

AVALIAÇÃO DO IMPACTO DOS TIPOS DE EQUIPAMENTOS DE MEDIÇÃO  
NO DESEMPENHO DA DETECÇÃO DE DEFEITOS EM SISTEMAS DE  
DISTRIBUIÇÃO UTILIZANDO REDES NEURAIIS

Tamara Oliveira Diniz

DISSERTAÇÃO SUBMETIDA AO CORPO DOCENTE DA COORDENAÇÃO DOS  
PROGRAMAS DE PÓS-GRADUAÇÃO DE ENGENHARIA DA UNIVERSIDADE  
FEDERAL DE JUIZ DE FORA COMO PARTE DOS REQUISITOS NECESSÁRIOS  
PARA A OBTENÇÃO DO GRAU DE MESTRE EM CIÊNCIAS EM ENGENHARIA  
ELÉTRICA.

Aprovada por:

---

Prof. Leandro Ramos de Araujo, D.Sc.

---

Profa. Débora Rosana Ribeiro Penido Araujo, D.Sc.

---

Prof. Vander Menengoy da Costa, D.Sc.

---

Profa. Marina Lavorato de Oliveira, D.Sc.

JUIZ DE FORA, MG – BRASIL

AGOSTO DE 2015

Ficha catalográfica elaborada através do programa de geração automática da Biblioteca Universitária da UFJF, com os dados fornecidos pelo(a) autor(a)

Diniz, Tamara Oliveira.

Avaliação do Impacto dos Tipos de Equipamentos de Medição no Desempenho da Detecção de Defeitos em Sistemas de Distribuição Utilizando Redes Neurais / Tamara Oliveira Diniz. -- 2015.  
116 p.

Orientador: Leandro Ramos de Araujo

Coorientadora: Débora Rosana Ribeiro Penido Araujo

Dissertação (mestrado acadêmico) - Universidade Federal de Juiz de Fora, Faculdade de Engenharia. Programa de Pós-Graduação em Engenharia Elétrica, 2015.

1. Sistemas Elétricos Desequilibrados. 2. Defeitos. 3. Equipamentos de Medição. 4. Redes Neurais. I. Araujo, Leandro Ramos de, orient. II. Araujo, Débora Rosana Ribeiro Penido, coorient. III. Título.

*“Portanto, ponham em primeiro lugar na sua vida o Reino de Deus e aquilo que Deus quer, e ele lhes dará todas essas coisas.” Mateus 6:33*

## **AGRADECIMENTOS**

Agradeço em primeiro lugar a Deus, por colocar pessoas em meu caminho que me ajudaram e dividiram os seus conhecimentos comigo. Eu agradeço a Ele por iluminar a minha trajetória, me dá força e sabedoria nos momentos em que me faltou. Eu agradeço a Ele as dificuldades, a alegria e o seu amor. Agradeço a Ele tudo o que tenho e tudo o que sou.

Aos meus orientadores Debora e Leandro, que acreditaram em mim quando eu mesma não acreditava. Muito obrigada por toda dedicação, empenho, conhecimento e trabalho dedicados a mim.

A minha mãe Maria das Graças, por ter me dado a vida e me ensinado a vivê-la. Por ser a minha fortaleza e por sempre dizer que queria uma filha “Mestre”. Ao meu irmão, Tadeu, por sempre manter a alegria em nossa casa.

Agradeço com muito carinho ao meu namorado, João Victor, por todo apoio e cumplicidade.

Gostaria de dividir os méritos deste trabalho com os meus amigos engenheiros eletricitas Mozart, Luciana e Salatiel. Vocês foram essenciais nessa caminhada.

A todos os meus amigos da CEMIG que me ajudaram nos meus questionamentos incontáveis.

A minha líder espiritual, Pastora Maria, por todas as orações.

Essa conquista não é minha, é NOSSA.

Resumo da Dissertação apresentada ao PPEE/UFJF como parte dos requisitos necessários para a obtenção do grau de Mestre em Ciências (M.Sc.)

Avaliação do Impacto dos Tipos de Equipamentos de Medição no Desempenho da Detecção de Defeitos em Sistemas de Distribuição Utilizando Redes Neurais

Tamara Oliveira Diniz

Agosto / 2015

Orientadores: Prof. Leandro Ramos de Araujo

Profa. Débora Rosana Ribeiro Penido Araujo

Programa: Engenharia Elétrica

Neste trabalho é desenvolvida uma metodologia para a detecção de defeitos monofásicos com impedância na média tensão de sistemas de distribuição e avalia-se o impacto da utilização de diferentes tipos de equipamentos no desempenho da detecção do defeito. A escolha da detecção de defeitos monofásicos é baseada no fato de que estas são a grande maioria nos sistemas de distribuição. A metodologia proposta consegue identificar defeitos monofásicos com resistência de arco variando entre 0 a 20 ohms, porém, a metodologia não teve como objetivo a detecção de defeitos de alta impedância. Além disto, a metodologia proposta é capaz de detectar corretamente os defeitos considerando a variação do carregamento do sistema. O índice de acerto da detecção alcançado pela metodologia proposta foi maior do que 95% em todos os casos simulados. Sendo que, neste trabalho, para realizar a detecção de defeitos em sistemas de distribuição foram utilizadas redes neurais artificiais, onde as entradas são grandezas elétricas de tensão e corrente, podendo ser medições fasoriais e/ou não-fasoriais. Esta variação serviu para analisar o desempenho na detecção do defeito do emprego de diferentes tipos de equipamentos de medição.

Abstract of Thesis presented to PPEE/UFJF as a partial fulfillment of the requirements for the degree of Master of Science (M.Sc.)

IMPACT ASSESSMENT OF TYPES OF MEASUREMENT EQUIPMENT DEFECTS  
IN THE DETECTION OF PERFORMANCE IN DISTRIBUTION SYSTEMS USING  
NEURAL NETWORKS

Tamara Oliveira Diniz

August / 2015

Advisors: Prof. Leandro Ramos de Araujo  
Prof. Débora Rosana Ribeiro Penido Araujo

Department: Electrical Engineering

In this work we developed a methodology for the detection of single-phase fault impedance in the medium voltage distribution systems and the impact is assessed using different types of equipment in the performance of the fault detection. The choice of single-phase fault detection is based on the fact that these are the vast majority in distribution systems. The proposed methodology can identify single-phase faults with arc resistance ranging from 0 to 20 ohms, however, the methodology did not aim to detect high impedance faults. Furthermore, the proposed method is able to correctly detect the flaws considering the variation in system load. The detection success rate achieved by the proposed method was greater than 95% in all simulated cases. And in this work, to perform the detection of faults in distribution systems were used artificial neural networks, where entries are electrical parameters of voltage and current can be fasorias and / or non-phasor measurements. This variation was used to analyze the performance of the fault detection using different types of measuring equipment.

## SUMÁRIO

<b>Capítulo 1</b>	<b><i>Introdução</i></b> .....	<b>1</b>
1.1	Considerações Iniciais .....	1
1.2	Motivações .....	2
1.3	Revisão Bibliográfica .....	4
1.4	Objetivos do Trabalho.....	6
1.5	Estrutura do Trabalho .....	7
1.6	Lista de Símbolos .....	8
<b>Capítulo 2</b>	<b><i>Definições e Fundamentação Teórica</i></b> .....	<b>10</b>
2.1	Considerações Iniciais .....	10
2.2	Redes Neurais.....	10
2.2.1	Redes Neurais Artificiais.....	12
2.2.2	Principais Tipos de Função de Ativação.....	13
2.2.3	Principais Tipos de Arquitetura de Redes Neurais .....	15
2.2.4	Aprendizado – Função de Treinamento.....	16
2.2.5	Avaliação de Performance .....	18
2.2.6	Rede Perceptron.....	19
2.2.7	Rede de Reconhecimento de Padrões ( <i>Pattern Recognition Network</i> ).....	20
2.2.7.1	Técnicas para o Reconhecimento de Padrões .....	20
2.2.7.2	Modelos de RNA's de Reconhecimento de Padrões.....	22
2.3	Alimentador Típico de um Sistema de Distribuição .....	26
2.4	Medidores Fasoriais e Não-Fasoriais .....	39
2.4.1	Medidores Fasoriais.....	40
2.4.2	Medidores Não-Fasoriais.....	43
<b>Capítulo 3</b>	<b><i>Metodologia Proposta para Detecção de Defeitos</i></b> .....	<b>47</b>
3.1	Introdução .....	47
3.2	Redes Neurais Considerando Medições Não-Fasoriais para Detecção de Defeitos 48	
3.3	Redes Neurais Considerando Medições Fasoriais para Detecção de Defeitos....	49
3.4	Redes Neurais Considerando Componentes de Sequência para Detecção de Defeitos.....	51
3.5	Algoritmo Proposto para a Detecção de Defeitos utilizando Redes Neurais .....	52
<b>Capítulo 4</b>	<b><i>Resultados</i></b> .....	<b>58</b>
4.1	Introdução .....	58
4.2	Testes com o Sistema IEEE 123 – Sem Carga.....	62
4.2.1	Avaliação do Desempenho do Método Aplicado ao Sistema Sem Carga.....	63
4.3	Testes com o Sistema 123 – Com Carga Fixa .....	76
4.3.1	Avaliação do Desempenho do Sistema com Carga Fixa .....	76
4.4	Testes com o Sistema 123 – Com Carga Variável.....	89
4.4.1	Avaliação do Desempenho do Sistema com Carga Variável.....	89

4.5	Constatações pelas comparações entre as estruturas analisadas.....	102
<i>Capítulo 5</i>	<i>Conclusões</i> .....	<i>103</i>
5.1	Conclusões Gerais .....	103
5.2	Trabalhos Futuros .....	104



# Capítulo 1      Introdução

## 1.1 Considerações Iniciais

No decorrer das últimas décadas, os sistemas de distribuição de energia elétrica vêm passando por grandes transformações, com a evolução tecnológica dos sistemas de comunicação permitindo o desenvolvimento de sistemas inteligentes. O conceito da utilização de redes inteligentes, em inglês “Smart Grids”, visa dar mais autonomia e segurança para o consumidor, com menos interrupções de fornecimento de energia elétrica.

Este conceito tende a transformar a maneira como as concessionárias gerenciam seus ativos de rede e se relacionam com seus clientes e com o mercado e a maneira como os últimos se relacionam com as redes de energia elétrica. Em termos práticos o *Smart Grid* permitirá a automação integrada e segura das redes, maior emprego de sistemas de medição, aumento da geração e armazenamento distribuído de energia, de modo a permitir que a rede, através de análises e diagnósticos em tempo real, se reconfigure automaticamente para atender, de forma otimizada, as necessidades da sociedade e do sistema elétrico.

O conceito inclui ainda o gerenciamento pelo lado da demanda que permitirá aos consumidores se beneficiarem de tarifas diferenciadas, que variarão de acordo com o horário que a energia é utilizada, tal como já acontece com a telefonia. Ao adequar seu comportamento de consumo de energia aos horários de tarifas menores, o cliente poderá se beneficiar reduzindo seus gastos com energia.

Tais benefícios podem ainda ser obtidos através da interação com fontes de geração e armazenamento distribuídos de energia, conectados diretamente na rede ou nas unidades consumidoras. Enfim, ganhos sinérgicos serão alcançados através de interações entre diferentes elementos do sistema elétrico tais como medição, dispositivos de rede, fontes de geração e armazenamento de energia e carga. Isto se traduzirá ao consumidor através da oferta de novas tarifas, produtos, serviços e canais de interação.

O aumento da competitividade de mercado, as exigências impostas pelas agências reguladoras e a crescente exigência na qualidade do produto recebido pelos usuários contribuem para a expansão desse processo.

Porém, para atender às necessidades de qualidade e continuidade na entrega de energia esperadas nos *Smart Grids* existem ainda diversos desafios a serem vencidos. Um deles é a melhoria nas questões associadas a detecção, localização e mitigação de defeitos nos sistemas,

uma vez que os defeitos são inerentes ao seu funcionamento, mas podem impactar negativamente nos índices do sistema causando grandes prejuízos de ordem econômica e até mesmo de segurança. Assim, torna-se de interesse estudos e desenvolvimentos nestas áreas, sendo a detecção de defeitos o foco deste trabalho.

## 1.2 Motivações

De acordo com (WARREN,1996), as concessionárias que possuem sistemas elétricos confiáveis são aquelas que possuem maior controle dos fatores de defeitos que afetam os seus sistemas. Define-se defeito como sendo a perda da habilidade de um item/equipamento realizar uma função requerida. Os defeitos em componentes provocam, dependendo da configuração destes sistemas, a interrupção do fornecimento de energia elétrica a uma parcela ou totalidade de consumidores, podendo causar as empresas detentoras destes sistemas, despesas com manutenção de reparação, compensação financeira aos consumidores, prejuízos com energia não servida e, ainda, com o pagamento de multas por violação dos índices de continuidade estabelecidos pelo órgão do setor.

No Centro de Operação da Distribuição (COD), por exemplo, os controladores possuem um programa que calcula o valor da compensação financeira que a Cemig pagará ao cliente pela falta da prestação do serviço como exemplificado na Figura 1-1:

Histórico de Multa Prevista do Serviço: 142251125			
Prazo de referência para os cálculos: 5:41			
Serviço	Valor	Evento	Data de Alteração
142251125	R\$ 0,46	SERVIÇO GERADO	18/05/2015 16:17
142251125	R\$ 0,43	ATUALIZAÇÃO APÓS VENCIMENTO DO PRAZO	18/05/2015 21:49
142251125	R\$ 0,85	ATUALIZAÇÃO APÓS VENCIMENTO DO PRAZO	18/05/2015 22:49
142251125	R\$ 1,28	ATUALIZAÇÃO APÓS VENCIMENTO DO PRAZO	18/05/2015 23:50
142251125	R\$ 1,70	ATUALIZAÇÃO APÓS VENCIMENTO DO PRAZO	19/05/2015 00:50
142251125	R\$ 2,12	ATUALIZAÇÃO APÓS VENCIMENTO DO PRAZO	19/05/2015 01:51
142251125	R\$ 2,54	ATUALIZAÇÃO APÓS VENCIMENTO DO PRAZO	19/05/2015 02:51
142251125	R\$ 2,96	ATUALIZAÇÃO APÓS VENCIMENTO DO PRAZO	19/05/2015 03:52
142251125	R\$ 3,39	ATUALIZAÇÃO APÓS VENCIMENTO DO PRAZO	19/05/2015 04:52
142251125	R\$ 3,82	ATUALIZAÇÃO APÓS VENCIMENTO DO PRAZO	19/05/2015 05:53
142251125	R\$ 4,24	ATUALIZAÇÃO APÓS VENCIMENTO DO PRAZO	19/05/2015 06:53
142251125	R\$ 4,67	ATUALIZAÇÃO APÓS VENCIMENTO DO PRAZO	19/05/2015 07:54

Figura 1-1 - Exemplo de Compensação Financeira em Cliente de Baixa Tensão

Empresas distribuidoras de energia sempre contam com programas de manutenções preventivas para manter as redes e seus equipamentos em boas condições de funcionamento por um tempo quanto maior melhor. Normalmente essas manutenções são planejadas utilizando as experiências das equipes de manutenção em campo e as orientações dos fabricantes dos equipamentos. Porém, ainda assim, as redes de distribuição de energia elétrica são susceptíveis

aos diversos defeitos devido a sua topologia, e, por isso, torna-se impossível se ter um sistema de fornecimento ininterrupto.

Um defeito no sistema de potência pode ocorrer devido ao mau funcionamento de equipamentos (que sofrem deterioração com o tempo), contato de animais com partes energizadas, ações do homem (vandalismo e acidentes de uma forma geral), queimadas, fenômenos naturais (tais como: descargas atmosféricas, fortes ventos, enchentes e etc). Conforme já citado, estes distúrbios impactam negativamente nos índices de qualidade de fornecimento de energia elétrica das concessionárias e elevam seus custos operacionais.

A demanda por serviços de qualidade (com baixos índices de interrupção) e a fiscalização do órgão regulador, a Agência Nacional de Energia Elétrica (ANEEL), em relação aos Indicadores de Continuidade e qualidade do serviço prestado, pressionam as empresas de distribuição de energia elétrica a investirem em programas de manutenção preventivas para assegurar a confiabilidade dos seus sistemas e em atuações rápidas em situações de defeitos.

A detecção e a localização rápida e precisa de um defeito é imprescindível para uma operação segura e econômica de um sistema elétrico de potência. Os Indicadores DEC e FEC avaliam a continuidade no fornecimento de energia, conforme descrito pela Resolução nº 024/2000 da ANEEL, e sua melhora nas empresas concessionárias está intimamente relacionada às melhorias nos processos de detecção, localização e mitigação dos defeitos. Indica-se que quanto maior o tempo de detecção de um defeito no sistema, os custos associados (multas, imagem da companhia, energia não faturada) são cada vez maiores. Desta forma é de grande interesse a rápida detecção destes defeitos.

Em décadas passadas, os alimentadores de distribuição de energia elétrica não possuíam um nível satisfatório de monitoramento, comunicação, controle e automação de suas operações. O estado operativo do sistema era monitorado a partir do mapeamento das reclamações realizadas pelos consumidores (por telefone, agência ou mídias sociais) e por meio de inspeção visual das oscilações de corrente e tensão feitas no COD. Isto ainda é verificado em muitos alimentadores de muitas concessionárias, porém, tem-se a tendência da maior utilização de equipamentos de medição e métodos para melhorar esta situação.

Atualmente, técnicas modernas e eficientes para identificação, localização e classificação de defeitos têm sido desenvolvidas a fim de auxiliar na tomada de decisão dos centros de operação das concessionárias de distribuição. Como benefício direto da aplicação de tais técnicas, pode-se constatar o aumento da eficiência operacional das equipes de manutenção quando da extinção de defeitos nos sistemas de distribuição, pois tais equipes serão despachadas para o local bem provável da ocorrência do defeito, reduzindo, portanto, o tempo de restabelecimento do serviço.

Devido a importância do tema, tem-se a motivação para trabalhar em aspectos relacionados aos defeitos em sistemas de distribuição, e mais especificamente neste trabalho decidiu-se trabalhar em metodologias para detecção das mesmas, e ainda avaliar a utilização de diferentes tipos de equipamentos de medição no auxílio a esta tarefa.

### **1.3 Revisão Bibliográfica**

Analisando-se a literatura, pode-se verificar que metodologias baseadas em redes neurais para detecção de defeitos em sistemas de potência são importantes ferramentas, alcançam bons resultados, e constantemente são desenvolvidas diferentes metodologias nesta área, portanto decidiu-se explorá-las neste trabalho. Porém, foram necessários maiores aprendizados de maneira geral sobre análise de defeitos.

Logo, a seguir será realizada uma revisão bibliográfica sobre metodologias recentes relacionadas à análise de defeitos e posteriormente uma revisão bibliográfica de aplicações de redes neurais para a detecção de defeitos em sistemas de distribuição.

#### **Análise de Defeitos**

Em SOUZA (2003) é apresentada uma análise de defeitos através de fluxo de potência continuado baseado no método de injeção de correntes trifásico, onde os parâmetros de continuação adotados foram as impedâncias de defeito. O método permitiu a análise de sistemas desequilibrados na presença de defeitos em derivação, séries e simultâneos, permitindo também a representação de ramais monofásicos e bifásicos. Neste método são necessárias diversas iterações para alcançar a convergência.

Em RIANI (2008) é apresentada uma continuação do método de análise de defeitos inicialmente proposto por SOUZA (2003), onde é realizada a modelagem do sistema trifásico a quatro condutores, com a representação explícita do cabo neutro e impedâncias de aterramento, sendo também utilizado um fluxo de potência continuado. Neste método também são necessárias diversas iterações para alcançar a convergência.

Em ABDEL-AKHER e NOR (2010) é desenvolvido um método para análise de defeitos para sistemas de distribuição desequilibrados. Neste método o autor chega a solução do curto-circuito da maneira tradicional, através das conexões das redes de sequência. Porém, devido a representação em componentes de sequências, diversas características de sistemas de distribuição

como os ramais bifásicos, monofásicos, além de neutros, aterramentos não são corretamente representados.

YAN *et al.* (2012) faz um estudo sobre linhas de transmissão com grande número de fases, neste caso, considerando doze fases. O autor destaca o atual interesse na tecnologia de sistemas com altos números de fases, com a vantagem de maior capacidade de transmissão de potência. Neste trabalho foram considerados apenas os modelos de geradores e linhas, não sendo abordados os aspectos relativos aos sistemas de distribuição.

LEDESMA (2012) apresenta uma metodologia para análise de defeitos em sistemas de distribuição pelo método de injeção de correntes em coordenadas de fase retangulares, onde o sistema elétrico é modelado a quatro condutores. O processo de solução se dá através de dois métodos: direto e iterativo. No método direto, as cargas do sistema são modeladas como impedância constante e assim a convergência do problema é alcançada com uma iteração. No método iterativo, as cargas são inicialmente modeladas como impedâncias constantes, e sua parametrização varia de acordo com as tensões nodais durante o processo iterativo.

Em OU (2013) é apresentado um método de análise de defeitos em coordenadas de fase considerando a contribuição de *microgrids*, definido como um conjunto de geradores distribuídos, podendo ser células solares, sistemas eólicos, dentre outros. A modelagem é realizada através de matrizes de impedâncias do sistema. O trabalho apresenta resultados interessantes, porém não é capaz de modelar todas as características dos sistemas de distribuição.

Em CARVALHO (2015) é apresentada uma metodologia de análise de defeitos em sistemas elétricos de distribuição pelo método de injeção de correntes a  $n$  condutores em coordenadas de fase retangulares, apresentando modelos bastante detalhados. Esta metodologia permite simular todas as características dos sistemas de distribuição, bem como praticamente qualquer tipo de defeito, como exemplo, defeitos internos em equipamentos ou contatos entre a média e baixa tensão. Esta metodologia será utilizada para a criação da base de dados de defeitos para os casos que serão analisados neste trabalho.

### **Identificação de Defeitos em Sistemas de Distribuição Utilizando Redes Neurais**

Em BUTLER e MOMOH (1993) é proposta uma rede neural para detectar e classificar os defeitos em sistemas de distribuição. Um recurso de pré-processamento, onde se extrai as principais características da onda referente à corrente de defeito, é apresentado. A mesma serve como dados de entrada para rede neural, na qual busca a identificação de defeitos com resistência de arco.

Em HUANG *et al.* (1997) é apresentado um método baseado em redes neurais para detecção de defeitos. O método identifica a seção em defeito e reconhece o tipo de defeito através de uma rede neural perceptron multicamadas (MLP). Neste trabalho foram inseridas camadas intermediárias de neurônios nas MLPs e com isto, foi possível tratar problemas não linearmente separável.

Em EBERL *et al.* (2000) é realizada uma comparação de rede neurais artificiais com tradicionais algoritmos de detecção de defeito usualmente implementados em relés de proteção. As redes neurais apresentaram bons resultados.

Em SALIM *et al.* (2008) é proposto um sistema híbrido para a detecção e localização defeitos em sistemas de distribuição. No método proposto a detecção do defeito é realizada através da transformada de *wavelet* e para estimar o local do defeito são utilizados sinais de tensão e corrente fasoriais como grandezas de entrada de uma rede neural.

Em MICHALIK *et al.* (2008) são propostos dois métodos baseados em redes neurais para a detecção dos defeitos de alta impedância na média tensão de redes de distribuição multiaterradas. As entradas da rede neural são constituídas de valores de tensão e correntes instantâneos obtidos de uma janela deslizante, sendo necessário com isto um pequeno número de neurônios de entrada.

Em SARLAK *et al.* (2011) é proposto um algoritmo de reconhecimento de padrões para detecção de condutores partidos em sistemas de distribuição. É utilizado o método de multiresolução gradiente morfológico (MMG) para a extração dos dados para alimentar três redes neurais perceptron com base em três meios ciclos da onda de corrente de pós-perturbação. A resposta do algoritmo é a média das saídas das redes neurais.

Em NIKOOFEKR *et al.* (2013) são utilizadas redes neurais do tipo *Adaptive Resonance Theory* (ART) que possuem propriedades úteis na área de reconhecimento de padrões. Em um ciclo de onda são extraídas informações da corrente de defeito e, então aplicada às estas redes para a detecção de defeitos nos sistemas de distribuição.

Em BRETAS *et al.* (2012) é apresentado um método de diagnóstico de defeitos híbrido para sistemas de distribuição subterrâneos desequilibrados. A formulação proposta é uma abordagem híbrida baseada em duas redes neurais artificiais e transformadas *wavelet*.

Em GARCIA *et al.* (2014) é apresentada uma metodologia para a detecção de defeitos em sistemas de distribuição com base em grandezas de um medidor de qualidade de energia (PQM), tais como componentes harmônicas e a sequência das correntes medidas em uma subestação.

## **1.4 Objetivos do Trabalho**

Estima-se que os defeitos monofásicos são em torno de 80% dos defeitos observados nos sistemas de distribuição. Deste modo, o objetivo principal desta dissertação é desenvolver um método de detecção de defeitos monofásicos que venham a ocorrer na média tensão de sistemas de distribuição. A ferramenta utilizada nesta dissertação para realizar a detecção de defeitos serão as redes neurais artificiais de reconhecimento de padrões.

O método proposto também será capaz de detectar defeitos monofásicos com resistência de arco variando entre 0 a 20 ohms, porém, a metodologia não tem como objetivo a detecção de falhas de alta impedância (resistência de falta maior que 20 ohms). Ressalta-se que à medida que ocorre o aumento da resistência de arco, torna-se mais difícil a detecção da falha. O valor de 20 ohms foi utilizado, pois muitos trabalhos consideram este valor como o limiar entre falhas de média resistência e alta resistência.

Além disto, o método proposto deverá ser capaz de detectar corretamente as falhas considerando a variação do carregamento do sistema. A variação do carregamento impacta diretamente no desempenho dos métodos de detecção, tornando a detecção mais difícil, pois a variação da corrente de carga pode ser da mesma ordem de grandeza que defeitos de média impedância. Muitos métodos que apresentam bons resultados não representam a variação do carregamento, sendo isto uma outra contribuição desta dissertação.

Também é realizada uma extensiva avaliação de topologias de redes neurais para comparar como diferentes entradas de dados e tipos de redes neurais impactam na detecção de falhas, por exemplo, será avaliado o comportamento de uma rede neural quando submetida a apenas entradas não-fasoriais, apenas entradas fasoriais e entradas em componentes de sequência, além de modificações na estrutura da rede como o número de neurônios da camada intermediária.

Espera-se que o método proposto nesta dissertação contribua para melhorar as análises dos sistemas, mais especificamente a análise de defeitos, buscando um melhor aproveitamento dos dados disponíveis nos sistemas elétricos de distribuição.

## **1.5 Estrutura do Trabalho**

Além deste capítulo introdutório, outros quatro capítulos compõem o trabalho.

No capítulo 2 são apresentadas as definições e fundamentação teórica do trabalho.

No capítulo 3 são apresentadas metodologias baseadas em redes neurais para a detecção de defeitos de baixa e média impedância na média tensão em sistemas de distribuição considerando a variação do carregamento.

No capítulo 4 são apresentados os resultados e as análises realizadas com a metodologia desenvolvida, a partir de testes e simulações em sistemas elétricos.

No capítulo 5 são apresentadas as conclusões gerais do trabalho e os trabalhos futuros.

## **1.6 Lista de Símbolos**

ANEEL: Agência Nacional de Energia Elétrica

ART: Adaptive Resonance Theory

COD: Centro de operação da distribuição

CS: Componentes simétricas

DEC: Duração equivalente de interrupção por unidade consumidora

DNP3: Distributed Network Protocol

FEC: Frequência equivalente de interrupção por unidade consumidora

GPS: Global positioning system

IA: Inteligência artificial

IBGE: Instituto Brasileiro de Geografia e Estatística

IED: Intelligent electronic device

JFAD: Juiz de Fora 2

JFAQ: Juiz de Fora 4

JFAU: Juiz de Fora 1

GEMINI: Sistema de geoprocessamento da Cemig

MED: Medidor

MLP: Multi-layer perceptron



MMG: Multiresolução gradiente morfológico

ONS: Operador nacional do sistema

PMDC: Phasor measurements data concentrator

PMU: Phasor measurement unit

PPS: Pulse per second

PQM: Power quality meter

PRODIST: Procedimentos de Distribuição de Energia Elétrica no Sistema Elétrico Nacional

RMS: Root mean square

RN: Redes neurais

RNA: Redes neurais artificiais

RT: Regulador de tensão

SCADA: Supervisory control and data acquisition

SEP: Sistema elétrico de potência

SIN: Sistema interligado nacional

SMF: Sistema de medição fasorial

TC: Transformador de corrente

TP: Transformador de potencial

UHJS: Usina de Joasal

UHMS: Usina de Marmelos

## **Capítulo 2 Definições e Fundamentação Teórica**

### **2.1 Considerações Iniciais**

Ao longo deste capítulo serão apresentados os principais conceitos e a fundamentação teórica sobre alguns tópicos que foram base de estudos para o desenvolvimento desta dissertação.

Serão abordados conceitos básicos de redes neurais visando a formação de uma base mínima de conhecimento para compreensão dos conceitos utilizados na detecção de defeitos. Algumas características típicas dos sistemas de distribuição de energia elétrica do estado de Minas Gerais, considerando subestações e alimentadores, e definições (por exemplo, de características e parâmetros dos equipamentos) adotadas na metodologia proposta neste trabalho também serão apresentadas. Para exemplificar serão utilizados nas explicações os alimentadores da cidade de Juiz de Fora. E além disso, serão mostrados os tipos diferentes de medidores fasoriais e não fasoriais implantados no sistema elétrico.


### **2.2 Redes Neurais**

Nesta seção os conceitos principais de redes neurais, baseados principalmente no descrito em (SILVA, 2005), serão apresentados junto aos seguintes tópicos:

- Principais tipos de função de ativação;
- Principais tipos de arquitetura de uma rede neural;
- Função de treinamento;
- Rede perceptron;
- Rede de reconhecimento de padrões.

A rede neural artificial é uma técnica de Inteligência Artificial (IA) que tenta simular em computadores o funcionamento do cérebro humano, de uma maneira simplificada. Os sistemas computacionais imitam as funcionalidades do sistema nervoso, através do uso de elementos processadores interconectados, chamados neurônios artificiais (HAYKIN, 2001).

As redes neurais são baseadas na biologia: neurônios e conexões entre eles. O neurônio pode ser dividido em três partes: dendritos, soma (ou corpo celular) e axônio.



**Figura 2-1 - Esquema de um Neurônio Biológico (SILVA, 2005)**

Na Figura 2-1 é apresentado o esquema de um neurônio biológico. Como se pode observar, a partir do corpo celular, se projetam filamentos que são os dendritos e o axônio. O funcionamento de um neurônio biológico pode ser resumido basicamente da seguinte maneira: os dendritos recebem sinais de entrada vindos de outra célula, o corpo celular processa estes sinais, a informação é transmitida ao longo do axônio para outros neurônios por meio das sinapses, que são as ligações entre os dendritos de neurônios diferentes.

Modelos de redes neurais artificiais foram motivados pelo desejo de se entender e simular o funcionamento do cérebro humano, e têm sido desenvolvidos através de generalização via modelos matemáticos inspirados na cognição humana ou na biologia neural (FAUSETT, 1994), com base nas seguintes hipóteses genéricas:

- O processamento de informações ocorre em elementos simples chamados neurônios;
- São transmitidos sinais entre os neurônios através de conexões (sinapses) existentes entre eles;
- Cada conexão tem associada a si uma ponderação, a qual, em uma rede neural típica, processa o sinal transmitido; o conjunto destas ponderações pode ser visto como o conhecimento armazenado na rede, contido em uma memória distribuída;
- Neurônios que desempenham função semelhante durante o processamento da informação recebida são dispostos em uma mesma camada; assim, camadas sucessivas são criadas na rede neural com o intuito de se realizar em cada uma delas uma fase distinta do processamento (redes multicamadas);

- A cada neurônio se aplica uma função de ativação (geralmente não linear) que computa seu sinal de saída a partir dos dados recebidos.

## 2.2.1 Redes Neurais Artificiais

Com base nos conhecimentos sobre o neurônio biológico, dois pesquisadores Warren McCulloch e Walter Pitts criaram o primeiro modelo de um neurônio artificial (CHURCHLAND e SEJNOWSKI,1992). O modelo inspirado nas células nervosas é ilustrado na Figura 2-2:




Figura 2-2 - Modelo de um Neurônio Artificial (SILVA, 2005)

O modelo é descrito pelos elementos básicos:

- Sinais de entrada descrito pelos elementos -  $\{x_1, x_2, \dots, x_n\}$ ;
- Pesos Sinápticos -  $\{w_1, w_2, \dots, w_n\}$ : são responsáveis pelo armazenamento das informações. Definem o efeito que a saída de um neurônio exerce sobre a entrada do neurônio seguinte;
- Função de soma -  $\{\Sigma\}$  : soma todos os sinais de entrada já ponderados pelos pesos sinápticos;
- Função de Ativação  $\{g(\cdot)\}$  : tem como função restringir a amplitude de saída de um neurônio para algum valor finito;
- Existe também um Bias ( $\theta$ ) ligado externamente a rede, que serve para diminuir ou aumentar a entrada líquida da função de ativação, dependendo do seu sinal.

Descrevendo o modelo neural em termos matemáticos pelas equações (2.1) e (2.2):

$$u = \sum_{i=1}^n w_i x_i \quad (2.1)$$

$$y = g(u) \quad (2.2)$$

A variável  $u$  recebe o nome de campo local induzido.

A função de ativação calcula a saída do neurônio artificial com relação à variável  $u$ , limitando a amplitude do intervalo do sinal de saída do neurônio para algum valor finito, geralmente no intervalo  $[0,1]$  ou  $[-1,1]$ .

## 2.2.2 Principais Tipos de Função de Ativação

Dentre as principais funções de ativação utilizadas, os tipos básicos são:

- a) Função Degrau: sua resposta pode assumir dois valores: 0 ou 1 conforme descrito pela equação (2.3), e a sua curva é exemplificada pela Figura 2-3.

$$g(u) = \begin{cases} 0 & \text{se } u < 0 \\ 1 & \text{se } u \geq 0 \end{cases} \quad (2.3)$$




Figura 2-3 - Função Degrau (SILVA, 2005)

- b) Função Linear: sua resposta será um valor constante descrita pela equação (2.4), e exemplificada pela Figura 2-4.

$$g(u) = u \quad (2.4)$$




Figura 2-4 - Função Linear (SILVA, 2005)

- c) Função Sigmóide: esta função assume valores em um intervalo contínuo entre 0 e 1, descrita pela equação (2.5), e exemplificada pela Figura 2-5.

$$g(u) = \frac{1}{1 + e^{-\beta u}} \quad (2.5)$$

$e = 2,718281$  (Número de Euler)  
 $\beta =$  constante de inclinação




Figura 2-5 - Função Sigmóide (SILVA, 2005)

- d) Função Tangente Hiperbólica: descrita pela equação (2.6), e exemplificada pela Figura 2-6.

$$g(u) = \frac{1 - e^{-\beta u}}{1 + e^{-\beta u}} \quad (2.6)$$




Figura 2-6 - Função Tangente Hiperbólica (SILVA, 2005)

## 2.2.3 Principais Tipos de Arquitetura de Redes Neurais

O tipo de conexão, o número de camadas de neurônios e o tipo de treinamento são os aspectos que diferem os tipos de redes neurais. Cada um é mais adequado para um tipo de tarefa determinado. A Figura 2-7 e a Figura 2-8 mostram algumas topologias possíveis.

### a) Redes *feedforward* com camada única

É a forma mais simples de redes neurais. Nesse tipo tem-se uma camada de entrada que se projeta para a camada de saída. Estruturas como essa são capazes de resolver problemas multivariáveis, mas com algumas restrições por serem de uma única camada. Essa rede é exemplificada na Figura 2-7:




Figura 2-7 - Rede alimentada com uma camada (SILVA, 2005)

### b) Redes alimentadas com Múltiplas Camadas

Essa arquitetura representa um segundo tipo de rede neural alimentada adiante, conforme Figura 2-8. Se distingue da arquitetura apresentada anteriormente pela presença de uma camada de neurônios ocultos. A camada intermediária confere a RNA uma maior capacidade computacional na aproximação de funções contínuas.

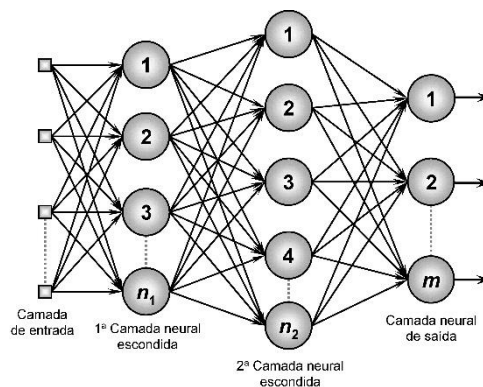


Figura 2-8 - Rede Alimentada Adiante de duas camadas (SILVA, 2005)

### c) Redes Recorrentes

Este tipo de rede, conforme Figura 2-9, se diferencia das redes alimentadas adiante por ter pelo menos um laço de realimentação, ou seja, um neurônio pode receber entradas de qualquer outra camada da rede. Essa estrutura de RNA é utilizada na resolução de problemas que envolvam processamento temporal, como por exemplo, em previsão de eventos futuros.




Figura 2-9 - Rede com recorrência entre saídas e camada intermediária

## 2.2.4 Aprendizado – Função de Treinamento

A propriedade mais importante de uma rede neural é a sua habilidade de aprender por meio de exemplos. Através de um processo iterativo, a RNA sofre ajustes aplicados a seus pesos sinápticos, ou seja, ela consegue se modificar em função de aprender a informação que lhe foi apresentada (a essa etapa dá-se o nome de treinamento). O aprendizado ocorre quando a rede neural atinge uma representação generalizada de um determinado problema.

Assim como o cérebro humano, as redes neurais aprendem a partir de experiências e não através de programação.

Uma definição de aprendizagem é dada por Mendel e McLaren (CHURCHLAND e SEJNOWSKI, 1992):


*“Aprendizagem é o processo pelo qual os parâmetros de uma rede neural são ajustados através de uma forma continuada de estímulos pelo ambiente no qual a rede está operando, sendo o tipo específico de aprendizagem realizada definido pela maneira particular como ocorrem os ajustes nos parâmetros.”*

Os diversos métodos criados para aprendizagem de redes neurais são chamados de paradigmas. Os paradigmas são classificados como:



- **Aprendizado Supervisionado (ou aprendizagem com professor):**


Nesse paradigma existe um elemento, o professor, que conhece o sistema que a rede deve descrever e é responsável por estimular as entradas da rede. A rede sofre um estímulo e sua resposta é analisada pelo professor que conhece o resultado certo. Se o resultado extraído da rede não for igual a uma resposta ótima conhecida pelo professor, os pesos sinápticos da rede são ajustados de maneira que a saída da rede se aproxime do resultado previamente conhecido, conforme Figura 2-10.



**Figura 2-10 - Aprendizado Supervisionado**

- **Aprendizado Não Supervisionado (ou aprendizagem sem professor):**

Nesse tipo de rede não existe um professor indicando a resposta desejada para os padrões de entrada. Neste esquema de treinamento somente se tem os padrões de entrada, diferente do que ocorre no aprendizado supervisionado, cujo conjunto de treinamento possui pares de entrada e saída. A rede deve aprender a classificar os dados de entrada através dos estímulos que estes provocam. Seus parâmetros são alterados de forma a se obter as propriedades do espaço de entrada, conforme Figura 2-11.



**Figura 2-11 - Aprendizado não Supervisionado**

## 2.2.5 Avaliação de Performance

Existem quatro tipos possíveis de resultados de uma rede neural conforme exemplificado na Figura 2-12. Estes são descritos a seguir:

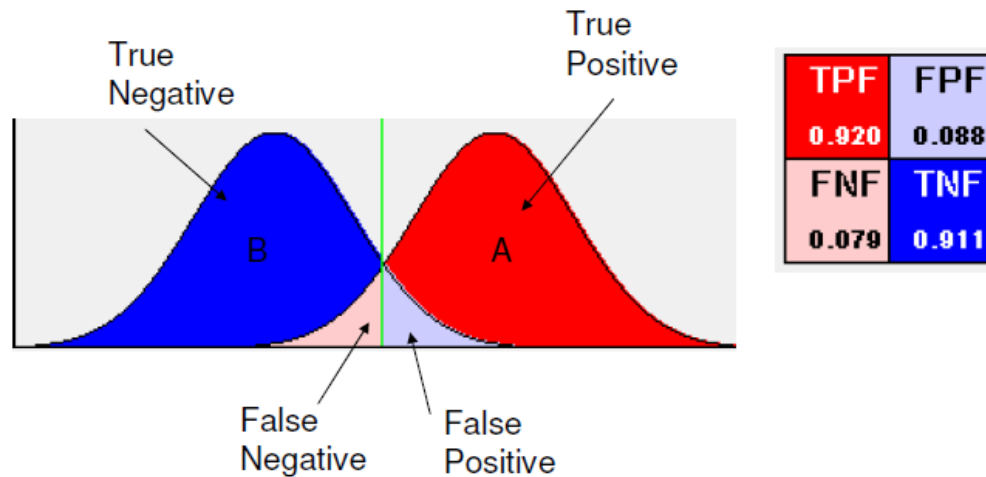


Figura 2-12 – Possíveis resultados de uma rede neural (GOMES, 2012)

*True Negative:* É o verdadeiro negativo, no caso de detecção de defeito. Significa a rede informar que não existe defeito e realmente não existir defeito na rede. Neste caso é considerado um acerto da rede.

*True Positive:* É o verdadeiro positivo, no caso de detecção de defeito. Significa a rede informar que existe defeito e realmente existir defeito na rede. Neste caso é considerado um acerto da rede.

*False Negative:* É o falso negativo, no caso de detecção de defeito. Significa a rede informar que não existe defeito e existir defeito na rede. Neste caso é considerado um erro da rede.

*False Positive:* É o falso positivo, no caso de detecção de defeito. Significa a rede informar que existe defeito e não existir defeito na rede. Neste caso é considerado um erro da rede.

Neste trabalho, a eficiência de determinada rede será definida conforme a equação (2.7):

$$Ef(\%) = \frac{TN + TP}{NS} 100\% \quad (2.7)$$

Onde:

*NS* – É o número de casos que foram avaliados pela rede neural;

*TN* – É a quantidade de verdadeiros negativos nos casos avaliados;

*TP* – É a quantidade de verdadeiros positivos nos casos avaliados.

Neste trabalho, para verificar a performance de cada rede foi realizada uma validação cruzada do tipo *k-fold* (representada na Figura 2-13), onde o conjunto de dados é dividido em *k* partições (subconjuntos disjuntos) de mesma dimensão. Para cada partição de teste *i*, a rede neural foi treinada com as *k-1* partições restantes, e depois testada incluindo a partição *i*. O teste foi repetido para  $i = 1, \dots, k$  e o índice de performance da rede foi calculado conforme a equação (2.8). Nos testes do trabalho utilizou-se  $k = 5$  para todas as simulações.

$$Perf(\%) = \sum_{i=1, \dots, 5} \frac{Ef(\%)_i}{5} \quad (2.8)$$

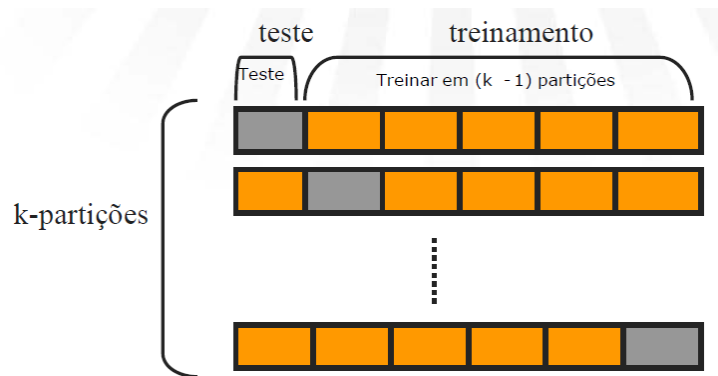


Figura 2-13 – Validação cruzada – *k-fold* (GOMES, 2012)

## 2.2.6 Rede Perceptron

O primeiro modelo de neurônio artificial é a rede Perceptron (Figura 2-14) proposta por ROSENBLATT (1958). O perceptron é a forma mais simples de uma rede neural e só pode ser usado para classificar padrões linearmente separáveis. Essa é a condição para que o algoritmo de aprendizagem consiga convergir com um número finito de iterações.

A rede é composta por um único neurônio e seus pesos sinápticos e bias são ajustáveis. Usualmente, devido às várias limitações dos perceptron, sua aplicação em sistemas de potência é bastante limitada. Por critérios didáticos e para facilitar o entendimento do processo de separação de um simples neurônio, um exemplo do funcionamento do perceptron será apresentado. Este exemplo foi apresentado em (SILVA, 2005).

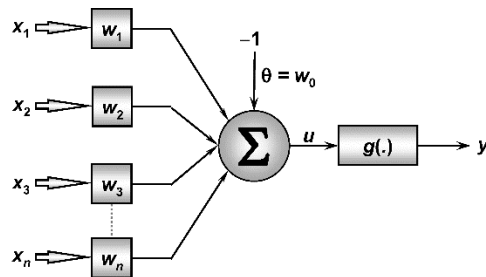


Figura 2-14 - Rede Perceptron

## 2.2.7 Rede de Reconhecimento de Padrões (*Pattern Recognition Network*)

Nos dias de hoje, as RNAs têm sido muito utilizadas na tarefa de reconhecer padrões em um conjunto de dados, que em termos gerais, é a ciência que compreende a identificação e classificação da informação em categorias. O objetivo desse processo é apresentar à rede um conjunto de dados conhecidos de maneira que, através da técnica de aprendizagem, ela determine subconjuntos de dados com características semelhantes (ou seja, padrões), e seja capaz de reconhecer tais características em um novo elemento, que a ela seja apresentado, de acordo com um dos padrões previamente fixados.

Em termos gerais, a RNA pode ser utilizada para monitorar o processo, tomar decisões sobre a operação do sistema e ajustar controles apropriados para manter o processo operando com uma eficiência ótima. Isto pode ser aplicado para problemas de sistemas elétricos de potência. Além disso, tem a vantagem de poder ser atualizada com novas informações através de uma aprendizagem dinâmica. Assim, esta rede pode apresentar especial interesse à área de detecção de defeitos.

Devido a sua boa capacidade de aplicação, este tipo de rede foi o escolhido para ser utilizado no desenvolvimento deste trabalho.

### 2.2.7.1 Técnicas para o Reconhecimento de Padrões

O termo de reconhecimento de padrões é um processo de categorizar amostras de dados observados ou medidos como sendo membros de uma dentre um conjunto de classes ou categorias. Na prática computacional, pode-se enumerar algumas áreas:

- Análise, segmentação e pré-processamento de imagens;
- Reconhecimento de faces;
- Identificação de impressões digitais;

- Reconhecimento de caracteres;
- Diagnóstico médico.

Existem muitas práticas de reconhecimento de padrões que se baseiam em técnicas matemáticas, estatísticas e/ou técnicas de Inteligência Artificial (sendo esse o foco da dissertação).

Independentemente da técnica ou estrutura de rede neural usada no reconhecimento de padrão divide-se o problema em três estágios ou espaços: o espaço do padrão, o espaço das características e o espaço da classificação (Figura 2-15). O mundo físico é representado por um contínuo de parâmetros que é essencialmente de dimensionalidade infinita. Porém, representa-se o problema do mundo real por  $R$  características. Esta é a dimensionalidade do espaço dos padrões. Por exemplo, no caso da análise de defeitos, existem infinitas possibilidades, sendo uma variação dos locais de defeitos (todo o comprimento dos alimentadores), variação do carregamento, ocorrência ou não de defeito, tipos de defeitos e valores da resistência de defeitos ( $0-\infty$  ohms). As  $R$  características serão valores determinados da resistência de defeito e pontos discretos para aplicação de defeitos (postes).

Como  $R$  é, geralmente, muito grande, é desejável reduzi-lo (redução de dimensionalidade) de forma que os dados resultantes ainda mantenham o poder discriminatório dos padrões que estão inerentes aos dados. O espaço das características é postulado de dimensão  $N$  ( $N < R$ ) no qual as regras de classificação podem ser executadas em tempo razoável. Na análise de defeito, o número de simulação é determinado, no caso, não superior a 5000, sendo o carregamento, a ocorrência de defeito, os postes com defeito e valores de defeitos escolhidos de forma aleatória para tentar representar  $R$ .

O espaço de classificação, então, simplesmente é o espaço de decisão no qual  $K$  classes podem ser selecionadas e, portanto, de dimensão  $K$ . No caso desta dissertação,  $K$  será apenas a ocorrência ou não de defeito.


Conceitualmente, o problema de reconhecimento de padrões pode, então, ser descrito como uma transferência do espaço de padrões  $P$  (dimensão  $R$ ), para o espaço de características  $F$  (dimensão  $N$ ) e finalmente para o espaço de classificação  $C$  (dimensão  $K$ ) conforme a equação (2.9):

$$P \rightarrow F \rightarrow C \quad (2.9)$$

Estas transformações são altamente não lineares e não inversíveis, mas o único objetivo é manter o poder discriminatório dos padrões. A Figura 2-15 ilustra um caminho razoável para um sistema de classificação de padrões.

Neste processo encontram-se duas transformações:

- 1º) Redução de dimensionalidade;
- 2º) Classificação dos dados em K classes.



**Figura 2-15 - O problema de reconhecimento de padrões (SOUZA, 1999)**

O problema em reconhecimento de padrões está na sua definição ou composição, já que definir um conjunto de características que o representa pode não ser uma tarefa trivial. A chave é escolher e extrair um conjunto finito de características que o represente totalmente e que possa ser passível de manuseio (SOUZA, 1999).

### **2.2.7.2 Modelos de RNA's de Reconhecimento de Padrões**

Algumas aplicações de reconhecimento podem requerer que seja encontrada uma ocorrência exata de um padrão, enquanto outras são satisfeitas por encontrar uma ocorrência aproximada. Existe na literatura a denominação de abordagens sintáticas ou estruturais e de abordagens estatísticas ou numéricas.

O reconhecimento contextual, conceitual e baseado em regras é uma tentativa de adicionar contexto, conceito e conhecimento especializado no processamento, de maneira que aproveite a perícia humana nas tarefas de reconhecimento (TODESCO, 1995).

O conhecimento normalmente consiste de dois tipos de informação:

- O estado conhecido do ambiente, representado por fatos (informação a priori);
- Observações (medições) sobre o ambiente obtidas em termos de sensores.

Existe um conjunto de regras intuitivas que explicam de forma geral a representação do conhecimento em uma rede neural, como pode ser verificado conforme Figura 2-16.

Regra 1	Regra 2	Regra 3	Regra 4
<ul style="list-style-type: none"> <li>• Entradas similares de classes similares devem normalmente produzir representações similares dentro da rede neural, e devem portanto ser classificadas como sendo da mesma classe.</li> </ul>	<ul style="list-style-type: none"> <li>• Objetos que serão classificados em classes diferentes devem receber representações amplamente diferentes dentro da rede neural.</li> </ul>	<ul style="list-style-type: none"> <li>• Se uma característica em particular é importante, então deve existir um grande número de neurônios envolvidos na representação daquela característica na rede neural.</li> </ul>	<ul style="list-style-type: none"> <li>• A informação a priori e invariâncias devem ser incorporadas ao projeto de uma rede neural, portanto simplificando o problema de aprendizagem.</li> </ul>

**Figura 2-16 – Regras gerais para aplicação de reconhecimento de padrões em RN**

São vários os modelos de redes neurais que possibilitam o reconhecimento de padrões, entre estes destacam-se: perceptron de camada simples e perceptron de múltiplas camadas.

**a) Perceptron de camadas simples**

O perceptron de camada simples é a arquitetura mais simples de rede neural capaz de classificar padrões linearmente separáveis. Este modelo consiste em uma única camada de neurônios com pesos sinápticos e bias ajustáveis. Este algoritmo de treinamento é capaz de encontrar um conjunto de pesos que classifica corretamente os dados (convergência garantida) se os padrões de entrada forem linearmente separáveis.

A função de ativação é do tipo degrau e inclui bias e pesos associados.

Um exemplo da funcionalidade da rede perceptron e de suas limitações pode ser feito usando as portas lógicas considerando que a função de ativação seja a função linear.

Ao analisar a porta lógica OU (or), pode se perceber que possui um espaço de decisão linearmente separável como mostra o exemplo apresentado na Tabela 2-1.

Tabela 2-1 - Exemplo de uma rede perceptron linearmente separável (BORGES, 2013)

Sinal (x <sub>1</sub> )	Sinal 1 (x <sub>2</sub> )	Sinal 2 Saída (x <sub>1</sub> OR x <sub>2</sub> )
0	0	0 (Vermelho)
0	1	1 (Verde)
1	0	1 (Verde)
1	1	1 (Verde)




Figura 2-17 - Solução para a porta lógica OU (BORGES, 2013)

Como pode-se verificar através da Figura 2-17 é possível traçar uma (ou mais) reta(s), que divide o espaço de decisão em duas regiões. De um lado, com os pontos em verde, tem-se a saída 1 (na metodologia proposta quando a saída da RN for 1, há detecção de defeito) e do outro lado, com o ponto vermelho, tem-se a saída 0 (na metodologia proposta quando a RN for zero, significa dizer que não houve defeito). Essa mesma reta pode ser modificada para definir uma porta lógica E (and).

### b) Perceptron multi-camadas (MLP)

Quando são utilizadas Redes Neurais Artificiais de uma só camada os padrões de treinamento apresentados à entrada são mapeados diretamente em um conjunto de padrões de saída da rede, sendo assim não é possível a formação de uma representação interna. Neste caso, a codificação proveniente do mundo exterior deve ser suficiente para implementar esse mapeamento.


Esta restrição implica que padrões de entrada similares resultem em padrões de saída similares, o que leva a este tipo de sistema a incapacidade de aprender importantes mapeamentos. Como resultado, padrões de entrada com estruturas similares (fornecidos do mundo externo) que levem a saídas diferentes não são possíveis de serem mapeados por redes sem camadas intermediárias. Um bom exemplo deste é a função ou-exclusivo (XOR).



Analisado a porta OU-EXCLUSIVO (x-or) através da Tabela 2-2, nota-se que não há maneiras de dividir o espaço de decisão em duas partes. Neste exemplo a rede perceptron é não linearmente separável, conforme mostra a Figura 2-18.

**Tabela 2-2 - Exemplo de uma rede perceptron não linearmente separável (BORGES, 2013)**

Sinal (x <sub>1</sub> )	Sinal (x <sub>2</sub> )	Saída (x <sub>1</sub> XOR x <sub>2</sub> )
0	0	0 (Vermelho)
0	1	1 (Verde)
1	0	1 (Verde)
1	1	0 (Vermelho)



**Figura 2-18 - Solução para a porta X-OR (BORGES, 2013)**

Através de análise matemática do modelo do Perceptron realizada por Minsky e Papert, chegou-se à conclusão que redes de uma camada não são capazes de solucionar problemas que não sejam linearmente separáveis.

Pode-se dizer que o desenvolvimento do algoritmo de treinamento *backpropagation*, por Rumelhart, Hinton e Williams em 1986, mostrou que é possível treinar eficientemente redes com camadas intermediárias, resultando no modelo de RNAs mais utilizado atualmente, as redes Perceptron Multi-Camadas (MLP), treinadas com o algoritmo *backpropagation*.

Nesse modelo de redes cada camada tem uma função específica. A camada de saída recebe os estímulos da camada intermediária e constrói o padrão que será a resposta. As camadas intermediárias funcionam como extratoras de características (classificação), seus pesos são uma codificação de características apresentadas nos padrões de entrada e permitem que a rede crie sua própria representação (reconhecimento), mais rica e complexa, do problema.

É interessante comentar que existem algumas limitações em modelos de redes que utilizam o *backpropagation*, pois pode-se chegar a resultados em que os modelos não apresentam justificativas do comportamento da rede para as respostas. Também questiona-se que o tempo de treinamento das redes que utilizam o *backpropagation* tende a ser lento. (VON ZUBEN, 2003)

## 2.3 Alimentador Típico de um Sistema de Distribuição

A partir desta seção pretende-se, por meio da descrição das informações reais do sistema da região de Juiz de Fora, embasar questões associadas aos alimentadores de distribuição, que são o foco deste trabalho.

O sistema de distribuição de energia elétrica em Juiz de Fora é operado por três principais subestações: Juiz de Fora 1 (JFAU), Juiz de Fora 2 (JFAD) e Juiz de Fora 4 (JFAQ). Essas três subestações atendem a aproximadamente 250.800 instalações ligadas para uma população de 550.710 habitantes (valor estimado pelo IBGE da população residente com data de referência 1º de julho de 2014 publicada no Diário Oficial da União em 28/08/2014) e possuem uma carga total instalada de 580MVA. A Figura 2-19 mostra os dados gerais das três subestações:

Subestação	JFAU
Nome da Subestação	JUIZ DE FORA 1
Telecomando	Não
Demanda Fase A (MVA)	015,534
Demanda Fase B (MVA)	015,242
Demanda Fase C (MVA)	014,911
Demanda Total (MVA)	045,688
Carga Distribuída (MVA)	106,690
Carga Primária (MVA)	055,352
Carga Rural (MVA)	041,179
Carga Total (MVA)	203,221
Consumidores Distribuídos	66421
Consumidores Primários	135
Consumidores Rurais	3864
Total de Consumidores	70420

Subestação	JFAD
Nome da Subestação	JUIZ DE FORA 2
Telecomando	Sim
Demanda Fase A (MVA)	025,174
Demanda Fase B (MVA)	025,009
Demanda Fase C (MVA)	025,085
Demanda Total (MVA)	075,270
Carga Distribuída (MVA)	177,414
Carga Primária (MVA)	038,524
Carga Rural (MVA)	003,251
Carga Total (MVA)	219,189
Consumidores Distribuídos	108823
Consumidores Primários	112
Consumidores Rurais	445
Total de Consumidores	109380

Subestação	JFAQ
Nome da Subestação	JUIZ DE FORA 4
Telecomando	Sim
Demanda Fase A (MVA)	020,525
Demanda Fase B (MVA)	020,475
Demanda Fase C (MVA)	022,062
Demanda Total (MVA)	063,063
Carga Distribuída (MVA)	113,183
Carga Primária (MVA)	036,442
Carga Rural (MVA)	006,338
Carga Total (MVA)	155,963
Consumidores Distribuídos	71025
Consumidores Primários	88
Consumidores Rurais	408
Total de Consumidores	71521

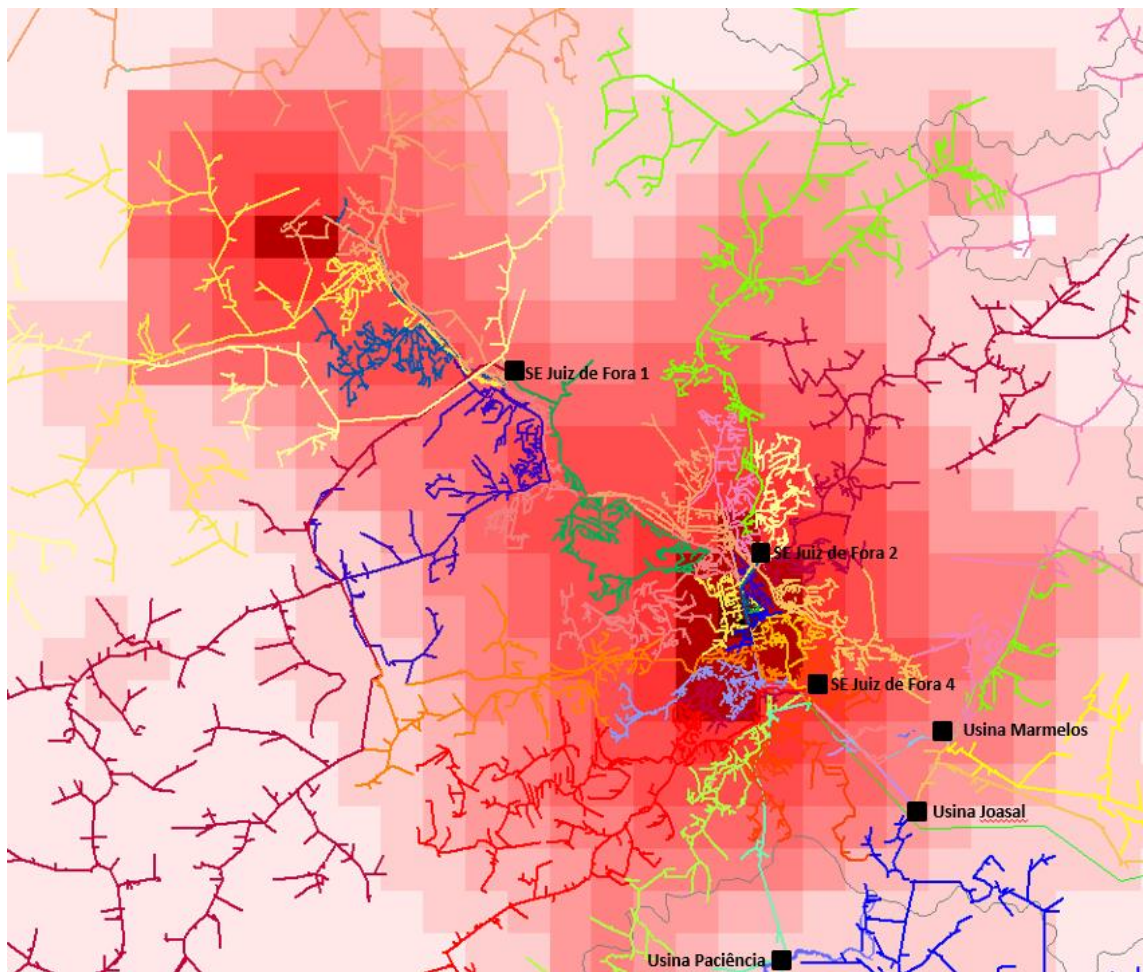
**Figura 2-19 – Dados técnicos das Subestações de Juiz de Fora (Gemini - Cemig)**

A CEMIG desenvolveu o projeto Gemini. Este sistema de geoprocessamento possui um banco de dados que engloba toda a rede de distribuição de energia elétrica da região geográfica de sua concessão. As telas apresentadas neste item fazem parte desse banco de dados e possibilita estudar o sistema de distribuição. (CEMIG programa Gemini)

A subestação JFAU possui classe de tensão 345kV:138kV:22kV, já as subestações JFAD e JFAQ possuem classe de tensão 138kV:22kV.

A Figura 2-20 mostra a cidade de Juiz de Fora representada pelos seus alimentadores e por todas as subestações. Cada ramo colorido representa um alimentador, os quadrados pretos são as subestações e onde a “mancha” está mais vermelho escuro significa maior densidade de carga.

Observa-se na Figura 2-20 (retirada do programa de fluxo de potência utilizado na Cemig - CYME) que os alimentadores possuem tamanhos distintos e que alimentadores em locais com maior densidade de carga geralmente são curtos e alimentadores em locais de pouca densidade de carga são longos. Por causa disto, usualmente o desempenho de métodos de identificação de defeitos, com medições apenas nas subestações, apresentam eficiência distinta entre alimentadores, pois é mais simples a detecção de defeitos em alimentadores curtos (menor impedância elétrica entre a subestação e o local de defeito).



**Figura 2-20 - Mapa dos alimentadores da cidade de Juiz de Fora (Programa CYME utilizado na Cemig)**

Para análise de defeitos um fator importante é a análise do comprimento dos alimentadores. Existe uma tendência de que na proteção convencional aconteça como exemplificado na Figura 2-21:



**Figura 2-21 - Análise de defeitos em alimentadores de diferentes comprimentos**

Em um alimentador longo se o defeito ocorrer perto da subestação a tendência é que a proteção detecte defeitos de baixas e médias resistências. E se o defeito ocorrer longe da subestação é mais difícil a detecção de defeito de baixas e médias resistências.

Analisando o alimentador curto, para o defeito que ocorre perto da subestação, a proteção detecta mais facilmente quando são defeitos de baixas e médias resistências. Se o defeito ocorrer longe da subestação, em um alimentador curto, um defeito de baixa resistência será mais fácil de detectar e o defeito de média resistência mais difícil. Defeito de alta impedância é sempre muito difícil de identificar e não é escopo desta dissertação.

Outra característica das cargas no sistema de distribuição é o tipo de conexão: estão conectadas através de transformadores e o tipo de conexão é delta no lado primário (22kV) e estrela aterrada no lado secundário (127V – fase-neutro, 220V – fase-fase).

A subestação JFAQ possui dois transformadores, na Barra 1 e na Barra 2 e cada um possui uma potência nominal de 33,2MVA. A JFAQ atende 71.270 consumidores e uma carga total de 154,33 MVA. A Figura 2-22 mostra informações detalhadas e também a posição do alimentador 408 que será analisado em mais detalhes a seguir.

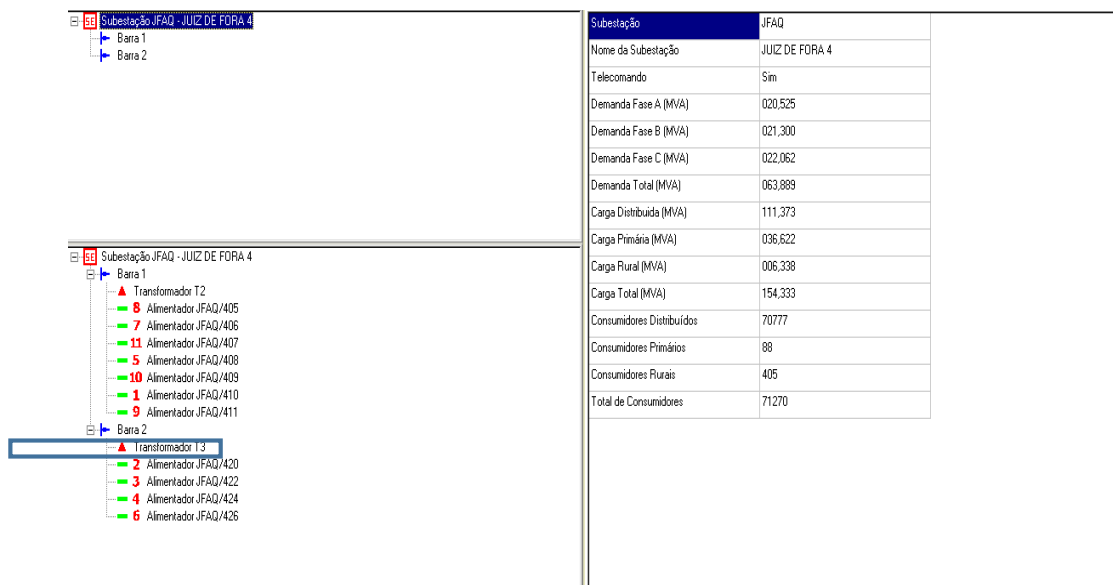


Figura 2-22 - Características da subestação JFAQ (Gemini - Cemig)

O alimentador 408 pertence a Barra 1 e possui aproximadamente um total de 7.000 clientes. A Figura 2-23 mostra dados técnicos do alimentador (curto-circuito e fator de potência) e medições de corrente nas fases A, B e C.

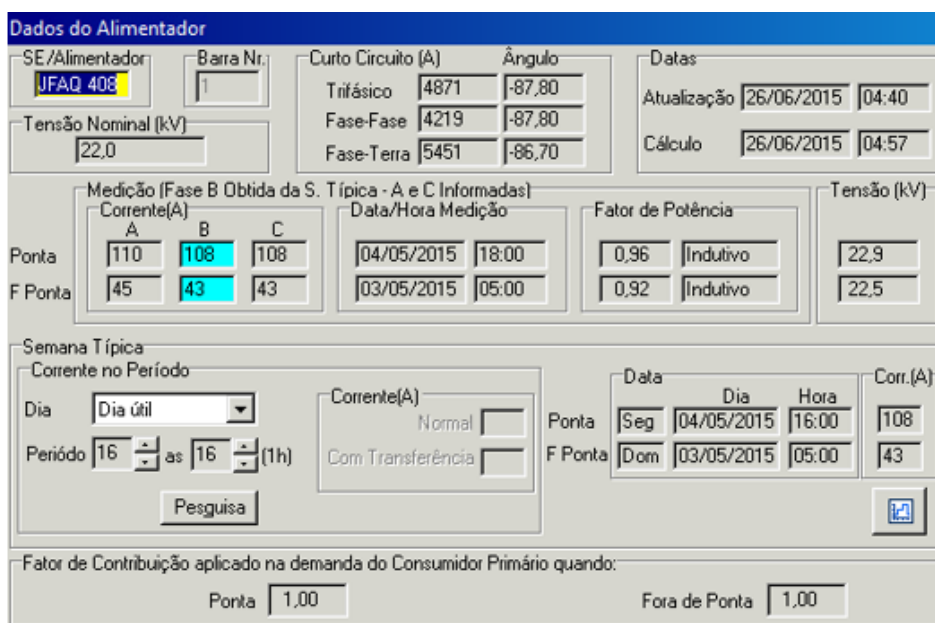


Figura 2-23 - Dados técnicos do alimentador JFAQ408 (Gemini - Cemig)



A Figura 2-24 mostra os dados gerais do alimentador, tais como, extensão na rede urbana e na rede rural, quantidade de equipamentos e carga instalada.

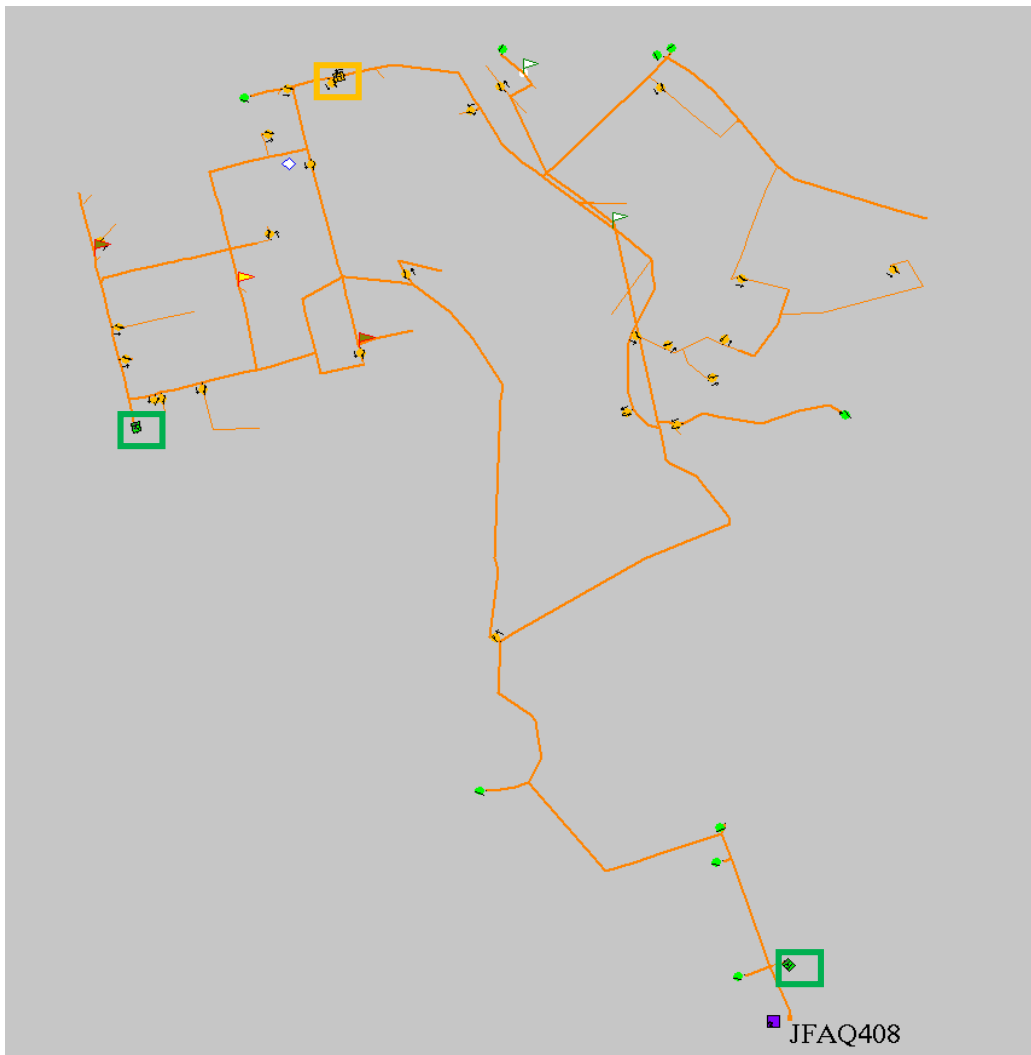
Dados do Alimentador - JFAQ408			
<b>Dados Gerais</b>			
Comprimento Total	17,24	Km	
Comprimento do Tronco	7,43	Km	
Comprimento dos Ramais	9,80	Km	
Número de Trafos	153		
Demanda Total	4141	kVA	
Perdas Totais	0,6	%	
<b>Extensão por Tipo de Rede (Km)</b>			
<b>Rede Urbana</b>		<b>Rede Rural</b>	
Convencional	11,65	Convencional	0,0
Protegida	5,31	Protegida	0,0
Isolada	0,08	Isolada	0,0
Subterrânea	0,12	Subterrânea	0,0
<b>Número de Equipamentos</b>			
Reguladores	0	Capacitores	2
Religadores	2	Seccion.	0
CH Fusível	35	CH Tripolares	0
CH Unipolares	39	CH Trip. - CR	0
Auto-Trafo	0	Pt Trafo 34,5kV	0
<b>Carga Instalada (kVA)</b>			
Distribuída	15775	Rural	0
Concentrada	2211	Total	17986
<b>Número de Clientes</b>			
Secundários	6990	Rurais	0
Primários	9	Total	6999
Equipamentos com capacidade de interrupção ultrapassada			
			57867

**Figura 2-24 - Dados gerais do alimentador JFAQ408 (Gemini - Cemig)**

Os pontos de medição na média tensão são representados pelos religadores. No alimentador 408 existem três religadores que são destacados na Figura 2-25. Os indicadores em verde significam religadores do tipo normalmente aberto (NA) e os indicadores em amarelo significam religadores do tipo normalmente fechado (NF), conforme indicado na Tabela 2-3.

**Tabela 2-3 - Exemplo de simbologia usada no Gemini (Gemini – Cemig)**

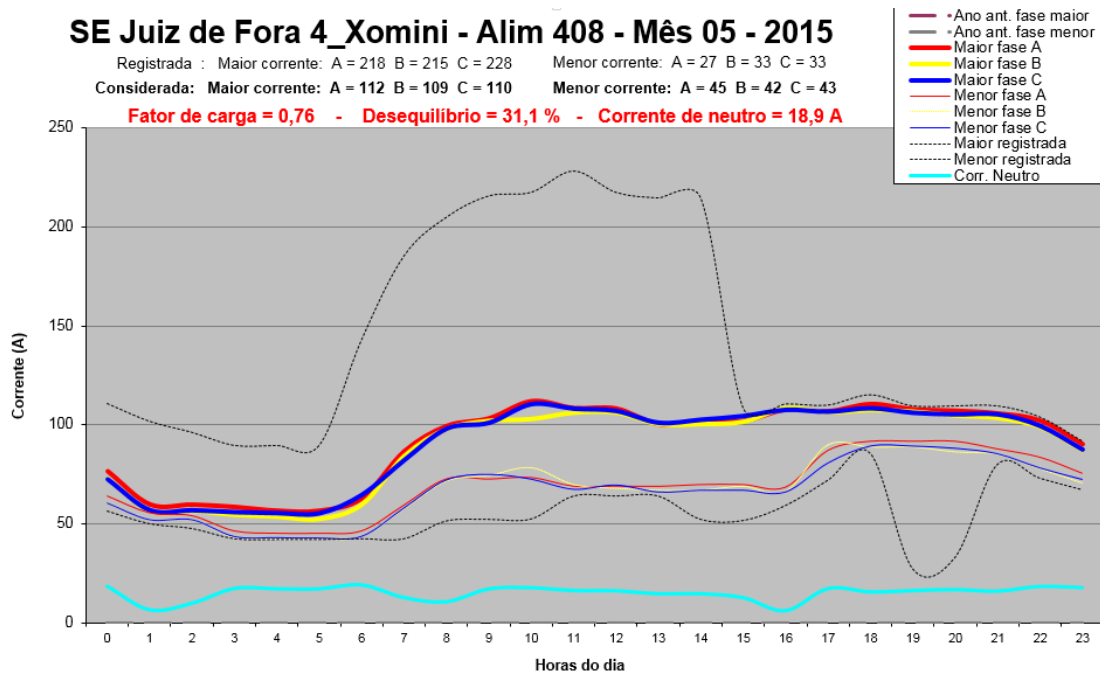
Simbologia do Equipamento	Tipo de Religador
	NA
	NF



**Figura 2-25 - Representação dos religadores no alimentador JFAQ408 (Gemini – Cemig)**

A área de planejamento operacional trabalha atualizando as curvas típicas de corrente, diária e mensal, na média tensão. A semana típica retrata a curva de carga do alimentador, sendo atualizada pelo operador ao fazer a análise dos dados gerais do alimentador, conforme apresentada na Figura 2-26.





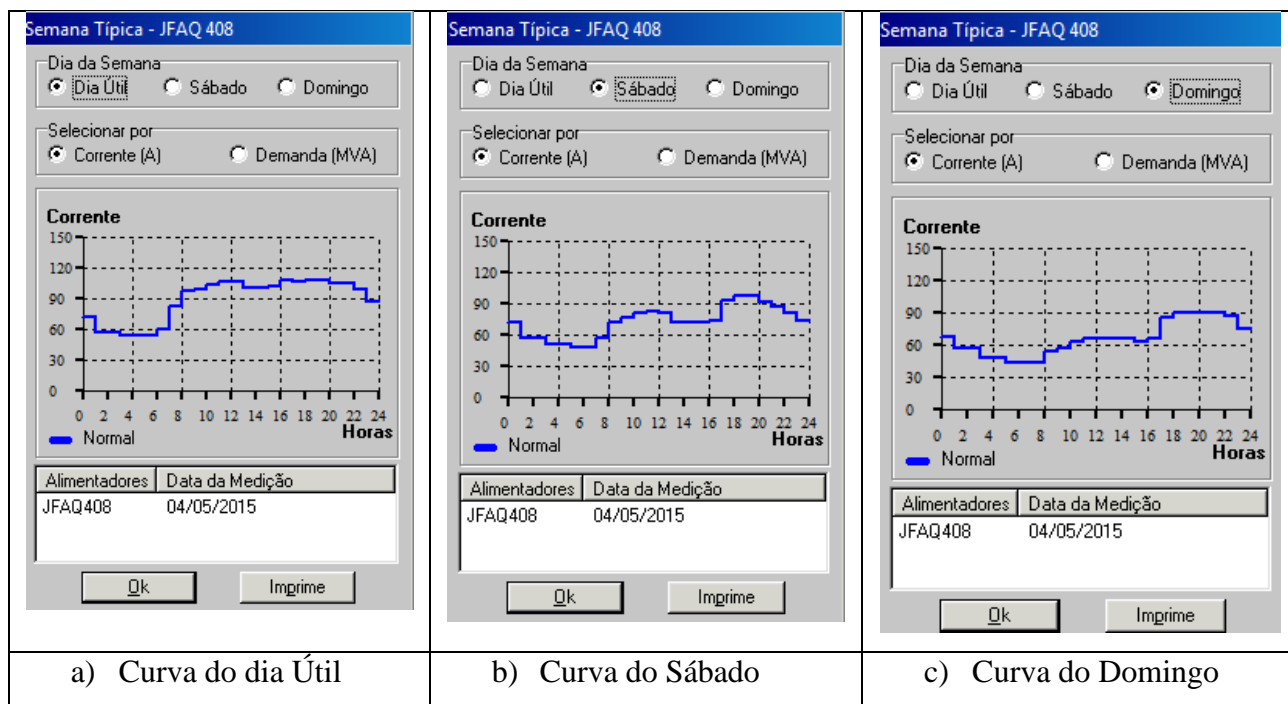
**Figura 2-26 – Gráfico do alimentador 408 (SICMAT – Cemig)**

Nessa curva tem-se os dados das correntes nas fases A, B, C e neutro do mês de maio em função das horas do dia, com os expurgos de valores máximos e mínimos.

Existem três tipos de representação das cargas da semana típica:

- curva do dia útil;
- curva de sábado;
- curva de domingo.


A Figura 2-27 mostra a representação gráfica de um dia em patamares de hora em hora.



**Figura 2-27 – Semana Típica do Alimentador JFAQ 408 (Gemini – Cemig)**

As Figura 2-28 e Figura 2-31 ilustram dois exemplos de alimentadores mais elaborados: UHMS10 e UHJS10, onde há uma quantidade maior de religadores, sendo esse ponto outra diferença entre alimentadores curtos e longos. O alimentador UHMS10 pertence a Usina Marmelos, possui 8 religadores e passa pelas cidades de Juiz de Fora, Matias Barbosa, Santana do Deserto, Chiador e Mar de Espanha. Já o alimentador UHJS10 é da Usina de Joasal, possui 12 religadores e passa pelas seguintes cidades: Juiz de Fora, Pequeri, Guarara, Maripá de Minas e Senador Cortes.

Nas Figura 2-28 e Figura 2-31 todos os religadores dos alimentadores UHMS10 e UHJS10 estão destacados. As Figura 2-29 e Figura 2-32 mostram os dados técnicos e as Figura 2-30 e Figura 2-33 mostram os dados gerais dos alimentadores.



**Figura 2-28 - Representação dos religadores no Alimentador UHMS10 (Gemini - Cemig)**

**Dados do Alimentador**

SE/Alimentador: **UHJS 10** Barra Nr.: **1**

Tensão Nominal (kV): **22,0**

Curto Circuito (A) Ângulo

Trifásico	3493	-79,30
Fase-Fase	3025	-79,30
Fase-Terra	4076	-81,00

Datas

Atualização: **07/08/2015** **10:00**

Cálculo: **07/08/2015** **10:00**

Medição (Fase B Obtida da S. Típica - A e C Informadas)

Corrente(A)	A	B	C	Data/Hora Medição	Fator de Potência	Tensão (kV)
Ponta	59	57	76	02/05/2015 18:00	0,97 Indutivo	22,8
F Ponta	28	24	35	03/05/2015 07:00	0,92 Indutivo	22,5

Semana Típica

Corrente no Período

Dia: **Dia útil**

Período: **10** as **10** (1h)

Corrente(A)

Normal

Com Transferência

Data Dia Hora Corr.(A)

Ponta	Sab	06/06/2015	18:00	57
F Ponta	Dom	07/06/2015	07:00	24

Fator de Contribuição aplicado na demanda do Consumidor Primário quando:

Ponta: **0,18** Fora de Ponta: **0,70**

Figura 2-29 - Dados técnicos do alimentador UHJS10 (Gemini - Cemig)

**Dados do Alimentador - UHJS 10**

Dados Gerais

Comprimento Total	433,61	Km
Comprimento do Tronco	6,41	Km
Comprimento dos Ramais	427,19	Km
Número de Traços	747	
Demanda Total	2439	kVA
Perdas Totais	7,8	%

Extensão por Tipo de Rede (Km)

Rede Urbana	Rede Rural		
Convencional	29,83	Convencional	393,20
Protegida	8,86	Protegida	1,63
Isolada	0,01	Isolada	0,06
Subterrânea	0,0	Subterrânea	0,0

Número de Equipamentos

Reguladores	2	Capacitores	0
Religadores	8	Seccion.	2
CH Fusível	196	CH Tripolares	0
CH Unipolares	84	CH Trip. - CR	0
Auto-Trafo	0	Pt Trafo 34,5kV	0

Carga Instalada (kVA)


Distribuída	6204	Rural	8099
Concentrada	1250	Total	15553

Número de Clientes

Secundários	3256	Rurais	672
Primários	5	Total	3933

Equipamentos com capacidade de interrupção ultrapassada: **25969**

Figura 2-30 - Dados gerais do alimentador UHJS10 (Gemini - Cemig)



**Figura 2-31 - Representação dos religadores no alimentador UHMS10 (Gemini – Cemig)**

**Dados do Alimentador**

SE/Alimentador <b>UHMS 10</b>	Barra Nr. 2	Curto Circuito (A) Trifásico 3932 Fase-Fase 3405 Fase-Terra 4283	Ângulo -80,40 -80,40 -81,20	Datas Atualização 07/08/2015 10:18 Cálculo 07/08/2015 10:18
Tensão Nominal (kV) 22,0	Medição (Fase B Obtida da S. Típica - A e C Informadas) Corrente(A) A B C Ponta 93 97 100 F Ponta 36 35 39		Data/Hora Medição 04/05/2015 18:00 03/05/2015 04:00	Fator de Potência 0,53 Capacitivo 0,15 Capacitivo
Tensão (kV) 22,7 22,3		Semana Típica Corrente no Período Dia Dia útil Período 10 as 10 (1h) Pesquisa		
Fator de Contribuição aplicado na demanda do Consumidor Primário quando: Ponta 0,10 Fora de Ponta 0,10		Data Dia Hora Corr.(A) Ponta Seg 08/06/2015 18:00 97 F Ponta Dom 07/06/2015 04:00 35		

Figura 2-32 - Dados técnicos do alimentador UHMS10 (Gemini – Cemig)

**Dados do Alimentador - UHMS 10**

Dados Gerais		Extensão por Tipo de Rede (Km)	
Comprimento Total	605,73 Km	Rede Urbana	Rede Rural
Comprimento do Tronco	29,76 Km	Convencional	37,44
Comprimento dos Ramais	575,96 Km	Protegida	5,96
Número de Trafos	1128	Isolada	0,42
Demanda Total	3683 kVA	Subterrânea	0,00
Perdas Totais	21,2 %		
Número de Equipamentos		Carga Instalada (kVA)	
Reguladores	2	Capacitores	3
Religadores	12	Seccion.	2
CH Fusível	287	CH Tripolares	0
CH Unipolares	101	CH Trip. - CR	0
Auto-Trafo	0	Pt Trafo 34,5kV	0
		Número de Clientes	
		Secundários	5068
		Rurais	1073
		Primários	8
		Total	6149
Equipamentos com capacidade de interrupção ultrapassada			

Figura 2-33 - Dados gerais do alimentador UHMS10 (Gemini – Cemig)

## 2.4 Medidores Fasoriais e Não-Fasoriais

A modernização do sistema elétrico, decorrente do aumento de carga, dentre diversos outros fatores, tem estimulado estudos para a introdução de novas tecnologias para atender as novas demandas de gerenciamento, controle e monitoramento do sistema elétrico.

Os números de unidades geradoras têm aumentado, a topologia dos sistemas elétricos tem se modificado, tornando-se mais interligada e extensa, abrangendo grandes áreas geográficas. Além disto, observa-se a contínua incorporação de novas tecnologias de equipamentos, que adicionam novos mecanismos à dinâmica do sistema, ainda não plenamente modelados.

Diante deste cenário, que impõe severas restrições operativas aos Operadores do Sistema, percebe-se a necessidade de um constante aprimoramento dos métodos e instrumentos dedicados à monitoração e ao controle da operação dos sistemas elétricos, em tempo real (EHRENSPERGER, 2004).

Os medidores implantados no sistema elétrico podem ser fasoriais e não-fasoriais. A maioria das concessionárias de energia usa as medições não-fasoriais, da seguinte forma na média tensão: nas saídas de alimentadores são instalados conjuntos de medição (Figura 2-34). Nos transformadores de distribuição, os medidores só são instalados a pedido de cliente, devido a reclamação de variação de tensão (PRODIST 8, 2010) e medições amostrais da ANEEL. Outra forma de medir na média tensão são os religadores instalados em pontos estratégicos da rede elétrica. Esses medidores medem tensão, corrente, potência, fator de potência, entre outros.



**Figura 2-34 – Conjunto de medição instalado na rede (Equipamento homologado na Cemig)**

### 2.4.1 Medidores Fasoriais

A medição fasorial é conceituada como a estimação dos parâmetros de fase, amplitude e frequência do componente fundamental.

As tecnologias de monitoramento do sistema elétrico de potência vêm ganhando espaço em virtude do aumento da dificuldade de controle, do aumento da complexidade destes e do aumento de exigência por confiabilidade. Nesta direção surgiram as unidades de medição fasorial sincronizada chamada PMU (*phasor measurement unit*), que permitem ao operador saber o estado do sistema elétrico em tempo real e com sincronismo. Consequentemente, a PMU pode ser utilizada para permitir medidas corretivas antes que um colapso aconteça.

Atualmente, as PMUs se mostram bem eficientes no registro de perturbações, monitoração de segurança, controle de emergência e implementações de caráter experimental. Sua função é coletar e registrar medições de tensão e de corrente instantâneas, a fim de se calcularem os fasores (módulo e ângulo) sincronizados no tempo, empregando a tecnologia do GPS (*global positioning system*). Vários países possuem estudos de implementações, tais como: Estados Unidos, Dinamarca, Japão, China, Islândia, França, entre outros.


No Brasil temos o Sistema Interligado Nacional (SIN) que é formado pelos sub-sistemas Sul, Sudeste, Centro-Oeste, Norte e Nordeste, interligados por extensa rede de transmissão de energia. Em sistemas destas proporções, distúrbios originados por desequilíbrios entre blocos de geração e de carga podem ocasionar variações expressivas na frequência do sistema, situações de colapso de tensão e até o desligamento de partes da rede e a perda de importantes centros consumidores, o que representa enormes prejuízos financeiros (FILHO, 2005).

O ONS, com o objetivo de implantar o uso de medição fasorial na operação do SIN, iniciou em 2009 um projeto para instalar um sistema para registro do desempenho dinâmico do SIN durante perturbações. Este projeto, descrito no Plano de Ação do ONS como projeto 6.2 – “Implantação do Sistema de Oscilografia de Longa Duração”, teve como objetivo implantar um Sistema de Medição Fasorial (SMF) e o desenvolvimento de aplicativos *off-line*.

A Figura 2-35 mostra o conceito de Sistemas de Medição Fasorial Sincronizada, os SMFS. O SMFS é um sistema de medição de fasores de grandezas elétricas, coletadas em instalações geográficas distintas. O sinal denominado PPS (*pulse per second*) das unidades de Medição Fasorial, denominadas PMDC (*Phasor Measurements Data Concentrator*), é obtido a partir da sincronização do GPS. Este sinal é a referência temporal, a partir da qual as fases dos fasores remotos podem ser estimadas.



A Figura 2-35 apresenta a configuração do SMFS. Os dados são conectados no SEP pelas PMU, de forma sincronizada e enviadas a um Concentrador de Dados Fasoriais, estando, assim, disponibilizadas para serem usadas de acordo com a necessidade do usuário (BORBA, 2006).



**Figura 2-35 – Representação de um sistema de medição fasorial sincronizado via GPS (BORBA, 2006)**

A Figura 2-36 mostra de forma exemplificada a instalação de duas PMUs sincronizadas em rede elétrica de duas barras. A medição dos fasores é feita simultaneamente. Observa-se também que existe diferença angular entre as barras, tanto nos gráficos da forma de onda, quanto no diagrama fasorial.

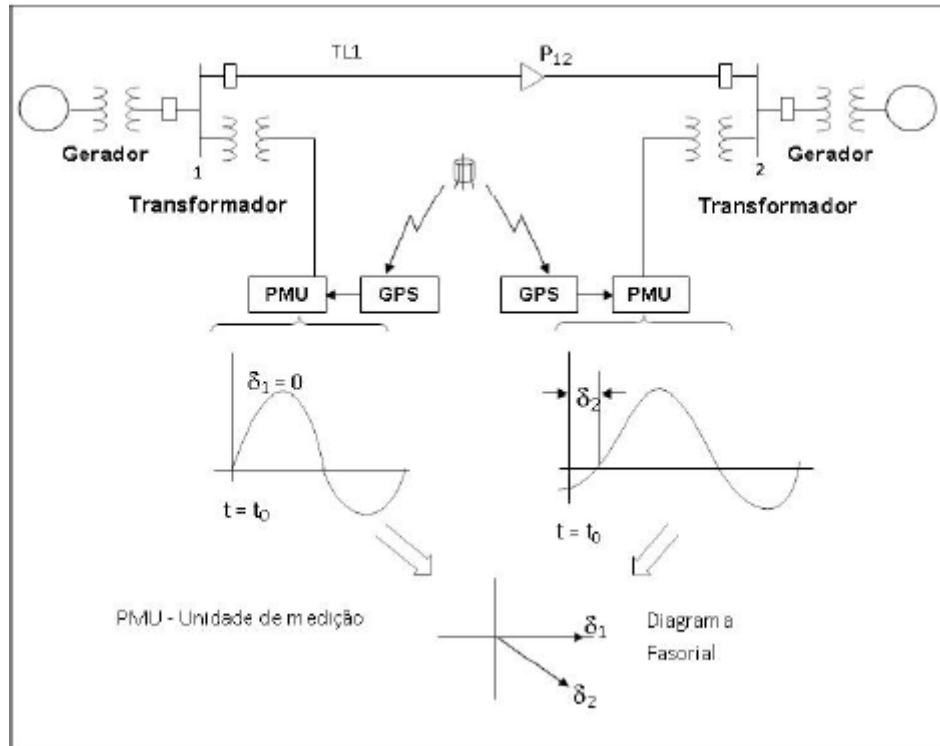


Figura 2-36 – Exemplo de como o ângulo é medido (ANDRADE, 2008)

A Figura 2-37 mostra a instalação em uma subestação de uma PMU.




Figura 2-37 – Instalação na subestação (Mynam, 2011)

## 2.4.2 Medidores Não-Fasoriais

Os equipamentos auxiliares mais importantes para a medição são os transformadores para instrumentos, que constituem parte essencial da maioria dos sistemas elétricos de medição, pois possibilitam que tensões ou correntes primárias, normalmente elevadas, sejam transformadas em valores secundários, apropriados para uso de medidores ou de instrumentos de medidas elétricas, além de permitir o isolamento entre o circuito primário (alta tensão) e o circuito secundário (baixa tensão) ou de medição. Existem dois tipos:


### a) Transformadores de Corrente - TC

O transformador de corrente, mostrado na Figura 2-38, é um equipamento destinado a produzir, proporcionalmente no circuito secundário, a corrente no circuito primário com a posição fasorial mantida, conhecida e adequada para uso em equipamentos de medição, controle e proteção.

Os TC's têm basicamente três finalidades em um Sistema Elétrico de Potência:

1. Isolar os equipamentos de medição, controle e proteção do circuito de alta tensão;
2. Fornecer no secundário uma corrente proporcional à do primário;
3. Fornecer no secundário correntes de dimensões adequadas para serem usadas nos equipamentos de medição e proteção.

A utilização do TC é necessária porque é impraticável a utilização de instrumentos e circuitos eletrônicos em altas correntes, sendo necessário reduzi-las a valores menores, passíveis de utilização normal. O TC é amplamente utilizado em sistemas elétricos (baixa, média e alta tensão), pois informa as condições reais de corrente em regime normal, picos e faltas de energia, proporcionando um maior controle sobre o sistema. Também possui outra grande vantagem, que é a isolamento entre o medidor e o circuito a ser medido.



**Figura 2-38 – Transformador de corrente (Equipamento homologado na Cemig)**


b) Transformadores de Potencial - TP

Os transformadores de tensão, também conhecidos como transformadores de potencial (TP), mostrados na Figura 2-39, são equipamentos que permitem aos instrumentos de medição e proteção funcionarem adequadamente sem que seja necessário possuir tensão de isolamento de acordo com a da rede a qual estão ligados.

Na sua forma mais simples, os transformadores de potencial possuem um enrolamento primário com muitas espiras e um enrolamento secundário com poucas espiras. A tensão secundária é normalmente padronizada em 115 V ou  $115/\sqrt{3}$  V.

Dessa forma os instrumentos de proteção e medição são dimensionados em tamanhos reduzidos com bobinas e demais componentes de baixa isolamento.

Os transformadores de potencial são equipamentos utilizados para suprir aparelhos que apresentam elevada impedância, tais como voltímetros, reles de tensão, bobinas de tensão de medidores de energia, etc.



**Figura 2-39 – Transformador de potencial (Equipamento homologado na Cemig)**

A seguir serão mostradas fotos de religadores (Figura 2-40) e chaves telecomandadas (Figura 2-41), que exemplificam equipamentos com medições não-fasoriais na área de concessão da Cemig.

Reguladores de tensão (RT) de alimentadores são bastante utilizados para ajustar a tensão em alimentadores. Seu principal objetivo é manter a tensão entre limites especificados por mudanças de tapes sob carga.

Muitas concessionárias indicam que o caminho mais econômico para a regulação de tensão é a utilização de reguladores e capacitores em derivação.



**Figura 2-40 – Modelos de religadores instalados no sistema de energia elétrica (Equipamento homologado na Cemig)**



**Figura 2-41 – Chave telecomandada (Equipamento homologado na Cemig)**

## **Capítulo 3      Metodologia Proposta para Detecção de Defeitos**

### **3.1 Introdução**

Apresenta-se neste capítulo a metodologia proposta para detecção de defeitos monofásicos de baixa e média impedância que utilizam a tecnologia de redes neurais artificiais do tipo de reconhecimento de padrões.

Grande parte das interrupções não programadas no fornecimento de energia elétrica pelo sistema de distribuição provém da ocorrência de defeitos ao longo da extensão dos alimentadores. Desta forma, técnicas modernas e eficientes para detecção e localização de defeitos têm sido desenvolvidas para auxiliar na tomada da decisão dos Centros de Operação do sistema de distribuição, conforme indicado na revisão bibliográfica apresentada no capítulo 1, mas ainda não foi apresentado um método infalível na detecção de defeitos. Os grandes desafios na área de detecção de defeito em sistemas de distribuição são: a variedade dos tipos de defeito, variação da impedância de contato, variação diária do carregamento, alta impedância dos alimentadores e reduzidos pontos de medição.

Mesmo conhecendo-se todas as necessidades citadas, tem-se consciência da dificuldade de solucioná-las, e, portanto foi necessário, em termos de desenvolvimento, restringir-se a uma das necessidades. Logo, deixa-se claro que o desenvolvimento deste trabalho tem como objetivo principal a detecção de defeitos de baixa e média impedância considerando a variação da carga, podendo também detectar defeitos de alta impedância, mas este não é o foco principal desta dissertação. Também se destaca que defeitos de baixa impedância muitas vezes são facilmente detectados pela proteção da subestação.

A metodologia proposta neste capítulo considera a detecção de defeitos usando a tecnologia de Redes Neurais Artificiais aplicadas às medições não-fasoriais e medições fasoriais. Atualmente a maioria dos equipamentos na distribuição fornecem apenas medições não-fasoriais, mas há uma tendência de que existam, cada vez mais, equipamentos que permitam a obtenção de medições fasoriais nos sistemas. Logo, estas duas possibilidades foram exploradas no desenvolvimento da metodologia.

Os estudos com RNAs buscam diminuir o erro de previsão. Almeja-se uma precisão, para garantir que os resultados da previsão sejam os mais próximos da realidade encontrada pelas concessionárias.

Assim, será analisado como a quantidade de medições e os tipos das mesmas impactam em uma rotina de detecção de defeitos utilizando as redes neurais. E ainda, será realizada uma variação na apresentação dos dados de entrada da rede, buscando avaliar se esta variação impacta nos resultados da detecção.

Neste trabalho foram escolhidas as redes neurais do tipo *Pattern Recognition Network*. A função de treinamento utilizada foi *Levenberg-Marquardt Backpropagation*, e não foram avaliadas outras funções de treinamento.

### **3.2 Redes Neurais Considerando Medições Não-Fasoriais para Detecção de Defeitos**

Uma arquitetura para detecção de defeitos é apresentada na Figura 3-1. Nesta arquitetura, conforme citado no item 2.4.1, os dados de correntes são amostrados por medidores alocados nos alimentadores dos sistemas de distribuição. Estes medidores podem ser religadores (Figura 2-40), chaves telecomandadas (Figura 2-41) ou qualquer outro equipamento que possa realizar medições e transmitir os dados para um centro de comando, como os TC's e TP's (Figura 2-38 e Figura 2-39).

Praticamente toda a amostragem de dados em sistema de distribuição é realizada utilizando protocolos do tipo DNP3. Este protocolo apesar de ter um relógio interno, não é suficientemente preciso para fazer a amostragem de valores fasoriais. Deste modo, muitas vezes são disponibilizados no centro de comando apenas valores RMS. Assim, é importante o desenvolvimento de arquiteturas de detecção que considerem somente a utilização de dados não-fasoriais.

Sendo assim, para casos de medições não-fasoriais, foi proposta uma rede neural na qual as entradas são apenas os valores de módulo das correntes amostradas no sistema de distribuição, conforme apresentado na Figura 3-1.

Ressalta-se que a rede neural proposta na Figura 3-1 possui como saída apenas um neurônio. Caso seja detectado algum defeito, este neurônio assume o valor 1.

Nesta rede neural, o número de entradas é igual a três vezes o número de medidores de corrente (TC's). Considerando as tensões das fases A, B e C, o número de entradas é igual a três vezes o número de medidores de tensão (TP's).

Considera-se que a rede possui apenas uma camada interna de neurônios.



No capítulo de resultados serão realizados diversos testes para verificar o comportamento da rede neural quando houver as seguintes variações: diferentes números de neurônios da camada interna, diferente número de entradas dos medidores de corrente.

Testes, em algumas aplicações, indicam que o aumento de entradas semelhantes prejudica o desempenho de redes neurais. Sendo este um ponto importante, deve-se informar para redes neurais um conjunto de dados relevantes para o objeto em estudo e com pouca redundância de informações. Isto foi uma consideração para se realizar os testes com diferentes números de entradas de medidores.

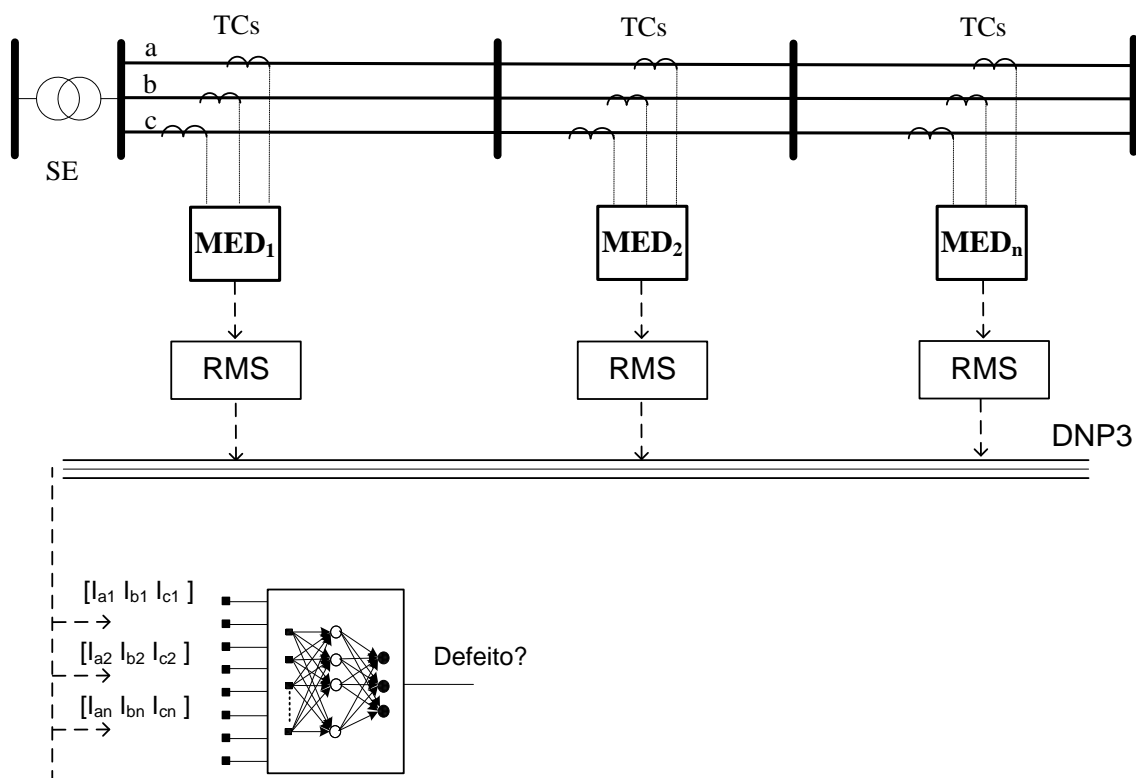


Figura 3-1 – Esquema de detecção considerando medição não-fasorial

### 3.3 Redes Neurais Considerando Medições Fasoriais para Detecção de Defeitos

Outra arquitetura considerada para detecção de defeitos é apresentada na Figura 3-2, que são redes neurais considerando medições fasoriais.

Como citado no item 2.4.1, a medição fasorial é conceituada como a estimação dos parâmetros de fase, amplitude e frequência do componente fundamental. A Figura 2-35 mostra o

conceito de Sistemas de Medição Fasorial Sincronizada e a Figura 2-36 mostra, de forma exemplificada, a instalação de duas PMUs sincronizadas em rede elétrica de duas barras.

A consideração realizada para o desenvolvimento desta rede é que a informação dos dados é obtida através de GPS, sendo este componente o principal diferencial em termos de possibilidades do que foi utilizado no esquema proposto na Figura 3-1. Neste caso, os dados de correntes são amostrados por medidores alocados nos alimentadores dos sistemas de distribuição, juntamente com um sinal de tempo sincronizado via satélite. Deste modo é possível conseguir estimar o ângulo da corrente, o que pode ser considerado no desenvolvimento da topologia desta rede.

Ressalta-se que para utilizar a metodologia com medições fasoriais são necessários dados RMS do módulo da corrente e dados do ângulo em relação a uma referência angular. Deste modo, cada medidor deve amostrar pontos da curva de corrente com sua respectiva estampa de tempo e enviar os dados para um computador central para o cálculo do componente angular utilizada na rede neural.

Um ponto de estudo futuro é identificar um protocolo de comunicação que seja apto a trabalhar com os requisitos necessários para esta aplicação de forma otimizada. O protocolo DNP3 apresenta considerável espaço de tempo entre a comunicação de uma unidade de medição e o servidor. Isto pode diminuir a precisão dos resultados e tornar as estimações de ângulo impróprias para a metodologia. Neste trabalho é considerado que existe o acesso aos dados corretos de módulo e ângulo, uma vez que estudos sobre protocolos de comunicação não são o foco desta dissertação.

Sendo assim, para casos de medições fasoriais, foi proposta uma rede neural na qual as entradas são os valores de módulo e ângulo das correntes amostradas no sistema de distribuição, conforme apresentado na Figura 3-2.

Ressalta-se que a rede neural proposta na Figura 3-2 possui como saída apenas um neurônio, e caso seja detectado algum defeito, este neurônio assume o valor 1 e se não houver nenhum defeito o neurônio assume o valor 0.

Novamente, como mencionado no item 3.1, o objetivo principal desta rede é a detecção de defeitos monofásicos de baixa e média impedância, podendo também detectar defeitos de alta impedância, não sendo este o foco principal desta dissertação.

Nesta topologia de rede neural, o número de entradas é igual a seis vezes o número de medidores de corrente (três informações de módulo e três informações de ângulo).

Considera-se que a rede possui apenas uma camada interna de neurônios.

No capítulo de resultados serão realizados testes para verificar o comportamento desta rede neural semelhante ao indicado para redes neurais com medições não-fasoriais.

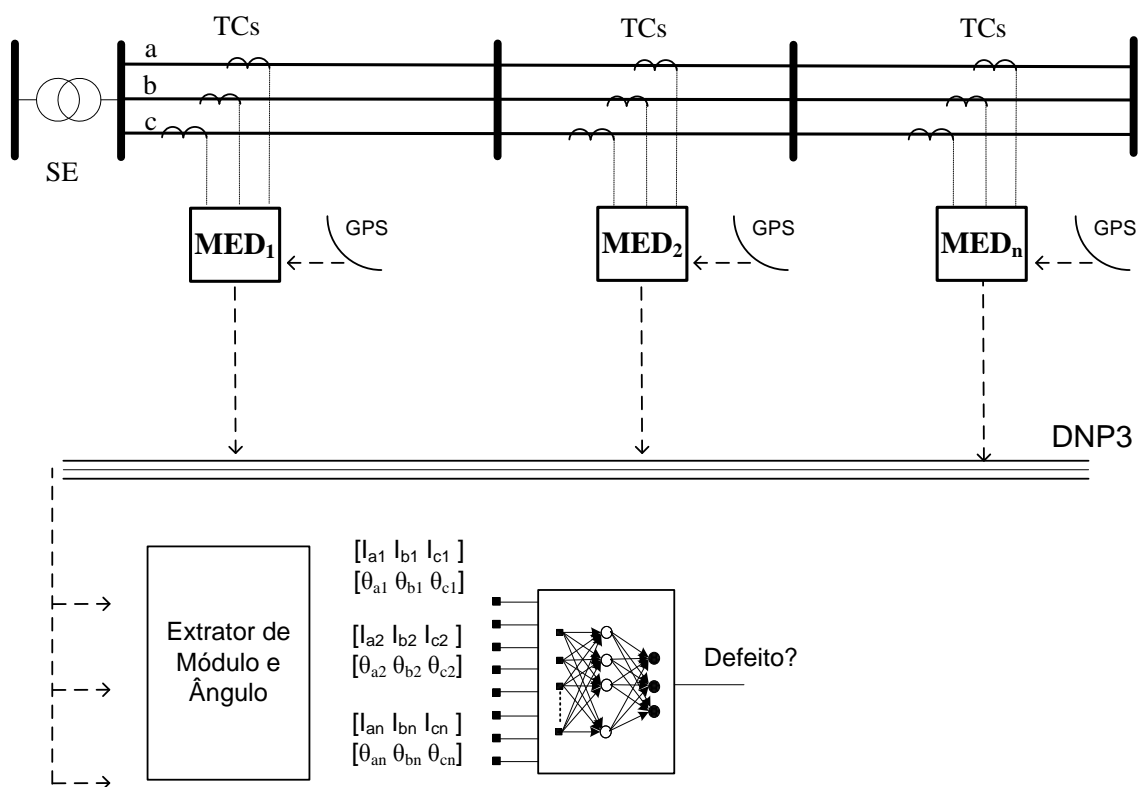


Figura 3-2 – Esquema de detecção considerando medição fasorial

### 3.4 Redes Neurais Considerando Componentes de Sequência para Detecção de Defeitos

Procurando avaliar outra possibilidade de estrutura de rede neural, na Figura 3-3 é apresentada uma arquitetura de rede neural para detecção de defeitos, na qual os dados de correntes em coordenadas de fase são transformados em dados de componentes de sequência (atualmente todos os dispositivos inteligentes, *Intelligent Electronic Device* – IED, modernos fazem esta transformação). Nesta arquitetura, os dados de correntes também são amostrados por medidores alocados nos alimentadores dos sistemas de distribuição, conforme já indicado.

Ressalta-se que para utilizar a metodologia com valores de componentes de sequências são necessários dados em valores eficazes (RMS) da corrente de sequência, que são obtidos facilmente a partir dos dados de fases. Sendo assim, foi proposta uma rede neural na qual as entradas são os valores de módulos de correntes amostradas e calculadas pelos IEDs no sistema de distribuição, conforme apresentado na Figura 3-3.

Nota-se que a rede neural proposta na Figura 3-3 possui como saída apenas um neurônio. Caso seja detectado algum defeito, este neurônio assume o valor 1.

Nesta arquitetura de rede neural, o número de entradas é igual a três vezes o número de medidores de corrente (três informações de módulo em componentes de sequência).

Considera-se que a rede possui apenas uma camada interna de neurônios.

No capítulo de resultados serão realizados testes para verificar o comportamento desta rede neural, semelhante ao indicado para redes neurais com medições não-fasoriais.

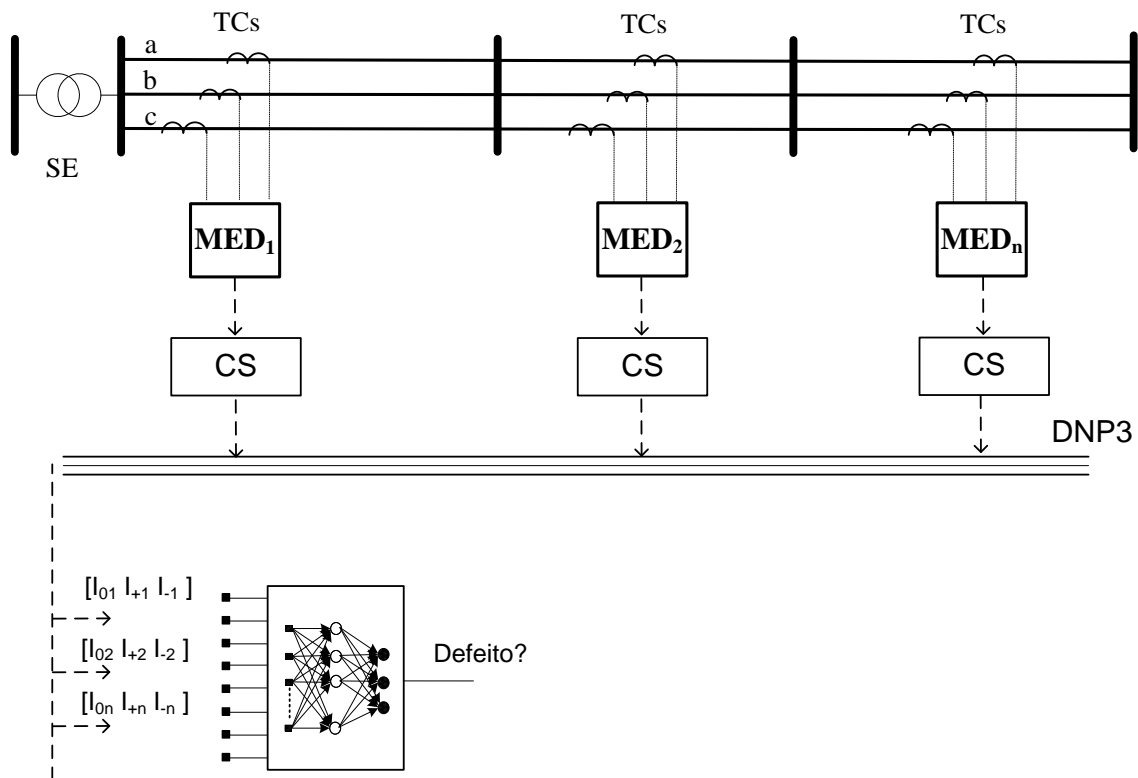


Figura 3-3 – Esquema de detecção considerando medição em dados de componentes de sequência

### 3.5 Algoritmo Proposto para a Detecção de Defeitos utilizando Redes Neurais

Nesta seção será apresentado o algoritmo para a criação da base de dados de simulação e o algoritmo proposto para a detecção de defeitos de baixa e média resistência em sistemas de distribuição.

Na Figura 3-4 é apresentado o algoritmo para a criação da base de dados de simulação. A necessidade desta base de dados consiste devido às inúmeras situações aleatórias de defeitos no sistema elétrico.

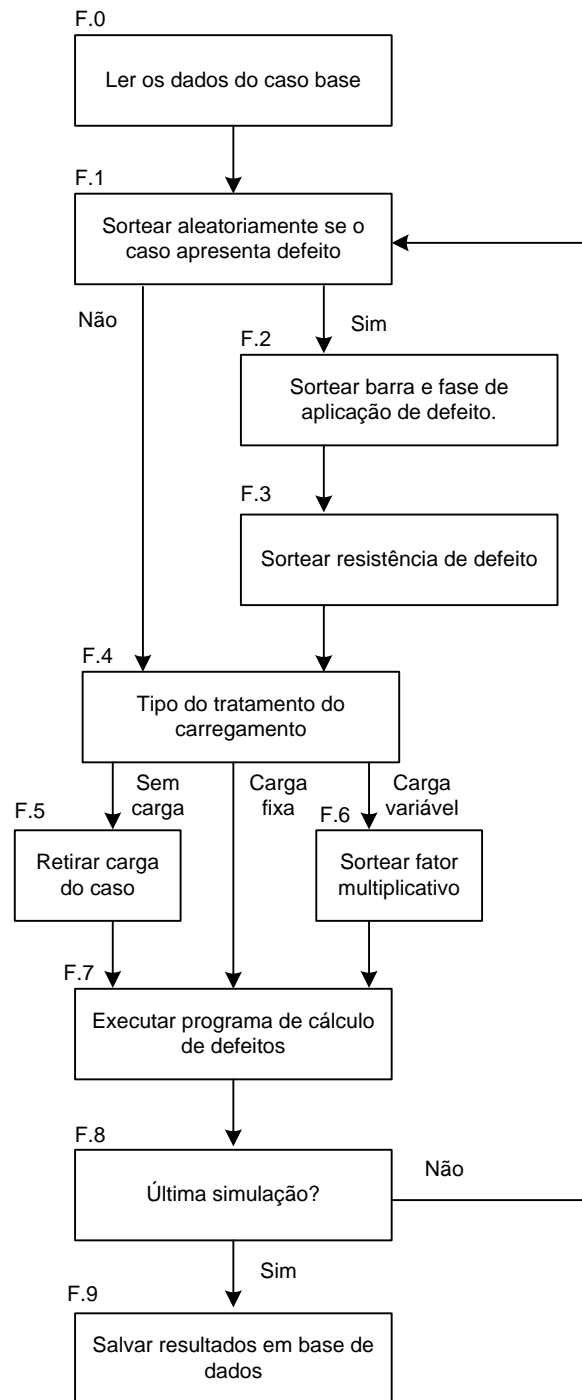


Figura 3-4 – Fluxograma da criação da base de dados

No passo **F.0** são lidos os dados de barras, cargas, transformadores e alimentadores relativos ao caso base.

No passo **F.1** é feito um sorteio aleatório para definir se o caso apresentará um defeito ou não. Objetivo deste sorteio é inserir sistemas sem defeitos na base de dados para evitar "viciar" o treinamento da rede neural. 10% dos casos não apresentam defeitos.

Caso seja simulado um defeito, no passo **F.2** é sorteado uma barra e uma fase para a aplicação de um defeito fase-terra. Os defeitos só são aplicados em barras de média tensão. No passo **F.3** é sorteado a resistência de falta do defeito, cujos valores variam aleatoriamente de 0 a 20 ohms.

No passo **F.4** é analisado o tipo de tratamento de carga. Este tipo é definido antes da execução do algoritmo. Podem ser três tipos de tratamento de carga:

- Retirar as cargas: Todas as cargas são retiradas no passo **F.5**. Este tipo de situação leva aos melhores resultados, mas esta não é uma condição real do sistema.
- Carga fixa: As cargas não são alteradas, e todas as simulações apresentam o mesmo carregamento.
- Carga variável: No passo **F.6** é sorteado um valor entre 0,8 e 1,20 para multiplicar as cargas. Esta é uma condição mais próxima dos sistemas reais (variação horária da carga x momento de ocorrência do defeito), porém a detecção do defeito é mais complexa de ser realizada.

No passo **F.7** é realizada a execução de um programa de fluxo de potência ou análise de defeito de acordo com a decisão feita no passo **F.7**. O programa de fluxo de potência utilizado é apresentado em (PENIDO, 2013) e o programa de análise de defeitos utilizado é apresentado em (PENIDO, 2015).

No passo **F.8** é verificado se foi simulado o número de casos definidos para a criação da base de dados. Neste trabalho foram definidos 5000 casos.

No passo **F.9**, os resultados são gravados em um arquivo em formato texto para ser utilizados no algoritmo de detecção de defeitos. O formato da base de dados criado é apresentado na Figura 3-5, onde cada linha do arquivo é o resultado de uma simulação de defeito.

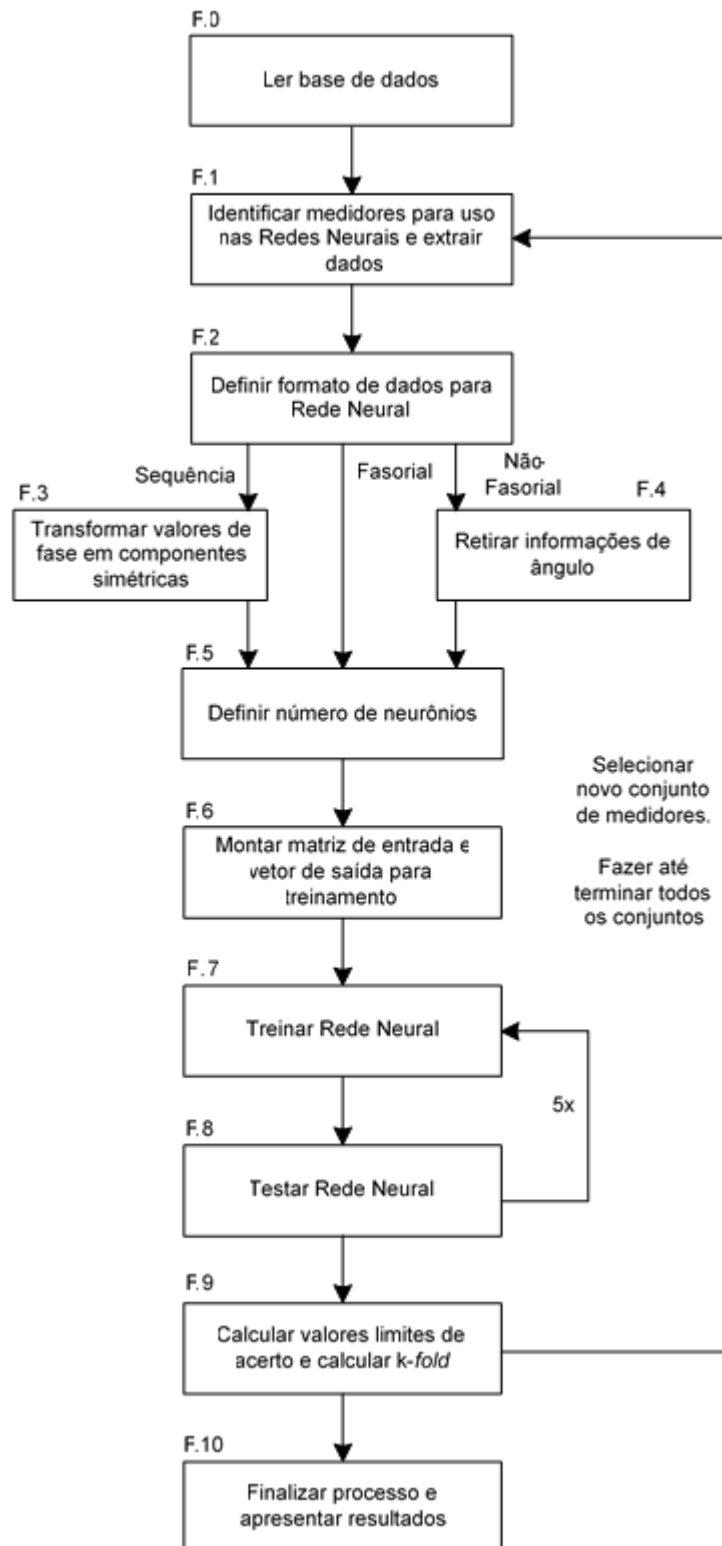
CC	Fase	Barra	Area	Rf	Ia-m1	Ta-m1	Ib-m1	Tb-m1	Ic-m1	Tc-m1	Ia-m2	Ta-m2	
1	2	18	2	6.820	557.887	-68.464	785.919	-173.375	531.651	56.652	537.930	-68.173	758.396
1	2	108	6	0.839	554.683	-72.050	1724.872	165.576	498.784	60.653	535.162	-71.801	1703.990
1	1	29	7	11.588	730.934	-61.559	469.382	178.032	539.442	56.535	712.465	-61.130	444.129
1	2	78	5	16.187	557.056	-68.394	593.145	-177.244	530.428	57.446	537.911	-68.072	563.387
1	2	61	4	11.489	556.641	-68.825	641.429	-175.705	531.144	57.465	538.384	-68.510	613.953
1	2	21	2	16.713	564.893	-68.162	590.906	-176.726	530.967	57.443	546.201	-67.910	564.719
1	3	61	4	16.109	555.872	-68.389	472.449	178.141	666.313	61.364	535.712	-68.116	442.255
1	3	25	7	9.100	546.559	-68.224	478.129	178.068	762.165	63.368	527.211	-67.833	450.039
1	1	76	5	13.494	701.629	-62.869	469.389	178.135	545.761	56.424	683.534	-62.490	443.719
1	2	29	7	11.983	567.641	-68.272	652.226	-176.047	538.391	57.120	548.833	-68.061	624.244
1	2	97	6	10.099	566.184	-69.392	664.661	-175.551	536.513	57.747	546.343	-69.062	637.020
1	2	72	5	1.550	574.923	-71.576	1483.116	176.507	512.589	59.136	555.067	-71.391	1457.867
1	1	42	3	1.156	1844.585	-67.299	438.994	-179.837	547.958	52.090	1827.561	-67.182	411.820
1	3	30	7	16.114	565.363	-68.364	469.357	177.513	665.425	62.044	548.643	-68.134	441.567
1	1	56	4	13.754	703.531	-62.674	458.062	178.820	545.254	57.114	684.779	-62.254	429.126
0	2	7	1	15.739	543.322	-68.391	456.842	179.253	533.785	57.168	525.631	-68.232	428.258
1	3	1	1	18.731	557.717	-68.408	463.992	178.084	647.607	62.657	539.210	-68.078	437.155
1	3	60	4	0.548	495.373	-63.908	458.558	171.094	2307.854	42.261	478.850	-63.508	431.597
1	2	152	4	19.931	556.437	-68.198	579.637	-176.909	534.789	56.944	536.628	-67.902	549.059
1	2	99	6	4.676	576.779	-69.459	886.357	-176.284	529.806	57.622	557.297	-69.204	857.476
0	2	55	4	5.756	558.744	-68.779	462.756	178.802	543.934	57.679	541.012	-68.512	437.294
1	3	56	4	14.677	551.931	-68.022	475.450	177.633	675.312	62.093	533.473	-67.736	448.472
0	1	63	4	7.033	562.589	-68.268	467.444	178.042	539.954	57.759	544.247	-67.976	441.794
1	2	54	4	16.753	555.482	-67.975	588.754	-176.274	520.679	57.101	537.300	-67.769	559.114

Figura 3-5 – Exemplos de dados de entrada.

Onde (identificadores localizado no cabeçalho do arquivo da Figura 3-5):

- **CC** – Indica a existência ou não de defeito na simulação;
- **Fase** – Indica a fase em que foi aplicado o defeito;
- **Barra** – Indica a barra na qual foi aplicado o defeito;
- **Área** – Indica a parte do sistema entre dois religadores na qual foi aplicado o defeito, (este dado não foi utilizado neste trabalho);
- **Rf** – Indica a resistência de arco (falta) do defeito;
- **Ia-m1** – Módulo da corrente medida no medidor 1 na fase a;
- **Ta-m1** – Ângulo da corrente medida no medidor 1 na fase a;
- **Ib-m1** – Módulo da corrente medida no medidor 1 na fase b;
- **Tb-m1** – Ângulo da corrente medida no medidor 1 na fase b;
- **Ic-m1** – Módulo da corrente medida no medidor 1 na fase c;
- **Tc-m1** – Ângulo da corrente medida no medidor 1 na fase c;
- **Ta-m2** – Ângulo da corrente medida no medidor 2 na fase a.

Na Figura 3-6 é apresentado o algoritmo para múltiplos treinamentos das redes neurais apresentadas nas seções 3.2, 3.3 e 3.4, utilizando a base de dados construída de acordo com o algoritmo apresentada na Figura 3-4.



**Figura 3-6 – Fluxograma das etapas implementadas no software Matlab®.**

No passo **F.0** é lida a base de dados de barras que foi gerada conforme procedimento apresentado na Figura 3-4. Os dados lidos são separados da seguinte forma: 70% para treinamento, 15% para testes durante o treinamento e 15% para validação do treinamento.



No passo **F.1**, o usuário escolhe quais medidores trifásicos de corrente serão utilizados como entrada da rede neural. A princípio cada ramo do sistema elétrico pode ter um medidor de corrente. Pode ser escolhido desde 1 medidor até o número total de ramos do sistema elétrico.

No passo **F.2** é escolhido qual o tratamento de dados será realizado nos valores das medições de correntes indicados no passo **F.1**. Caso seja utilizada a rede com dados de medições não-fasoriais (seção 3.2), os valores de módulo serão informados e os valores dos ângulos das correntes não serão informados para a rede neural (passo **F.4**). Caso seja utilizada a rede com dados de medições fasoriais (seção 3.3), os valores de correntes e ângulos serão informados para a rede neural. Caso seja utilizada a rede com dados de sequência (seção 3.4), os valores de fase serão transformados para componentes simétricas e apenas os valores de módulo das grandezas serão informados para a rede neural (passo **F.3**).

No passo **F.5** é definido o número de neurônios da camada oculta da rede neural.

No passo **F.6** é montada a matriz de entrada da rede neural, onde cada linha informa os valores de correntes dos medidores definidos no passo **F.1** para um determinado caso. O número máximo de casos para treinamento é definido pelo usuário e não pode ser maior que o número de casos existente na base de dados. Também é informado um vetor coluna binário, onde é indicado se existe defeito no caso atual (valor 1) ou não existe defeito (valor 0). Este vetor é considerado o professor da rede neural.

No passo **F.7** é treinada a rede neural de reconhecimento de padrões. No Matlab 2015 é utilizada a função *newpr*.

No passo **F.8** é testada a rede neural com dados da base de dados que não foram utilizados para o treinamento.

Os passos **F.7** e **F.8** são repetidos 5 vezes para verificação da eficiência da estrutura da rede proposta. Esta repetição é necessária, pois a escolha de dados de treinamento é aleatória e isto pode impactar no desempenho da rede. Por exemplo, podem ser escolhidos como dados de treinamento apenas casos que não representem defeitos. Deste modo, a rede errará quando analisar um dado que não representa defeito.

No passo **F.9** são calculados os fatores de desempenho conforme apresentação na seção 2.2.5. Dessas cinco execuções anotam-se: \*melhor resultado, \*pior resultado, \*média entre os resultados das cinco execuções e \*média entre os resultados das cinco execuções retirando o pior valor encontrado.

Os resultados são apresentados no passo **F.10**, sendo criado um arquivo em Excel com os resultados das simulações executadas.

## Capítulo 4 Resultados

### 4.1 Introdução

Nesta seção serão apresentados resultados obtidos com os métodos propostos para detecção de defeitos utilizando as RN's propostas no Capítulo 3.

O sistema IEEE 123 barras (IEEE123), mostrado na Figura 4-1, apresenta diversas características de sistemas reais e foi utilizado para os testes. Porém, para tornar o sistema IEEE123 mais parecido com os sistemas brasileiros, foram acrescentados diversos transformadores abaixadores e diversas cargas foram alocadas nos secundários dos transformadores de distribuição, como pode ser observado na Figura 4-2. Os círculos vermelhos indicam barras com cargas e os transformadores de corrente, representados em dourado, indicam equipamentos de medição. Observa-se que o sistema é composto de doze medidores (M-1, M-2, M-3, M-4, M-5, M-6, M-7, M-8, M-9, M-10, M-11 e M-12).




Figura 4-1 - Sistema IEEE123




Figura 4-2 – Sistema IEEE123 com cargas alocadas no secundário

A base de dados de casos de defeitos utilizada nos testes foi criada da seguinte forma:

- (i) Foram simulados 5000 casos no sistema IEEE123 utilizando o método proposto em (PENIDO, 2015);
- (ii) Para cada simulação, o carregamento foi representado de três formas distintas:
  - (ii.a) as cargas foram desconsideradas. Com estes casos espera-se uma maior taxa de acerto com a utilização da rede neural, mas esta situação não ocorre em sistemas reais;
  - (ii.b) as cargas são consideradas constantes. Apesar de ser considerada uma razoável aproximação do sistema real para vários estudos, esta condição pode influenciar nos resultados da aplicação da rede neural, tornando a detecção mais fácil, porém, resultará em um aumento da taxa de erro da rede neural quando aplicada em outros sistemas reais. Sendo assim, não é indicada para o problema tratado nesta dissertação;

(ii.c) as cargas são variadas de forma aleatória. Nestes casos, cada carga individualmente possui seu valor base multiplicado por um valor escolhido aleatoriamente entre 0,8 a 1,2 para cada simulação realizada. O objetivo disto é representar alguma variação da carga durante o dia e com isto tentar evitar o problema de particularização da rede neural para apenas um determinado patamar de carregamento.

- (iii) Para cada caso, foi considerada uma chance de 10% de não ser simulado um defeito. O objetivo disto é fornecer subsídios para que a rede neural definida com estes casos possa diferenciar condições normais das condições de defeito;
- (iv) Para os casos de simulação da rede com defeito, uma fase e uma barra são escolhidas aleatoriamente para a aplicação do defeito;
- (v) A impedância de defeito é escolhida aleatoriamente entre 0 a 20 ohms.

Nas próximas seções serão apresentados diversos tipos de testes realizados para definir qual tipo de rede neural apresenta melhor desempenho para a detecção de defeitos monofásicos no sistema IEEE123. Para tanto foram propostos nove tipos de redes neurais (redes com características diferentes), sendo os tipos enumerados a seguir, e representados na Figura 4-3, com a descrição de suas principais características.


- 1) Dados de entrada não-fasorial – 20 neurônios na camada interna
- 2) Dados de entrada não-fasorial – 30 neurônios na camada interna
- 3) Dados de entrada não-fasorial – 40 neurônios na camada interna
- 4) Dados de entrada em sequência – 20 neurônios na camada interna
- 5) Dados de entrada em sequência – 30 neurônios na camada interna
- 6) Dados de entrada em sequência – 40 neurônios na camada interna
- 7) Dados de entrada fasorial – 20 neurônios na camada interna
- 8) Dados de entrada fasorial – 30 neurônios na camada interna
- 9) Dados de entrada fasorial – 40 neurônios na camada interna

Apenas para facilitar o entendimento, a árvore indica a utilização de nove redes, porém, como para cada uma haverá ainda a variação de medidores (2 ou 3), as redes testadas na realidade serão um total de dezoito redes (9 tipos de redes x 2 quantidades de medidores consideradas).

Para as redes neurais com entrada de dois medidores, será feita uma combinação de medidores 2x2, na qual os locais de instalação são indicados na Figura 4-1. Ressalta-se que 1

medidor será sempre a subestação. Neste caso, para cada rede neural de dois medidores, serão realizadas 11 simulações distintas.

Para as redes neurais com entrada de três medidores, será feita uma combinação de medidores 3x3, na qual os locais de instalação são indicados na Figura 4-1. Ressalta-se que 1 medidor será sempre a subestação. Neste caso, para cada rede neural de três medidores, serão realizadas 55 simulações distintas.



**Figura 4-3 – Arvore de simulação**

Em que:

- Não-Fasorial – Nas redes desenvolvidas nesta linha de característica são utilizados dados de entrada não-fasoriais (considera-se somente os módulos das grandezas nas entradas da rede neural). Essas considerações foram basicamente realizadas para atender a situação mais comum atualmente, na qual os medidores instalados nos sistemas de distribuição disponibilizam informações de módulos das grandezas para serem utilizados nas detecções;
- Fasorial – Nas redes desenvolvidas nesta linha de característica são utilizados dados de entrada fasoriais (consideram-se os módulos e ângulos das grandezas nas entradas da rede neural). A principal ideia é a possibilidade de termos, cada vez mais, equipamentos nos sistemas de distribuição que disponibilizem as grandezas de forma fasorial para serem utilizadas nas detecções;
- Sequência – É uma opção de utilização dos dados da linha na forma fasorial. Porém, nesta abordagem os dados de entrada são representados em componentes de sequência (exemplo:  $I_0, I_+, I_-$ );

- Fase – Também é uma opção de utilização dos dados da linha na forma fasorial. Nesta abordagem, os dados de entrada são dados dos medidores do sistema trifásico em coordenadas de fase (exemplo:  $I_A, I_B, I_C$ );
- $n$  – indica a variação do número de neurônios na camada interna testada.

Para realizar a validação das redes neurais desenvolvidas foi utilizado o método de validação cruzada *k-fold*, conforme teoria já indicada no capítulo anterior, onde o conjunto de dados de teste foi dividido em cinco partes. Na apresentação de dados, também foi utilizado o *k-fold-1*, onde o pior resultado é retirado do conjunto em análise. Também serão apresentados o melhor e o pior resultado em todas as análises.

A seguir serão mostrados os testes, apresentando o desempenho dos métodos propostos nesta dissertação.

Em todos os gráficos apresentados, o eixo das ordenadas indica o erro em percentual da atuação da rede para cada caso específico.

## **4.2 Testes com o Sistema IEEE 123 – Sem Carga**

Neste item serão apresentados os resultados obtidos através do método desenvolvido para detectar defeitos no sistema de energia, onde no caso as cargas foram desconsideradas.

Será realizada a variação do número de camadas ocultas, conforme indicado na árvore de simulações da Figura 4-4. Para cada situação indicada na árvore também haverá a variação do número de medidores considerados como entrada da rede neural, sendo dois ou três medidores. Além disso, não serão utilizados sempre os mesmos medidores, sendo feitas combinações dois a dois ou três a três dos medidores M2 ao M12 na Figura 4-1, com exceção do medidor M1 que será sempre considerado.

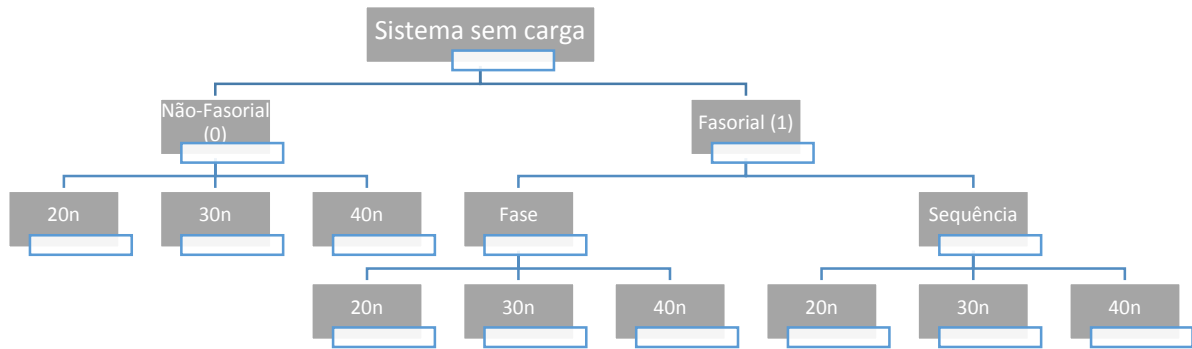


Figura 4-4 – Árvore de simulações do sistema sem carga

#### 4.2.1 Avaliação do Desempenho do Método Aplicado ao Sistema Sem Carga

##### 1. Dados não-fatoriais:

##### (i) 2 Medidores

Seguem as Figura 4-5, Figura 4-6 e Figura 4-7 referentes às simulações do sistema sem carga, considerando dados de entrada de 2 medidores, com variação do número de neurônios na rede.






Figura 4-5 - Não-fatorial / sem carga/ 2 medidores/ 20 neurônios



**Figura 4-6 - Não-fasorial / sem carga/ 2 medidores/ 30 neurônios**



**Figura 4-7 - Não-fasorial / Sem Carga/ 2 medidores/ 40 neurônios**

A Tabela 4-1 mostra um resumo de resultados encontrados nas simulações feitas em relação à variação de neurônios nas redes, todas com dados não-fasoriais, considerando variações de medições de dois medidores, sem consideração de carga. As porcentagens indicam a incidência de erros nulos em cada situação.

Analisando-se os resultados, a rede que apresentou melhor comportamento foi aquela com uma menor quantidade de neurônios na camada interna. Nessa situação, 100% das execuções, independentemente dos dois medidores usados, possuem erros nulos como melhor resultado. Além disso, 36% dos piores resultados possuem erros nulos.




**Tabela 4-1 – Comparativo da variação de neurônios – Dados não-fasoriais / Sem Carga / 2M**


2 Medidores			
Quantidade de neurônios	20	30	40
Pior	36%	18%	18%
Melhor	100%	90%	90%
<i>k</i> -folder	36%	18%	18%
<i>k</i> -folder-1	64%	64%	64%

**(ii) 3 Medidores**


Seguem as Figura 4-8, Figura 4-9 e Figura 4-10 referentes às simulações do sistema sem carga, considerando dados de entrada de 3 medidores, com variação do número de neurônios na rede.



**Figura 4-8 - Não-fasorial / sem carga/ 3 medidores/ 20 neurônios**



**Figura 4-9 - Não-fasorial / sem carga/ 3 medidores/ 30 neurônios**



**Figura 4-10 - Não-fasorial / sem carga/ 3 medidores/ 40 neurônios**

A Tabela 4-2 mostra um resumo de resultados encontrados nas simulações feitas em relação à variação de neurônios nas redes, todas com dados não-fasoriais, considerando variações de medições agora de três medidores, sem consideração de carga. As percentagens indicam a incidência de erros nulos em cada situação.

Analisando-se os resultados, a rede que apresentou melhor comportamento foi aquela com uma maior quantidade de neurônios na camada interna. Isto era esperado, pois como há o aumento do número de entradas, então é normalmente necessário um maior número de neurônios para processamento das informações.

Com 40 neurônios, 93% das execuções, independentemente dos três medidores utilizados nas combinações, possuem erros nulos como melhor resultado, enquanto 7% das execuções apresentam valores de erro bem próximos a zero. Além disso, 29% dos piores resultados e 56% dos resultados considerando *k-folder-1* apresentaram erros nulos.

**Tabela 4-2 – Comparativo da variação de neurônios – Dados não-fasoriais / sem carga / 3M**

<b>3 Medidores</b>			
<b>Quantidade de neurônios</b>	<b>20</b>	<b>30</b>	<b>40</b>
Pior	36%	29%	29%
Melhor	84%	93%	93%
<i>k-folder</i>	36%	29%	29%
<i>k-folder-1</i>	51%	55%	56%


Comparando-se as Tabela 4-2 e Tabela 4-1, verifica-se que, de forma geral, o aumento do número de medidores utilizados não melhorou os valores globais. Contudo, isto não significa que a rede com três medidores é pior, uma vez que apresentou diversas configurações de entrada que levaram a erros nulos.

Analisando-se as execuções pode-se supor que a posição dos medidores deve influenciar nos resultados das redes neurais. Este tipo de análise não faz parte do escopo desta dissertação, ficando como um trabalho futuro.


## **2. Dados Fasoriais em Fase:**

### **(i) 2 Medidores**

Seguem as Figura 4-11, Figura 4-12 e Figura 4-13 referentes às simulações do sistema sem carga, considerando dados de entrada de 2 medidores, com variação do número de neurônios na rede.



**Figura 4-11 - Fasorial em fase / sem carga/ 2 medidores/ 20 neurônios**



**Figura 4-12 - Fasorial em fase / sem carga/ 2 medidores/ 30 neurônios**




Figura 4-13 - Fasorial em fase / sem carga/ 2 medidores/ 40 neurônios

A Tabela 4-3 mostra um resumo de resultados encontrados nas simulações feitas em relação à variação de neurônios nas redes, todas com dados fasoriais, considerando variações de medições de dois medidores, sem consideração de carga. As percentagens indicam a incidência de erros nulos em cada situação.

Analisando os resultados, a rede que apresentou melhor comportamento foi aquela com uma menor quantidade de neurônios na camada interna. Nessa situação, 100% das execuções, independentemente dos dois medidores usados, possuem erros nulos como melhor resultado. Além disso, 45% dos piores resultados e *k-folder-1* possuem erros nulos.


Verifica-se que as entradas fasoriais detectam os defeitos no sistema com um melhor desempenho quando comparadas com as redes que utilizam as entradas não fasoriais, desconsiderando a carga do sistema.

Tabela 4-3 – Comparativo da variação de neurônios – Dados fasoriais em fase / sem Carga / 2M


2 Medidores			
Quantidade de neurônios	20	30	40
Pior	45%	27%	45%
Melhor	100%	100%	100%
<i>k-folder</i>	45%	27%	0%
<i>k-folder-1</i>	91%	73%	45%

**(ii) 3 Medidores**


Seguem as Figura 4-14, Figura 4-15 e Figura 4-16 referentes às simulações do sistema sem carga, considerando dados de entrada de 3 medidores, com variação do número de neurônios na rede.



**Figura 4-14 - Fasorial em fase / sem carga/ 3 medidores/ 20 neurônios**



**Figura 4-15 - Fasorial em fase / sem carga/ 3 medidores/ 30 neurônios**



**Figura 4-16 - Fasorial em fase / sem carga/ 3 medidores/ 40 neurônios**

A Tabela 4-4 mostra um resumo de resultados encontrados nas simulações feitas em relação à variação de neurônios nas redes, todas com dados fasoriais em fase, considerando variações de medições agora de três medidores, sem consideração de carga. As percentagens indicam a incidência de erros nulos em cada situação.

Analisando-se os resultados, a rede que apresentou melhor comportamento foi aquela com uma menor quantidade de neurônios na camada interna. Nessa situação, 100% das execuções, nas três variações de quantidade de neurônios (20, 30 ou 40), independentemente dos três medidores utilizados nas combinações, possuem erros nulos como melhor resultado. Com 20 neurônios, 40% dos piores resultados apresentaram erros nulos.

**Tabela 4-4 – Comparativo da variação de neurônios – Dados fasoriais em fase / sem carga / 3M**

<b>3 Medidores</b>			
<b>Quantidade de neurônios</b>	<b>20</b>	<b>30</b>	<b>40</b>
Pior	40%	36%	25%
Melhor	100%	100%	100%
<i>k-folder</i>	40%	36%	25%
<i>k-folder-1</i>	69%	75%	64%

### 3. Dados Fasoriais em Sequência:

#### (i) 2 Medidores

Seguem as Figura 4-17, Figura 4-18 e Figura 4-19 referentes às simulações do sistema sem carga, considerando dados de entrada de 2 medidores, com variação do número de neurônios na rede.




Figura 4-17 - Fasorial em sequência / sem carga/ 2 medidores/ 20 neurônios




Figura 4-18 - Fasorial em sequência / sem carga/ 2 medidores/ 30 neurônios






Figura 4-19 - Fasorial em sequência / sem carga/ 2 medidores/ 40 neurônios

A Tabela 4-5 mostra um resumo de resultados encontrados nas simulações feitas em relação à variação de neurônios nas redes, todas com dados fasoriais em sequência, considerando variações de medições de dois medidores, sem consideração de carga. As percentagens indicam a incidência de erros nulos em cada situação.


Analisando-se os resultados, a rede que apresentou melhor comportamento foi aquela com uma quantidade de 30 neurônios na camada interna. Nessa situação, 100% das execuções, independentemente dos dois medidores usados, possuem erros nulos como melhor resultado. Além disso, 73% dos piores resultados e 100% dos resultados considerando *k-folder-1* apresentaram erros nulos.

Tabela 4-5 – Comparativo da variação de neurônios – Dados fasoriais em sequência / sem carga / 2M


2 Medidores			
Quantidade de neurônios	20	30	40
Pior	73%	73%	55%
Melhor	100%	100%	100%
<i>k-folder</i>	73%	73%	55%
<i>k-folder-1</i>	91%	100%	91%

**(ii) 3 Medidores**


Seguem as Figura 4-20, Figura 4-21 e Figura 4-22 referentes às simulações do sistema sem carga, considerando dados de entrada de 3 medidores, com variação do número de neurônios na rede.



**Figura 4-20 - Fasorial em sequência / sem carga/ 3 medidores/ 20 neurônios**



**Figura 4-21 - Fasorial em sequência / sem carga/ 3 medidores/ 30 neurônios**



**Figura 4-22 - Fasorial em sequência / sem carga/ 3 medidores/ 40 neurônios**

A Tabela 4-6 mostra um resumo de resultados encontrados nas simulações feitas em relação à variação de neurônios nas redes, todas com dados não-fasoriais, considerando variações de medições agora de três medidores, sem consideração de carga. As porcentagens indicam a incidência de erros nulos em cada situação.

Analisando-se os resultados, a rede que apresentou melhor comportamento foi aquela com uma menor quantidade de neurônios na camada interna. Nessa situação, 100% das execuções, nas três variações de quantidade de neurônios (20, 30 ou 40), independentemente dos três medidores utilizados nas combinações, possuem erros nulos como melhor resultado. Com 20 neurônios, 56% dos piores resultados apresentaram erros nulos.

**Tabela 4-6 – Comparativo da variação de neurônios – Dados fasoriais em sequência / sem carga / 3M**

<b>3 Medidores</b>			
<b>Quantidade de neurônios</b>	<b>20</b>	<b>30</b>	<b>40</b>
Pior	56%	51%	38%
Melhor	100%	100%	100%
<i>k-folder</i>	56%	51%	38%
<i>k-folder-1</i>	91%	89%	71%

A utilização de dados fasoriais levou a um maior índice de acerto, e as redes se comportaram melhor que aquelas que usaram dados não-fasoriais. Nos casos simulados considerando a

utilização de dados fasoriais, observa-se erro nulo de detecção como melhor resultado. O conjunto de execuções utilizando dados em componentes de sequência (módulos) gerou resultados melhores que com a utilização de dados considerando as coordenadas de fase. Isto é uma informação relevante, uma vez que todos os medidores podem fornecer dados em componentes de sequência.

### 4.3 Testes com o Sistema 123 – Com Carga Fixa

Neste item serão apresentados os resultados obtidos através do método desenvolvido para detectar defeitos no sistema de energia, onde no caso as cargas foram consideradas constantes.

Será realizada a variação do número de camadas ocultas, conforme indicado na árvore de simulações mostrada na Figura 4-23. Para cada situação indicada na árvore também haverá a variação do número de medidores considerados como entrada da rede neural. Nesta variação do número de medidores serão considerados dois ou três medidores utilizados. Além disso, não serão utilizados sempre os mesmos medidores, sendo feitas combinações dois a dois ou três a três dos medidores M2 a M12 na Figura 4-1, com exceção do medidor da subestação M1 que será sempre considerado.

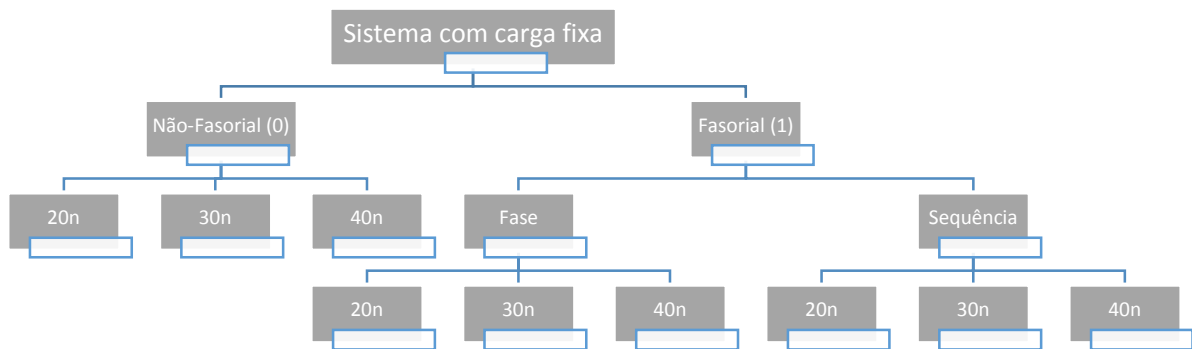


Figura 4-23 – Simulações do sistema com carga fixa

#### 4.3.1 Avaliação do Desempenho do Sistema com Carga Fixa

## 1. Dados não-fasoriais:

### (i) 2 Medidores

Seguem as Figura 4-24, Figura 4-25 e Figura 4-26 referentes às simulações do sistema sem carga, considerando dados de entrada de 2 medidores, com variação do número de neurônios na rede.




Figura 4-24 - Não-fasorial / carga fixa/ 2 medidores/ 20 neurônios




Figura 4-25 - Não-fasorial / carga fixa/ 2 medidores/ 30 neurônios




Figura 4-26 - Não-fatorial / carga fixa/ 2 medidores/ 40 neurônios

A Tabela 4-7 mostra um resumo de resultados encontrados nas simulações feitas em relação à variação de neurônios nas redes, todas com dados não-fatoriais, considerando variações de medições de dois medidores, com consideração de carga constante. As percentagens indicam a incidência de erros nulos em cada situação.


Analisando-se os resultados, 100% das execuções, independentemente dos dois medidores usados e da quantidade de neurônios na camada interna, possuem erros nulos como melhor resultado. Analisando os piores resultados e os dados de *k-folder-1*, nota-se que o sistema se comporta melhor com uma menor quantidade de neurônios na camada interna.

Tabela 4-7 – Comparativo da variação de neurônios – Dados não-fatoriais / carga fixa / 2M


2 Medidores			
Quantidade de neurônios	20	30	40
Pior	9%	0%	9%
Melhor	100%	100%	100%
<i>k-folder</i>	9%	9%	9%
<i>k-folder-1</i>	45%	36%	36%

**(ii) 3 Medidores**


Seguem as Figura 4-27, Figura 4-28 e Figura 4-29 referentes às simulações do sistema sem carga, considerando dados de entrada de 3 medidores, com variação do número de neurônios na rede.



**Figura 4-27 - Não-fatorial / carga fixa/ 3 medidores/ 20 neurônios**



**Figura 4-28 - Não-fatorial / carga fixa/ 3 medidores/ 30 neurônios**



**Figura 4-29 – Não-fasorial / carga fixa/ 3 medidores/ 40 neurônios**

A Tabela 4-8 mostra um resumo de resultados encontrados nas simulações feitas em relação à variação de neurônios nas redes, todas com dados não-fasoriais, considerando variações de medições de três medidores, com consideração de carga fixa. As porcentagens indicam a incidência de erros nulos em cada situação.

Na Tabela 4-8 como nas demais tabelas dessa seção, nota-se que os resultados ótimos são obtidos, mas os valores de *k-folder* e *k-folder-1* são mais baixos que os valores obtidos em redes elétricas na qual as cargas não são representadas. Isto mostra a dificuldade de achar bons resultados com representação de cargas.

**Tabela 4-8 – Comparativo da variação de neurônios – Dados não-fasoriais / carga fixa / 3M**

<b>3 Medidores</b>			
<b>Quantidade de neurônios</b>	<b>20</b>	<b>30</b>	<b>40</b>
Pior	13%	4%	5%
Melhor	91%	87%	89%
<i>k-folder</i>	13%	4%	5%
<i>k-folder-1</i>	33%	18%	25%



## 2. Dados Fasoriais em Fase:

### (i) 2 Medidores

Seguem as Figura 4-30, Figura 4-31 e Figura 4-32 referentes às simulações do sistema com carga fixa, considerando dados de entrada de 2 medidores, com variação do número de neurônios na rede.




Figura 4-30 - Fasorial em fase / carga fixa/ 2 medidores/ 20 neurônios





Figura 4-31 - Fasorial em fase / carga fixa/ 2 medidores/ 30 neurônios



**Figura 4-32 - Fasorial em fase / carga fixa/ 2 medidores/ 30 neurônios**

A Tabela 4-9 mostra um resumo de resultados encontrados nas simulações feitas em relação à variação de neurônios nas redes, todas com dados fasoriais em fase, considerando variações de medições de dois medidores e carga fixa. As percentagens indicam qual foi a incidência de erros nulos em cada situação.


Analisando-se os resultados, a rede que apresentou melhor comportamento foi aquela com uma quantidade de 30 neurônios na camada interna. Nessa situação, 100% das execuções, independentemente dos dois medidores usados, possuem erros nulos como melhor resultado. Além disso, nenhuma variação dos piores resultados possuem erros nulos.

**Tabela 4-9 – Comparativo da variação de neurônios – Dados fasoriais em fase / carga fixa / 2M**


2 Medidores			
Quantidade de neurônios	20	30	40
Pior	9%	0%	9%
Melhor	82%	100%	73%
<i>k-folder</i>	9%	0%	9%
<i>k-folder-1</i>	27%	27%	27%

**(ii) 3 Medidores**


Seguem as Figura 4-33, Figura 4-34 e Figura 4-35 referentes às simulações do sistema com carga fixa, considerando dados de entrada de 3 medidores, com variação do número de neurônios na rede.



**Figura 4-33 - Fatorial em fase / carga fixa/ 3 medidores/ 20 neurônios**



**Figura 4-34 - Fatorial em fase / carga fixa/ 3 medidores/ 30 neurônios**



**Figura 4-35 - Fasorial em fase / carga fixa/ 3 medidores/ 40 neurônios**

A Tabela 4-10 mostra um resumo dos resultados encontrados nas simulações feitas em relação à variação de neurônios nas redes, todas com dados fasoriais em fase, considerando variações de medições de três medidores e carga constante. As porcentagens indicam a incidência de erros nulos em cada situação.

Analisando os resultados, a rede que apresentou melhor comportamento foi aquela com uma maior quantidade de neurônios na camada interna. Isto era esperado, pois como há o aumento do número de entradas, então é normalmente necessário um maior número de neurônios para processamento das informações.

Com 40 neurônios, 76% das execuções, independentemente dos três medidores utilizados nas combinações, possuem erros nulos como melhor resultado. Nota-se que os resultados ótimos são obtidos, mas os valores de *k-folder* e *k-folder-1* são baixos. Isto mostra a dificuldade de achar bons resultados com representação de cargas.

**Tabela 4-10 – Comparativo da variação de neurônios – Dados fasoriais em fase / carga fixa / 3M**

3 Medidores			
Quantidade de neurônios	20	30	40
Pior	0%	2%	0%
Melhor	65%	69%	76%
<i>k-folder</i>	0%	2%	0%
<i>k-folder-1</i>	2%	5%	9%

### 3. Dados Fasoriais em Sequência:

#### (i) 2 Medidores

Seguem as Figura 4-36, Figura 4-37 e Figura 4-38 referentes às simulações do sistema com carga fixa, considerando dados de entrada de 2 medidores, com variação do número de neurônios na rede.




Figura 4-36 - Fasorial em sequência / carga fixa/ 2 medidores/ 20 neurônios




Figura 4-37 - Fasorial em sequência / carga fixa/ 2 medidores/ 30 neurônios




Figura 4-38 - Fasorial em sequência / carga fixa/ 2 medidores/ 40 neurônios

A Tabela 4-11 mostra um resumo de resultados encontrados nas simulações feitas em relação à variação de neurônios nas redes, todas com dados fasoriais em sequência, considerando variações de medições de dois medidores e carga constante. As percentagens indicam a incidência de erros nulos em cada situação.

Analisando-se os resultados, a rede que apresentou melhor comportamento foi aquela com uma menor quantidade de neurônios na camada interna. Nessa situação, 100% das execuções, independentemente da quantidade de neurônios e dos dois medidores utilizados nas combinações, possuem erros nulos como melhor resultado. Com 20 neurônios, 36% dos piores resultados apresentaram erros nulos.

Neste tipo de sistema, com representação de cargas, as redes fasoriais em sequência apresentaram os melhores resultados. Uma possível explicação consiste na existência da sequência zero, pois a rede diferencia a sequência zero (referentes ao defeito) dos valores de carga. Nas redes fasoriais, apesar de possível realizar esta verificação, seriam necessários mais neurônios (seria como transformar dados em fase para sequência, e então analisar).

Tabela 4-11 – Comparativo da variação de neurônios – Dados fasoriais em sequência / carga fixa / 2M

2 Medidores			
Quantidade de neurônios	20	30	40
Pior	36%	18%	9%
Melhor	100%	100%	100%
<i>k-folder</i>	36%	18%	9%
<i>k-folder-1</i>	82%	82%	45%

(ii) 3 Medidores

Seguem as Figura 4-39, Figura 4-40 e Figura 4-41 referente às simulações do sistema com carga fixa, considerando dados de entrada de 3 medidores, com variação do número de neurônios na rede.




Figura 4-39 - Fasorial em sequência / carga fixa/ 3 medidores/ 20 neurônios





Figura 4-40 - Fasorial em sequência / carga fixa/ 3 medidores/ 30 neurônios



**Figura 4-41 - Fasorial em seqüência / carga fixa/ 3 medidores/ 40 neurônios**

A Tabela 4-12 mostra um resumo de resultados encontrados nas simulações feitas em relação à variação de neurônios nas redes, todas com dados fasoriais em seqüência, considerando variações de medições de dois medidores e carga constante. As porcentagens indicam a incidência de erros nulos em cada situação.

Analisando-se os resultados, a rede que apresentou melhor comportamento foi aquela com uma menor quantidade de neurônios na camada interna. Nessa situação, 100% das execuções, independentemente dos três medidores usados, possuem erros nulos como melhor resultado. Além disso, 33% dos piores resultados possuem erros nulos.

**Tabela 4-12 – Comparativo da variação de neurônios – Dados fasoriais em seqüência / carga fixa / 3M**

<b>3 Medidores</b>			
<b>Quantidade de neurônios</b>	<b>20</b>	<b>30</b>	<b>40</b>
Pior	33%	16%	15%
Melhor	100%	100%	100%
<i>k-folder</i>	33%	16%	15%
<i>k-folder-1</i>	69%	53%	44%

Nas análises feitas, as cargas dos sistemas foram consideradas constantes, sendo esta situação uma boa aproximação do sistema real. Nota-se uma maior taxa de acerto nos dados em seqüência. 100% dos dados em seqüência possuem erros nulos como melhor resultado, ou seja, a



detecção de defeito utilizando esta rede é mais eficiente. Observa-se também que uma quantidade menor de neurônios apresentou uma melhor performance no sistema IEEE 123.

#### 4.4 Testes com o Sistema 123 – Com Carga Variável

Neste item serão apresentados os resultados obtidos através do método desenvolvido para detectar defeitos no sistema de energia, onde no caso as cargas consideradas são variáveis.

Será realizada a variação do número de camadas ocultas, conforme indicado na árvore de simulações na Figura 4-42. Para cada situação indicada na árvore também haverá a variação do número de medidores considerados como entrada da rede neural, sendo dois ou três medidores utilizados. Além disso, não serão utilizados sempre os mesmos medidores, sendo feitas combinações dois a dois ou três a três dos medidores existentes no sistema M2 ao M12 na Figura 4-1, com exceção do medidor M1 que será sempre considerado.

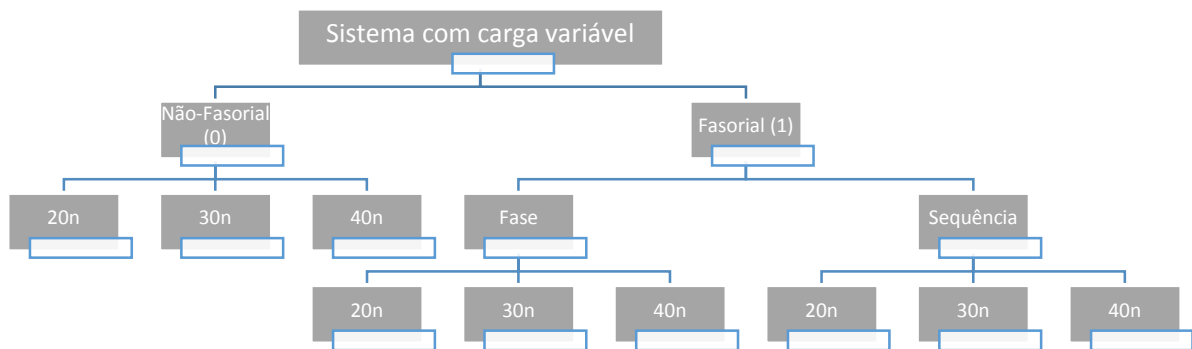



Figura 4-42 – Simulações do sistema com carga fixa

##### 4.4.1 Avaliação do Desempenho do Sistema com Carga Variável


###### 1. Dados não-fatoriais:

###### (i) 2 Medidores

Seguem as Figura 4-43, Figura 4-44 e Figura 4-45 referentes às simulações do sistema com carga variável, considerando dados de entrada de 2 medidores, com variação do número de neurônios na rede.



**Figura 4-43 - Não-fasorial / carga variável/ 2 medidores/ 20 neurônios**



**Figura 4-44 - Não-fasorial / carga variável/ 2 medidores/ 30 neurônios**




Figura 4-45 - Não-fasorial / carga variável/ 2 medidores/ 40 neurônios

A Tabela 4-13 mostra um resumo de resultados encontrados nas simulações feitas em relação à variação de neurônios nas redes, todas com dados não-fasoriais, considerando variações de medições de dois medidores e variação de carga. As percentagens indicam a incidência de erros nulos em cada situação.

Analisando-se os resultados, a rede que apresentou melhor comportamento foi aquela com 30 neurônios na camada interna. Nessa situação, 82% das execuções, independentemente dos dois medidores usados nas combinações, possuem erros nulos como melhor resultado.


Nota-se que os valores de *k-folder* e *k-folder-1* são baixos, o que demonstra a dificuldade de achar bons resultados com representação de cargas variáveis.

Tabela 4-13 – Comparativo da variação de neurônios – Dados não-fasoriais/ carga variável/ 2M


2 Medidores			
Quantidade de neurônios	20	30	40
Pior	0%	0%	9%
Melhor	55%	82%	73%
<i>k-folder</i>	0%	0%	9%
<i>k-folder-1</i>	9%	18%	9%

**(ii) 3 Medidores**


Seguem as Figura 4-46, Figura 4-47 e Figura 4-48 referentes às simulações do sistema com carga variável, considerando dados de entrada de 3 medidores, com variação do número de neurônios na rede.



**Figura 4-46 - Não-fasorial / carga variável/ 3 medidores/ 20 neurônios**



**Figura 4-47 - Não-fasorial / carga variável/ 3 medidores/ 30 neurônios**



**Figura 4-48 - Não-fasorial / carga variável/ 3 medidores/ 40 neurônios**

A Tabela 4-14 mostra um resumo de resultados encontrados nas simulações feitas em relação à variação de neurônios nas redes, todas com dados não-fasoriais, considerando variações de medições de três medidores e variação de carga. As percentagens indicam a incidência de erros nulos em cada situação.

Analisando-se os resultados, a rede que apresentou melhor comportamento foi aquela com uma maior quantidade de neurônios na camada interna. Com 40 neurônios, 53% das execuções, independentemente dos três medidores utilizados nas combinações, possuem erros nulos como melhor resultado.

Nota-se que os valores de *k-folder* e *k-folder-1* são baixos, o que demonstra a dificuldade de achar bons resultados com representação de cargas variáveis.

**Tabela 4-14 – Comparativo da variação de neurônios – Dados não-fasoriais / carga variável/ 3M**

3 Medidores			
Quantidade de neurônios	20	30	40
Pior	0%	2%	0%
Melhor	40%	36%	53%
<i>k-folder</i>	0%	2%	0%
<i>k-folder-1</i>	0%	5%	2%

## 2. Dados Fasoriais em Fase:

### (i) 2 Medidores

Seguem as Figura 4-49, Figura 4-50 e Figura 4-51 referentes às simulações do sistema com carga variável, considerando dados de entrada de 2 medidores, com variação do número de neurônios na rede.




Figura 4-49 - Fasorial em fase / carga variável/ 2 medidores/ 20 neurônios




Figura 4-50 - Fasorial em fase / carga variável/ 2 medidores/ 30 neurônios




Figura 4-51 - Fasorial em fase / carga variável/ 2 medidores/ 40 neurônios

A Tabela 4-15 mostra um resumo de resultados encontrados nas simulações feitas em relação à variação de neurônios nas redes, todas com dados fasoriais em fase, considerando variações de medições de dois medidores e variação de carga. As porcentagens indicam a incidência de erros nulos em cada situação.

Analisando-se os resultados, a rede que apresentou melhor comportamento foi aquela com 30 neurônios na camada interna. Nessa situação, 18% das execuções, independentemente dos dois medidores utilizados nas combinações, possuem erros nulos como melhor resultado.


Nota-se que os valores de *k-folder* e *k-folder-1* são baixos, o que demonstra a dificuldade de achar bons resultados com representação de cargas variáveis.

Tabela 4-15 – Comparativo da variação de neurônios – Dados fasoriais em fase / carga variável / 2M


2 Medidores			
Quantidade de neurônios	20	30	40
Pior	0%	9%	0%
Melhor	9%	18%	9%
<i>k-folder</i>	0%	9%	0%
<i>k-folder-1</i>	9%	9%	9%

**(ii) 3 Medidores**

Seguem as Figura 4-52, Figura 4-53 e Figura 4-54 referentes às simulações do sistema com carga variável, considerando dados de entrada de 3 medidores, com variação do número de neurônios na rede.




**Figura 4-52 - Fatorial em fase / carga variável/ 3 medidores/ 20 neurônios**



**Figura 4-53 - Fatorial em fase / carga variável/ 3 medidores/ 30 neurônios**





**Figura 4-54 - Fasorial em fase / carga variável/ 3 medidores/ 40 neurônios**

A Tabela 4-16 mostra um resumo de resultados encontrados nas simulações feitas em relação à variação de neurônios nas redes, todas com dados fasoriais em fase, considerando variações de medições de três medidores e variação de carga. As porcentagens indicam a incidência de erros nulos em cada situação.

Analisando-se os resultados, a rede que apresentou melhor comportamento foi aquela com uma maior quantidade de neurônios na camada interna. Nessa situação utilizando 40 neurônios, 18% das execuções, independentemente dos três medidores utilizados nas combinações, possuem erros nulos como melhor resultado. Além disso, 5% dos piores resultados possuem erros nulos.

Nota-se que, para cargas variáveis, a taxa de acerto na simulação diminui muito. Os valores de *k-folder* e *k-folder-1* são baixos, o que demonstra a dificuldade de achar bons resultados com representação de cargas variáveis.

**Tabela 4-16 – Comparativo da variação de neurônios – Dados fasoriais em fase / carga variável/ 3M**

3 Medidores			
Quantidade de neurônios	20	30	40
Pior	5%	2%	5%
Melhor	13%	18%	18%
<i>k-folder</i>	5%	2%	5%
<i>k-folder-1</i>	11%	9%	11%

### 3. Dados Fasoriais em Sequência:

(i) 2 Medidores

Seguem as Figura 4-55, Figura 4-56 e Figura 4-57 referentes às simulações do sistema com carga variável, considerando dados de entrada de 2 medidores, com variação do número de neurônios na rede.




Figura 4-55 - Fasorial em sequência / carga variável/ 2 medidores/ 20 neurônios




Figura 4-56 - Fasorial em sequência / carga variável/ 2 medidores/ 30 neurônios




Figura 4-57 - Fasorial em sequência / carga variável/ 2 medidores/ 40 neurônios

A Tabela 4-17 mostra um resumo de resultados encontrados nas simulações feitas em relação à variação de neurônios nas redes, todas com dados fasoriais em sequência, considerando variações de medições de dois medidores e variação de carga. As porcentagens indicam a incidência de erros nulos em cada situação.

Analisando-se os resultados, a rede que apresentou melhor comportamento foi aquela com 30 neurônios na camada interna. Nessa situação, 73% das execuções, independentemente dos dois medidores utilizados nas combinações, possuem erros nulos como melhor resultado.


Nota-se que, para cargas variáveis, a taxa de acerto na simulação diminui muito. Os valores de *k-folder* e *k-folder-1* são baixos, o que demonstra a dificuldade de achar bons resultados com representação de cargas variáveis.

Tabela 4-17 – Comparativo da variação de neurônios – Dados fasoriais em sequência / carga variável/ 2M


2 Medidores			
Quantidade de neurônios	20	30	40
Pior	0%	0%	0%
Melhor	64%	73%	64%
<i>k-folder</i>	0%	0%	0%
<i>k-folder-1</i>	9%	9%	0%

**(ii) 3 Medidores**


Seguem as Figura 4-58, Figura 4-59 e Figura 4-60 referentes às simulações do sistema com carga variável, considerando dados de entrada de 3 medidores, com variação do número de neurônios na rede.



**Figura 4-58 - Fatorial em seqüência / carga variável/ 3 medidores/ 20 neurônios**



**Figura 4-59 - Fatorial em seqüência / carga variável/ 3 medidores/ 30 neurônios**



**Figura 4-60 - Fasorial em sequência / carga variável/ 3 medidores/ 40 neurônios**

A Tabela 4-18 mostra um resumo de resultados encontrados nas simulações feitas em relação à variação de neurônios nas redes, todas com dados fasoriais em sequência, considerando variações de medições de três medidores e variação de carga. As percentagens indicam a incidência de erros nulos em cada situação.

Analisando-se os resultados, a rede que apresentou melhor comportamento foi aquela com uma menor quantidade de neurônios na camada interna. Nessa situação utilizando 20 neurônios, 53% das execuções, independentemente dos três medidores utilizados nas combinações, possuem erros nulos como melhor resultado.

**Tabela 4-18 – Comparativo da variação de neurônios – Dados fasoriais em sequência / carga variável/ 3M**

3 Medidores			
Quantidade de neurônios	20	30	40
Pior	0%	0%	5%
Melhor	53%	42%	16%
<i>k-folder</i>	0%	0%	5%
<i>k-folder-1</i>	0%	0%	13%

Nas análises feitas com cargas dos sistemas variáveis, notou-se que a detecção ficou muito mais difícil, com valores muito baixos de acertos e *k-folder* quase nulos em todas as simulações.

## **4.5 Constatações pelas comparações entre as estruturas analisadas**

Depois de realizadas diversas simulações no sistema IEEE123 para detecção de defeitos de baixa e média impedância, considerando nos dados de teste a resistência de curto-circuito variável, notou-se fatos relevantes que serão resumidos a seguir. Porém, cabe ressaltar que não podem ser considerados constatações generalizadas, uma vez que mais testes seriam necessários. No entanto, considera-se importante salientá-los, uma vez que são informações interessantes e úteis para maiores investigações.

- O aumento do número de medições, utilizadas como entradas das redes, não conduz sempre para uma maior taxa de acerto das redes neurais do tipo reconhecimento de padrões utilizadas neste trabalho. Um motivo seria que dois medidores podem apresentar informações semelhantes e confundir a rede neural;
- O aumento ou redução do número de neurônios da camada oculta da rede neural não se generalizou como uma característica que leva a uma melhor eficiência da rede neural. Nos casos testados, notou-se que, para cada tipo de rede neural, uma determinada configuração de camada oculta seria indicada. Portanto, devem ser feitos testes para tomar a decisão quanto a este quesito em cada situação;
- Verificou-se que as redes com dados de entrada informados em componentes de sequência apresentaram, em geral, melhores resultados que aqueles obtidos com redes cujos dados de entrada eram informados em coordenadas de fase. Este resultado contrariou expectativas iniciais nas quais esperava-se que as entradas em coordenadas de fase, considerando os fasores diretamente, apresentariam melhores resultados;
- Notou-se também que as localizações das unidades de medição utilizadas nos dados de entrada apresentaram grande impacto na eficiência dos métodos propostos. Contudo, não foram realizados estudos aprofundados neste quesito.

## Capítulo 5 Conclusões

### 5.1 Conclusões Gerais

Neste trabalho foi desenvolvido um método utilizando redes neurais para a detecção de defeitos monofásicos na média tensão envolvendo o solo, com baixa e média impedância de curto-circuito, em sistemas de distribuição.

Foram propostas e analisadas diversas configurações de redes neurais para esta tarefa. Foram utilizadas no desenvolvimento as redes neurais artificiais de reconhecimento de padrões, onde as entradas são grandezas elétricas de tensão e corrente, podendo ser medições fasoriais e/ou não-fasoriais.

O método proposto conseguiu identificar defeitos monofásicos com resistência de arco variando entre 0 a 20 ohms, e para isto foram testadas a utilização de dados de medições em diversos pontos da rede de distribuição.

Também foi realizada uma extensiva avaliação para comparar diferentes características para as redes utilizadas para a detecção, considerando variações nas entradas de dados e arranjos de redes neurais para a detecção de defeitos. Resumindo, foi avaliado o comportamento da uma rede neural quando submetida a apenas entradas não-fasoriais, apenas entradas fasoriais e entradas em componentes de sequências, além de modificações na estrutura da rede como o número de neurônios da camada intermediária.

Notou-se, para a detecção do tipo de defeitos e sistema estudados, que medições com base em componentes de sequência utilizadas como dados de entrada auxiliaram consideravelmente na detecção, mas notou-se também que uma alocação otimizada dos pontos de medições não-fasoriais pode melhorar a detecção. Uma questão que permaneceu em aberto é a comparação do aumento da qualidade das medições (aumento de medições fasoriais) x aumento da quantidade de informações (medições não-fasoriais).

Considera-se os resultados obtidos interessantes, porém, tem-se a clareza de que muito mais trabalho (mais simulações, mais correlações, mais casos analisados) é necessário para poder generalizar as observações e conclusões aqui obtidas para outros sistemas também.

## **5.2 Trabalhos Futuros**

Pode-se pensar em melhorias para os métodos propostos e além disso, existem análises relativas à detecção de defeitos que podem também ser mais exploradas utilizando o método proposto e estratégias diferenciadas de simulação de redes neurais. Assim, ficam como sugestões para trabalhos futuros:

- ✓ Comparação do aumento da qualidade das medições (aumento de medições fasoriais) x aumento da quantidade de informações (medições não-fasoriais).
- ✓ Desenvolvimento de redes neurais para detecção de outros tipos de defeitos, como fase-fase.
- ✓ Consideração da detecção de defeitos em redes de distribuição na presença de geração distribuída.
- ✓ Utilização do método proposto em um sistema de distribuição real.



## Bibliografia

- Abdel-Akher, M.; Nor, K. M., 2010 “*Fault analysis of multiphase distribution systems using symmetrical components*”, Power Delivery, IEEE Transactions on, v. 25, n. 4, p. 2931–2939.
- Andrade, S. R. C., 2008, “*Sistemas de medição fasorial sincronizada*”, Belo Horizonte.
- Borba, S; Pires, R, 2006, “*Vantagens da instalação para as empresas de transmissão e para o operador nacional do sistema de PMU/SPMS (unidade de medição fasorial/sistemas de medição fasorial sincronizada)*”. X Simpósio de Especialistas em Planejamento da Operação e Expansão Elétrica, Florianópolis, Brasil.
- Borges, A. Afonso, 2013, “*Redes neurais artificiais (perceptron e adaline)*”. Material de Aula - Universidade Federal de Uberlândia.
- Bretas, A. S., Salim, K. C., & Salim, R. H. 2012, “*Hybrid fault diagnosis formulation for unbalanced underground distribution feeders*”, International Journal of Power and Energy Systems, 32(1), 12.
- Butler, K. L.; Momoh, J. A., 1993, “*Detection and classification of line faults on power distribution systems using neural networks*”, Proceedings of the 36<sup>th</sup> Midwest Symposium on Circuits and Systems, 1993, p. 368–371 vol.1”.
- Carvalho Filho, M., Penido, D. R. R., Araujo, L. R., 2015, “*A fault analysis algorithm for unbalanced distribution systems*”. Revista IEEE América Latina, v. 13, p. 107-115.
- Churchland, P. S. and Sejnowski, T. J., 1992, “*The computational brain*”, MA: MIT Press.
- Eberl, G., Hänninen, S., Lehtonen, M., & Schegner, P., 2000, “*Comparison of artificial neural networks and conventional algorithms in ground fault distance computation*”. In Power Engineering Society Winter Meeting, IEEE (Vol. 3, pp. 1991-1996).

- Ehrensperger, J. G., 2004, “*Sistemas de medição fasorial sincronizada: análise do estado da arte e aplicações no monitoramento de sistemas de energia elétrica*”, Dissertação, Santa Catarina: Universidade Federal de Santa Catarina.
- Fausett, L., 1994, “*Fundamentals of neural networks: architectures, algorithms, and applications*”. Englewood Cliffs, Prentice Hall.
- Filho, S. M. Et all, 2005, “*Sistema de medição fasorial princípios e aplicações*”, VIII STPC-ST21.
- Garcia, J. C., Vega Garcia, V., & Kagan, N. 2014, “*Detection of high impedance faults in overhead multi grounded networks*”, In Industry Applications (INDUSCON), 2014 11<sup>th</sup> IEEE/IAS International Conference on (pp. 1-6). IEEE.
- Gomes, H. M., 2012, “*Reconhecimento de Padrões e Redes Neurais*”.
- Haykin, S., 2001, “*Redes neurais princípios e prática*”, 2<sup>o</sup> edição, Porto Alegre.
- Huang, Y.-C.; Yang, H.-T.; Huang, C.-L., 1997, “*A new intelligent hierarchical fault diagnosis system*”, IEEE Transactions on Power Systems, v. 12, n. 1, p. 349–356.
- Ledesma, J. J. G., 2012, “*Uma metodologia para análise da coordenação e seletividade da proteção de sistemas de distribuição*”, Juiz de Fora: Universidade Federal de Juiz de Fora.
- Michalik, M., Rebizant, W., Lee, S. J., & Kang, S. H., 2008, “*New ANN-based algorithms for detecting HIFs in multigrounded MV networks*”, Power Delivery, IEEE Transactions on, 23(1), 58-66
- Mynan, M. V., Harikrishna A., Singh V., 2011, “*Sincrofasores redefinindo os sistemas SCADA*”.
- Nikoofekr, I., Sarlak, M., & Shahrtash, S., 2013, “*Detection and classification of high impedance faults in power distribution networks using ART neural networks*”, In Electrical Engineering (ICEE), 2013 21st Iranian Conference on (pp. 1-6). IEEE.

- Ou, T. C., 2013, “*Ground fault current analysis with a direct building algorithm for microgrid distribution*”, International Journal of Electrical Power & Energy Systems, 53, 867-875.
- Penido, D. R. R., Araujo, L. R., Carneiro JR, S., Pereira, J. L. R., 2013, “*A new tool for multiphase electrical systems analysis based on current injection method*”, International Journal of Electrical Power & Energy Systems, v. 44, p. 410-420.
- Penido, D. R. R., Araujo, L. R., Carvalho Filho, M., 2015 “*An Enhanced Tool for Fault Analysis in Multiphase Electrical Systems*” International Journal of Electrical Power & Energy Systems, Volume 75, Pages 215–225.
- PRODIST 8, 2010 - Agência Nacional de Energia Elétrica – ANEEL, “*Procedimentos de distribuição de energia elétrica no sistema elétrico nacional – PRODIST: qualidade da energia elétrica, procedimento (módulo 8)*”. Brasília, DF. Disponível [http://www.aneel.gov.br/arquivos/PDF/Modulo8\\_Revisao\\_5.pdf](http://www.aneel.gov.br/arquivos/PDF/Modulo8_Revisao_5.pdf). Acesso em: 15 Maio 2015.
- Riani, L. M., 2008 “*Análise de defeitos em coordenadas de fase utilizando modelagem a quatro condutores e fluxo de potência continuado*”, Juiz de Fora: Universidade Federal de Juiz de Fora.
- Rosenblatt, F., 1958, “*The Perceptron: A probabilistic model for information storage and organization in the brain*”. Psychol. Ver., 65:386-408.
- Salim, R. H., De Oliveira, K. R. C., Filomena, A. D., Resener, M., & Bretas, A. S., 2008, “*Hybrid fault diagnosis scheme implementation for power distribution systems automation*”, Power Delivery, IEEE Transactions on, 23(4), 1846-1856.
- Sarlak, M., & Shahrtash, S., 2011, “*High impedance fault detection using combination of multi-layer perceptron neural networks based on multi-resolution morphological gradient features of current waveform*”, Generation, Transmission & Distribution, IET, 5(5), 588-595.
- Silva, I. N., 2005, “*Redes neurais artificiais para engenharia e ciências aplicadas*”.

- Souza, J. A., 1999, “*Reconhecimento de padrões usando indexação recursiva*”, Florianópolis.
- Souza, M. de S., 2003, “*Análise trifásica de defeitos utilizando-se fluxo de potência continuado baseado no método de injeção de correntes trifásico – MICT*”, Juiz de Fora: Universidade Federal de Juiz de Fora.
- Todesco, J.L, 1995, “*Reconhecimento de Padrões usando uma rede neuronal artificial com uma função de base radial: uma aplicação na classificação de cromossomos humanos*”. Tese apresentada ao Programa de Pós-Graduação em Engenharia de Produção da Universidade Federal de Santa Catarina para obtenção do Título de Doutor em Engenharia, Florianópolis.
- Von Zuben, F. J, Castro, L. N., 2003, “*RNAs, Classificação de Padrões e Motivação Geométrica*”, Notas de aula da disciplina Redes Neurais, Faculdade de Engenharia Elétrica e Engenharia Computação da Unicamp, Campinas-SP, 2003.
- Warren, C. A., 1996, “*Distribution reliability: what is it?*”, IEEE Industry Applications Magazine, Piscataway .
- Yan, X. Q., Xu, Z. Y., Wen, A.; Yang, Q. X., 2012, “*Fault analysis principle for twelve-phase transmission system*”, IEEE PES General Meeting, pp.1-6.