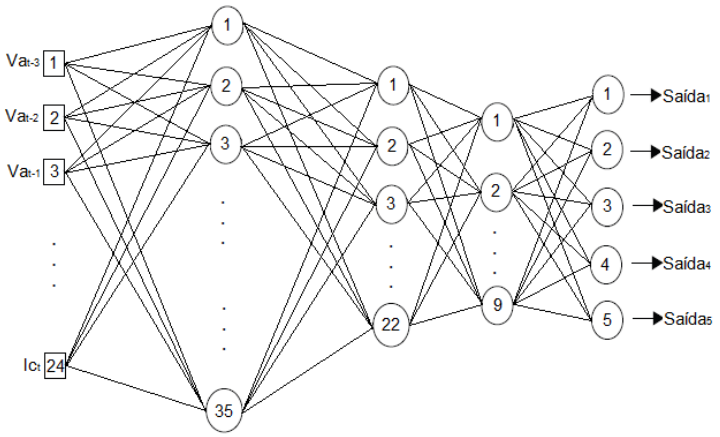

Figura 4.6: RNA 2 do módulo de localização

O resultado da validação cruzada para esta topologia escolhida considerando os três grupos criados e contidos na tabela 4.13 se encontra na tabela 4.16.

Tabela 4.16: Validação Cruzada da 2ª RNA eleita para o módulo de localização

Grupo	Porcentagem de Acertos					
	Trecho L-M	Trecho M-N	Trecho N-O	Trecho N-P	Trecho N-Q	Geral
1	88,1%	93,6%	91,0%	88,4%	80,8%	88,2%
2	95,0%	91,7%	83,8%	81,2%	84,7%	86,8%
3	85,3%	93,6%	84,6%	82,4%	88,8%	86,8%

A partir destes resultados se verifica que a rede obtém um bom nível de generalização. Importante ressaltar que se podem melhorar ainda mais estes resultados a partir da leitura de dados através de dois ou três nós, ao invés de apenas um como ocorreu neste caso.

4.3.3 Rede Neural Artificial 3

Esta RNA é a rede encarregada de determinar o trecho em que ocorreu a falta para as do tipo ABC. Na tabela 4.17 temos para os três grupos em estudo a divisão das amostras de treinamento e de testes e cada uma das suas porcentagens em relação ao conjunto total de amostras para a validação desta rede neural.

Tabela 4.17: Divisão do total de amostras em conjunto de treinamento e teste para os três grupos da RNA 3 módulo de localização

Grupo	Quantidade de Amostras de Treinamento	Quantidade de Amostras de Teste
1	620 (86,1%)	100 (13,9%)
2	570 (79,2%)	150 (20,8%)
3	520 (72,2%)	200 (27,8%)

Para o módulo de localização voltado para as faltas do tipo fase-fase-fase foi selecionada a RNA da figura 4.7, cujas características estão presentes nas tabelas 4.18 e 4.19.

Tabela 4.18: Características da 3ª RNA do módulo de localização de falta

Característica	**RNA 3 de localização da falta**
Quantidade de amostras na janela de dados	4 amostras/janela
Quantidade de camadas intermediárias	2
Número de Neurônios da camada de entrada	24
Número de Neurônios na camada de intermediária	Primeira camada – 18 Segunda camada – 15
Função de Ativação da camada Intermediária	Primeira camada – Logística Segunda camada – Logística
Número de Neurônios na camada de saída	5
Função de Ativação da camada de saída	Degrau

Tabela 4.19: Parâmetros de Treinamento da 3ª RNA do módulo de localização de falta

Parâmetros	**Valores estabelecidos para a 3ª RNA de localização de falta**
Número de Épocas	300
Taxa de Aprendizado	0,1
Erro final estabelecido	10^{-3}

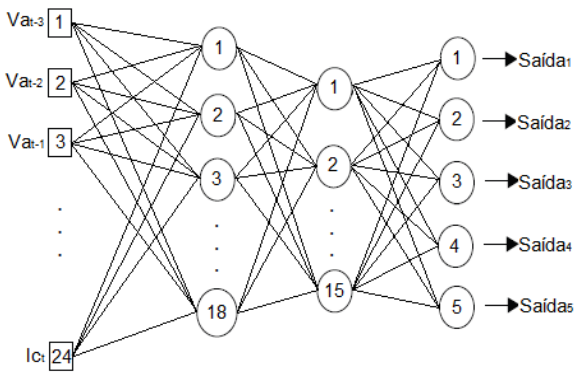

Figura 4.7: RNA 3 do módulo de localização

O resultado da validação cruzada para esta topologia escolhida considerando os três grupos criados e contidos na tabela 4.17 se encontra na tabela 4.20.

Tabela 4.20: Validação Cruzada da 3ª RNA eleita para o módulo de localização

Grupo	**Porcentagem de Acertos**					
	Trecho L-M	**Trecho M-N**	**Trecho N-O**	**Trecho N-P**	**Trecho N-Q**	**Geral**
1	100,00%	89,66%	100,00%	86,96%	95,00%	93,00%
2	92,00%	96,70%	80,60%	96,80%	78,80%	88,70%
3	82,20%	82,10%	87,80%	89,50%	83,80%	85,00%

Observa-se que a rede neural em questão atinge resultados satisfatórios, evidenciando um bom nível de generalização dos dados trabalhados.

Capítulo 5

Conclusão

O objetivo deste Trabalho de Conclusão de curso foi analisar e desenvolver um algoritmo de proteção de linhas de distribuição de energia elétrica, capaz de detectar, classificar e localizar curtos-circuitos que porventura ocorressem nestas linhas, tema interessante para esta finalidade por abordar diferentes áreas da engenharia elétrica.

Com o auxílio do MATLAB se pôde simular o sistema de distribuição de energia elétrica baseado em outro sistema similar contido em [2]. Nesta etapa foram abordados os conceitos de tratamento dos sinais advindos da aquisição de dados para que pudessem servir como entrada para as redes neurais artificiais criadas, com a conversão analógica digital (CAD) do sinal, e se evitassem problemas como o *aliasing*. Além disso, com este *software* se construiu algoritmos capazes de manipular os dados adquiridos do sistema simulado, construindo as janelas de dados de diferentes comprimentos para posterior estudo, as matrizes de entradas dos três módulos do trabalho, e a divisão em amostras de treinamento e de testes segundo os conceitos da validação cruzada. Mais uma vez com o MATLAB, se elaborou e estudou as diferentes topologias de redes neurais artificiais para serem aplicadas em cada um dos módulos. Neste caso foi utilizada a arquitetura do Perceptron Multi-Camadas (PMC). Observou-se que para um aumento da precisão dos resultados no módulo de localização uma alternativa foi a criação de três redes neurais ao invés de uma, sendo divididas de acordo com a quantidade de fases do sistema de distribuição envolvidas na falta. Também no módulo de localização foi necessário o uso da Transformada Discreta de Fourier (TDF) para que se extraíssem as componentes fundamentais das formas de onda de tensão e corrente, e assim as RNAs fossem capazes de extrair as informações dos sinais do sistema de distribuição operando em diferentes condições.

Ao longo dos capítulos 2 e 3 houve a descrição de todo aprendizado que as atividades deste trabalho proporcionaram aos envolvidos, e com o capítulo 4 se verifica que as RNAs desenvolvidas obtiveram resultados muito satisfatórios, e assim, o objetivo inicial traçado pôde ser atingido.

Como sugestões para o aperfeiçoamento deste trabalho se propõe:

1. Simulação de Sistema de Distribuição que seja ainda mais próxima do real, simplificado neste trabalho já que o intuito dele era a princípio mostrar a viabilidade das técnicas inteligentes implementadas.

2. Aumento da quantidade de amostras obtidas através da simulação, com a inclusão de mais resistências de faltas, mais ângulos de incidência e com outras possíveis localizações, este último que já ocorreria com a implantação da medida anteriormente descrita.
3. Elaboração e implementação de algoritmo que agrupasse os três módulos desenvolvidos tornando o trabalho ainda mais completo.
4. Estudo de outras arquiteturas e topologias de RNAs e inclusive outras ferramentas inteligentes, como algoritmos genéticos e sistemas *Fuzzy* para que se pudesse através de resultados concretos selecionar o que melhor se adéqua no desenvolvimento deste tema.
5. Estudo da eficácia da inclusão de um segundo ou até terceiro terminal de aquisição de dados no sistema com o objetivo de aumentar a porcentagem de acertos de cada um dos módulos criados.
6. Estudo e implementação de algoritmos voltados para a proteção de outros elementos dos sistemas de distribuição de energia elétrica, como transformadores por exemplo.

Referências Bibliográficas:

[1] COURY, D. V.; OLESKOVICZ, M.; GIOVANINI R. **Proteção Digital de Sistemas Elétricos de Potência: dos Relés Eletromecânicos aos Microprocessadores Inteligentes**. São Carlos, SP: EESC-USP, 2007.

[2] GOES, E. A.; CREPPE, R. C.; RODRIGUES, J. F.; ULSON, J. A. C.; PORTO, L. G. C. **Aplicação de Redes Neurais na Identificação de Setores em Curto-Circuito nos Sistemas de Distribuição de Energia Elétrica.** Bauru, SP, 2010.

[3] SOUZA, F. A. de **Detecção de Falhas em Sistema de Distribuição de Energia Elétrica Usando Dispositivos Programáveis.** Ilha Solteira, SP, 2008.

[4] FÉ, S. de la; MIRAGLIA, D.; JAIME, D.; CABRERA, A. **Empleo de redes neuronales artificiales en redes de distribución eléctrica.** Santiago de Cuba, Cuba, 2009.

[5] SILVA, M. **Implementação de um localizador de faltas híbrido para linhas de transmissão com três terminais baseado na transformada Wavelet.** São Carlos, SP, 2008.

[6] GÓMEZ-EXPÓSITO, A.; CONEJO, A. J.; CAÑIZARES, G. **Electric Energy Systems – Analysis and Operation.** Boca Raton, Flórida, Estados Unidos, 2009.

[7] RUTH, L. **GTD - Geração, Transmissão e Distribuição de Energia Elétrica.** Fortaleza, CE, 2012.

[8] KOUKA, N. **Electro Magnetic Field (EMF).** Disponível em: <http://brain101.info/EMF.php>. Último acesso em: 10 de Agosto de 2014.

[9] MATOS, E. dos R. **Um método de classificação de curtos-circuitos em Redes de Distribuição de Energia Elétrica Baseado na Transformada de Fourier e em Redes Neurais Artificiais.** Ilha Solteira, SP, 2009.

[10] COURY, D. V.; GIOVANINI R. **Classificação Rápida de Faltas em Sistemas Elétricos utilizando redes neurais artificiais.** São José dos Campos, SP, 1999.

[11] RÊGO, D. F.; ZEVALLOS, M. E. **Simulação de Falta Monofásica na Interligação Nordeste-Sudeste utilizando o ATPDraw: Validação da manobra monopolar.** Palmas, TO, 2012.

[12] SILVA, I. N. da; SPATTI, D. H.; FLAUZINO, R. A. **Redes neurais artificiais para engenharia e ciências aplicadas: curso prático.** São Paulo, SP: Artliber, 2010.

[13] MARTINS-FILHO, L. S.; MOL, A. A.; ROCHA, R. **Desenvolvimento de ferramenta computacional para auxílio ao projeto de gemas lapidadas.** Ouro Preto, MG, 2005.

[14] ZUBEN, F. J. V.; CASTRO, L. N. de. **Redes Neurais Artificiais.** Campinas, SP.

[15] BISHOP, C. M. **Neural Networks for Pattern Recognition.** Oxford, Inglaterra, 1995.

[16] HAQUE, M. T.; KASHTIBAN, A. M. **Application of Neural Networks in Power Systems; A Review.** Tabriz, Irã, 2007.

[17] RAYBOLT, A. C. da S. **Localização de faltas em linhas de transmissão em circuito duplo utilizando redes neurais artificiais.** Rio de Janeiro, RJ, 2011.

[18] BAM, L.; JEWELL, W. **Review: Power System Analysis Software Tools.** Wichita, Kansas, Estados Unidos, 2005.

[19] SYBILLE, G.; BRUNELLE, P.; GIROUX, P.; CASORIA, S.; GAGNON, R.; KAMWA, I.; ROUSSEL, R.; CHAMPAGNE, R.; DESSAINT, L.; LEHUY, H. **SimPowerSystems User's Guide.** 2003. Disponível em: <http://www.mathworks.com>. Último acesso em: 30 de Julho de 2014.

[20] TAYEB, E. B. M. **Faults Detection in Power Systems Using Artificial Neural Network.** Omdurman, Sudão.

[21] OLESKOVICZ, M.; COURY, D. V.; AGGARWAL, R. K. **O emprego de redes neurais artificiais na detecção, classificação e localização de faltas em linhas de transmissão.** Campinas, SP, 2000.

[22] SANDOVAL-IBARRA, F; CUESTAS-CLAROS, M.; MORENO-ESPINOSA, R. **Design of 2nd order low-pass active filters by preserving the physical meaning of design variables.** Zapopan, Jalisco, México, 2011.

[23] Electronics Tutorials. **Butterworth Filter Design.** Disponível em: < http://www.electronics-tutorials.ws/filter/filter_8.html>. Último acesso em: 28 de Julho de 2014.

[24] SILVEIRA, E. G. da **Localização de faltas em linhas de transmissão: Desenvolvimento de novos algoritmos e implementação de sistema computacional para aplicações práticas.** Belo Horizonte, MG, 2007.

[25] 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.** São José dos Campos, SP, 1999.

[26] TAKAHASHI, R. H. C. **Transformada Discreta de Fourier: Motivação e Aplicações.** Belo Horizonte, MG, 2002.

Anexos

Aqui se pode ter acesso ao resumo dos programas desenvolvidos no MATLAB ao longo do desenvolvimento deste trabalho.

MentDET.m – Algoritmo responsável por agrupar as amostras obtidas do *SimPowerSystems* em um arquivo .txt e atribuir a saída para cada uma das situações, e assim formar a entrada do módulo de detecção deste trabalho.

MentClass.m – Algoritmo responsável por agrupar as amostras obtidas do *SimPowerSystems* em um arquivo .txt e atribuir a saída para cada uma das situações, e assim formar a entrada do módulo de classificação deste trabalho.

MentLOC.m – Algoritmo responsável por agrupar as amostras obtidas do *SimPowerSystems* em um arquivo .txt e atribuir a saída para cada uma das situações levando em conta que o módulo trabalhado neste caso é o de localização.

MentLOCFOURIER.m – Algoritmo responsável por calcular a Transformada Discreta de Fourier (TDF) de todas amostras obtidas após as amostras passarem pelo algoritmo MentLoc.m.

Separador.m – Algoritmo responsável por separar as amostras obtidas do algoritmo MentLOCFOURIER.m em três conjuntos, cada um correspondente às respectivas entradas das três RNAs desenvolvidas para o módulo de localização.

Alterador_janela.m – Algoritmo responsável por alterar o comprimento da janela de dados e permitir com que fosse observada a diferença entre a velocidade de atuação e a precisão das RNAs conforme se alterava o comprimento da janela de dados.

geracao_n_det.m – Algoritmo responsável por selecionar as amostras do conjunto de testes do módulo de detecção.

geracao_n.m – Algoritmo responsável por selecionar as amostras do conjunto de testes do módulo de classificação.

geracao_n_LOC_FT.m – Algoritmo responsável por selecionar as amostras do conjunto de testes do módulo de localização em cada umas das três RNAs.

Mteste_trein_det.m – Algoritmo responsável por separar o conjunto total de amostras do módulo de detecção em amostras de testes e de treinamento de acordo com os resultados obtidos em geracao_n_det.m.

Mteste_trein.m – Algoritmo responsável por separar o conjunto total de amostras do módulo de classificação em amostras de testes e de treinamento de acordo com os resultados obtidos em geracao_n.m.

Mteste_trein_LOC_FT.m – Algoritmo responsável por separar o conjunto total de amostras do módulo de localização em amostras de testes e de treinamento de acordo com os resultados obtidos em geracao_n_LOC_FT.m para cada uma das três RNAs desenvolvidas.

DETECCAO_RN.m – Algoritmo responsável por simular a RNA do módulo de detecção.

CLASSIFICACAO_RN.m – Algoritmo responsável por simular a RNA do módulo de classificação.

LOCALIZACAO_RN_1.m – Algoritmo responsável por simular a RNA para as faltas do tipo fase-terra do módulo de localização.

LOCALIZACAO_RN_2.m – Algoritmo responsável por simular a RNA para as faltas do tipo fase-fase e fase-fase-terra do módulo de localização.

LOCALIZACAO_RN_3.m – Algoritmo responsável por simular a RNA para as faltas do tipo fase-fase-fase do módulo de localização.