



UNIVERSIDADE ESTADUAL PAULISTA
“JÚLIO DE MESQUITA FILHO”
Campus de Ilha Solteira

PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

Desenvolvimento de um Sistema Inteligente para o
Diagnóstico e Prognóstico de Falhas em Sistemas de
Distribuição de Energia Elétrica

MAURO DE SOUZA TONELLI NETO

Orientador: Prof. Dr. Carlos Roberto Minussi

Tese apresentada à Faculdade de
Engenharia – UNESP – Campus de Ilha
Solteira, para obtenção do título de Doutor
em Engenharia Elétrica.

Área de Conhecimento: Automação.

Ilha Solteira – SP
Janeiro/2015

FICHA CATALOGRÁFICA

Desenvolvido pelo Serviço Técnico de Biblioteca e Documentação

T664d Tonelli-Neto, Mauro de Souza.
Desenvolvimento de um sistema inteligente para o diagnóstico e prognóstico de falhas em sistemas de distribuição de energia elétrica / Mauro de Souza Tonelli-Neto. -- Ilha Solteira: [s.n.], 2015
111 f. : il.

Tese (doutorado) - Universidade Estadual Paulista. Faculdade de Engenharia de Ilha Solteira. Área de conhecimento: Automação, 2015

Orientador: Carlos Roberto Minussi
Inclui bibliografia

1. Transformada wavelet. 2. Redes neurais artificiais. 3. Teoria da evidência. 4. Diagnóstico de falhas. 5. Prognóstico de falhas. 6. Sistema de distribuição de energia elétrica.



CERTIFICADO DE APROVAÇÃO

TÍTULO: Desenvolvimento de um Sistema Inteligente para o Diagnóstico e Prognóstico de Falhas em Sistemas de Distribuição de Energia Elétrica

AUTOR: MAURO DE SOUZA TONELLI NETO

ORIENTADOR: Prof. Dr. CARLOS ROBERTO MINUSSI

Aprovado como parte das exigências para obtenção do Título de DOUTOR EM ENGENHARIA ELÉTRICA, Área: AUTOMAÇÃO, pela Comissão Examinadora:


Prof. Dr. CARLOS ROBERTO MINUSSI
Departamento de Engenharia Elétrica / Faculdade de Engenharia de Ilha Solteira


Prof. Dr. DILSON AMANCIO ALVES
Departamento de Engenharia Elétrica / Faculdade de Engenharia de Ilha Solteira


Prof. Dr. FABIO ROBERTO CHAVARETTE
Departamento de Matemática / Faculdade de Engenharia de Ilha Solteira


Prof. Dra. FERNANDA CASEÑO LIMA TRINDADE
Departamento de Sistemas de Energia Elétrica / Universidade Estadual de Campinas


Prof. Dra. LUCIANA CAMBRAIA LEITE
Departamento de Sistemas de Engenharia Elétrica / Universidade Federal do Mato Grosso do Sul

Data da realização: 30 de janeiro de 2015.

AGRADECIMENTOS

Primeiramente, agradeço a Deus por ter me concedido o dom da vida, pela força, luz e oportunidades dadas a mim para que conseguisse alcançar meus objetivos.

Ao meu incrível orientador Prof. Dr. Carlos Roberto Minussi, por depositar em mim a confiança de realização desta pesquisa, pela atenção, dedicação, empenho e por contribuir para o meu aprendizado desde o segundo ano de graduação. Pelo amigo e pai que se mostrou, sempre com palavras incentivadoras a cada vitória, e palavras consoladoras a cada tropeço.

Aos meus pais, Mauro de Souza Tonelli Júnior e Maria Abadia Marques Gaspar Tonelli, que sempre estiveram ao meu lado dando total apoio e incentivo em minha busca pelo conhecimento e realização de meus sonhos. Às minhas irmãs, Jackeline Marques Tonelli e Karolinne Marques Tonelli, pelo carinho e apoio. À minha namorada, e futura esposa, Virgínia Utida Barros, pelo amor, incentivo, paciência e compreensão.

A todos os meus amigos que sempre estiveram ao meu lado. Em especial, ao meu irmão de espírito Thiago Augusto Dolacio Maia e Silva pela sincera e eterna amizade. Aos meus grandes amigos e companheiros de trabalho José Guilherme Magalini Santos Decanini e Ana Claudia Barros, por contribuírem de forma providencial para o meu crescimento pessoal e profissional.

A todos os professores que contribuíram para o desenvolvimento desta tese, em especial Prof^a. Dr^a. Anna Diva Plasencia Lotufo, Prof. Dr. Dilson Amancio Alves, Prof. Dr. Fábio Roberto Chavarette, Prof^a. Dr^a. Fernanda Caseño Lima Trindade, Prof^a. Dr^a Lilian Yuli Isoda, Prof^a. Dr^a. Luciana Cambraia Leite e Prof^a. Dr^a. Mara Lúcia Martins Lopes.

A Fapesp pelo auxílio financeiro concedido, através de uma bolsa de estudos e reserva técnica, que permitiu que eu pudesse me dedicar exclusivamente ao desenvolvimento desta pesquisa.

RESUMO

Nesta pesquisa apresenta-se o desenvolvimento de um sistema inteligente que realize, de maneira integrada, o diagnóstico e o prognóstico de falhas nos sistemas de distribuição de energia elétrica de maneira proativa. Trata-se de um procedimento para identificar, classificar e localizar situações críticas de defeitos que potencialmente podem provocar danos em componentes do sistema em um estágio incipiente àquele que venha causar a interrupção do fornecimento de energia aos consumidores. Este sistema inteligente baseia-se no uso combinado da transformada *wavelet*, teoria da evidência de Dempster-Shafer e redes neurais artificiais, em especial uma arquitetura da família ART (*Adaptive Resonance Theory*), a rede neural ARTMAP-*Fuzzy*. Por ser uma arquitetura estável e plástica, esta rede neural permite a inclusão do módulo do treinamento continuado, o qual possibilita a extração do conhecimento sem a necessidade de reiniciar o processo de treinamento com a inclusão de novos padrões, diferentemente do que ocorre com a maioria das redes neurais. O sistema contempla as principais falhas caracterizadas por distúrbios de tensão e faltas de alta impedância. Resultados obtidos mostram a eficiência, confiabilidade e robustez da metodologia desenvolvida, o que permite sua aplicação em sistemas de tempo real.

Palavras-chave: Transformada *wavelet*. Redes neurais artificiais. Teoria da evidência. Diagnóstico de falhas. Prognóstico de falhas. Sistema de distribuição de energia elétrica.

ABSTRACT

This project presents the development of an intelligent system that performs, on an integrated way, the failure diagnosis and prognosis in electric power distribution systems. It is a procedure to identify, classify and localize critical situations of failures that can potentially cause damage to system's components in an incipient stage of that which will cause the interruption of electric power supply to consumers. This intelligent system is based on the combined use of wavelet transform, Dempster-Shafer theory of evidence and artificial neural networks, in special the ART (*Adaptive Resonance Theory*) family architecture, i.e., the ARTMAP-*Fuzzy*. Due to the stability and plasticity characteristics, this architecture enables the introduction of the continuous training module, which allows the knowledge extraction without the need to restart the training process when a new training pattern is included, unlike what happens in most neural networks. The system contemplates the main failures characterized by voltage disturbances and high impedance faults. Results show the efficiency, speed, reliability and robustness of the developed methodology, which allows its application in real-time systems.

Keywords: Wavelet transform. Artificial neural networks. Evidence theory. Failure diagnosis. Failure prognosis. Electric power distribution system.

SUMÁRIO

1	INTRODUÇÃO	17
1.1	Contribuições da Tese	20
1.2	Estrutura do Texto	21
2	ESTADO DA ARTE	23
3	FALHAS EM SISTEMAS DE DISTRIBUIÇÃO DE ENERGIA ELÉTRICA	31
4	METODOLOGIA DE DIAGNÓSTICO E PROGNÓSTICO DE FALHAS	37
5	EXEMPLO DE APLICAÇÃO	51
6	APLICAÇÕES, RESULTADO E DISCUSSÕES	59
6.1	Base de Dados	59
<i>6.1.1</i>	<i>Sistema Teste</i>	<i>59</i>
<i>6.1.2</i>	<i>Simulações</i>	<i>60</i>
6.2	Diagnóstico e Prognóstico de Falhas	63
7	CONCLUSÕES	67
	REFERÊNCIAS	71
	APÊNDICE A – TRANSFORMADA <i>WAVELET</i>	77
A.1	Transformada Wavelet Contínua	77
A.2	Transformada <i>Wavelet</i> Discreta	78
A.3	Análise Multirresolução	79
A.4	Famílias de Wavelets	80
A.5	Energia	81
	APÊNDICE B – REDES NEURAIS ARTIFICIAIS	83
B.1	Rede Neural ARTMAP-<i>Fuzzy</i>	83
<i>B.1.1</i>	<i>Dados de Entrada</i>	<i>84</i>
<i>B.1.2</i>	<i>Parâmetros</i>	<i>85</i>

B.1.3	<i>Inicialização dos Pesos</i>	85
B.1.4	<i>Escolha da Categoria</i>	86
B.1.5	<i>Ressonância ou Reset</i>	87
B.1.6	<i>Aprendizado</i>	87
B.2	Algoritmos da Rede Neural ARTMAP-Fuzzy	88
B.2.1	<i>Algoritmo de Treinamento</i>	88
B.2.2	<i>Algoritmo de Teste</i>	90
APÊNDICE C – REDE NEURAL DE BASE RADIAL		93
C.1	Estrutura da Rede Neural de Base Radial	93
C.1.1	<i>Camada Escondida</i>	94
C.1.2	<i>Camada da Saída</i>	95
C.2	Treinamento da Rede Neural de Base Radial	96
C.2.1	<i>Ajuste dos Centros</i>	96
C.2.2	<i>Ajuste das Escalas</i>	96
C.2.3	<i>Ajuste dos Pesos</i>	97
C.3	Rede Neural de Base Radial x <i>Multilayer Perceptron</i>	97
APÊNDICE D – TEORIA DA EVIDÊNCIA DE DEMPSTER-SHAFFER		99
APÊNDICE E – SOFTWARE EMTP-RV		103
E.1	Modelagem da Alimentação	103
E.2	Modelagem do Transformador de Potência da Subestação Principal	104
E.3	Modelagem das Linhas	105
E.4	Modelagem de Cargas	106
E.5	Aquisição das Oscilografias de Tensão e de Corrente	107
E.6	Definição dos Parâmetros de Simulação	107
E.7	Exportação de Oscilografias	108
APÊNDICE F – TRABALHOS PUBLICADOS		111
F.1	Periódicos Internacionais	111

1 INTRODUÇÃO

No novo paradigma de sistemas elétricos, os chamados *Smart Grids*, a inteligência e a capacidade de aprendizado a serem incorporadas no sistema será fortemente dependente da aplicação de técnicas/tecnologias baseadas na extração, armazenamento e utilização do conhecimento (FAN; BORLASE, 2009; KEZUNOVIC, 2011; RUSSEL; BENNER, 2010). Estes itens serão necessários para dotar os *smart grids* com a capacidade de monitorar, corrigir, reconfigurar e propor ações antecipatórias de maneira automática à medida que sejam identificadas situações anormais na operação, visando garantir a confiabilidade, eficiência e a segurança do atendimento aos usuários da energia elétrica. Dentro desta perspectiva, faz-se necessário, então, desenvolver um sistema integrado, combinando aquisição, processamento e análise de dados, proporcionando a assistência necessária para realizar o controle e a tomada de decisão no ambiente de subestações de distribuição de energia elétrica (FAN; BORLASE, 2009; NORTHCORE-GREEN; WILSON, 2007; MCDONALD, 2003).

Com a expansão do sistema elétrico, em consequência do crescimento dos centros urbanos, grandes investimentos vêm sendo aplicados no desenvolvimento de novas técnicas/tecnologias e filosofias de proteção. Estes investimentos têm como principal objetivo a automação do sistema de distribuição de energia elétrica, *i.e.*, elementos e operação. A automação dos elementos está relacionada com a utilização de conceitos da inteligência artificial, de modo que os equipamentos sejam capazes de detectar, classificar, localizar e eliminar anormalidades sem a necessidade da intervenção dos operadores. Já a automação das operações, que corresponde a uma consequência da automação dos elementos, visa tornar o sistema proativo, ou seja, o processo de manutenção torna-se mais objetivo e eficiente como consequência da antecipação de informações a respeito da falha identificada no alimentador, *e.g.*, natureza e local. Desta forma, o centro de operações, a partir de informações adicionais, poderá mobilizar antecipadamente as equipes de manutenção, reduzindo o tempo necessário para restauração do estado normal de operação, elevando os índices de confiabilidade e qualidade do fornecimento de energia.

Em seu estado atual, o sistema de distribuição possui um baixo nível de monitoramento e uma baixa confiabilidade nos serviços disponibilizados aos consumidores. O baixo nível de monitoramento está relacionado com as informações obtidas do alimentador, *e.g.*, tensão,

corrente e potência, que são feitas, em sua maioria, somente na subestação principal. Por outro lado, a baixa confiabilidade se deve às práticas de diagnóstico de distúrbios serem realizadas por meio da inspeção visual de oscilografias pelos operadores, sendo fortemente dependentes da experiência em análise destes recursos. Ao utilizar operadores humanos, o processo torna-se passível de erros, que, em alguns casos extremos, podem causar a interrupção do fornecimento de energia. Logo, com a falta de informações mais abrangentes e completas de cada trecho do alimentador, a função do operador em determinar possíveis eventos de falha se torna ainda mais complexa, acarretando prejuízos para as concessionárias e consumidores. Neste contexto, as filosofias dos *smart grids* objetivam solucionar tais problemas, pois ao longo do alimentador serão alocados medidores, *e.g.*, *IEDs (Intelligent Electronic Devices)*, que, ininterruptamente, fornecerão informações aos operadores. Além disso, empregando técnicas inteligentes no sistema de distribuição, o processo de diagnóstico e prognóstico de falhas será automatizado, não dependendo exclusivamente da experiência dos operadores. Por fim, juntamente com os dados finais, informações qualitativas a respeito da confiabilidade serão disponibilizadas, tornando o procedimento mais robusto e imune a erros causados por agentes externos, *e.g.*, decisões equivocadas tomadas pelos operadores.

Em comparação com o sistema de transmissão de energia elétrica, o sistema de distribuição, por apresentar uma topologia predominantemente radial com inúmeras ramificações, está mais susceptível a falhas provocadas de forma direta ou indireta. As falhas podem ser causadas por animais que entram em contato com a rede energizada, queimadas, tempestades, pela ação do homem, *e.g.*, vandalismo e depredação, e por problemas elétricos, *e.g.*, queima/explosão de transformadores, excesso de carga e subdimensionamento de componentes. Na maior parte dos casos, as falhas são facilmente detectadas e localizadas, não acarretando em maiores prejuízos às concessionárias e seus consumidores. Como exemplo têm-se os curtos-circuitos e os distúrbios de tensão, que são identificados no alimentador de forma “reativa”, ou seja, os consumidores ao perceberem qualquer anormalidade no fornecimento de energia comunicam à concessionária tal evento. Posteriormente, via mapeamento das ligações, a equipe de manutenção é deslocada até a região provável da falha para iniciar o processo de busca e eliminação. No entanto, existem falhas que os sistemas de proteção não conseguem identificar em uma etapa incipiente àquela da interrupção do fornecimento de energia e eventuais danos aos equipamentos ligados à rede elétrica, isto por causa do seu comportamento singular, sendo denominadas falhas sutis. Normalmente este tipo de falha é confundido com a operação normal, *i.e.*, operando com uma falha sutil o alimentador não possui nenhum indício

de defeito ou interrupção no fornecimento de energia. Isto se deve aos transitórios nos sinais de tensão e corrente serem imperceptíveis (não suficientes para a atuação da proteção), fazendo com que tais falhas perdurem no alimentador por horas, dias ou até semanas, acarretando na drenagem de elevadas potências do sistema de distribuição de energia elétrica.

Uma falha que se enquadra no conjunto de falhas sutis são as faltas de alta impedância (FAI). Elas são oriundas do contato do condutor energizado, rompido ou não, com superfícies de alta impedância, *e.g.*, asfalto, calçada e areia, ou objetos de alta impedância, *e.g.*, galhos de árvores, os quais limitam os níveis de corrente de falta a valores inferiores aos detectáveis pelos equipamentos de proteção. Além disso, os sinais de corrente e de tensão consequentes das FAI são caracterizados por serem randômicos, *i.e.*, não apresentam comportamento bem definido, por causa das não-linearidades e pelo possível surgimento do arco elétrico. Existem relatos da presença de faltas de alta impedância no sistema de distribuição de energia elétrica que passam despercebidas pelos operadores, e que somente são identificadas quando evoluem para uma falha crítica, a qual danifica equipamentos ligados à rede elétrica e interrompem o fornecimento de energia (ETEMADI; SANAYE-PASAND, 2008; GAUTAM; BRAHMA, 2013; LAI *et al.*, 2005; SAMANTARAY, 2012; SAMANTARAY; DASH; UPADHYAY, 2009; SHENG; ROVNYAK, 2004; WAI; YIBIN, 1998).

Assim, com a reestruturação técnica e filosófica do sistema de distribuição de energia elétrica em andamento, as concessionárias devem objetivar o desenvolvimento e implementação de metodologias para identificação de falhas sutis, já que os problemas causados pelas falhas não sutis, *e.g.*, curtos-circuitos e distúrbios de tensão, vem sendo minimizados em virtude do emprego de equipamentos de proteção capazes de isolarem tais fenômenos de forma mais eficiente e confiável.

Dentro desta perspectiva, neste trabalho apresenta-se uma nova metodologia para o diagnóstico e o prognóstico de falhas sutis, mais especificamente as faltas de alta impedância, em sistema de distribuição de energia elétrica por meio do uso combinado de técnicas de processamento de sinais, sistemas inteligentes e fusão de sensores/informações. A metodologia apresenta duas etapas: (1) diagnóstico de falhas, e (2) prognóstico de falhas, as quais estão diretamente relacionadas, ou seja, todo o processo de detecção, classificação e localização de anormalidades possui características proativas. A etapa referente ao diagnóstico consiste na detecção, na classificação e na localização da falha. Já o prognóstico se deve a execução de todas estas tarefas para que a falha seja detectada, classificada e localizada em seu estágio

incipiente, *i.e.*, instante real de ocorrência, e não em um instante futuro após sofrer uma evolução crítica.

O procedimento de detecção e classificação de falhas é realizado pela análise contínua de oscilografias advindas de distintos pontos do alimentador. Empregando a análise multirresolução e o conceito energia extraem-se as principais características dos sinais de tensão e de corrente, de forma que seja possível distinguir a operação normal da operação sob falha. Por conseguinte, os índices representativos dos sinais compõem o vetor de entrada de múltiplas redes neurais ARTMAP-*Fuzzy*, as quais são responsáveis pelo diagnóstico inicial do estado operativo do sistema, *i.e.*, operação normal ou presença de falha. Caso o operador analise as informações de saída individualmente, a decisão tomada pode ser comprometida. Assim, um esquema de votação simples é usado para agregar as informações produzidas por cada rede neural, produzindo probabilidades referentes a cada estado de operação do sistema.

Ao serem identificados estados operativos anormais, *i.e.*, com falha, ativa-se o processo de localização. Como na etapa anterior, informações extraídas dos sinais de corrente e de tensão são utilizadas na composição dos vetores de entrada de novas redes ARTMAP-*Fuzzy*, agora responsáveis por definir a seção do alimentador em que a falha pode estar situada. Com isso, calcula-se a distância real das barras pertencentes à esta seção com relação às barras medidoras (referências). Concomitantemente, redes neurais de base radial fornecem a distância aproximada da falha com relação às mesmas referências. A diferença entre as distâncias reais e aproximadas são computadas e avaliadas por meio de uma função de densidade gaussiana e agregadas via teoria da evidência (BARNETT, 2008). Então, como resultado final é gerada uma lista com os possíveis locais de falha (barras), sendo associado a cada barra um valor de probabilidade, *i.e.*, chance real de a falha estar situada naquela barra.

1.1 Contribuições da Tese

Neste trabalho é proposta uma nova metodologia para a detecção, classificação e localização proativa de falhas sutis em sistemas de distribuição de energia elétrica. Todo o procedimento é realizado para evitar a evolução para eventos críticos das falhas sutis, minimizando, assim, os prejuízos causados às concessionárias e seus consumidores. A partir da aplicação desta ferramenta é possível identificar qualquer tipo de falha, incluindo as falhas sutis, em um estágio incipiente. Com isso, reduz-se os custos de manutenção nos alimentadores de distribuição, pois a chance de dano irreversível aos equipamentos/componentes do sistema é

menor, e também tem-se o aumento no valor dos índices de confiabilidade e qualidade do fornecimento da energia elétrica.

Esta tese possui contribuição com relação ao desenvolvimento de uma ferramenta de detecção e classificação em etapa única, ou seja, ininterruptamente é fornecido o estado operativo do alimentador. Para detecção de anormalidades não existe a necessidade de definição de parâmetros baseados na experiência do engenheiro de proteção ou do operador, como é feito nas metodologias clássicas. Isto faz com que a detecção e a classificação de anormalidades sejam mais confiáveis e eficientes, eliminando possíveis erros causados pela análise equivocada dos operadores humanos. Também, apresenta-se uma ferramenta inédita de localização de falhas sutis, que pode ser aplicada para localização de qualquer tipo de falha elétrica. Trata-se de uma metodologia simples e eficiente, pois utiliza dados obtidos de medidores alocados no sistema de distribuição. O resultado final é apresentado na forma de uma lista de barras candidatas a barra em falha, sendo cada barra acompanhada por um valor de probabilidade. Este valor de probabilidade serve de suporte para a equipe de manutenção, que pode traçar o caminho a ser percorrido com base nestes valores, tornando, assim, a busca pela falha mais objetiva.

A utilização das redes neurais nos processos de detecção, classificação e localização permite a autoadaptação do sistema de monitoramento, *i.e.*, com o surgimento de novas falhas e a constante expansão do sistema de distribuição novas informações podem ser incorporadas nos módulos por meio de realização de novos treinamentos ou por meio do treinamento continuado.

1.2 Estrutura do Texto

Quanto a apresentação do texto, este está disposto da seguinte forma: na Seção 2 faz-se uma breve revisão bibliográfica, descrevendo as contribuições dos principais artigos técnicos que abordam o diagnóstico e o prognóstico de falhas em sistemas elétricos de potência, enfatizando as técnicas empregadas. O comportamento das oscilografias de cada uma das falhas elétricas abordadas neste trabalho, *i.e.*, faltas de alta impedância, afundamento de tensão e transitório oscilatório, é descrito e ilustrado na Seção 3. Na Seção 4 apresenta-se a metodologia para a solução do problema de diagnóstico e de prognóstico, bem como as etapas do algoritmo e suas funções. A eficiência, confiabilidade e a aplicabilidade da metodologia são analisadas considerando um alimentador de distribuição de energia elétrica composto por 123 barras, conforme disposto na Seção 5. As conclusões e sugestões de trabalhos futuros são mostradas na Seção 6. As principais ferramentas empregadas no desenvolvimento do algoritmo, *i.e.*,

transformada *wavelet*, rede neural ARTMAP-*Fuzzy*, rede neural de base radial e teoria da evidência, são apresentadas nos Apêndices A, B, C e D, respectivamente. Nos apêndices E e F são mostrados o *software* EMTP-RV e as principais publicações do autor durante a realização da pesquisa, respectivamente.

2 ESTADO DA ARTE

Nos últimos anos, com o aumento da competitividade de mercado e leis mais rígidas impostas pelas agências reguladoras, as concessionárias se viram na necessidade de modernizar todos componentes do sistema de distribuição, melhorando a qualidade e confiabilidade do fornecimento da energia aos seus consumidores. Apesar de não ser uma tarefa simples, a difusão do conceito *smart grid* contribuiu para o aprimoramento do sistema. Esta difusão fez com que os centros de pesquisa dedicassem mais recursos para o desenvolvimento de ferramentas e de métodos mais inteligentes, possibilitando a automação de todas as operações do sistema de distribuição, tornando o processo de identificação de falhas menos dependentes da experiência em análise dos operadores humanos. As ferramentas e métodos propostos pela comunidade científica são, em sua maior parte, baseadas em modernas técnicas de processamento de sinais, *e.g.*, transformada *wavelet* (DAUBECHIES, 1992; MALLAT, 2009), conceitos da inteligência artificial, *e.g.*, redes neurais (KARTALOPOULOS, 1996; KUNG, 1993; WIDROW; LEHR, 1990), lógica *fuzzy* (JANG, 1993; KARTALOPOULOS, 1996; ZADEH, 1965) e sistemas imunológicos artificiais (CASTRO; VON ZUBEN, 2002), e técnicas de fusão da informação (HALL. LLINAS, 1997), *e.g.*, teoria da evidência (BARNETT, 2008; BUCHANAN; SHORTLIFFE, 1984; SHAFER, 1976; WILSON, 1999), modelo de Weibull (GROER, 2000; SCHÖMIG; ROSE, 2003; WEIBULL, 1951) e teoria da probabilidade Bayesiana (ARULAMPALAM *et al.*, 2002). Usando-se uma combinação destas técnicas, os algoritmos de diagnóstico e de prognóstico de falhas tornam-se mais robustos, eficientes e autoadaptativos, possibilitando, desta forma, a identificação de eventos mais críticos, *i.e.*, falhas sutis.

A seguir são apresentadas, em ordem cronológica, as publicações mais relevantes na área de diagnóstico e prognóstico de faltas de alta impedância, pois, além de serem as falhas sutis mais conhecidas, representam grandes problemas para as concessionárias.

Sultan, Swift e Fedirchuk (1992) propõem um detector de faltas de alta impedância. Um ciclo da corrente normal de carga do alimentador é armazenado como o padrão de referência da corrente de carga, sendo seu valor eficaz calculado. Um algoritmo é usado visando comparar o valor eficaz do ciclo atual com a referência. Caso o novo valor seja suficientemente diferente do valor de referência, o detector faz a aquisição de vinte ciclos de corrente. Assim, aplica-se uma rede neural *multilayer perceptron* com três camadas, treinada pelo algoritmo

backpropagation (WERBOS, 1974), a qual é responsável por definir se o distúrbio se trata de uma falta de alta impedância. O algoritmo proposto possui elevada capacidade de distinção entre os diferentes tipos de falha.

Mamishhev, Russell e Benner (1996) descrevem a aplicação dos conceitos da geometria fractal para analisar o comportamento aleatório das faltas de alta impedância. Os valores eficazes das correntes são usados na quantificação do comportamento do sistema de potência por algoritmos de cálculo da dimensão fractal e estimação estatística. O reconhecimento de padrões e, conseqüentemente, a detecção das faltas de alta impedância, é realizado por uma rotina de análise de pequenos conjuntos de dados. As simulações e os resultados mostram elevada capacidade de discriminação de falhas sutis e outros transitórios em sistemas de potência.

Wai e Yibin (1998) propõem uma técnica baseada em bancos de filtros de análise *wavelet* para identificar faltas de alta impedância no sistema de distribuição. O sinal é decomposto no domínio da frequência e do tempo, e, por meio da análise dos coeficientes de detalhe do primeiro e segundo nível determina-se o estado de operação do sistema. Os resultados mostram que os bancos de filtros de análise *wavelet* são úteis na detecção de falhas sutis com rapidez e precisão.

Huang e Hsieh (1999) apresentam uma aplicação das *wavelets* de Morlet na análise de sinais característicos de faltas de alta impedância. Devido a capacidade de localização no domínio tempo-frequência das *wavelets*, as informações do tempo e da frequência das oscilografias são preservadas, sendo mais indicadas na monitoração de sinais elétricos. A metodologia foi testada para sinais de faltas de alta impedância e sinais de transitórios gerados por outros eventos. Os resultados obtidos mostram a praticidade e eficiência das *wavelets* de Morlet na identificação de falhas sutis.

Jota e Jota (1999) propõem uma metodologia para a detecção de falhas sutis em alimentadores de distribuição de energia elétrica radiais. A técnica consiste na análise comparativa das respostas do alimentador aos pulsos injetados na subestação principal. As respostas às distintas operações compõem um conjunto padrão de falhas, e neurônios artificiais são treinados para reconhecer cada estado operativo, normal ou sob falha. Após o treinamento, os neurônios formam o sistema supervisorio, o qual será responsável pela identificação de faltas de alta impedância passivas. Para comprovar a eficiência do sistema supervisorio, utilizou-se um alimentador real de distribuição, obtendo resultados satisfatórios.

Lien *et al.* (1999) apresentam um método para detecção de faltas de alta impedância que monitora a variação de energia nas harmônicas de segunda, quarta e sexta ordem da corrente trifásica desbalanceada, diferentemente de como é feito nas metodologias convencionais, sendo a análise feita sobre os sinais de corrente das três fases. Para isso, a confiabilidade estatística é empregada na definição dos limiares de variação da energia, distinguindo a operação normal da falha sutil. Testes realizados indicam que a metodologia proposta possui elevada sensibilidade e confiabilidade quando aplicada na identificação de faltas de alta impedância.

Sheng e Rovnyak (2004) apresentam um método de detecção de faltas de alta impedância baseado em árvores de decisão. As características das falhas são todas extraídas dos sinais de corrente, sendo elas: valor eficaz da corrente, magnitudes da segunda, terceira e quinta harmônica, e a fase da terceira harmônica. O algoritmo, que foi treinado de forma *off-line*, é capaz de distinguir com sucesso a falta de alta impedância da operação normal. Os resultados obtidos indicam a possibilidade de aplicação em tempo real.

Lai *et al.* (2005) propõem a utilização da transformada *wavelet* discreta, análise de frequência e conversão eficaz no reconhecimento de padrões das faltas de alta impedância em sistemas de distribuição de energia elétrica. A análise empregando transformada *wavelet* discreta e a conversão produz medidas de tensão e corrente, as quais são entrada de um classificador. O classificador baseia-se na regra da vizinhança, e funciona como ferramenta de suporte à tomada de decisão. Resultados obtidos indicam a possibilidade de aplicação em um sistema real de monitoramento.

Sedighi, Haghifam e Malik (2005) propõem dois métodos para identificação de faltas de alta impedância em sistemas de distribuição de energia elétrica. A extração de características é feita por meio da transformada *wavelet*, a qual decompõe os sinais de corrente em três níveis. Correspondem às informações de entrada empregadas no processo os coeficientes dos três níveis. Em um dos métodos é aplicado o algoritmo genético para a redução da dimensão do vetor de características, sendo a identificação feita por um classificador Bayes. No outro, a redução da dimensão do vetor de entrada é feita pela análise do componente principal e a classificação feita por uma rede neural. Para validação da metodologia foram utilizados dados obtidos por meio de testes experimentais em laboratório e simulações no *software* EMTP. Os resultados mostram que qualquer uma das metodologias é capaz de identificar a falha sutil.

Michalik *et al.* (2006) apresentam um simples e efetivo algoritmo para identificação de falhas sutis nos alimentadores de distribuição de energia elétrica. A metodologia desenvolvida compara a defasamento angular entre os coeficientes *wavelet* calculados para tensão e corrente

de sequência zero para um determinado nível de resolução. No processo de tomada de decisão emprega-se lógica determinística juntamente com redes neurais artificiais, fornecendo a medida corretiva para eliminação da falha. Utilizando o *software* EMTP foram realizadas simulações para validação do algoritmo. Analisando-se os resultados obtidos observa-se que a técnica é robusta, uma vez que o algoritmo foi capaz de distinguir as faltas de alta impedância de transitórios gerados a partir de eventos normais.

Etemadi e Sanaye-Pasand (2008) propõem uma ferramenta de identificação de faltas de alta impedância em sistemas de distribuição de energia elétrica. As características são extraídas dos sinais de corrente pela análise multirresolução. Em seguida, estas informações são utilizadas como entrada de um sistema de inferência neuro-*fuzzy* adaptativo, o qual é responsável pela detecção e classificação da condição de operação do alimentador. Por causa da grande quantidade de famílias *wavelet*, faz-se um estudo da influência da *mother wavelet* empregada no processamento dos sinais. Analisando os resultados, conclui-se que a utilização do ANFIS tornou a metodologia eficiente, flexível e tolerante a dados imprecisos.

Samantaray, Panigrahi e Dash (2008) apresentam uma metodologia inteligente para a detecção de faltas de alta impedância em sistemas de distribuição de energia elétrica utilizando modernas ferramentas de processamento de sinais e redes neurais. Como existe certa dificuldade na identificação de falhas sutis empregando os relés convencionais, informações adicionais foram usadas na composição de um vetor de características. Para isso, foram aplicadas as transformadas S e TT para extração de singularidades no domínio tempo-frequência e tempo-tempo, respectivamente. Com isso, uma rede neural probabilística é treinada para que ela possua alta capacidade de generalização. Também, faz-se uma comparação qualitativa das redes *feedforward* e probabilística quando estas são aplicadas no processo de classificação. Os resultados alcançados caracterizam o método como rápido e preciso, podendo ser aplicado na proteção de grandes alimentadores.

Samantaray, Dash e Upadhyay (2009) propõem um sistema inteligente para detecção de faltas de alta impedância em sistemas de distribuição de energia elétrica usando, de forma combinada, filtro de Kalman adaptativo e rede neural probabilística. O filtro de Kalman é utilizado para estimar diferentes componentes de frequência presentes nas falhas sutis, os quais são empregados no treinamento e teste da rede neural. Uma comparação entre os desempenhos das redes *feedforward* e probabilística também é apresentado, e o resultado final mostra a robustez da técnica proposta com relação a presença de ruídos nas oscilografias.

Baqui *et al.* (2011) apresentam uma técnica baseada na combinação da transformada *wavelet* e redes neurais para a solução do problema de identificação de faltas de alta impedância em sistemas de distribuição de energia elétrica. A transformada *wavelet* é empregada na decomposição dos sinais de corrente no domínio do tempo em diferentes componentes harmônicas no domínio tempo-frequência, sendo, em seguida, selecionadas as assinaturas mais relevantes para treinamento da rede neural *multilayer perceptron*. Esta seleção reduz a dimensão do vetor de entrada da rede, melhorando sua convergência. Para verificação da metodologia foram aplicados dados obtidos por simulações em um alimentador real de distribuição sob inúmeras condições de operação. Os resultados obtidos mostram a eficiência na detecção e discriminação dos estados operativos do sistema.

Sarlak e Shahrtash (2011) propõem um algoritmo baseado no reconhecimento de padrões para a identificação de falhas sutis em sistemas de distribuição de energia elétrica com ou sem condutores rompidos. No sistema proposto é empregado o gradiente morfológico na extração das características no domínio tempo-frequência das oscilografias de corrente. A partir destas assinaturas, três redes neurais *multilayer perceptron* são treinadas, sendo suas saídas combinadas para fornecer o diagnóstico final. Além disso, faz-se uma comparação entre as metodologias de extração de características mais utilizadas, ou seja, transformada de Fourier, transformada S, transformada TT, transformada *wavelet* discreta e gradiente morfológico. Analisando-se o resultado final, nota-se que o gradiente morfológico apresenta desempenho melhor que as outras ferramentas.

Milioudis, Andreou e Labridis (2012a) apresentam uma técnica para a detecção de faltas de alta impedância em alimentadores rurais. Esta técnica utiliza-se da comunicação presente na rede elétrica para analisar a superposição de sinais e verificar a mudança na impedância de entrada da rede, levando em consideração parâmetros que possam interferir no resultado, *e.g.*, impedância e localização da falta, propriedades do campo magnético terrestre. Em determinadas faixas de frequência pode-se observar uma variação significativa da impedância de entrada do sistema operando normalmente em relação a impedância de entrada do sistema na presença de uma falha sutil. Aplicada em um sistema de distribuição rural real, a metodologia mostra que sua implementação pode ser simplificada se for monitorada frequências previamente definidas, e não todas faixas, provendo elevada rapidez de resposta.

Milioudis, Andreou e Labridis (2012b) propõem um método para a localização exata de faltas de alta impedância a partir da comunicação que o sistema elétrico possui com a concessionária. Logo após a identificação da falha, ocorre a injeção de sinais específicos no

sistema. Com isso, utilizando os conceitos de ondas viajantes e resposta impulsiva determina-se o local da falta. Além disso, destaca-se a influência do tipo de falta e sua impedância na eficiência da metodologia, a qual é aplicada em um alimentador rural real. Os resultados mostram que se for conhecida a velocidade do pulso, a localização da falha sutil é feita com precisão.

Samantaray (2012) apresenta uma técnica para detecção de faltas de alta impedância em sistemas de distribuição de energia elétrica utilizando o conceito de árvores de decisão. O processo inicia-se com a estimativa da amplitude e da fase dos componentes harmônicos dos sinais de corrente aplicando-se a teoria de filtragem de Kalman. Com isso, o algoritmo de diagnóstico é treinado utilizando as informações obtidas anteriormente, de modo que o classificador possua elevada capacidade de generalização. Os resultados obtidos mostram que a metodologia é bastante eficiente e confiável, mesmo em quando há ruídos nas oscilografias de corrente.

Gautam e Brahma (2013), a partir da afirmação de que as correntes de falta das FAI possuem valores muito baixos, não sendo identificadas pelos relés de sobrecorrente, apresentam um método baseado na morfologia matemática para detecção de falhas sutis. Empregando a morfologia matemática, verifica-se o comportamento da oscilografia de tensão em busca de singularidades (transitórios) no sinal que indiquem a presença de uma falta de alta impedância no sistema de distribuição de energia elétrica. A vantagem de utilização desta ferramenta se deve a não necessidade de uma etapa de treinamento ou aprendizado. Os resultados obtidos por meio de simulações mostram que a metodologia é rápida, segura e confiável.

Sarлак e Shahrtash (2013) propõem um indicador de faltas de alta impedância a ser fixado nos postes dos sistemas de distribuição de energia elétrica. Estes indicadores realizam a identificação e localização das falhas sutis por meio do reconhecimento de padrões do campo magnético medido na vizinhança do condutor energizado. O processamento e a classificação do sinal são realizados aplicando-se o gradiente morfológico de multirresolução e máquina de vetores suporte, respectivamente. A localização fornece a barra na qual se encontra a falta de alta impedância. Os resultados mostram que o método é capaz de discriminar com sucesso faltas de alta impedância de outros transitórios semelhantes.

Bakar *et al.* (2014) apresentam uma metodologia de localização de faltas de alta impedância, uma vez que este tipo de falha pode causar a interrupção do fornecimento de energia. Utilizando transformada *wavelet* discreta e a análise multirresolução, informações são extraídas das oscilografias de tensão, medidas na subestação principal, as quais são comparadas

com um banco de dados previamente definido por simulações. Por causa da única medida realizada e as múltiplas ramificações, é produzido um conjunto com os possíveis locais da falta. Este problema é solucionado aplicando-se uma análise classificatória, gerando uma lista das seções mais prováveis até as menos prováveis. A metodologia foi verificada em um sistema de distribuição real simulado no *software* PSCAD/EMTDC. Considerando-se os resultados obtidos, observa-se a simplicidade da metodologia, uma vez que somente as tensões da subestação principal são utilizadas, tornando possível sua implementação em tempo real.

Observando tais publicações, tem-se uma grande quantidade de trabalhos que abordam a detecção e classificação das faltas de alta impedância. Em contrapartida, poucos destes visam a localização destas falhas problemáticas. Com isso, aproveitando os investimentos atuais aplicados no setor elétrico, deve-se focar no desenvolvimento de métodos que realizem de forma rápida, confiável e eficiente a localização das falhas sutis, já que estão disponíveis na literatura especializada metodologias de detecção e classificação para este tipo de falha.


3 FALHAS EM SISTEMAS DE DISTRIBUIÇÃO DE ENERGIA ELÉTRICA

Todo o sistema elétrico de potência está sujeito a falhas que vem a comprometer a geração, transmissão e distribuição de energia elétrica. Em virtude do crescimento populacional e econômico dos centros urbanos, as concessionárias têm tido como desafio acompanhar esta evolução, sendo capazes de fornecer uma energia com qualidade.

A proximidade dos alimentadores em relação aos seus consumidores e sua extensão, *i.e.*, cobrem longos trechos urbanos com diversas ramificações, faz com que eles estejam sujeitos a inúmeras falhas, mais frequentes do que aquelas observadas na geração e na transmissão de energia. Mesmo utilizando modernos equipamentos de medição, monitoramento e controle, as concessionárias não são capazes de solucionar os problemas identificados instantaneamente, causando grandes prejuízos. Por outro lado, tem-se alguns problemas que não são capazes de serem identificados mesmo utilizando os melhores e mais modernos equipamentos de proteção. Neste contexto, outras ferramentas/técnicas devem ser incorporadas aos equipamentos.


Um exemplo claro de falha que os equipamentos atuais não conseguem identificar são as faltas de alta impedância. Isto se deve ao comportamento singular das oscilografias de tensão e de corrente, *i.e.*, não apresentam variações suficientes para ativar a proteção do sistema, podendo ser confundidas com a operação normal. Nas figuras 1 e 2 são apresentadas as oscilografias de tensão e de corrente para a operação normal e para uma falta de alta impedância, respectivamente.

Figura 1 – Oscilografias de tensão e de corrente para a operação normal



Fonte: Elaborada pelo autor.

Figura 2 – Oscilografias de tensão e de corrente para uma falta de alta impedância




Fonte: Elaborada pelo autor.

Observando estas figuras, pode-se afirmar que é impossível estar aplicando técnicas de diagnósticos baseadas na inspeção visual de oscilografias para a identificação das faltas de alta impedância, uma vez que nenhum tipo de transitório é gerado. Neste sentido, caso as oscilografias sejam analisadas em um domínio diferente do domínio do tempo, *e.g.*, domínio *wavelet*, pode-se vir a observar a presença de alguns transitórios gerados pelas faltas de alta impedância.


Com o propósito de ilustrar este fato, as figuras 3 e 4 mostram a análise das oscilografias de tensão e de corrente, respectivamente, no domínio *wavelet* para a operação normal. Já as figuras 5 e 6 mostram a análise das oscilografias de tensão e de corrente, respectivamente, no domínio *wavelet* para uma falta de alta impedância.

Figura 3 – Oscilografia de tensão no domínio *wavelet* para a operação normal



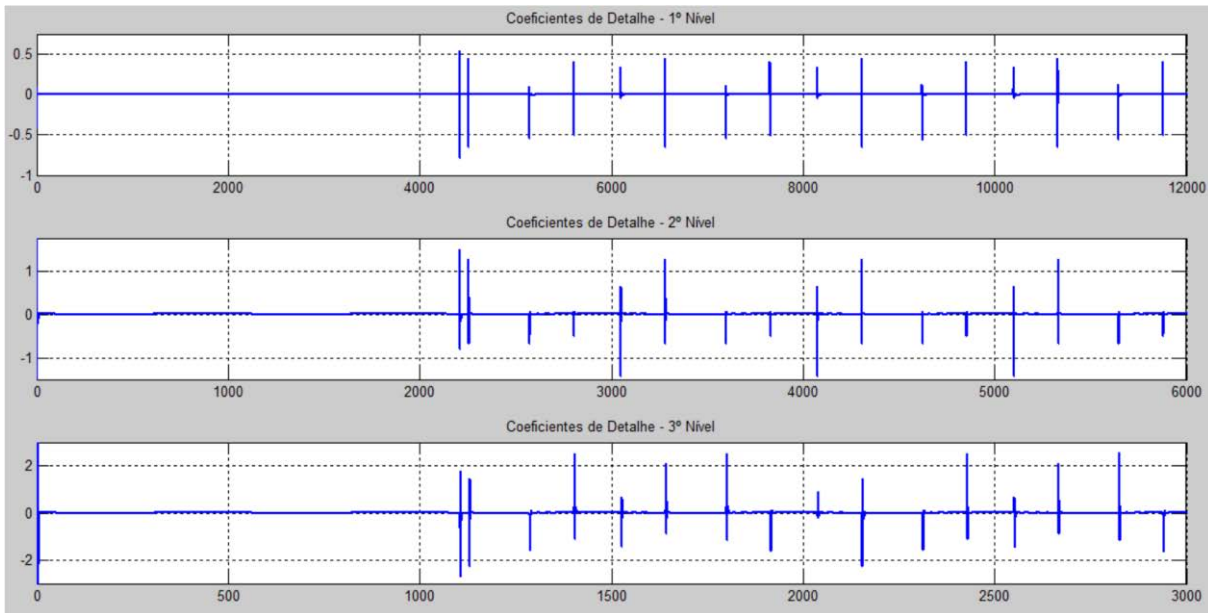
Fonte: Elaborada pelo autor.

Figura 4 – Oscilografia de corrente no domínio *wavelet* para a operação normal



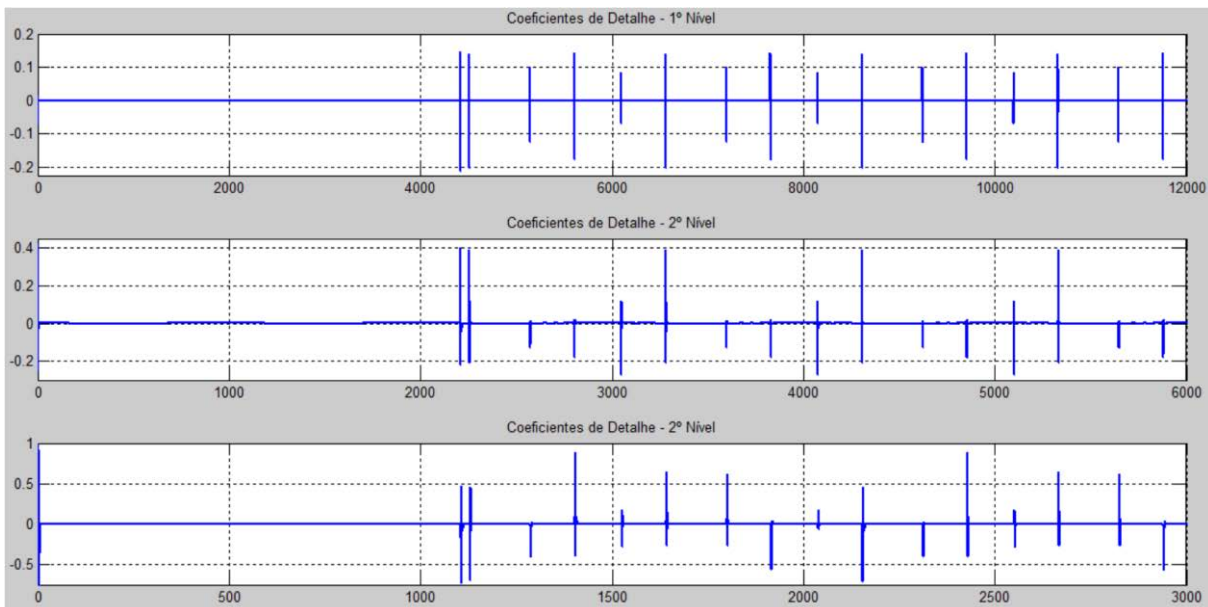
Fonte: Elaborada pelo autor.

Figura 5 – Oscilografia de tensão no domínio *wavelet* para uma falta de alta impedância



Fonte: Elaborada pelo autor.

Figura 6 – Oscilografia de corrente no domínio *wavelet* para uma falta de alta impedância




Fonte: Elaborada pelo autor.

Nas figuras 3 e 4 não são observados transitórios de frequência, o que caracteriza corretamente a operação normal. Por outro lado, nas figuras 5 e 6 observam-se alguns transitórios que ocorrem aleatoriamente no sinal. A presença dos transitórios com comportamento aleatório é característico das faltas de alta impedância, e estes ocorrem sempre quando há o contato do condutor energizado com uma superfície de alta impedância, *i.e.*, “chicoteamento” do condutor. A partir destas figuras é possível verificar a necessidade de

utilização de técnicas de processamento de sinais para que seja possível realizar o diagnóstico completo das faltas de alta impedância, *i.e.*, detecção, classificação e localização.


Como nos alimentadores não ocorrem somente as faltas de alta impedância, outros exemplos de falhas mais comuns e menos problemáticas são os curtos-circuitos francos e os chaveamentos de bancos de capacitores. Devido aos transitórios mais definidos nas oscilografias gerados por estes eventos, pode-se facilmente empregar técnicas de identificação baseadas na experiência em análise do operador. Para ilustrar tal afirmação, as figuras 7 e 8 mostram o comportamento dos sinais de tensão e de corrente na ocorrência de um curto-circuito franco e de um chaveamento de banco de capacitor, respectivamente.

Figura 7 – Oscilografias de tensão e de corrente para um curto-circuito franco



Fonte: Elaborada pelo autor.

Figura 8 – Oscilografias de tensão e de corrente para um chaveamento de banco de capacitor



Fonte: Elaborada pelo autor.

Se técnicas de processamento de sinais forem aplicadas às oscilografias dos curtos-circuitos francos e dos chaveamentos de bancos de capacitores, o que irá ocorrer será apenas uma ampliação dos transitórios já bem definidos.

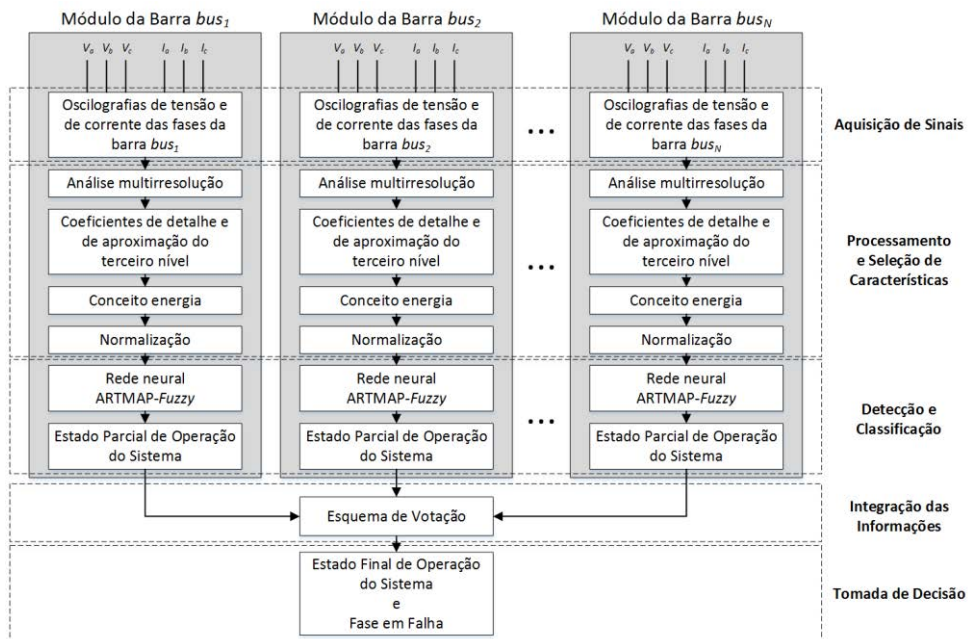
Então, conclui-se que a utilização de ferramentas de processamento de sinais, *e.g.*, transformada de Fourier e transformada *wavelet*, auxiliam bastante na identificação de falhas, principalmente quando elas apresentam transitórios singulares, *e.g.*, transitórios das faltas de alta impedância.

4 METODOLOGIA DE DIAGNÓSTICO E PROGNÓSTICO DE FALHAS

Nesta seção, é apresentada a metodologia desenvolvida para realizar o diagnóstico e o prognóstico de diferentes falhas, incluindo as faltas de alta impedância, em sistemas de distribuição. A aplicação desta metodologia visa detectar, classificar e localizar a falha em um estágio incipiente, ou seja, antes que ela evolua para um evento crítico e cause a interrupção do fornecimento de energia.

Com o propósito de tornar o processo de identificação de falhas no sistema de distribuição de energia elétrica menos dependente dos operadores, *i.e.*, sem a necessidade de definir limiares para detecção, uma metodologia alternativa foi desenvolvida. Esta realiza a detecção e a classificação em uma única etapa, indicando sua natureza, *e.g.*, falta de alta impedância, afundamento de tensão e transitório oscilatório, e a fase em que ela se encontra, *e.g.*, fase *a*, *b* ou *c*, facilitando, assim, sua posterior eliminação pela equipe de manutenção. Na figura 9 são ilustrados os procedimentos a serem realizados para a detecção e a classificação de falhas no sistema de distribuição.

Figura 9 – Estrutura do módulo de diagnóstico de falhas



Fonte: Elaborada pelo autor.

A partir das tensões e correntes trifásicas advindas de múltiplos medidores alocados no alimentador, os sinais são decompostos em três níveis por meio da análise multirresolução, definindo em um ciclo o janelamento do sinal e o passo em análise. O número de níveis de resolução que um determinado sinal comporta pode ser avaliado por meio da função ‘*wmaxlev*’ do *software* MATLAB. Para isso, informações referentes ao número de amostras do sinal e *mother wavelet* são utilizadas (MISITI *et al.*, 2010). Como todos os sinais analisados, neste trabalho, possuem 256 amostras e foram avaliados empregando a *mother wavelet* Daubechies com filtro de quarta ordem (‘*db4*’), o número máximo de níveis que as oscilografias comportam é cinco. Assim, os três níveis escolhidos nesta metodologia são mais que suficientes, *i.e.*, apresentando uma melhor relação “custo-benefício”, considerando-se o processamento e as características extraídas para a análise dos sinais no domínio *wavelet*.

Devido à grande quantidade de coeficientes produzidos pela análise multirresolução, emprega-se o conceito energia na redução desta, transformando os conjuntos de coeficientes obtidos anteriormente em escalares. Como a aquisição das oscilografias é realizada em distintos pontos do alimentador, para cada medidor são selecionadas as energias dos coeficientes de detalhe e de aproximação do terceiro nível dos sinais de tensão e de corrente das três fases do sistema, compondo os seguintes vetores:

$$\mathbf{E}^{V, bus} = \left[E_{det_3}^{V_a, bus} \quad E_{det_3}^{V_b, bus} \quad E_{det_3}^{V_c, bus} \quad E_{apr_3}^{V_a, bus} \quad E_{apr_3}^{V_b, bus} \quad E_{apr_3}^{V_c, bus} \right] \quad (1)$$

$$\mathbf{E}^{I, bus} = \left[E_{det_3}^{I_a, bus} \quad E_{det_3}^{I_b, bus} \quad E_{det_3}^{I_c, bus} \quad E_{apr_3}^{I_a, bus} \quad E_{apr_3}^{I_b, bus} \quad E_{apr_3}^{I_c, bus} \right] \quad (2)$$

sendo:

$E_{det_3}^{V_a, bus}$, $E_{det_3}^{V_b, bus}$, $E_{det_3}^{V_c, bus}$: energia dos coeficientes de detalhe do terceiro nível extraídos dos sinais de tensão das fases *a*, *b* e *c* da barra *bus*, respectivamente;

$E_{det_3}^{I_a, bus}$, $E_{det_3}^{I_b, bus}$, $E_{det_3}^{I_c, bus}$: energia dos coeficientes de detalhe do terceiro nível extraídos dos sinais de corrente das fases *a*, *b* e *c* da barra *bus*, respectivamente;

$E_{apr_3}^{V_a, bus}$, $E_{apr_3}^{V_b, bus}$, $E_{apr_3}^{V_c, bus}$: energia dos coeficientes de aproximação do terceiro nível extraídos dos sinais de tensão das fases *a*, *b* e *c* da barra *bus*, respectivamente;

$E_{apr_3}^{I_a, bus}$, $E_{apr_3}^{I_b, bus}$, $E_{apr_3}^{I_c, bus}$: energia dos coeficientes de aproximação do terceiro nível extraídos dos sinais de corrente das fases *a*, *b* e *c* da barra *bus*, respectivamente;

bus : barra do alimentador no qual são realizadas as medições, *i.e.*, barras 149, 13, 18, 47, 54, 60, 67, 76 e 97;

$E^{V, bus}$: vetor das energias de tensão com relação as medições da barra bus ;

$E^{I, bus}$: vetor das energias de corrente com relação as medições da barra bus ;

Os vetores obtidos nas equações 1 e 2 são normalizados para serem utilizados como entrada de múltiplas redes neurais. A normalização é realizada identificando o valor máximo de tensão e de corrente de cada um dos vetores analisados. Com isso, normalizam-se os outros componentes daquele vetor, sempre diferenciando tensão e corrente. Como exemplo, um determinado vetor de tensão é normalizado a partir de seu componente de máximo valor. De forma similar, um vetor de corrente é normalizado a partir de seu componente de máximo valor. Esta normalização produz novos vetores conforme as equações 3 e 4.

$$\psi^{V, bus} = [\psi_1^{V, bus} \ \psi_2^{V, bus} \ \psi_3^{V, bus} \ \psi_4^{V, bus} \ \psi_5^{V, bus} \ \psi_6^{V, bus}] \quad (3)$$

$$\psi^{I, bus} = [\psi_1^{I, bus} \ \psi_2^{I, bus} \ \psi_3^{I, bus} \ \psi_4^{I, bus} \ \psi_5^{I, bus} \ \psi_6^{I, bus}] \quad (4)$$

sendo:

$$\psi_p^{V, bus} = \frac{E_p^{V, bus}}{E_{max}^{V, bus}}, \text{ para } p = 1, \dots, 6;$$

$$E_{max}^{V, bus} = \max\{E_p^{V, bus}, p = 1, \dots, 6\};$$

$$\psi_p^{I, bus} = \frac{E_p^{I, bus}}{E_{max}^{I, bus}}, \text{ para } p = 1, \dots, 6;$$

$$E_{max}^{I, bus} = \max\{E_p^{I, bus}, p = 1, \dots, 6\}.$$

Em cada barra, nas quais foram realizadas medições, existe uma rede neural ARTMAP-*Fuzzy*, a qual é responsável por identificar e qualificar o estado de operação do alimentador. A entrada de cada rede (\mathbf{a}_{input}) é formada pelos vetores $\psi^{V, bus}$ e $\psi^{I, bus}$ da respectiva barra de medição bus . A entrada de cada uma das redes ARTMAP-*Fuzzy* tem dimensão doze, *i.e.*, seis informações de tensão (equação 3) e seis informações de corrente (equação 4).

$$\mathbf{a}_{input}^{bus} = [\psi^{V, bus} \ \psi^{I, bus}] \quad (5)$$

Como exemplo, a rede neural ARTMAP-*Fuzzy* da barra 47 tem como entrada o vetor $\mathbf{a}_{input}^{47} = [\psi^{V,47} \ \psi^{I,47}]$, ou seja, nela são utilizadas somente as informações de tensão e corrente da barra 47.

As redes neurais fornecerão como saída (\mathbf{a}_{output}) o estado operativo do sistema, *e.g.*, operação normal, falta de alta impedância, afundamento de tensão ou transitório oscilatório, e a fase em que a falha está presente (quando existir a falha). Para representar cada estado de operação, utiliza-se uma codificação predefinida, apresentada na tabela 1.

Tabela 1 – Codificação de saída dos estados de operação

Estado de Operação	Codificação de Saída
Operação Normal	[0 0 0 0]
Falta de Alta Impedância na Fase <i>a</i>	[0 1 0 1]
Falta de Alta Impedância na Fase <i>b</i>	[0 1 1 0]
Falta de Alta Impedância na Fase <i>c</i>	[0 1 1 1]
Afundamento de Tensão na Fase <i>a</i>	[1 0 0 1]
Afundamento de Tensão na Fase <i>b</i>	[1 0 1 0]
Afundamento de Tensão na Fase <i>c</i>	[1 0 1 1]
Transitório Oscilatório na Fase <i>a</i>	[1 1 0 1]
Transitório Oscilatório na Fase <i>b</i>	[1 1 1 0]
Transitório Oscilatório na Fase <i>c</i>	[1 1 1 1]

Fonte: Elaborada pelo autor.

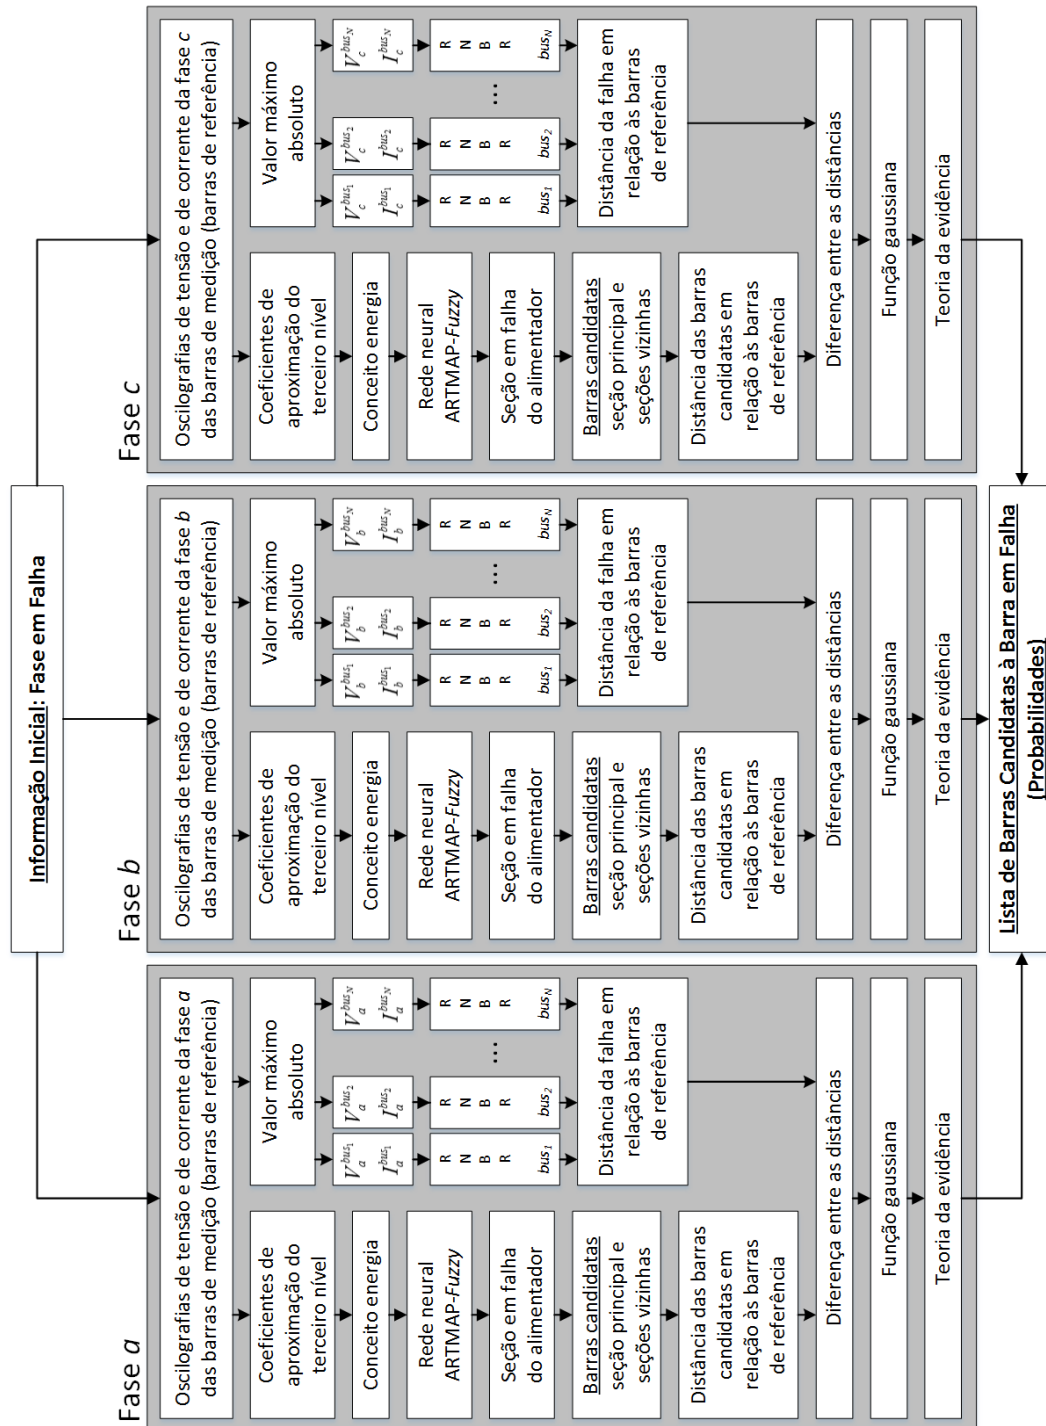
A codificação de saída foi definida da seguinte maneira: os dois primeiros *bits* indicam o estado operativo e os dois últimos *bits* a fase envolvida na falha. Como existem quatro estados de operação possíveis, os dois primeiros *bits* possuem a função de representar tais estados, *i.e.*, operação normal ([0 0]), falta de alta impedância ([0 1]), afundamento de tensão ([1 0]) e transitório oscilatório ([1 1]). De forma similar, os dois últimos *bits* indicam as quatro combinações de envolvimento das fases na falha, *i.e.*, sem presença de fases ([0 0]), fase *a* ([0 1]), fase *b* ([1 0]) e fase *c* ([1 1]).

As redes neurais, responsáveis pela detecção e classificação, fornecem, ao operador, distintos diagnósticos, *i.e.*, um para cada ponto de medição. Caso sejam analisadas as informações individualmente, o operador pode não ser capaz de inferir se o alimentador está operando com ou sem falha. Neste sentido, aplica-se um critério de votação simples, ou seja, aquele estado que apresenta maior número de “votos” é o vencedor. Isto torna o procedimento

de identificação de falhas mais eficiente e confiável, pois independe da tomada de decisão por parte do operador humano.

O processo para identificar o local de ocorrência da falha é iniciado logo após a detecção de uma anormalidade no sistema, *i.e.*, qualquer operação diferente da operação normal. Na figura 10 é apresentada a estrutura básica da metodologia de localização de falhas.

Figura 10 – Estrutura do módulo de localização de falhas



Fonte: Elaborada pelo autor.

A partir da informação da fase em que a falha se encontra, obtida no processo anterior, e, considerando os múltiplos pontos de medição no alimentador (barras 149, 13, 18, 47, 54, 60, 67, 76 e 97), são definidos dois novos vetores. Eles são compostos pela energia dos coeficientes de aproximação da tensão e da corrente da fase em falha, conforme as equações 6 e 7, respectivamente.

$$\mathbf{vet}^{V_f} = \left[E_{apr_3}^{V_f,149} \ E_{apr_3}^{V_f,13} \ E_{apr_3}^{V_f,18} \ E_{apr_3}^{V_f,47} \ E_{apr_3}^{V_f,54} \ E_{apr_3}^{V_f,60} \ E_{apr_3}^{V_f,67} \ E_{apr_3}^{V_f,76} \ E_{apr_3}^{V_f,97} \right] \quad (6)$$

$$\mathbf{vet}^{I_f} = \left[E_{apr_3}^{I_f,149} \ E_{apr_3}^{I_f,13} \ E_{apr_3}^{I_f,18} \ E_{apr_3}^{I_f,47} \ E_{apr_3}^{I_f,54} \ E_{apr_3}^{I_f,60} \ E_{apr_3}^{I_f,67} \ E_{apr_3}^{I_f,76} \ E_{apr_3}^{I_f,97} \right] \quad (7)$$

sendo:

f : fase na qual foi identificada a anormalidade, fase a - $f = a$, fase b - $f = b$, e fase c - $f = c$;

\mathbf{vet}^{V_f} : vetor energia dos coeficientes de aproximação da tensão da fase f em análise;

\mathbf{vet}^{I_f} : vetor energia dos coeficientes de aproximação da corrente da fase f em análise.

Os vetores característicos de tensão (\mathbf{vet}^{V_f}) e de corrente (\mathbf{vet}^{I_f}), agora no domínio *wavelet*, são combinados, produzindo o vetor definido na equação 8:

$$\mathbf{vet}^f = \left[\mathbf{vet}^{V_f} \ \mathbf{vet}^{I_f} \right] \quad (8)$$

Em seguida, realiza-se uma normalização, como é apresentado a seguir.

$$\mathbf{vet}_{norm}^f = \left[\mathbf{vet}_{1,norm}^f \ \mathbf{vet}_{2,norm}^f \ \dots \ \mathbf{vet}_{18,norm}^f \right] \quad (9)$$

sendo:

$$\mathbf{vet}_{q,norm}^f = \frac{\mathbf{vet}_q^f}{\mathbf{vet}_{max}^f}, \text{ para } q = 1, \dots, 18;$$

$$\mathbf{vet}_{max}^f = \max \{ \mathbf{vet}_q^f, q = 1, \dots, 18 \}.$$

A definição destes vetores se deve à necessidade de utilizar a distância elétrica da seção, *i.e.*, impedância, como informação para determinar a seção da falha, podendo ser feita de maneira direta ou indireta. Levando em consideração que os coeficientes de detalhe guardam a informação referente aos transitórios de frequência, ao longo do tempo e, conseqüentemente, da presença ou não de falhas na oscilografias, estes não podem ser utilizados no cálculo da distância elétrica. Em contrapartida, os coeficientes de aproximação descrevem o


comportamento da amplitude do sinal ao longo do tempo e, desta forma, são os mais indicados para cálculo da distância elétrica, uma vez que esta grandeza nada mais é do que a relação entre a amplitude dos sinais de tensão e de corrente. Assim, visando eficiência e elevado desempenho computacional, empregam-se três redes *ARTMAP-Fuzzy*, *i.e.*, uma para cada fase do alimentador, que calculam, de forma automática e indireta, a impedância da seção em falha. Elas operam de forma não simultânea, ou seja, são ativadas de acordo com a fase na qual foi identificada a anormalidade, *i.e.*, *a*, *b* ou *c*, não permitindo a ativação de duas ou mais redes no mesmo instante. As redes neurais possuem como entrada o vetor \mathbf{vet}_{norm}^f definido na equação 9:

$$\mathbf{a}_{input}^f = \mathbf{vet}_{norm}^f \quad (10)$$

Como exemplo, quando for constatada a operação anormal na fase *c*, ativa-se a terceira rede, que tem como entrada o vetor $\mathbf{a}_{input}^c = \mathbf{vet}_{norm}^c$. Então, tanto a rede a ser ativada como as informações utilizadas na composição do vetor de entrada são referentes à fase na qual foi determinada a presença da falha.

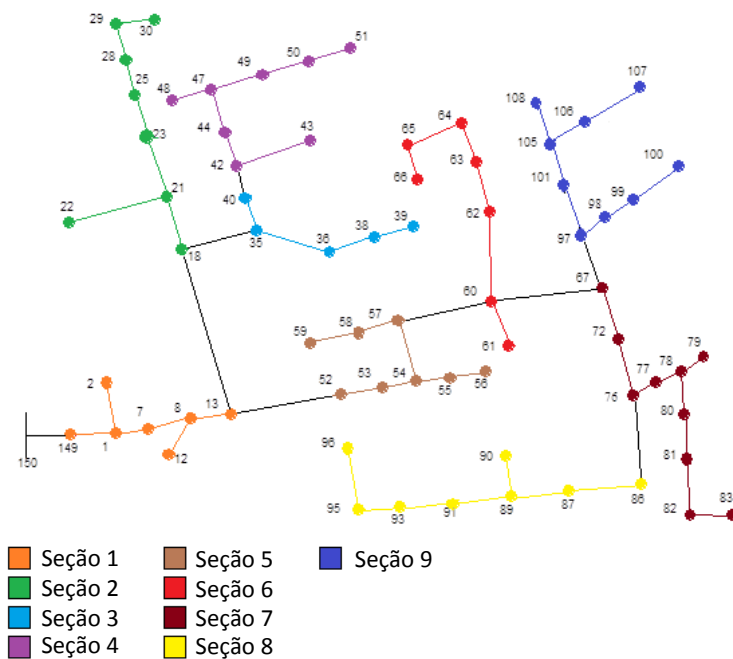
A rede neural ativada no processo fornece em sua saída a seção do alimentador em falha. Cada seção é identificada por uma codificação binária previamente estabelecida pelo operador. Para que o número de seções não interfira na qualidade dos resultados, deve-se avaliar dois casos distintos: (a) número reduzido de seções e (b) número elevado de seções. No caso (a), observa-se que a equipe de manutenção leva um tempo consideravelmente maior para a localização da barra em falha, uma vez que as seções possuem um maior número de barras. Já no caso (b) o tempo de localização torna-se inferior ao do caso (a), uma vez que o número de barras em cada seção é relativamente pequeno. Com um elevado número de seções, a rede neural *ARTMAP* começa a apresentar erros de classificação das seções, *i.e.*, quando deveria fornecer como saída uma determinada seção, a mesma fornece uma seção vizinha a esta. Então, a divisão das seções de um alimentador tem de ser feita de forma a prover um melhor “custo-benefício” em relação ao acerto na classificação/tempo de localização da barra em falha. As seções nas quais o alimentador foi dividido são apresentadas nas figuras 11, 12 e 13 considerando as fases *a*, *b* e *c*, respectivamente.

Figura 11 – Seções do alimentador – fase *a*

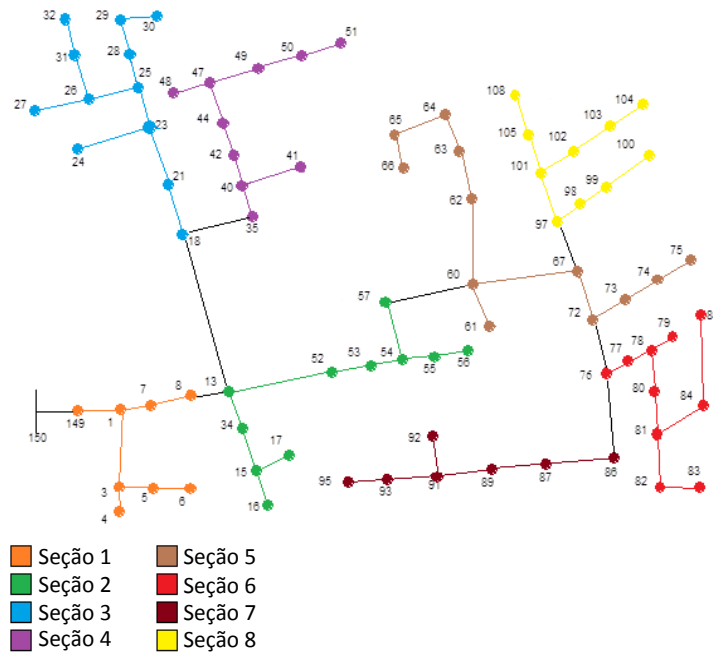


Fonte: Elaborada pelo autor.

Figura 12 – Seções do alimentador – fase *b*



Fonte: Elaborada pelo autor.

Figura 13 – Seções do alimentador – fase *c*

Fonte: Elaborada pelo autor.

Analisando as figuras observa-se que as seções são distintas para cada uma das fases, pois o alimentador possui trechos monofásicos, bifásicos e trifásicos. A codificação de saída de cada seção do alimentador é definida conforme tabela 2.

Tabela 2 – Codificações de saída das seções

Seção	Codificação de Saída		
	Fase <i>a</i>	Fase <i>b</i>	Fase <i>c</i>
1	[0 0 0 1]	[0 0 0 1]	[0 0 0 1]
2	[0 0 1 0]	[0 0 1 0]	[0 0 1 0]
3	[0 0 1 1]	[0 0 1 1]	[0 0 1 1]
4	[0 1 0 0]	[0 1 0 0]	[0 1 0 0]
5	[0 1 0 1]	[0 1 0 1]	[0 1 0 1]
6	[0 1 1 0]	[0 1 1 0]	[0 1 1 0]
7	[0 1 1 1]	[0 1 1 1]	[0 1 1 1]
8	[1 0 0 0]	[1 0 0 0]	[1 0 0 0]
9	[1 0 0 1]	[1 0 0 1]	*
10	[1 0 1 0]	*	*
11	[1 0 1 1]	*	*

Fonte: Elaborada pelo autor.

* seção inexistente nesta fase.

Após a informação da seção em falha, o processo, utilizando o conceito de conectividade, indica as seções vizinhas àquela indicada pela rede neural. Esta informação é importante na execução da segunda parte do procedimento de localização de falhas. Na tabela 3 são mostradas as seções vizinhas de cada seção, para cada fase, obtidas de acordo com as figuras 11, 12 e 13.

Tabela 3 – Conectividade entre as seções para cada fase do alimentador

Seção	Seção Vizinha		
	Fase <i>a</i>	Fase <i>b</i>	Fase <i>c</i>
1	2 e 5	2 e 5	2
2	1, 3 e 4	3	1, 3 e 5
3	2	2 e 4	2 e 4
4	2	3	3
5	1 e 6	1 e 6	2, 6 e 8
6	5 e 7	5 e 7	5 e 7
7	6, 8 e 10	6, 8 e 9	6
8	7 e 9	7	5
9	8	7	*
10	7 e 11	*	*
11	10	*	*

Fonte: Elaborada pelo autor.

* vizinhança inexistente.

A localização da barra em falha é iniciada logo após a identificação da seção, descrita anteriormente. A partir das distâncias reais de cada linha (trecho) do sistema de distribuição de energia elétrica, considerando a fase na qual foi constatada a anormalidade, calcula-se a matriz de distância inversa, a partir da matriz de distância primitiva, descrita pela equação 11.

$$\mathbf{D}^{-1} = (\hat{\mathbf{A}})^T (\mathbf{D}_{primitiva})^{-1} (\hat{\mathbf{A}}) \quad (11)$$

sendo:

$\mathbf{D}_{primitiva}$: matriz de distância primitiva;

\mathbf{D}^{-1} : matriz de distância inversa;

\hat{A} : matriz de incidência (ANDERSON; FOUAD, 2002; STAGG; EL-ABIAD, 1968), definida por:

$$\hat{A} \equiv [A_{ij}] \quad (12)$$

sendo:

$A_{ij} = +1$ se o i -ésimo elemento está conectado ao nó j e está orientado a partir deste nó;

$A_{ij} = -1$ se o i -ésimo elemento está conectado ao nó j e está orientado na direção a este nó;

$A_{ij} = 0$ em nenhum dos casos anteriores.

A matriz $D_{primitiva}$ é semelhante à matriz de impedância primitiva ($Z_{primitiva}$), que é empregada no cálculo do fluxo de potência, apresentando diferença na grandeza de sua composição, *i.e.*, a matriz $D_{primitiva}$ utiliza a distância em metros e a matriz $Z_{primitiva}$ utiliza a impedância em ohms. Assim, como na matriz $Z_{primitiva}$, a matriz $D_{primitiva}$ possui somente elementos na diagonal principal, sendo os valores correspondentes a extensão de cada linha do alimentador.

Para o cálculo da matriz de distância D deve-se adotar uma barra de referência. Normalmente, o ponto de medição na saída da subestação principal é tomado como a referência do sistema. Porém, nesta metodologia, as medições são realizadas em distintos locais. Por conseguinte, para cada ponto de medição, *i.e.*, barras 149, 13, 18, 47, 54, 60, 67, 76 e 97, calcula-se a matriz de distância D , ou seja, a inversa da matriz D^{-1} após remoção da linha e da coluna da barra de referência, obtendo a distância das outras barras do sistema em relação à referência adotada. Em seguida, as distâncias são normalizadas a partir da distância máxima de cada ponto de medição. Exemplificando, após o cálculo das distâncias de cada barra em relação à barra 13 (barra de medição), determina-se a distância máxima, a qual é empregada na normalização das distâncias referentes a barra 13. Repete-se este procedimento para as outras barras de medição (referência), obtendo nove distâncias máximas distintas.

Para cada uma das barras em que são realizadas as aquisições (medições) das oscilografias, estão presentes três redes neurais de base radial, *i.e.*, uma para cada fase, as quais foram implementadas com o auxílio da *toolbox* de redes neurais do *software* MATLAB (BEALE; HAGAN; DEMUTH, 2013). O vetor de entrada das redes neurais é composto pelo valor máximo absoluto da tensão e da corrente, extraídos do ciclo do respectivo medidor da fase em falha, como mostra a equação 13.

$$\mathbf{X}_f^{bus} = \begin{bmatrix} V_f^{bus} & I_f^{bus} \end{bmatrix} \quad (13)$$

sendo:

f : fase na qual foi identificada a anormalidade, fase a - $f = a$, fase b - $f = b$, e fase c - $f = c$;

bus : ponto do alimentador no qual são realizadas as medições, *i.e.*, barras 149, 13, 18, 47, 54, 60, 67, 76 e 97;

V_f^{bus} : valor máximo absoluto da tensão obtido na fase f da barra bus ;

I_f^{bus} : valor máximo absoluto da corrente obtido na fase f da barra bus ;

\mathbf{X}_f^{bus} : vetor de entrada da rede neural de base radial da fase f da barra bus .

Estas redes neurais fornecem em sua saída a distância aproximada da falha a partir de cada referência ($d_{bus}^{rede,f}$). Desta forma, as distâncias das barras da seção em falha e das seções vizinhas ($d_{conj,bus}^{real,f}$) são subtraídas da distância calculada pela rede neural ($d_{bus}^{rede,f}$), considerando cada referência do alimentador.

$$e_{conj,bus}^f = \left| d_{conj,bus}^{real,f} - d_{bus}^{rede,f} \right| \quad (14)$$

sendo:

$conj$: barra pertencente ao conjunto formado pelas barras da seção em falha e das seções vizinhas;

f : fase na qual foi identificada a anormalidade;

bus : ponto do alimentador adotado como referência, *i.e.*, barras 149, 13, 18, 47, 54, 60, 67, 76 e 97;

$d_{conj,bus}^{real,f}$: distância real da barra $conj$ em relação à barra de referência bus para a fase f ;

$d_{bus}^{rede,f}$: distância fornecida pela rede neural em relação à barra de referência bus para a fase f ;

$e_{conj,bus}^f$: valor absoluto da diferença entre a distância real e a distância fornecida pela rede neural.

Em seguida, avalia-se a diferença entre as distâncias utilizando uma função de densidade Gaussiana, com o propósito de fornecer a probabilidade da localização (barra) da falha. A função de densidade Gaussiana é definida pela equação 15.

$$f(x) = e^{-\frac{(x-x_0)^2}{2\sigma^2}} \quad (15)$$

sendo:

x_0 : média, *i.e.*, centro da função gaussiana, calculada a partir dos valores de $e_{conj,bus}^f$ levando em consideração o conjunto de barras candidatas para cada barra de referência *bus*.

σ : desvio padrão calculado utilizando os valores de $e_{conj,bus}^f$ do conjunto de barras candidatas para uma determinada barra de referência *bus*.

A informação final disponibilizada ao operador depende da confiabilidade com que os valores de probabilidade gerados a partir da função Gaussiana são analisados. No entanto, devido à grande quantidade e similaridades entre eles, a tomada de decisão torna-se impraticável. Neste contexto, a teoria da evidência é um conceito disponível, uma vez que ela agrega as probabilidades de cada barra do sistema e gera intervalos de confiança a respeito do verdadeiro local em que se situa a falha.

Antes de iniciar a avaliação, via teoria da evidência, deve-se normalizar os valores das probabilidades referentes a uma determinada barra de referência pela soma de todas estas probabilidades. Por exemplo, as probabilidades das barras candidatas considerando a barra de referência 149 são normalizadas pela soma de todas as probabilidades referentes à barra 149. Isto tem de ser feito, pois, o somatório total das probabilidades deve ser igual a 100%, já que não existe a possibilidade de ocorrência de probabilidades superiores a 100%. Assim, todas as evidências (probabilidades) referentes a uma determinada barra são agregadas, sendo traduzidas em um único valor após aplicação da teoria da evidência. Com a aplicação desta ferramenta criam-se duas listas com as possíveis barras sob falha: (1) indica as barras da seção principal, e (2) indica as barras das seções vizinhas à seção principal. Logo, a equipe de manutenção deve percorrer todas as barras das duas listas em busca da falha sem descartar nenhuma delas, pois, mesmo que apresentem valor de probabilidade zero, a barra pertence à seção em operação anormal definida no processo de identificação da seção em falha. Desta forma, o número de barras candidatas, que inicialmente é elevado (todas as barras do alimentador), é reduzido em um número aproximado de 20 barras, tornando a restauração do estado normal de operação mais rápida, robusta e eficiente.

A seguir, tem-se um exemplo de aplicação de modo a facilitar a compreensão do funcionamento desta metodologia.

5 EXEMPLO DE APLICAÇÃO

Neste tópicó apresenta-se um exemplo de aplicação para a compreensão do funcionamento de todas as etapas da metodologia desenvolvida.

Inicialmente, considere que ocorra uma falha na barra 71 do alimentador de distribuição de energia elétrica, mais especificamente uma falta de alta impedância na fase *a*. Como as medições são realizadas ininterruptamente em nove barras distintas, sempre analisando ciclo a ciclo dos sinais de todas as fases, tem-se, neste caso, os seguintes vetores característicos obtidos conforme equação 5.

$$\mathbf{a}_{input}^{149} = [0 \ 0 \ 0 \ 0,9711 \ 1,0 \ 0,9702 \ 0 \ 0 \ 0 \ 1,0 \ 0,4594 \ 0,6452] \quad (16)$$

$$\mathbf{a}_{input}^{13} = [0 \ 0 \ 0 \ 0,9142 \ 1,0 \ 0,9409 \ 0 \ 0 \ 0 \ 1,0 \ 0,5403 \ 0,6787] \quad (17)$$

$$\mathbf{a}_{input}^{18} = [0 \ 0 \ 0 \ 0,9031 \ 1,0 \ 0,9342 \ 0 \ 0 \ 0 \ 1,0 \ 0,4498 \ 0,4490] \quad (18)$$

$$\mathbf{a}_{input}^{47} = [0 \ 0 \ 0 \ 0,9001 \ 1,0 \ 0,9380 \ 0 \ 0 \ 0 \ 0,6678 \ 1,0 \ 0,8935] \quad (19)$$

$$\mathbf{a}_{input}^{54} = [0 \ 0 \ 0 \ 0,8989 \ 1,0 \ 0,9361 \ 0 \ 0 \ 0 \ 1,0 \ 0,8058 \ 0,8050] \quad (20)$$

$$\mathbf{a}_{input}^{60} = [0 \ 0 \ 0 \ 0,8029 \ 1,0 \ 0,9358 \ 0 \ 0 \ 0 \ 1,0 \ 0,6829 \ 0,8570] \quad (21)$$

$$\mathbf{a}_{input}^{67} = [0 \ 0 \ 0 \ 0,8895 \ 1,0 \ 0,9331 \ 0 \ 0 \ 0 \ 1,0 \ 0,5792 \ 0,6623] \quad (22)$$

$$\mathbf{a}_{input}^{76} = [0 \ 0 \ 0 \ 0,8902 \ 1,0 \ 0,9357 \ 0 \ 0 \ 0 \ 0,7929 \ 1,0 \ 0,5725] \quad (23)$$

$$\mathbf{a}_{input}^{97} = [0 \ 0 \ 0 \ 0,8887 \ 1,0 \ 0,9328 \ 0 \ 0 \ 0 \ 1,0 \ 0,5040 \ 0,6619] \quad (24)$$

A partir destas entradas, as redes neurais ARTMAP-*Fuzzy*, responsáveis pelo diagnóstico inicial do estado operativo do sistema, fornecem como saída os seguintes resultados:

- Módulo de diagnóstico da barra 149: “Falta de alta impedância na fase *a*”;
- Módulo de diagnóstico da barra 13: “Falta de alta impedância na fase *a*”;
- Módulo de diagnóstico da barra 18: “Falta de alta impedância na fase *a*”;
- Módulo de diagnóstico da barra 47: “Falta de alta impedância na fase *a*”;
- Módulo de diagnóstico da barra 54: “Falta de alta impedância na fase *b*”;
- Módulo de diagnóstico da barra 60: “Falta de alta impedância na fase *b*”;
- Módulo de diagnóstico da barra 67: “Falta de alta impedância na fase *a*”;

- Módulo de diagnóstico da barra 76: “Falta de alta impedância na fase *a*”;
- Módulo de diagnóstico da barra 97: “Falta de alta impedância na fase *a*”;

Desta forma, com o auxílio do esquema de votação, tem-se o diagnóstico final do estado operativo, o qual é apresentado na tabela 4.

Tabela 4 – Diagnóstico final do estado operativo do sistema de distribuição

Estado Operativo do Sistema	Probabilidade (%)
Operação Normal	0,0
Falta de Alta Impedância na Fase <i>a</i>	77,78
Falta de Alta Impedância na Fase <i>b</i>	22,22
Falta de Alta Impedância na Fase <i>c</i>	0,0
Afundamento de Tensão na Fase <i>a</i>	0,0
Afundamento de Tensão na Fase <i>b</i>	0,0
Afundamento de Tensão na Fase <i>c</i>	0,0
Transitório Oscilatório na Fase <i>a</i>	0,0
Transitório Oscilatório na Fase <i>b</i>	0,0
Transitório Oscilatório na Fase <i>c</i>	0,0

Fonte: Elaborada pelo autor.

Com isso, tem-se que o sistema de distribuição de energia elétrica está operando sob a presença de uma falta de alta impedância na fase *a*, *i.e.*, mesmo tipo de falha que foi inserida inicialmente no alimentador.

Após constatação de qualquer anormalidade, tem-se a necessidade de localização desta falha no alimentador. Utilizando as oscilografias de tensão e de corrente da fase em falha, *i.e.*, fase *a*, define-se o vetor de entrada da rede neural ARTMAP-*Fuzzy* responsável pela indicação da seção em falha, conforme equação 9:

$$\mathbf{vet}_{norm}^a = \begin{bmatrix} 1,0 & 0,928 & 0,910 & 0,895 & 0,907 & 0,888 & 0,883 & 0,882 & 0,881 & \dots \\ 0,062 & 0,048 & 0,009 & 0,001 & 0,013 & 0,012 & 0,009 & 0,002 & 0,001 & \dots \end{bmatrix} \quad (25)$$

De acordo com a rede neural, tem-se que a falha se encontra na seção 7 (codificação [0 1 1 1]) da fase *a* do alimentador, a qual pode ser observada na figura 11. Utilizando o conceito da conectividade, determinam-se as seções vizinhas, e as respectivas barras, à seção em falha definida pelo módulo neural, sendo estas informações apresentadas na tabela 5.

Tabela 5 – Seções vizinhas à seção em falha e suas respectivas barras

Seção	Classificação	Barras Pertencentes à Seção
7	Seção em Falha	67, 68, 69, 70, 71 e 72
6	Seção Vizinha	60, 61, 62, 63, 64, 65 e 66
8	Seção Vizinha	76, 77, 78, 79, 80, 81, 82 e 83
10	Seção Vizinha	97, 98, 99, 100, 101 e 105

Fonte: Elaborada pelo autor.

Em seguida, determinam-se as distâncias reais de todas estas barras em relação a cada ponto de medição, *i.e.*, barra utilizadas como referências no cálculo da matriz de distância D . As tabelas a seguir mostram os valores das distâncias reais das barras de cada uma das seções da tabela 5 em relação aos pontos de referência.

Tabela 6 – Distância real das barras da seção 6 em relação aos pontos de medição

Barra	Distância em Relação à Barra de Referência								
	149	13	18	47	54	60	67	76	97
60	0,4960	0,3476	0,4362	0,5372	0,2431	0	0,0690	0,1486	0,1127
61	0,5543	0,4524	0,5267	0,6115	0,3646	0,1164	0,1773	0,2477	0,2160
62	0,5078	0,3952	0,4774	0,5709	0,2983	0,0529	0,1182	0,1937	0,1596
63	0,5349	0,4286	0,5062	0,5946	0,3370	0,0899	0,1527	0,2252	0,1925
64	0,5891	0,4952	0,5638	0,6419	0,4144	0,1640	0,2217	0,2883	0,2582
65	0,6550	0,5762	0,6337	0,6993	0,5083	0,2540	0,3054	0,3649	0,3380
66	0,7054	0,6381	0,6872	0,7432	0,5801	0,3228	0,3695	0,4234	0,3991

Fonte: Elaborada pelo autor.

Tabela 7 – Distância real das barras da seção 7 em relação aos pontos de medição

Barra	Distância em Relação à Barra de Referência								
	149	13	18	47	54	60	67	76	97
67	0,5233	0,4143	0,4938	0,5845	0,3204	0,0741	0	0,0856	0,0469
68	0,5543	0,4524	0,5267	0,6115	0,3646	0,1164	0,0394	0,1216	0,0845
69	0,5969	0,5048	0,5720	0,6486	0,4254	0,1746	0,0936	0,1712	0,1362
70	0,6473	0,5667	0,6255	0,6926	0,4972	0,2434	0,1576	0,2297	0,1972
71	0,6899	0,6190	0,6708	0,7297	0,5580	0,3016	0,2118	0,2793	0,2488
72	0,5659	0,4667	0,5391	0,6216	0,3812	0,1323	0,0542	0,0360	0,0986

Fonte: Elaborada pelo autor.

Tabela 8 – Distância real das barras da seção 8 em relação aos pontos de medição

Barra	Distância em Relação à Barra de Referência								
	149	13	18	47	54	60	67	76	97
76	0,5969	0,5048	0,5720	0,6486	0,4254	0,1746	0,0936	0	0,1362
77	0,6589	0,5810	0,6379	0,7027	0,5138	0,2593	0,1724	0,0721	0,2113
78	0,6744	0,6000	0,6543	0,7162	0,5359	0,2804	0,1921	0,0901	0,2300
79	0,7093	0,6429	0,6914	0,7466	0,5856	0,3280	0,2365	0,1306	0,2723
80	0,7481	0,6905	0,7325	0,7804	0,6409	0,3810	0,2857	0,1757	0,3192
81	0,8217	0,7810	0,8107	0,8446	0,7459	0,4815	0,3793	0,2613	0,4085
82	0,8605	0,8286	0,8519	0,8784	0,8011	0,5344	0,4286	0,3063	0,4554
83	0,8992	0,8762	0,8930	0,9122	0,8564	0,5873	0,4778	0,3514	0,5023

Fonte: Elaborada pelo autor.

Tabela 9 – Distância real das barras da seção 10 em relação aos pontos de medição

Barra	Distância em Relação à Barra de Referência								
	149	13	18	47	54	60	67	76	97
97	0,5620	0,4619	0,5350	0,6182	0,3757	0,1270	0,0493	0,1306	0
98	0,6047	0,5143	0,5802	0,6554	0,4365	0,1852	0,1034	0,1802	0,0516
99	0,6899	0,6190	0,6708	0,7297	0,5580	0,3016	0,2118	0,2793	0,1549
100	0,7364	0,6762	0,7202	0,7703	0,6243	0,3651	0,2709	0,3333	0,2113
101	0,6008	0,5095	0,5761	0,6520	0,4309	0,1799	0,0985	0,1757	0,0469
105	0,6434	0,5619	0,6214	0,6892	0,4917	0,2381	0,1527	0,2252	0,0986

Fonte: Elaborada pelo autor.

As distâncias reais devem ser confrontadas com as distâncias fornecidas pelas redes neurais de base radial, que utilizam como entrada o valor absoluto da tensão e da corrente da fase em falha do medidor do qual são provenientes as oscilografias para análise, como definido na equação 13.

$$\mathbf{X}_a^{149} = [3275,01 \ 822,69] \quad (26)$$

$$\mathbf{X}_a^{13} = [3156,22 \ 723,68] \quad (27)$$

$$\mathbf{X}_a^{18} = [3125,87 \ 307,05] \quad (28)$$

$$\mathbf{X}_a^{47} = [3100,00 \ 103,25] \quad (29)$$

$$\mathbf{X}_a^{54} = [3121,78 \ 375,99] \quad (30)$$

$$\mathbf{X}_a^{60} = [3088,66 \quad 364,33] \quad (31)$$

$$\mathbf{X}_a^{67} = [3080,71 \quad 310,18] \quad (32)$$

$$\mathbf{X}_a^{76} = [3078,78 \quad 154,24] \quad (33)$$

$$\mathbf{X}_a^{97} = [3077,60 \quad 107,80] \quad (34)$$

Por conseguinte, tem-se como saída das nove redes neurais de base radial os valores aproximados da distância da falha em relação à cada barra de medição, sendo mostradas na tabela 10.

Tabela 10 – Distância aproximada da falha em relação às barras de medição

Local do Módulo Neural	Distância Aproximada da Falha
Barra 149	0,7556
Barra 13	0,6669
Barra 18	0,6453
Barra 47	0,8246
Barra 54	0,5100
Barra 60	0,4241
Barra 67	0,3489
Barra 76	0,2967
Barra 97	0,4453

Fonte: Elaborada pelo autor.

Estes valores são subtraídos dos valores obtidos nas tabelas 6, 7, 8 e 9 da seguinte forma: para os valores de distância real das barras candidatas em relação à barra de medição 149 (segunda coluna das tabelas 6, 7, 8 e 9) subtrai-se o valor da distância aproximada em relação à barra 149 (segunda linha da tabela 10). Repete-se tal procedimento respeitando sempre a barra tomada como referência. Então, os valores absolutos da diferença obtida para as barras candidatas, em relação à cada barra de referência, são utilizados no cálculo da média aritmética e do desvio padrão, parâmetros necessários para definir a função de densidade gaussiana de acordo com a equação 15. Por causa da existência de nove barras de referência (medição), a cada análise serão produzidos nove valores de média aritmética e nove valores de desvio padrão, *i.e.*, um par de valores para cada referência adotadas. A tabela 11 apresenta os valores de probabilidade obtidos para cada barra candidata pela função de densidade gaussiana.

Tabela 11 – Probabilidade de cada barra candidata à barra em falha em relação aos pontos de referência

Barra Candidata	Probabilidade das Barras Candidatas em Relação à Barra de Referência (%)								
	149	13	18	47	54	60	67	76	97
60	45,22	45,22	36,47	45,22	35,49	45,22	41,11	38,34	45,22
61	97,31	97,31	99,24	97,31	99,64	97,31	98,08	78,49	97,31
62	73,00	73,00	70,82	73,00	71,23	73,00	71,64	90,81	73,00
63	89,68	89,68	91,63	89,68	92,58	89,68	90,16	97,54	89,68
64	98,27	98,27	92,02	98,27	89,55	98,27	96,46	30,21	98,27
65	61,87	61,87	37,01	61,87	31,66	61,87	51,82	95,78	61,87
66	28,41	28,41	62,21	28,41	75,26	28,41	38,22	64,52	28,41
67	50,31	50,31	42,43	50,31	40,50	50,31	50,31	75,42	50,31
68	79,66	79,66	79,10	79,66	79,91	79,66	79,66	93,89	79,66
69	99,99	99,99	98,49	99,99	96,71	99,99	99,99	98,21	99,99
70	71,47	71,47	49,29	71,47	39,91	71,47	71,47	70,64	71,47
71	32,26	32,26	55,74	32,26	71,64	32,26	32,26	38,67	32,26
72	88,79	88,79	90,35	88,79	91,69	88,79	88,79	43,18	88,79
76	36,32	71,16	93,97	19,21	87,81	19,28	19,06	30,21	30,20
77	98,53	95,75	55,99	77,06	51,86	86,21	77,39	70,35	70,35
78	99,01	84,80	57,05	90,44	62,36	97,45	90,78	80,35	80,35
79	70,00	48,45	80,85	98,60	84,51	88,82	98,36	96,60	96,61
80	26,64	48,11	98,03	69,58	98,95	44,05	68,36	98,39	98,38
81	90,64	99,28	80,38	40,75	79,23	56,62	41,22	59,35	59,30
82	94,42	71,50	53,80	80,65	53,56	96,34	81,43	44,32	44,35
83	53,36	31,56	29,33	99,95	29,95	87,32	99,87	70,69	70,73
97	48,34	45,63	32,74	48,34	41,25	48,34	48,34	38,51	48,34
98	86,31	86,41	99,40	86,31	99,46	86,31	86,31	88,13	86,31
99	73,56	67,66	54,58	73,56	77,96	73,56	73,56	45,49	73,56
100	32,12	37,15	91,93	32,12	69,12	32,12	32,12	65,79	32,12
101	83,38	83,26	97,26	83,38	99,96	83,38	83,38	84,39	83,38
105	99,81	99,42	51,66	99,81	37,13	99,81	99,81	95,70	99,81

Fonte: Elaborada pelo autor.

Então, com a aplicação da teoria da evidência, na integração das probabilidades de cada barra, são produzidas duas listas com as candidatas à barra em falha, sendo estas acompanhadas das probabilidades finais. As tabelas 12 e 13 mostram a primeira e a segunda lista das barras candidatas, respectivamente, e seus valores de probabilidade.

O operador, em posse destas listas, organiza as barras da seção principal (primeira lista) em ordem decrescente de valor de probabilidade, repetindo a tarefa para as barras da seção vizinha. Em seguida, informa à equipe de manutenção os locais a serem percorridos em busca da falha, sendo a ordem: barra 69, 72, 68, 70, 67, 71. Ao verificar a inexistência de qualquer falha nestas barras, passa-se para as barras da seção vizinha. Em determinado momentos, podem aparecer barras com probabilidade zero. Estas não devem ser excluídas do processo, pois, mesmo com probabilidade zero, pertencem à seção em falha indicada pela rede neural.

Tabela 12 – Primeira lista das candidatas a barra em falha

Barra	Probabilidade de Falha (%)
67	7,17
68	19,04
69	33,13
70	11,60
71	4,76
72	21,06

Fonte: Elaborada pelo autor.

Tabela 13 – Segunda lista das candidatas a barra em falha

Barra	Probabilidade de Falha (%)
60	4,84
61	23,68
62	13,27
63	20,91
64	19,95
65	8,41
66	5,00
76	5,79
77	13,27
78	15,59
79	16,56
80	12,41
81	10,81
82	11,04
83	9,64
97	5,71
98	24,90
99	12,89
100	6,45
101	23,02
105	23,69

Fonte: Elaborada pelo autor.

Logo, conclui-se que a metodologia foi eficiente no diagnóstico e no prognóstico da falha, uma vez que ela identificou a natureza da falha e a fase faltosa de forma correta, *i.e.*, falta de alta impedância na fase *a*, além da barra em falha estar presente na primeira lista das candidatas a barra em falha *i.e.*, barra 71.

6 APLICAÇÕES, RESULTADO E DISCUSSÕES

Nesta seção, apresentam-se os resultados obtidos pela aplicação da metodologia de diagnóstico e prognóstico de falhas em um sistema teste que corresponde a um alimentador de distribuição de energia elétrica. O que se pretende é avaliar a viabilidade, eficiência e esforço computacional do método caso seja implementado em tempo real.


6.1 Base de Dados

Normalmente, os centros de pesquisas e as concessionárias não possuem um banco de dados representativo do sistema de distribuição operando sob a influência de falhas elétricas. Devido à escassez destes registros, torna-se necessária a utilização de sistemas teste para a simulação de falhas, possibilitando, então, a extração de informações pertinentes e validação de metodologias de diagnóstico e prognóstico.

6.1.1 Sistema Teste

Nesta pesquisa, utilizou-se o alimentador de 123 barras do IEEE (IEEE Power Engineering Society, 2013) como sistema teste, o qual é fortemente caracterizado pelo desbalanceamento entre as fases, *i.e.*, características de operação real de um alimentador de distribuição. Na figura 14 apresenta-se a estrutura do sistema teste de 123 barras. Ele foi modelado com o auxílio do *software* EMTP-RV (*EletroMagnetic Transients Program – Revised Version*) (DOMMEL, 1996) para a realização de simulações a serem empregadas na validação da metodologia.

Figura 14 – Alimentador de distribuição de energia IEEE-123



Fonte: IEEE Power Engineering Society (2013).

Neste alimentador, assim como a maioria dos outros sistemas de distribuição, as medições de tensão e corrente são realizadas somente na subestação principal. Embora seja comum este tipo de medição, uma das características dos *smart grids* é a presença de inúmeros medidores ao longo do alimentador. Pelo fato da alocação ótima de medidores não ser o foco desta pesquisa, os locais em que foram alocados os medidores inteligentes são mostrados em vermelho na figura 14, os quais foram definidos após a eliminação dos trechos monofásicos e bifásicos, restando somente os trifásicos, e inserindo os pontos de medição em barras com uma ou mais derivações (ramificações).


6.1.2 Simulações

Utilizando uma frequência de amostragem de 15,36 kHz, que é comumente disponibilizada nos equipamentos de medição/aquisição, e correspondente a 256 amostras por ciclo, realizaram-se 2889 simulações considerando as seguintes variáveis: ângulo de inserção da falha (0° , 45° e 90°), fase de incidência da falha (a , b e c), local da falha e comportamento da falha. Deste total, as simulações podem ser divididas em: faltas de alta impedância, afundamentos de tensão (obtidos por meio de curtos-circuitos), e transitórios oscilatórios (obtidos via do chaveamento de banco de capacitores).

Por não existir um modelo preciso para a representação das faltas de alta impedância, muitas publicações da literatura especializada propõem modelos que podem ser usados na

análise das faltas de alta impedância (EMANUEL *et al.*, 1990; ETEMADI; SANAYE-PASAND, 2008; GAUTAM; BRAHMA, 2013; LAI *et al.*, 2005; SAMANTARAY, 2012; SAMANTARAY; DASH; UPADHYAY, 2009; SHENG; ROVNYAK, 2004; WAI; YIBIN, 1998). Para a simulação desta falha, utilizou-se o modelo proposto por Emanuel *et al.* (1990), mostrado na figura 15.

Figura 15 – Modelo para simulação de faltas de alta impedância



Fonte: Emanuel *et al.* (1990).

Este modelo possui duas fontes de tensão contínua, V_p e V_n , conectadas de maneira antiparalela por meio de dois diodos. A impedância série controla a magnitude do arco de corrente (EMANUEL *et al.*, 1990). A tabela 14 mostra três combinações de valores de V_p , V_n e da impedância série utilizados na representação da FAI.

Tabela 14 – Valores de V_p , V_n e da impedância série

FAI	Parâmetros			
	V_p (V)	V_n (V)	R (Ω)	X (Ω)
1	2000	2500	20	150
2	500	2000	10	200
3	1500	2000	100	300

Fonte: Elaborada pelo autor.

Para as outras falhas elétricas, *i.e.*, transitório oscilatório e afundamento de tensão, foram simulados chaveamentos de bancos de capacitores e curtos-circuitos francos, respectivamente. Nas tabelas 15 e 16 apresentam-se os valores dos bancos de capacitores utilizados e os valores das resistências de falta, respectivamente.

Tabela 15 – Valores de potência reativa dos bancos de capacitores chaveados no sistema

Número do Banco de Capacitor	Banco (kVAr)
1	150
2	300
3	600

Fonte: Elaborada pelo autor.

Tabela 16 – Valores da resistência de falta dos curtos-circuitos

Número do Curto-Circuito	Resistência de Falta (Ω)
1	1
2	10
3	50

Fonte: Elaborada pelo autor.

Considerando cada etapa da metodologia proposta, observa-se que as redes neurais artificiais são conceitos essenciais para o funcionamento da mesma. Entretanto, se os pesos não forem ajustados corretamente, por meio de um treinamento prévio, estas não produzem resultados satisfatórios. Logo, necessita-se da seleção de padrões para treinamento de todas as redes neurais empregadas, *i.e.*, redes ARTMAP-*Fuzzy* e redes de base radial. O conjunto de simulações foi dividido, de maneira pseudoaleatória, em dois conjuntos: treinamento e teste, conforme tabela 17.

Tabela 17 – Número de padrões empregados no treinamento e teste das redes neurais artificiais

Tipo de Falha	Conjunto de Padrões		
	Treinamento	Teste	Total
Falta de Alta Impedância na Fase <i>a</i>	266	76	342
Falta de Alta Impedância na Fase <i>b</i>	229	59	288
Falta de Alta Impedância na Fase <i>c</i>	259	74	333
Afundamento de Tensão na Fase <i>a</i>	276	66	342
Afundamento de Tensão na Fase <i>b</i>	227	61	288
Afundamento de Tensão na Fase <i>c</i>	265	68	333
Transitório Oscilatório na Fase <i>a</i>	272	70	342
Transitório Oscilatório na Fase <i>b</i>	235	53	288
Transitório Oscilatório na Fase <i>c</i>	271	62	333
Total	2300	589	2889

Fonte: Elaborada pelo autor.

6.2 Diagnóstico e Prognóstico de Falhas

O desenvolvimento de um eficiente sistema de diagnóstico e de prognóstico de falhas possui duas etapas fundamentais: extração de assinaturas dos sinais e utilização de modernas ferramentas para análise de dados.

A etapa inicial do processo de detecção e classificação de falhas, *i.e.*, extração de características dos sinais de tensão e corrente, é realizada empregando-se a *mother wavelet* Daubechies com filtro de quarta ordem ('*db4*'). O uso da transformada *wavelet* possibilitou a identificação dos transitórios de frequência característicos de falhas elétricas, além de tornar a decomposição das oscilografias mais eficiente, uma vez que não existe a necessidade de aplicar janelas no processamento, *e.g.*, janela de Hanning. Os índices comportamentais extraídos das oscilografias são avaliados via emprego das redes *ARTMAP-Fuzzy* situadas em cada um dos pontos de medição. A taxa de acerto dos módulos de detecção e classificação de falhas é apresentada na tabela 18. A primeira coluna da tabela abaixo indica o local (barra) que são provenientes as oscilografias de tensão e de corrente empregadas no módulo de diagnóstico na indicação da existência ou não de uma falha em qualquer ponto do alimentador. Já a segunda coluna representa a taxa de acerto no diagnóstico de anormalidades para todo o sistema, *i.e.*, se o sistema está sob operação de uma falha, estando a anormalidade presente ou não em uma barra de medição. Por exemplo, o módulo de diagnóstico da barra 54 pode indicar a presença de uma falha no sistema de distribuição mesmo que esta tenha ocorrido na barra 50.

Tabela 18 – Taxa de acerto dos módulos de detecção e classificação de falhas

Local do Módulo de Diagnóstico	Taxa de Acerto (%)
Módulo da Barra 149	98,47
Módulo da Barra 13	97,96
Módulo da Barra 18	97,45
Módulo da Barra 47	95,92
Módulo da Barra 54	97,28
Módulo da Barra 60	97,62
Módulo da Barra 67	96,26
Módulo da Barra 76	97,79
Módulo da Barra 97	96,43

Fonte: Elaborada pelo autor.

Analisando a tabela 18, tem-se que a metodologia de detecção e classificação desenvolvida possui elevada taxa de acerto, provando ser robusta com elevada capacidade de generalização e eficiente.

Após a identificação de uma falha, três redes ARTMAP-*Fuzzy* (uma para cada fase) são responsáveis por indicar a seção do alimentador na qual se encontra a falha. A taxa de acerto na determinação das seções em falha no alimentador é mostrada na tabela 19.

Tabela 19 – Taxa de acerto na determinação da seção da falha

Fase da Falha	Taxa de Acerto (%)
<i>a</i>	88,00
<i>b</i>	86,70
<i>c</i>	85,78

Fonte: Elaborada pelo autor.

Observando a tabela 19, tem-se que as taxas de acerto são todas inferiores a 90%, o que geram dúvidas com relação a eficiência do método de indicação da seção em falha. No entanto, ao analisar os resultados produzidos pelas redes neurais de forma mais aprofundada (análise individual dos resultados), pode-se concluir que os erros não são grosseiros, *i.e.*, os erros produzidos pelas redes são, de certa forma, aceitáveis, já que na maior parte dos equívocos, são fornecidas as seções vizinhas da seção na qual realmente se encontra a falha. Como exemplo, uma falha na fase *b* que se encontra na seção 5 (conforme figura 12) é informada pela rede como pertencente à seção 1, o que é aceitável, já que as seções vizinhas da seção 1 são as seções 2 e 5 (conforme tabela 3). O que não pode ocorrer é a indicação da seção 9 como seção em falha, isto porque esta não possui nenhuma conectividade com a seção 5. Desta forma, as seções a serem avaliadas devem sempre englobar a seção em falha, sendo ela a seção principal ou pertencente à seção vizinha àquela indicada pela rede neural.

Pelo fato do resultado final ser uma lista de barras, as quais são as candidatas à barra em falha, não é possível avaliar a taxa de acerto do método, já que cada barra é acompanhada de um valor de probabilidade. No entanto, pode-se verificar, a partir do total de casos teste, o número de vezes que a barra em falha está presente entre as barras da primeira e segunda lista, que é apresentado na tabela 20.

Tabela 20 – Número de vezes que a barra em falha estava presente entre as barras candidatas da primeira e segunda lista

Fase da Barra em Falha	Total de Casos	Barra em Falha	
		Primeira Lista	Segunda Lista
<i>A</i>	212	186	23
<i>B</i>	173	150	19
<i>C</i>	204	175	24

Fonte: Elaborada pelo autor.

Na Tabela 20, ilustra-se a eficiência e confiabilidade na localização da barra em falha. Para o operador, é interessante quando a barra em falha se encontra na primeira lista (seção principal) ou na segunda lista (seções vizinhas), possuindo probabilidade igual ou diferente de zero. Com isso, mesmo que tenha de percorrer todas as barras indicadas nas duas listas, a falha será identificada. Em contrapartida, caso a barra em falha não esteja presente em nenhuma das listas, significa que a metodologia errou de forma grosseira. Na tabela, tem-se que, do total de casos para as fases *a*, *b* e *c*, o número de erros grosseiros são 3 para a fase *a*, 4 para a fase *b*, e 5 para a fase *c*.

7 CONCLUSÕES

Neste trabalho é proposta uma metodologia inédita que executa o diagnóstico e o prognóstico de falhas em sistemas de distribuição de energia elétrica. Em uma etapa inicial, o sistema foi desenvolvido para detectar, classificar e localizar falhas sutis, *e.g.*, faltas de alta impedância, pois estas representam um grande problema para as concessionárias, uma vez que são constatadas no alimentador quando já evoluíram para um evento mais crítico e causaram a interrupção no fornecimento de energia. Por meio da aplicação deste método é possível antecipar a evolução da falha, *i.e.*, possui características proativas, evitando maiores prejuízos às concessionárias e seus consumidores. Além disso, após verificar sua eficiência, a metodologia foi aplicada no diagnóstico e prognóstico de outras falhas menos críticas, *e.g.*, curtos-circuitos e transitório oscilatórios, mostrando ser também bastante eficaz e confiável.

Para realizar a detecção de anormalidades nos alimentadores é preciso extrair singularidades das oscilografias de tensão e de corrente, permitindo a representação de qualquer estado operativo do sistema de distribuição. Em contraste de como são feitas atualmente, as medições, neste método, foram realizadas em diferentes pontos ao longo do alimentador. Isto se deve ao paradigma *smart grid*, o qual aborda a necessidade dos módulos serem dotados de inteligência e capacidade de aprendizado, *i.e.*, módulos desenvolvidos utilizando técnicas baseadas na inteligência artificial, e que, para isso, devem ser disponibilizadas informações mais abrangentes a respeito das barras e estados operativos do alimentador.

No sistema de diagnóstico e de prognóstico proposto, a análise é realizada automaticamente a partir dos registros oscilográficos via transformada *wavelet*, redes neurais artificiais e teoria da evidência de Dempster-Shafer. A integração de técnicas de processamento de sinais, algoritmos da inteligência artificial e técnicas de fusão de dados proporcionou alta capacidade de generalização, flexibilidade, robustez, eficiência, características imprescindíveis ao auxílio à tomada de decisão.

A primeira etapa, responsável pela detecção e classificação de anormalidades, as oscilografias de tensão e corrente são avaliadas no domínio *wavelet* na busca por transitórios de frequência característicos de falhas elétricas. Nove redes neurais ARTMAP-*Fuzzy* fornecem o estado operativo do sistema, sendo o estado final obtido por meio de um esquema de votação simples.

Identificada qualquer anormalidade, inicia-se o processo de localização da falha. A rede neural ARTMAP-*Fuzzy*, correspondente à fase faltosa, é ativada, utilizando, também, informações no domínio *wavelet* para indicar a seção do alimentador na qual se encontra a falha. Posteriormente, a distância real e a distância provável são estimadas empregando-se a matriz de distância e uma rede neural de base radial, respectivamente. Em seguida, após estas distâncias serem comparadas e analisadas por meio da teoria da evidência, são geradas duas listas com as prováveis barras em falha. Cada barra é acompanhada de um valor qualitativo a respeito da probabilidade da falha se encontrar naquele local. Com isso, o operador pode enviar a equipe de manutenção ao local correto do alimentador para que a falha seja eliminada antes de uma possível evolução (evento crítico), evitando, assim, maiores danos aos consumidores.

O emprego de redes neurais da família ART permite a inclusão do treinamento continuado, o que representa outra vantagem em relação às técnicas tradicionais utilizadas na literatura especializada. Nestas, a inserção de um novo padrão para treinamento requer a reinicialização deste processo, enquanto que na rede ARTMAP-*Fuzzy* este reforço pode ser realizado continuamente sem perda do conhecimento previamente adquirido, provendo a melhoria, de forma contínua, da qualidade dos resultados e adaptação automática do sistema de diagnóstico e de prognóstico à constante expansão e evolução do setor elétrico.

Para avaliar o desempenho do método proposto, foram simuladas falhas elétricas em um alimentador de distribuição de energia elétrica composto por 123 barras. Os resultados obtidos mostram que o algoritmo proposto é eficiente, confiável e robusto, principalmente quando aplicado no diagnóstico e no prognóstico de faltas de alta impedância, o que representa um grande avanço neste mesmo contexto, já que as FAIs possuem comportamentos/características bem complexos.

A metodologia desenvolvida, mesmo apresentando excelentes resultados, pode ser aprimorada. Neste sentido, apresentam-se a seguir algumas sugestões para trabalhos futuros:

- Inclusão da geração distribuída em barras do sistema de distribuição de forma a verificar como se comporta a metodologia;
- Acréscimo de novas barras e seções no alimentador para avaliar o impacto da expansão do sistema elétrico no diagnóstico e no prognóstico de falhas;
- Aplicação da metodologia para o diagnóstico e prognóstico de novas falhas;
- Inclusão do módulo de treinamento continuado nos módulos de diagnóstico e de prognóstico de falhas;

- Utilizar a metodologia para o prognóstico da poda de árvores com o propósito de reduzir a incidência das faltas de alta impedância no alimentador;
- Inserção do algoritmo em uma plataforma FPGA ou DSP para operação em tempo-real.

REFERÊNCIAS

ANDERSON, P. M.; FOUAD, A. A. **Power system control and stability**. 2. ed., New York: John Wiley & Sons: IEEE Press, 2002.

ARULAMPALAM, M. S.; MASKELL, S.; GORDON, N.; CLAPP, T. A tutorial on particle filters for online nonlinear/non-Gaussian Bayesian tracking. **IEEE Transactions on Signal Processing**, v. 50, n. 2, p. 174–188, 2002.

BAKAR, A. H. A.; ALI, M. S.; TAN, C.; MOKHILS, H.; AROF, H.; ILLIAS, H. A. High impedance fault location in 11kV underground distribution systems using wavelet transforms. **International Journal of Electric Power and Energy Systems**, Oxford, v. 55, p. 723-730, 2014.

BAQUI, I.; ZAMORA, I.; MAZÓN, J.; BUIGUES, G. High impedance fault detection methodology using wavelet transform and artificial neural networks. **Electric Power Systems Research**, Lausanne, v. 81, n. 7, p. 1325-1333, 2011.

BARNETT, J. A. Computational methods for a mathematical theory of evidence. In: YAGER, R. R.; LIU, L. (Eds.). **Classic works of the Dempster-Shafer Theory of belief functions**. Berlin: Springer, 2008. p. 197–216.

BEALE, M. H.; HAGAN, M. T.; DEMUTH, H. B. **Neural network toolbox: user's guide**. The Math Works, 2013.

BROOMHEAD, D. S.; LOWE, D. Multivariable functional interpolation and adaptive networks. **Complex Systems**, v. 2, n. 3, p. 321-355, 1988.

BUCHANAN, B. G.; SHORTLIFFE, E. D. **Rule-based expert systems: the MYCIN experiments of the Stanford heuristic programming project**. Boston: Addison-Wesley, 1984.

CARPENTER, G. A.; GROSSBERG, S.; MARKUZON, N.; REYNOLDS, J. H. Fuzzy ARTMAP: a neural network architecture for incremental supervised learning of analog multidimensional maps. **IEEE Transactions on Neural Networks**, vol. 3, no. 5, pp. 698–713, 1992.

CARPENTER, G. A.; GROSSBERG, S. A self-organizing neural network for supervised learning, recognition and prediction. **IEEE Communications Magazine**, Piscataway, v. 30, n. 9, p. 38–49, 1992.

CASTRO, L. N.; VON ZUBEN, F. J. Learning and optimization using the clonal selection principle. **IEEE Transactions on Evolutionary Computation**, v. 6, n. 3, p. 239-251, 2002.

DAUBECHIES, I. **Ten lectures on wavelets**. Philadelphia: Society for Industrial and Applied Mathematics, 1992.

DECANINI, J. G. M. S.; TONELLI-NETO, M. S.; MALANGE, F. C. V.; MINUSSI, C. R. Detection and classification of voltage disturbances using a fuzzy-ARTMAP-wavelet network. **Electric Power Systems Research**, Lausanne, v. 81, n. 12, p. 2057–2065, 2011.

DECANINI, J. G. M. S.; TONELLI-NETO, M. S.; MINUSSI, C. R. Robust fault diagnosis in power distribution systems based on fuzzy ARTMAP neural network-aided evidence theory. **IET Generation, Transmission and Distribution**, Stevenage, v. 6, n. 11, p. 1112–1120, 2012.

DOMMEL, H. W. **EMTP theory book**. Microtran Power System Analysis Corporation, Vancouver, British Columbia, 1996.

EMANUEL, A. E.; GULACHENSKI, E. M. High impedance fault arcing on sandy soil in 15kV distribution feeders: contributions to the evaluation of the low frequency spectrum. **IEEE Transactions on Power Delivery**, Piscataway, v. 5, n. 2, p. 676-686, 1990.

ETEMADI, A. H.; SANAYE-PASAND, M. High-impedance fault detection using multi-resolution signal decomposition and adaptive neural fuzzy inference system. **IET Generation, Transmission and Distribution**, Stevenage, v. 2, n. 1, p. 110–118, 2008.

FAN, J.; BORLASE, S. The evolution of distribution. **IEEE Power and Energy Magazine**, Piscataway, v. 7, n. 2, p. 63-68, 2009.

GAUTAM, S.; BRAHMA, S. M. Detection of high impedance fault in power distribution systems using mathematical morphology. **IEEE Transactions on Power Systems**, Piscataway, v. 28, n. 2, p. 1226-1234, 2013.

GROER, P. G. Analysis of time-to-failure with a Weibull model. In: MAINTENANCE AND RELIABILITY CONFERENCE, 2000, Knoxville. **Proceedings...** Knoxville: MARCON, 2000.

GROSSBERG, S. Adaptive pattern classification and universal recoding, I: parallel development and coding of neural feature detectors. **Biological Cybernetics**, Heidelberg, v. 23, n. 3, p. 121–134, 1976a.

GROSSBERG, S. Adaptive pattern classification and universal recoding, II: feedback, expectation, olfaction, and illusions. **Biological Cybernetics**, Heidelberg, v. 23, n. 4, p. 187–202, 1976b.

HALICI, U. **Artificial neural networks**. 154 f. Notas de Aula – Department of Electrical and Electronics Engineering, Middle East Technical University, Ankara: Turkey, 2004.

HALL, D.; LLINAS, J. An introduction to multisensor data fusion. **Proceedings of the IEEE**, Piscataway, v. 85, n. 1, p. 6-23, 1997.

HAYKIN, S. **Neural networks and learning machines**. 3. ed. Upper Saddle River: Prentice-Hall, 2008.

HUANG, S.-J.; HSIEH, C.-T. High-impedance fault detection utilizing a Morlet wavelet transform approach. **IEEE Transactions on Power Delivery**, Piscataway, v. 14, n. 4, p. 1401-1410, 1999.

IEEE Power Engineering Society. Distribution System Analysis Subcommittee. **IEEE 123 node test feeder**. Austin, TX, 2013. Disponível em: <http://ewh.ieee.org/soc/pes/dsacom/testfeeders/feeder123.zip>. Acesso em: 30 jun. 2014.

JANG, J.-S. R. ANFIS: adaptive-network-based fuzzy inference system. **IEEE Transactions on Systems, Man, and Cybernetics**, Piscataway, v. 23, n. 3, p. 665-685, 1993.

JOTA, P. R. S.; JOTA, F. G. Fuzzy detection of high impedance faults in radial distribution feeders. **Electric Power Systems Research**, Lausanne, v. 49, n. 3, p. 169-174, 1999.

KARTALOPOULOS, S. V. **Understanding neural networks and fuzzy logic: basic concepts and applications**. Piscataway: IEEE Press, 1996.

KEZUNOVIC, M. Smart fault location for smart grids. **IEEE Transactions on Smart Grid**, Piscataway, v. 2, n. 1, p. 11-22, 2011.

KUNG, S. Y. **Digital neural networks**. Englewood Cliffs: Prentice-Hall, 1993.

LAI, T. M.; SNIDER, L. A.; LO, E.; SUTANTO, D. High-impedance fault detection using discrete wavelet transform and frequency range and RMS conversion. **IEEE Transactions on Power Delivery**, Piscataway, v. 20, n. 1, p. 397-407, 2005.

LEONARD, J. A.; KRAMER, M. A. Radial function networks for classifying process faults. **IEEE Transactions on Control Systems**, Piscataway, v. 11, n. 3, p. 31-38, 1991.

LIEN, K.-Y.; CHEN, S.-L.; LIAO, C.-J.; GUO, T.-Y.; LIN, T.-M.; SHEN, J.-S. Energy variance criterion and threshold tuning scheme for high impedance fault detection. **IEEE Transactions on Power Delivery**, Piscataway, v. 14, n. 3, p. 810-817, 1999.

LIM, C. P.; HARRISON, R. F. Modified fuzzy ARTMAP approaches bayes optimal classification rates: an empirical demonstration. **Neural Networks**, Oxford, v. 10, n. 4, p. 755-774, 1997.

LOPES, M. L. M. **Desenvolvimento de redes neurais para previsão de cargas elétricas de sistema de energia elétrica**. 149 f. Tese (Doutorado em Engenharia Elétrica) – Faculdade de Engenharia, Universidade Estadual Paulista, Ilha Solteira, 2005.

LOPES, M. L. M.; MINUSSI, C. R.; LOTUFO, A. D. P. Electric load forecasting using a fuzzy ART&ARTMAP neural network. **Applied Soft Computing**, Amsterdam, v. 5, n. 2, p. 235-244, 2005.

MACQUEEN, J. Some methods for classification and analysis of multivariate observations. In: LECAM, L. M.; NEYMAN, J. (Eds.). **Fifth Berkeley Symposium on Mathematical Statistics and Probability**, Berkeley: U. C. Berkeley Press, 1967. p. 281-297.

- MALLAT, S. **A wavelet tour of signal processing: the sparse way**. 3. ed. Burlington: Academic Press, 2009.
- MAMISHEV, A. V.; RUSSELL, B. D.; BENNER, C. L. Analysis of high impedance faults using fractal techniques. **IEEE Transactions on Power Systems**, Piscataway, v. 11, n. 1, p. 435-440, 1996.
- MCDONALD, J. D. **Electric power substations engineering**. Boca Raton: CRC Press, 2003.
- MICHALIK, M.; REBIZANT, W.; LUKOWICZ, M.; LEE, S.-J.; KANG, S.-H. High-impedance fault detection in distribution networks with use of wavelet-based algorithm. **IEEE Transactions on Power Delivery**, Piscataway, v. 21, n. 4, p. 1793-1802, 2006.
- MILIOUDIS, A. N.; ANDREOU, G. T.; LABRIDIS, D. P. Enhanced protection scheme for smart grids using power line communications techniques – part I: detection of high impedance fault occurrence. **IEEE Transactions on Smart Grid**, Piscataway, v. 3, n. 4, p. 1621-1630, 2012a.
- MILIOUDIS, A. N.; ANDREOU, G. T.; LABRIDIS, D. P. Enhanced protection scheme for smart grids using power line communications techniques – part II: location of high impedance fault position. **IEEE Transactions on Smart Grid**, Piscataway, v. 3, n. 4, p. 1631-1640, 2012b.
- MISITI, M.; MISITI, Y.; OPPENHEIM, G.; POGGI, J.-M. **Wavelet toolbox 4: user's guide**. The Math Works, 2010.
- MOODY, T. J.; DARKEN, C. J. Fast learning in networks of locally tuned processing units. **Neural Computation**, v. 1, p. 151-160, 1989.
- MOODY, T. J.; DARKEN, C. J. Learning with localized receptive fields. In: TOURETSKY, G. H.; SEJNOWSKI, T. (Eds.). **Connectionist models summer school**, San Mateo: Morgan Kaufman, 1989. p. 133-143.
- NORTHCOTE-GREEN, J.; WILSON, R. **Control and automation of electrical power distribution systems**. Boca Raton: CRC/Taylor & Francis, 2007.
- OPPENHEIM, A. V.; SCHAFER, R. W. **Digital signal processing**. Englewood Cliffs: Prentice Hall, 1975.
- RENALDS, S.; ROHWER, R. Phoneme classification experiments using radial basis functions. In: INTERNATIONAL JOINT CONFERENCE ON NEURAL NETWORKS, 1989, Washington. **Proceedings...** Piscataway: IEEE, 1989, v. 1, p. 461-467.
- RUSSELL, B. D.; BENNER, C. L. Intelligent systems for improved reliability and failure diagnosis in distribution systems. **IEEE Transactions on Smart Grid**, Piscataway, v. 1, n. 1, p. 48-56, 2010.
- SAMANTARAY, S. R. Ensemble decision trees for high impedance fault detection in power distribution network. **International Journal of Electric Power and Energy Systems**, Oxford, v. 43, n. 1, p. 1048-1055, 2012.

SAMANTARAY, S. R.; DASH, P. K.; UPADHYAY, S. K. Adaptive Kalman filter and neural network based high impedance fault detection in power distribution networks.

International Journal of Electric Power and Energy Systems, Oxford, v. 31, n. 4, p. 167-172, 2009.

SAMANTARAY, S. R.; PANIGRAHI, B. K.; DASH, P. K. High impedance fault detection in power distribution networks using time-frequency transform and probabilistic neural network. **IET Generation, Transmission and Distribution**, Stevenage, v. 2, n. 2, p. 261-270, 2008.

SARLAK, M.; SHAHRTASH, M. High-impedance faulted branch identification using magnetic-field signature analysis. **IEEE Transactions on Power Delivery**, Piscataway, v. 28, n. 1, p. 67-74, 2013.

SARLAK, M.; SHAHRTASH, S. M. High impedance fault detection using combination of multi-layer perceptron neural networks based on multi-resolution morphological gradient features of current waveform. **IET Generation, Transmission and Distribution**, Stevenage, v. 5, n. 5, p. 588-595, 2011.

SCHÖMIG, A. K.; ROSE, O. On the suitability of the Weibull distribution for the approximation of machine failures. In: INDUSTRIAL ENGINEERING RESEARCH CONFERENCE, 2003, Portland. **Proceedings...** Portland, 2003.

SEDIGHI, A.-R.; HAGHIFAM, M.-R.; MALIK, O. P. Soft computing applications in high impedance fault detection in distribution systems. **Electric Power Systems Research**, Lausanne, v. 76, n. 1-3, p. 136-144, 2005.

SHAFER, G. **A mathematical theory of evidence**. Princeton: Princeton University Press, 1976.

SHENG, Y; ROVNYAK, M. Decision tree-based methodology for high impedance fault detection. **IEEE Transactions on Power Delivery**, Piscataway, v. 19, n. 2, p. 533-536, 2004.

STAGG, G. W.; EL-ABIAD, A. H. **Computer methods in power system analysis**. New York: McGraw-Hill, 1968.

SULTAN, A. F.; SWIFT, G. W.; FEDIRCHUK, D. J. Detection of high impedance arcing faults using a multi-layer perceptron. **IEEE Transactions on Power Delivery**, Piscataway, v. 7, n. 4, p. 1871-1877, 1992.

TONELLI-NETO, M. S. **Formulação do controle preventivo em sistemas de distribuição de energia elétrica baseada na lógica fuzzy e redes neurais**. 137 f. Dissertação (Mestrado em Engenharia Elétrica) – Faculdade de Engenharia, Universidade Estadual Paulista, Ilha Solteira, 2012.

TONELLI-NETO, M. S.; DECANINI, J. G. M. S.; BARROS, A. C.; MINUSSI, C. R. Diagnóstico de faltas de alta impedância em alimentadores de distribuição de energia elétrica via sistema de inferência fuzzy e teoria da evidência. In: SIMPÓSIO BRASILEIRO DE AUTOMAÇÃO INTELIGENTE, 11., 2013, Fortaleza. **Anais...** Fortaleza: [s.n.], 2013. p. 1-6.

VERZI, S. I.; HEILEMAN, G. L.; GEORGIPOULOS, M.; ANAGNOSTOPOULOS, G. C. Universal approximations with fuzzy ART and fuzzy ARTMAP. In: INTERNATIONAL JOINT CONFERENCE ON NEURAL NETWORKS, 2003, Portland. **Proceedings...** Piscataway: IEEE, 2003. v. 3, p. 1987–1992.

WAI, D. C. T.; YIBIN, X. A novel technique for high impedance fault identification. **IEEE Transactions on Power Delivery**, Piscataway, v. 13, n. 3, p. 738-744, 1998.

WEENINK, D. Category ART: a variation on adaptive resonance theory neural networks. **Proceedings of the Institute of Phonetic Sciences**, Amsterdam, v. 21, p. 117–129, 1997.

WEIBULL, W. A statistical distribution function of wide applicability. **Journal of Applied Mechanics**, Evanston, v. 18, n. 3, p. 293–297, 1951.

WERBOS, P. J. Beyond regression: New tools for prediction and analysis in the behavioral sciences. **Master Thesis**, Harvard University, 1974.

WIDROW, B.; LEHR, M. A. 30 years of adaptive neural networks: perceptron, madaline, and backpropagation. **Proceedings of the IEEE**, Piscataway, v. 78, n. 9, p. 1415-1442, 1990.

WILSON, N. Algorithms for Dempster-Shafer theory. In: KOHLAS, J.; MORAL, S. (Eds.). **Algorithms for uncertainty and defeasible reasoning**. Dordrecht: Kluwer Academic Publishers, 1999.

YAO, S. C.; ZAFIRIOU, E. Control system sensor failure detection via networks of localized receptive fields. In: AMERICAN CONTROL CONFERENCE, 1990, San Diego. **Proceedings...** Piscataway: IEEE, 1990, p. 2472-2477.

ZADEH, L. A. Fuzzy sets. **Information and Control**, Maryland Heights, v. 8, n. 3, p. 338-353, 1965.

APÊNDICE A – TRANSFORMADA *WAVELET*

Uma das etapas mais importantes no diagnóstico de falhas é a extração de características. Na literatura, são encontradas diversas ferramentas para este propósito, sendo destacada a transformada de Fourier. Embora a transformada de Fourier seja amplamente empregada no processamento de sinais, ela possui limitações que não permite sua aplicação em modernos sistemas inteligentes de detecção, *i.e.*, não fornecem a evolução temporal de transitórios de frequência. Neste contexto, a transformada *wavelet* torna-se um método disponível que supera as limitações encontradas nos métodos baseados na transformada de Fourier (TONELLI-NETO *et al.*, 2013).

A transformada *wavelet* é uma moderna técnica de processamento de sinais, a qual relaciona escala e tempo. Ela tem como principal vantagem o fato de não empregar uma escala fixa na análise dos sinais, evitando o comprometimento com uma determinada escala. Neste sentido, utilizam-se escalas maiores para analisar sinais de baixa frequência e escalas menores para analisar sinais de alta frequência, sendo, assim, possível identificar os transitórios de frequência característicos de falhas elétricas em sistemas de distribuição de energia elétrica (DECANINI *et al.*, 2011).

A.1 Transformada Wavelet Contínua

A transformada *wavelet* contínua (TWC) provê uma descrição no domínio tempo-frequência para um determinado sinal $f(t)$. Ela utiliza uma função $\psi \in \mathbf{L}^2(\mathbb{R})$, *i.e.*, função *wavelet*, a qual é uma função oscilatória com valor médio nulo para decompor o sinal em análise (DAUBECHIES, 1992; MALLAT, 2009):

$$\int_{-\infty}^{+\infty} \psi(t) dt = 0 \quad (35)$$

A partir da função *wavelet* define-se um conjunto de funções $\psi_{r,s}(t)$ que serão utilizadas para representação do sinal. Este conjunto é obtido por meio de dilatações e translações da função *wavelet* ψ conforme descrito pela equação 36.

$$\psi_{r,s}(t) = \frac{1}{\sqrt{|r|}} \psi\left(\frac{t-s}{r}\right), \quad s \in \mathbb{R} \text{ e } r \in \mathbb{R}^+, \text{ com } r \neq 0 \quad (36)$$

sendo:

r : parâmetro de escala;

s : parâmetro de translação.

A TWC de um sinal $f(t)$ em relação às *wavelets* criadas, *i.e.*, versões dilatadas e transladadas da função ψ , é definida a seguir.

$$(TWC f)(r,s) = \langle f, \psi_{r,s} \rangle = \int_{-\infty}^{+\infty} f(t) \frac{1}{\sqrt{|r|}} \psi^*\left(\frac{t-s}{r}\right) dt \quad (37)$$

sendo:

ψ^* : conjugado complexo de ψ .

Como resultado da decomposição, na análise *wavelet* é gerado um conjunto de coeficientes que indicam o grau de semelhança entre o sinal original e as funções *wavelets* utilizadas no processo de decomposição.

A.2 Transformada *Wavelet* Discreta

A transformada *wavelet* discreta (TWD) é o resultado da amostragem da TWC, e tem como objetivo permitir sua implementação em sistemas discretos.

De modo a facilitar o processo de discretização da função *wavelet*, faz-se $r = r_0^m$, $s = ns_0 r_0^m$, sendo $m, n \in \mathbb{Z}$, e $r_0 > 1$, $s_0 > 0$. A escolha de r_0 e s_0 depende, é claro, da função *wavelet* ψ . Desta forma, a função *wavelet* é reescrita, conforme equação 38 (MALLAT, 2009).

$$\psi_{m,n}(t) = \frac{1}{\sqrt{r_0^m}} \psi\left(\frac{t - ns_0 r_0^m}{r_0^m}\right), \quad m, n \in \mathbb{Z} \quad (38)$$

sendo:

$r = r_0^m$: parâmetro de escala;

$s = ns_0 r_0^m$: parâmetro de translação.

Assim, discretizando a equação 38, define-se a função *wavelet* discreta.

$$\psi_{m,n}[k] = \frac{1}{\sqrt{r_0^m}} \psi \left[\frac{k - ns_0 r_0^m}{r_0^m} \right] \quad (39)$$

Por fim, a TWD de um sinal amostrado $f[k]$ é definida por:

$$(TWD f)(m,n) = \langle f, \psi_{m,n} \rangle = \sum_k f[k] \psi_{m,n}^*[k] \quad (40)$$

sendo:

$$\psi_{m,n}^*[k] = \frac{1}{\sqrt{r_0^m}} \psi^* \left[\frac{k - ns_0 r_0^m}{r_0^m} \right].$$

A.3 Análise Multirresolução

Para a aplicação da Análise Multirresolução (AMR) realizam-se convoluções do sinal em análise com duas funções ortonormais. Elas são conhecidas como função de escala ($\phi_{m,n}$) e função *wavelet* ($\psi_{m,n}$). Suas formas discretas são definidas pelas equações 41 e 42, respectivamente (MALLAT, 2009).

$$\phi_{m,n}[k] = \frac{1}{\sqrt{2^m}} \phi \left[\frac{k - 2^m n}{2^m} \right] \quad (41)$$

$$\psi_{m,n}[k] = \frac{1}{\sqrt{2^m}} \psi \left[\frac{k - 2^m n}{2^m} \right] \quad (42)$$

com $r_0 = 2$ e $s_0 = 1$, assim como na equação 38.

Logo, a AMR consiste no cálculo dos coeficientes apr_{m+1} e det_{m+1} , determinados conforme as equações 43 e 44, respectivamente. Para este cálculo, realiza-se a convolução discreta do sinal $f[k]$ com a função escala discreta, *i.e.*, filtro passa-baixa (h), e com a função *wavelet* discreta, *i.e.*, filtro passa-alta (g), sendo as saídas subamostradas por um fator de 2 (MALLAT, 2009):

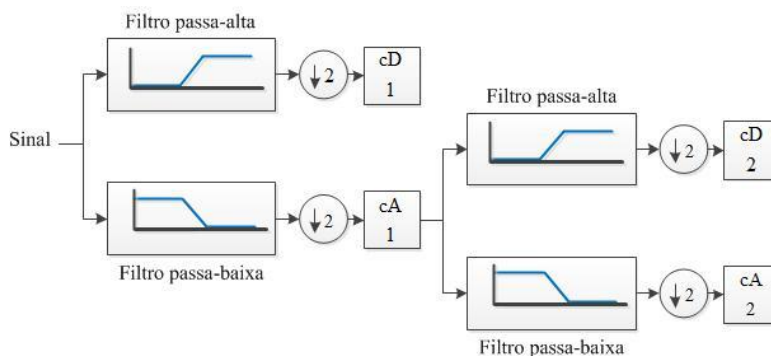
$$apr_m[p] = \sum_n h[n-2p] f[n] \quad (43)$$

$$det_m[p] = \sum_n g[n-2p] f[n] \quad (44)$$

Os coeficientes obtidos na saída do filtro passa-baixa (apr_m) são caracterizados por serem os componentes de alta escala e baixa frequência do sinal, denominados coeficientes de aproximação. Já os coeficientes obtidos na saída do filtro passa-alta (det_m) são os componentes de baixa escala e alta frequência, os coeficientes de detalhe.

A execução deste processo corresponde à decomposição do sinal em 1 nível de resolução. Para realizar a decomposição do sinal nos próximos níveis, ou seja, aqueles superiores ao primeiro, deve-se utilizar no lugar do sinal $f[n]$ os coeficientes de aproximação obtidos no nível anterior, e executar a convolução discreta destes com os filtros passa-baixa e passa-alta, obtendo os coeficientes de detalhe e de aproximação para o nível desejado. Na figura 16 apresenta-se a AMR com 2 níveis de resolução para o sinal f .

Figura 16 – Análise multirresolução com dois níveis de resolução



Fonte: Tonelli-Neto *et al.* (2013).

A.4 Famílias de Wavelets

Para que a decomposição seja realizada de forma eficiente, é necessária a escolha de uma família adequada, *i.e.*, uma *wavelet* mãe (*mother wavelet*). Não há um consenso a respeito da metodologia empregada para a escolha da família de *wavelets* em relação à sua aplicação, de modo que, cabe ao usuário escolher de maneira empírica a família mais adequada para a solução do seu problema. O processo de escolha da família pode ser bastante custoso, haja vista o grande número de variações de cada uma das *wavelets* mães. Em geral, as famílias Daubechies e Symlet são as mais utilizadas, o que não quer dizer que outras famílias não apresentem bons resultados (DECANINI *et al.*, 2011).

Para que uma determinada função possa ser utilizada como *wavelet* mãe, esta deve apresentar as seguintes propriedades (MALLAT, 2009):

- deve ser uma função oscilatória;
- deve possuir uma rápido decaimento para zero;
- deve possuir energia finita;
- deve possuir valor médio nulo.

Além disso, o *design* desta deve ser ótimo, *i.e.*, sua aplicação na decomposição de um sinal deve produzir um elevado número de coeficientes próximos de zero. Isto depende, então, da regularidade da função ψ , do número de *vanishing moments* (ordem da *wavelet* mãe ou momentos nulos) e do *support size* (tamanho do suporte).

O número de *vanishing moments* está associado à ordem polinomial dos sinais que podem ser representados por uma determinada *wavelet* mãe, o *support size* é o intervalo para o qual ela é definida (fora deste intervalo a função é nula), e a regularidade está relacionada ao erro introduzido no sinal reconstruído pelos coeficientes *wavelets*.

A.5 Energia

A aplicação da AMR na decomposição de um sinal gera um número considerável de coeficientes *wavelet*. No entanto, para minimizar a quantidade de coeficientes e tornar a metodologia mais eficiente, aplica-se o conceito energia para agregar as informações presentes nestes coeficientes, *i.e.*, para caracterizar e quantificar a ordenação de sinais não-estacionários (TONELLI-NETO *et al.*, 2013). O conceito energia é definido pela seguinte equação (OPPENHEIM; SCHAFER, 1975):

$$E = \sum_{x=1}^{NA} |f[x]|^2 \quad (45)$$

sendo:

NA : número de amostras do sinal f .

APÊNDICE B – REDES NEURAIS ARTIFICIAIS

Uma das características mais interessantes da memória humana é a capacidade de aprender continuamente com a inclusão de novas informações, sem perder o conhecimento previamente adquirido. Grande parte das redes neurais artificiais encontradas na literatura perde o conhecimento previamente adquirido caso novas informações sejam adicionadas para seu aprendizado. Neste sentido, Grossberg, em 1976, apresentou as redes neurais da família ART (*Adaptive Resonance Theory*) (GROSSBERG, 1976a, 1976b). A topologia desta família de redes é baseada na teoria da ressonância adaptativa, e possui duas importantes características: estabilidade e plasticidade. A estabilidade corresponde à capacidade de aprender por meio do ajuste dos pesos e a plasticidade à capacidade de continuar a aprender com a inclusão de novos padrões sem perder a memória previamente adquirida. Nas redes neurais *feedforward* supervisionadas, exemplificando a importância da estabilidade e da plasticidade, novas informações adicionadas gradualmente destroem as informações adquiridas anteriormente, não podendo atingir a estabilidade com uma mudança na configuração do ambiente (WEENINK, 1997).

As redes neurais da família ART são capazes de realizar, de maneira estável e por meio da auto-organização, o reconhecimento de categorias em resposta a sequências arbitrárias de padrões de entrada binários ou analógicos (CARPENTER; GROSSBERG, 1992; LOPES, 2005; WEENINK, 1997). Nos sistemas ART, diferente da representação adotada na literatura, os vetores são representados como linhas e não como colunas, o que simplifica a formulação das equações.

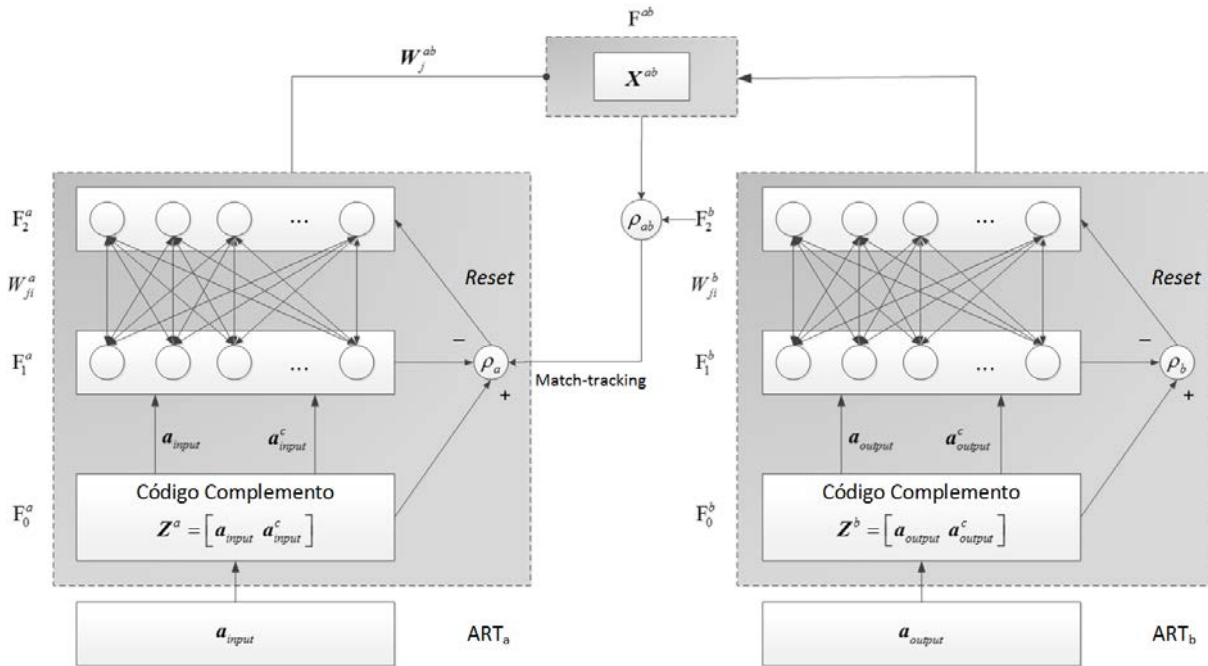
Como nesta pesquisa emprega-se a rede neural ARTMAP-*Fuzzy* no desenvolvimento da metodologia, é apresentado a seguir os principais conceitos desta rede neural.

B.1 Rede Neural ARTMAP-*Fuzzy*

A arquitetura neural ARTMAP-*Fuzzy* é um sistema de aprendizado auto-organizável, possui treinamento supervisionado e pertence à família ART, *i.e.*, sua estrutura é baseada na teoria da ressonância adaptativa, empregando cálculos baseados na lógica *fuzzy* (CARPENTER *et al.*, 1992; ZADEH, 1965).

Esta rede é composta por um par de módulos *ART-Fuzzy* (ART_a e ART_b), que são conectados por um módulo de memória associativa denominado inter-ART, como mostrado na figura 17.

Figura 17 – Estrutura da rede neural *ARTMAP-Fuzzy*



Fonte: Adaptado de Lopes (2005).

O módulo Inter-ART possui um mecanismo autorregulador interno chamado *match-tracking*, o qual objetiva maximizar a generalização e minimizar o erro da rede. Sempre que a rede faz um prognóstico errado, por meio de uma conexão associativa instruída, o parâmetro de vigilância ρ_a do módulo $ART_a-Fuzzy$ será incrementado em uma quantidade mínima necessária para corrigir o erro no módulo $ART_a-Fuzzy$. Assim, o módulo $ART_a-Fuzzy$ inicializará a busca de uma nova categoria para a entrada atual até que se encontre um prognóstico correto ou crie uma nova categoria no módulo $ART_a-Fuzzy$ e a sua conexão associativa correspondente à categoria no módulo $ART_b-Fuzzy$ (CARPENTER *et al.*, 1992; LIM; HARRISON, 1997; LOPES *et al.*, 2005).

B.1.1 Dados de Entrada

A rede neural *ARTMAP-Fuzzy* possui duas entradas, uma referente ao módulo $ART_a-Fuzzy$ e outra referente ao módulo $ART_b-Fuzzy$. A entrada referente ao módulo $ART_a-Fuzzy$ é representada pelo vetor \mathbf{a}_{input} , $\mathbf{a}_{input} = [a_{input,1} \ a_{input,2} \ \dots \ a_{input,M_a}]$, M_a -dimensional, e a saída do módulo $ART_b-Fuzzy$, que corresponde à saída desejada, é representada pelo vetor \mathbf{a}_{output} ,

$\mathbf{a}_{output} = [a_{output,1} \ a_{output,2} \ \dots \ a_{output,M_b}]$, M_b -dimensional. Os vetores de entrada dos módulos ART_a-*Fuzzy* e ART_b-*Fuzzy* são normalizados e complementados de maneira a compor as entradas da rede, \mathbf{Z}^a e \mathbf{Z}^b , definidas de acordo com as equações 46 e 47, respectivamente (CARPENTER *et al.*, 1992).

$$\mathbf{Z}^a = [\mathbf{a}_{input} \ \mathbf{a}_{input}^c] = [a_{input,1} \ \dots \ a_{input,M_a} \ a_{input,1}^c \ \dots \ a_{input,M_a}^c] \quad (46)$$

$$\mathbf{Z}^b = [\mathbf{a}_{output} \ \mathbf{a}_{output}^c] = [a_{output,1} \ \dots \ a_{output,M_a} \ a_{output,1}^c \ \dots \ a_{output,M_b}^c] \quad (47)$$

B.1.2 Parâmetros

Os parâmetros que precisam ser definidos para o correto funcionamento da rede neural ARTMAP-*Fuzzy* são apresentados a seguir (CARPENTER *et al.*, 1992).

- Parâmetro de escolha ($\alpha > 0$): atua na seleção de categorias;
- Taxa de treinamento ($\beta \in [0, 1]$): controla a velocidade de adaptação da rede;
- Parâmetro de vigilância do módulo ART_a-*Fuzzy* ($\rho_a \in [0, 1]$): controla a ressonância do módulo ART_a-*Fuzzy*;
- Parâmetro de vigilância do módulo ART_b-*Fuzzy* ($\rho_b \in [0, 1]$): controla a ressonância do módulo ART_b-*Fuzzy*;
- Parâmetro de vigilância do módulo Inter-ART ($\rho_{ab} \in [0, 1]$): controla a ressonância do módulo Inter-ART.

B.1.3 Inicialização dos Pesos

Inicialmente, todos os pesos da rede ARTMAP-*Fuzzy* ($\mathbf{W}_{(N \times 2M_a)}^a$, $\mathbf{W}_{(N \times 2M_b)}^b$ e $\mathbf{W}_{(N \times N)}^{ab}$) possuem o valor igual a um, indicando que não existe nenhuma categoria ativa (CARPENTER *et al.*, 1992).

$$W_{j,1}^a(0) = \dots = W_{j,2M_a}^a(0) = 1 \quad (48)$$

$$W_{k,1}^b(0) = \dots = W_{k,2M_b}^b(0) = 1 \quad (49)$$

$$W_{j,1}^{ab}(0) = \dots = W_{j,N}^{ab}(0) = 1 \quad (50)$$

sendo:

M_a : número de componentes do vetor \mathbf{a}_{input} (entrada);

M_b : número de componentes do vetor \mathbf{a}_{output} (saída desejada);

N : número de padrões de treinamento (pares de vetores $\{\mathbf{a}_{input}, \mathbf{a}_{output}\}$).

B.1.4 Escolha da Categoria

A rede neural ARTMAP-*Fuzzy* realiza o processamento de duas redes ART-*Fuzzy*, *i.e.*, ART_a e ART_b. Assim, para cada módulo ART calculam-se as funções de escolha T_j^a e T_k^b , para as entradas \mathbf{Z}^a e \mathbf{Z}^b , respectivamente (CARPENTER *et al.*, 1992).

$$T_j^a = \frac{|\mathbf{Z}^a \wedge \mathbf{W}_j^a|}{\alpha + |\mathbf{W}_j^a|} \quad (51)$$

$$T_k^b = \frac{|\mathbf{Z}^b \wedge \mathbf{W}_k^b|}{\alpha + |\mathbf{W}_k^b|} \quad (52)$$

Com isso, é escolhida uma categoria ativa para a rede ART_a-*Fuzzy* e uma para a rede ART_b-*Fuzzy*, como apresentado pelas equações 53 e 54 (CARPENTER *et al.*, 1992).

$$jv = \arg \{ \max T_j^a \}, \text{ para } j = 1, 2, \dots, N \quad (53)$$

$$kv = \arg \{ \max T_k^b \}, \text{ para } k = 1, 2, \dots, N \quad (54)$$

sendo:

jv : categoria ativa (vencedora) para a rede ART_a-*Fuzzy*;

kv : categoria ativa (vencedora) para a rede ART_b-*Fuzzy*.

Se existir mais de uma categoria ativa, a categoria escolhida será aquela que tiver o menor índice.

O vetor atividade de ART_b-*Fuzzy* é representado por $\mathbf{Y}^b = [Y_1^b \dots Y_N^b]$ e calculado conforme a equação 55 (VERZI *et al.*, 2003).

$$\begin{aligned} Y_k^b &= 1, \text{ para } k = kv \\ Y_k^b &= 0, \text{ para } k \neq kv \end{aligned} \quad (55)$$

B.1.5 Ressonância ou Reset

A ressonância ocorre se os critérios de vigilância, definidos pelas equações 56 e 57, forem satisfeito (CARPENTER *et al.*, 1992):

$$\frac{|Z^a \wedge W_{jv}^a|}{|Z^a|} \geq \rho_a \quad (56)$$

$$\frac{|Z^b \wedge W_{kv}^b|}{|Z^b|} \geq \rho_b \quad (57)$$

Se a equação 56 não for satisfeita, ocorre o *reset*, ou seja, o nó jv é excluído do processo de busca da categoria ativa dada pela equação 53, isto é, T_{jv}^a assume o valor igual a zero e então é escolhida uma nova categoria pela equação 53 para realizar novamente o processo de ressonância. Este processo é executado até que a rede encontre uma categoria ativa jv que satisfaça a equação 56. Caso a equação 57 não seja satisfeita, então o mesmo processo descrito acima é repetido para o módulo *ART_b-Fuzzy*, ou seja, exclui-se o nó kv do processo de busca da categoria ativa ($T_{kv}^b = 0$), escolhendo uma nova categoria por meio da equação 54 (CARPENTER *et al.*, 1992).

Após a identificação das categorias ativas em cada um dos módulos *ART-Fuzzy*, utiliza-se o *match tracking* com o objetivo de verificar se a categoria ativa em *ART_a-Fuzzy* corresponde à saída desejada apresentada em *ART_b-Fuzzy*. Assim, aplica-se o critério de vigilância apresentado na equação 58 (CARPENTER *et al.*, 1992):

$$\frac{|Y^b \wedge W_{jv}^{ab}|}{|Y^b|} \geq \rho_{ab} \quad (58)$$

B.1.6 Aprendizado

Após ocorrer o critério de vigilância dado pela equação 58, é feita a adaptação dos pesos da rede neural *ARTMAP-Fuzzy*. A adaptação dos pesos dos módulos *ART_a-Fuzzy* e *ART_b-Fuzzy* é realizada conforme apresentado pelas equações 59 e 60, respectivamente. Os pesos do módulo *Inter-ART* são adaptados conforme a equação 61 (CARPENTER *et al.*, 1992).

$$W_{jv}^a (novo) = \beta (Z^a \wedge W_{jv}^a (velho)) + (1 - \beta) W_{jv}^a (velho) \quad (59)$$

$$W_{kv}^{b(novo)} = \beta \left(Z^b \wedge W_{kv}^{b(velho)} \right) + (1 - \beta) W_{kv}^{b(velho)} \quad (60)$$

$$W_{jv,k}^{ab} = 1, \text{ para } k = kv$$

$$W_{jv,k}^{ab} = 0, \text{ para } k \neq kv \quad (61)$$

B.2 Algoritmos da Rede Neural ARTMAP-Fuzzy

B.2.1 Algoritmo de Treinamento

Com o propósito de facilitar a compreensão das etapas a serem realizadas no treinamento da rede ARTMAP-Fuzzy, Lopes (2005) elaborou um fluxograma explicativo destas etapas. Então, a seguir, serão apresentados todos os passos necessários para realização do treinamento da rede neural ARTMAP-Fuzzy (DECANINI; TONELLI-NETO; MINUSSI, 2012; TONELLI-NETO, 2012):

- Passo 1) Leem-se todos os parâmetros da rede neural (α , β , $\underline{\rho}_a$, ρ_b , ρ_{ab} , e ε).
- Passo 2) Inicialização das matrizes de pesos da rede neural ARTMAP-Fuzzy (os valores dos pesos das matrizes W^a , W^b e W^{ab} são iguais a 1).
- Passo 3) Realiza-se o complemento do vetor de entrada (\mathbf{a}_{input}), $Z^a = [\mathbf{a}_{input} \ \mathbf{a}_{input}^c]$, e do vetor de saída (\mathbf{a}_{output}), $Z^b = [\mathbf{a}_{output} \ \mathbf{a}_{output}^c]$.
- Passo 4) Verifica-se se a lista de padrões de treinamento foi concluída.
Se sim, o processo de treinamento é concluído;
Senão, vá ao Passo 5).
- Passo 5) Faz-se $\rho_a = \underline{\rho}_a$.
- Passo 6) Calcula-se a função de escolha T_k^b :
- $$T_k^b = \frac{|Z^b \wedge W_k^b|}{\alpha + |W_k^b|}, \text{ para } k = 1, 2, \dots, N.$$
- Passo 7) Escolha da categoria da ART_b-Fuzzy:
- $$kv = \arg \{ \max T_k^b \}, \text{ para } k = 1, 2, \dots, N.$$
- Passo 8) Verificação do critério de vigilância da ART_b-Fuzzy:

$$\frac{|\mathbf{Z}^b \wedge \mathbf{W}_k^b|}{|\mathbf{Z}^b|} \geq \rho_b.$$

Se sim, vá ao Passo 9);

Senão, ocorre o *reset*: faz-se $T_{kv}^b = 0$ e retorna ao Passo 7).

Passo 9) Calcula-se $\mathbf{Y}^b = [Y_1^b \ Y_2^b \ \dots \ Y_N^b]$:

$$Y_k^b = 1, \text{ para } k = kv$$

$$Y_k^b = 0, \text{ para } k = 1, 2, \dots, N; k \neq kv.$$

Passo 10) Atualização dos pesos da ART_b-Fuzzy:

$$\mathbf{W}_{kv}^{b(novo)} = \beta (\mathbf{Z}^b \wedge \mathbf{W}_{kv}^{b(velho)}) + (1 - \beta) \mathbf{W}_{kv}^{b(velho)}.$$

Passo 11) Calcula-se a função de escolha T_j^a :

$$T_j^a = \frac{|\mathbf{Z}^a \wedge \mathbf{W}_j^a|}{\alpha + |\mathbf{W}_j^a|}, \text{ para } j = 1, 2, \dots, N.$$

Passo 12) Escolha da categoria da ART_a-Fuzzy:

$$jv = \arg \{ \max T_j^a \}, \text{ para } j = 1, 2, \dots, N.$$

Passo 13) Verificação do critério de vigilância da ART_a-Fuzzy:

$$\frac{|\mathbf{Z}^a \wedge \mathbf{W}_j^a|}{|\mathbf{Z}^a|} \geq \rho_a.$$

Se sim, vá ao Passo 14);

Senão, ocorre o *reset*: faz-se $T_{jv}^a = 0$ e retorna ao Passo 12).

Passo 14) Verificação do critério de vigilância do módulo Inter-ART:

$$\frac{|\mathbf{Y}^b \wedge \mathbf{W}_{jv}^{ab}|}{|\mathbf{Y}^b|} \geq \rho_{ab}.$$

Se sim, vá ao Passo 15);

Senão, incrementa-se o parâmetro de vigilância ρ_a , $\rho_a = \frac{|\mathbf{Z}^a \wedge \mathbf{W}_{jv}^a|}{|\mathbf{Z}^a|} + \varepsilon$, e faz-se

$T_{jv}^a = 0$, retornando Passo 12).

Passo 15) Atualização dos pesos da ART_a-Fuzzy:

$$\mathbf{W}_{jv}^{a(\text{novo})} = \beta (\mathbf{Z}^a \wedge \mathbf{W}_{jv}^{a(\text{velho})}) + (1 - \beta) \mathbf{W}_{jv}^{a(\text{velho})}.$$

Passo 16) Atualização dos pesos do módulo Inter-ART, $\mathbf{W}_{jv}^{ab} = [W_{jv,1}^{ab} \ W_{jv,2}^{ab} \ \dots \ W_{jv,N}^{ab}]$:

$$W_{jv,k}^{ab} = 1, \text{ para } k = kv$$

$$W_{jv,k}^{ab} = 0, \text{ para } k = 1, 2, \dots, N; k \neq kv.$$

Passo 17) Retorna-se ao Passo 4).

sendo:

\wedge : operador AND fuzzy;

\mathbf{W}_i : i -ésima linha da matriz \mathbf{W} ;

$W_{i,j}$: componente da posição (i, j) da matriz \mathbf{W} ;

$\arg\{\text{máx } T_j\}$: obtenção do índice correspondente do máximo valor entre os coeficientes T_j ;

T_j : j -ésimo coeficiente de escolha;

jv : número do neurônio vencedor na rede ART_a-Fuzzy;

kv : número do neurônio vencedor na rede ART_b-Fuzzy;

ρ_a : valor inicial do parâmetro de vigilância da rede ART_a-Fuzzy;

ε : valor do parâmetro (positivo e pequeno) para incremento do parâmetro ρ_a .

B.2.2 Algoritmo de Teste

A etapa de teste é realizada utilizando o procedimento descrito a seguir (DECANINI *et al.*, 2011; TONELLI-NETO, 2012).

Passo 1) Compõem-se os vetores de teste \mathbf{a}_{input} e \mathbf{Z}^a , detonados $\underline{\mathbf{a}}_{input}$ e $\underline{\mathbf{Z}}^a$, respectivamente.

Passo 2) Identifica-se o neurônio vencedor na rede neural ART_{a-Fuzzy} (jv), sem realizar a adaptação dos pesos.

Passo 3) Calcula-se $\underline{\mathbf{z}}^b$ e conseqüentemente $\underline{\mathbf{a}}_{output}$:

$$\underline{\mathbf{z}}^b \equiv \mathbf{W}_{jv}^{ab} \mathbf{W}^b = \left[\underline{\mathbf{a}}_{output,1} \quad \underline{\mathbf{a}}_{output,2} \quad \dots \quad \underline{\mathbf{a}}_{output,M_b} \quad \underline{\mathbf{a}}_{output,1}^c \quad \underline{\mathbf{a}}_{output,2}^c \quad \dots \quad \underline{\mathbf{a}}_{output,M_b}^c \right]$$

$$\underline{\mathbf{a}}_{output} = \left[\underline{\mathbf{a}}_{output,1} \quad \underline{\mathbf{a}}_{output,2} \quad \dots \quad \underline{\mathbf{a}}_{output,M_b} \right]: \text{saída codificada.}$$

APÊNDICE C – REDE NEURAL DE BASE RADIAL

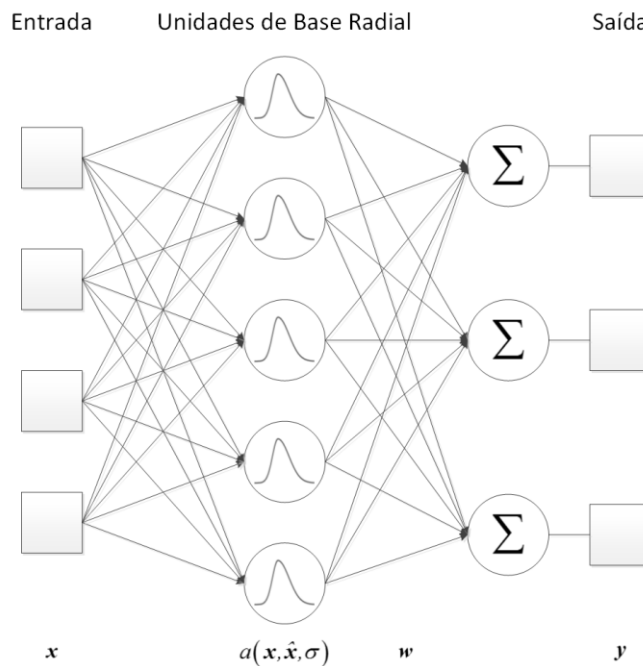
Redes neurais de base radial (RNBR) são redes *feed-forward* que tem seus pesos adaptados via emprego de um algoritmo de treinamento supervisionado. Elas normalmente são configuradas com uma única camada escondida de unidades cuja função de ativação é selecionada a partir de uma classe de funções especiais denominadas funções de base (HALICI, 2004; LEONARD; KRAMER, 1991; MOODY; DARKEN, 1989a; MOODY; DARKEN, 1989b; RENALDS; ROHWER, 1989; YAO; ZAFIRIOU, 1990).

A RNBR tem se mostrado uma arquitetura neural em potencial. Sua camada escondida possui comportamento característico, ou seja, ao invés de empregar uma função sigmoide como função de ativação, utiliza-se uma função Gaussiana. Cada função de base atua como um processador localmente sintonizado, que calcula um valor de similaridade entre o vetor de entrada e os pesos de conexão. Em outras palavras, estas unidades funcionam como detectores de padrões. A saída final é produzida a partir de combinações lineares dos pesos que conectam a camada escondida à camada de saída (HALICI, 2004; LEONARD; KRAMER, 1991).

C.1 Estrutura da Rede Neural de Base Radial

As funções de base radial foram introduzidas primeiramente na solução dos problemas de interpolação multivariável. Broomhead e Lowe (1988), e Moody e Darken (1989) foram os primeiros a explorar o uso das funções de base radial no projeto de redes neurais (HALICI, 2004). A estrutura de uma RNBR, na sua forma mais básica, inclui três camadas distintas, conforme apresentado na figura 18.

Figura 18 – Estrutura da rede neural de base radial



Fonte: Adaptado de Halici (2004).

A camada de entrada é constituída por nós (unidades sensoriais), cujo número é igual à dimensão do vetor de entrada x .

C.1.1 Camada Escondida

A segunda camada corresponde a camada escondida, a qual é composta por unidades lineares ligadas diretamente a todos os nós da camada de entrada, *i.e.*, cada nó da camada escondida recebe o valor da entrada original, possuindo dimensão bastante elevada. Como mencionado anteriormente, a camada escondida é formada por funções de base radial, ou seja, uma função não-monotônica, em contraste com a função monotônica sigmoideal das redes MLP (HALICI, 2004; LEONARD; KRAMER, 1991).

A camada escondida possui H nós. O centro de cada unidade radial é representado pelo vetor \hat{x} , o qual possui dimensão igual à do vetor de entrada x . A cada unidade escondida, associa-se um vetor \hat{x} distinto. Desta forma, calcula-se a distância radial $d_{h,k}$ entre o centro da h -ésima função base \hat{x} e o k -ésimo vetor de entrada x usando a distância Euclidiana, conforme equação a seguir (HALICI, 2004).

$$d_{h,k} = \|\hat{x}_h - x_k\| \quad (62)$$


Com isso, aplica-se a função de base radial na equação 62 para determinar a saída $a_{h,k}$ de cada unidade radial (HALICI, 2004; LEONARD; KRAMER, 1991).

$$a_{h,k} = \exp\left[-(d_{h,k})^2 / (\sigma_h)^2\right] \quad (63)$$

sendo $a_{h,k}$ a ativação da h -ésimo unidade na camada escondida dada uma entrada \mathbf{x}_k . A cada nó estão associados $N + 1$ parâmetros: as N -dimensionais posições do centro da unidade radial $\hat{\mathbf{x}}$ no espaço de entrada, e o parâmetro de escala da distância σ que determina sobre qual distância no espaço de entrada a unidade terá influência significativa (LEONARD; KRAMER, 1991).

Na figura 19 apresenta-se o comportamento de uma função de base radial (normalmente uma função Gaussiana com largura de valor igual à da variância σ), que possui pico em zero e decresce de valor à medida que se afasta do centro da função.

Figura 19 – Função de base radial (Gaussiana)



Fonte: Adaptado de Halici (2004).

C.1.2 Camada da Saída

As conexões na segunda camada são ponderadas de forma semelhante àquela de outras redes neurais, *e.g.*, MLP. A transformação do espaço de entrada para o espaço das unidades escondidas é não-linear, enquanto que a transformação do espaço das unidades escondidas para o espaço de saída é representada por um somatório linear. Assim, a saída \mathbf{y} da rede é dada por (LEONARD; KRAMER, 1991):

$$y_m = \sum_{h=1}^H w_{m,h} a_h \quad (64)$$

C.2 Treinamento da Rede Neural de Base Radial

O conjunto de dados para treinamento é separado da mesma forma como ocorre na rede MLP. Para que este classificador neural seja treinado, deve-se minimizar a seguinte função objetivo (LEONARD; KRAMER, 1991):

$$E(\hat{\mathbf{x}}, \boldsymbol{\sigma}, \boldsymbol{w}) = \sum_{k=1}^K \|\mathbf{y}_k - \mathbf{T}_k\|^2 \quad (65)$$

sendo \mathbf{T} o vetor correspondente à saída desejada.

Normalmente, o treinamento é decomposto em três distintas etapas: (1) cálculo dos centros das unidades $\hat{\mathbf{x}}$, (2) cálculo dos parâmetros de escala $\boldsymbol{\sigma}$, e (3) cálculo dos pesos das conexões da segunda camada da rede. Desta forma, tem-se a redução do esforço computacional exigido caso fosse aplicado um procedimento análogo ao *backpropagation* na otimização da função erro (LEONARD; KRAMER, 1991).

C.2.1 Ajuste dos Centros

Na rede MLP os pesos de todas as camadas são ajustado no mesmo instante de tempo. No entanto, na RNBR, os pesos da camada escondida são ajustados em um instante anterior ao do ajuste dos pesos da segunda camada. À medida que a entrada move ao longo das conexões, o valor de ativação é reduzido, influenciados por cada centro da unidade escondida. Os centros podem ser calculados usando mapas de Kohonen ou métodos estatísticos, *e.g.*, agrupamento *k-means*. Em qualquer caso, eles são utilizados para definir a área de sensibilidade das unidades escondidas, que, posteriormente, se mantêm fixas (LEONARD; KRAMER, 1991; MACQUEEN, 1967; MOODY; DARKEN, 1989a; MOODY; DARKEN, 1989b).

C.2.2 Ajuste das Escalas

Na sua forma mais simples, todas as unidades escondidas da RNBR possuem a mesma largura ou grau de sensibilidade. Entretanto, caso existam poucos padrões de entrada, é desejável ter unidades escondidas com uma ampla área de recepção. Da mesma forma, se estes padrões tiverem aglomerados, pode ser desejável ter processadores com campos estreitos de recepção. Então, o cálculo das larguras individuais das unidades escondidas aumenta o

desempenho da RNBR (HALICI, 2004; LEONARD; KRAMER, 1991; MOODY; DARKEN, 1989a).

C.2.3 *Ajuste dos Pesos*

Uma vez que os pesos de camada oculta são definidos, uma segunda etapa de treinamento é aplicada para ajuste dos pesos de saída. Esse processo geralmente usa o algoritmo do gradiente padrão (HALICI, 2004; LEONARD; KRAMER, 1991).

C.3 **Rede Neural de Base Radial x *Multilayer Perceptron***

Embora sejam semelhantes às *multilayer perceptron* (MLP), em muitos aspectos, as redes de função de base radial têm várias vantagens. Elas costumam treinar muito mais rápido do que as redes MLP, e são menos suscetíveis a problemas com entradas não-estacionários por causa do comportamento da função de base nas unidades escondidas radiais. Quando se compara uma RNBR com uma MLP, em uma mesma aplicação, observa-se que (HALICI, 2004; HAYKIN, 2008):

- o erro final atingido pela RNBR é menor do que o erro final atingido pela MLP,
- a convergência da RNBR pode chegar a uma ordem de grandeza mais rápida do que a convergência de uma MLP,
- a capacidade de generalização da MLP é, em geral, superior à capacidade de generalização da RNBR;
- a RNBR é menos suscetível a problemas causados por entradas não-estacionárias devido ao comportamento da função de base radial nas unidades escondidas.

APÊNDICE D – TEORIA DA EVIDÊNCIA DE DEMPSTER-SHAFER

A teoria da evidência de Dempster-Shafer é uma teoria baseada no raciocínio probabilístico e na combinação de evidências. Ela é chamada de teoria da evidência devido a capacidade de lidar com pedaços de evidências e seus valores numéricos de suporte, associando os vários pedaços de evidência relevantes a uma determinada hipótese. A seguir, apresenta-se esta teoria (BUCHANAN; SHORTLIFFE, 1984; SHAFER, 1976; WILSON, 1999).

Considere Θ um conjunto finito, mutuamente exclusivo e exaustivo, de todas as possíveis hipóteses ou proposições, n_{Θ} o número de elementos de Θ , e $2^{n_{\Theta}}$ a quantidade de subconjuntos de Θ ($Subconj(\Theta)$). Por exemplo, suponha o seguinte conjunto $\Theta = \{A, B\}$. Então, os subconjuntos de Θ são $Subconj(\Theta) = [\{A\}, \{B\}, \{A, B\} \text{ e } \emptyset]$.

Considere também que $m : 2^{n_{\Theta}} \rightarrow [0, 1]$ seja a função de atribuição probabilística, sendo $m(\emptyset) = 0$, e $\sum_{X \subseteq \Theta} m(X) = 1$. A quantidade $m(X)$ é o valor da probabilidade para o subconjunto X , e representa a parcela de confiança referente à X (BUCHANAN; SHORTLIFFE, 1984). Em outras palavras, esta parcela de confiança $m(X)$ não pode ser dividida entre os outros subconjuntos de X , e também não pode possuir nenhuma parcela de confiança referente a quaisquer um dos outros subconjuntos.

Seja agora $\mathfrak{Bel}(X) = \sum_{Y \subseteq X} m(Y)$, para todo $Y \subseteq X$, a função de confiança. Pela definição, a função de confiança $\mathfrak{Bel}(X)$ representa a parcela de confiança referente à X como também de todos os seus subconjuntos (BUCHANAN; SHORTLIFFE, 1984). Por exemplo, seja $X = \{A, C\}$, um subconjunto de $\Theta = \{A, B, C\}$. Então a função de confiança é calculada por $\mathfrak{Bel}(X) = \mathfrak{Bel}(\{A, C\}) = m(\{A, C\}) + m(A) + m(C)$.

Seja $\mathfrak{Dou}(X) = \mathfrak{Bel}(X^c)$, sendo $X^c = \Theta - X$, a função de dúvida. A função de dúvida $\mathfrak{Dou}(X)$ representa o grau de dúvida em relação à hipótese X . Uma função mais útil que a função de dúvida é a quantidade probabilística superior de X , $\mathfrak{B}^*(X)$, sendo

$\mathfrak{B}^*(X) = 1 - \mathfrak{Bel}(X^c)$. A quantidade probabilística superior de X , $\mathfrak{B}^*(X)$, representa o valor da chance de falhar ao duvidar que a hipótese X não esteja correta (BUCHANAN; SHORTLIFFE, 1984). Assim, define-se o intervalo de confiança por $[m(X), \mathfrak{B}^*(X)]$ (SHAFER, 1976).

A teoria da evidência de Dempster-Shafer foi inicialmente proposta por Arthur Dempster em 1960 e posteriormente reformulada pelo seu aluno Glenn Shafer em meados de 1970. Entretanto, a metodologia computacional somente foi desenvolvida por Jeffrey Barnett em 1980. A metodologia computacional é apresentada como segue (BARNETT, 2008).

Seja $\Theta = \{i | 1 \leq i \leq n\}$, sendo $n = |\Theta|$ o total de elementos em Θ . Também, considere $\mu_{i,j}$ a evidência j a favor da hipótese i , com $j = 1, 2, \dots, N$. Com isso, a evidência acumulada a favor da hipótese i , $u(\{i\})$, é definida por:

$$u(\{i\}) = 1 - \prod_{j=1}^N (1 - \mu_{i,j}(\{i\})) \quad (66)$$

Similarmente, seja $\omega_{i,k}$ a evidência k contra da hipótese i , com $k = 1, 2, \dots, M$. Assim, define-se a evidência acumulada contra a hipótese i , $u^*(\{i\})$.

$$u^*(\{i\}) = 1 - \prod_{k=1}^M (1 - \omega_{i,k}(\{i\})) \quad (67)$$

Agora, as evidências acumuladas a favor e contra a hipótese i , $u(\{i\})$ e $u^*(\{i\})$, respectivamente, são combinadas no valor da probabilidade $m(\{i\})$, como segue:

$$m(\{i\}) = K \left[p_i \prod_{q \neq i} d_q + r_i \prod_{q \neq i} c_q \right] \quad (68)$$

sendo:

$$p_i = \frac{u(\{i\})(1 - u^*(\{i\}))}{1 - u(\{i\})u^*(\{i\})} \quad (69)$$

$$c_i = \frac{u^*(\{i\})(1 - u(\{i\}))}{1 - u(\{i\})u^*(\{i\})} \quad (70)$$

$$r_i = 1 - (p_i + c_i) \quad (71)$$

$$d_i = c_i + r_i \quad (72)$$

$$K^{-1} = \left[\prod_{q=1}^n d_q \right] \left[1 + \sum_{q=1}^n \frac{p_q}{d_q} \right] - \prod_{q=1}^n c_q \quad (73)$$

Para efetuar o cálculo da quantidade probabilística superior $\mathfrak{B}^*(\{i\})$, primeiramente computa-se o valor da função de dúvida da hipótese i , $\mathfrak{Dou}(\{i\}) = \mathfrak{Bel}(\{Z\})$, com $Z = i^c = \Theta - i$. A função de dúvida e a quantidade probabilística superior são calculadas conforme as equações 74 e 75, respectivamente.

$$\mathfrak{Bel}(\{Z\}) = K \left(\left[\prod_{q=1}^n d_q \right] \left[\sum_{q \in Z} \frac{p_q}{d_q} \right] + \left[\prod_{q \notin Z} c_q \right] \left[\prod_{q \in Z} d_q \right] - \prod_{q=1}^n c_q \right) \quad (74)$$

$$\mathfrak{B}^*(\{i\}) = 1 - \mathfrak{Bel}(\{Z\}) \quad (75)$$

Assim, o intervalo de confiança é definido como:

$$[m(\{i\}), \mathfrak{B}^*(\{i\})] \quad (76)$$

sendo $m(\{i\})$ o valor da probabilidade da hipótese i estar correta, e $\mathfrak{B}^*(\{i\})$ a quantidade probabilística superior, ou seja, a chance de falhar ao duvidar da hipótese i .

APÊNDICE E – SOFTWARE EMTP-RV

Neste apêndice mostra-se como são modelados os elementos de um sistema de distribuição de energia elétrica, além das simulações que podem ser realizadas no mesmo utilizando o *software* EMTP-RV.

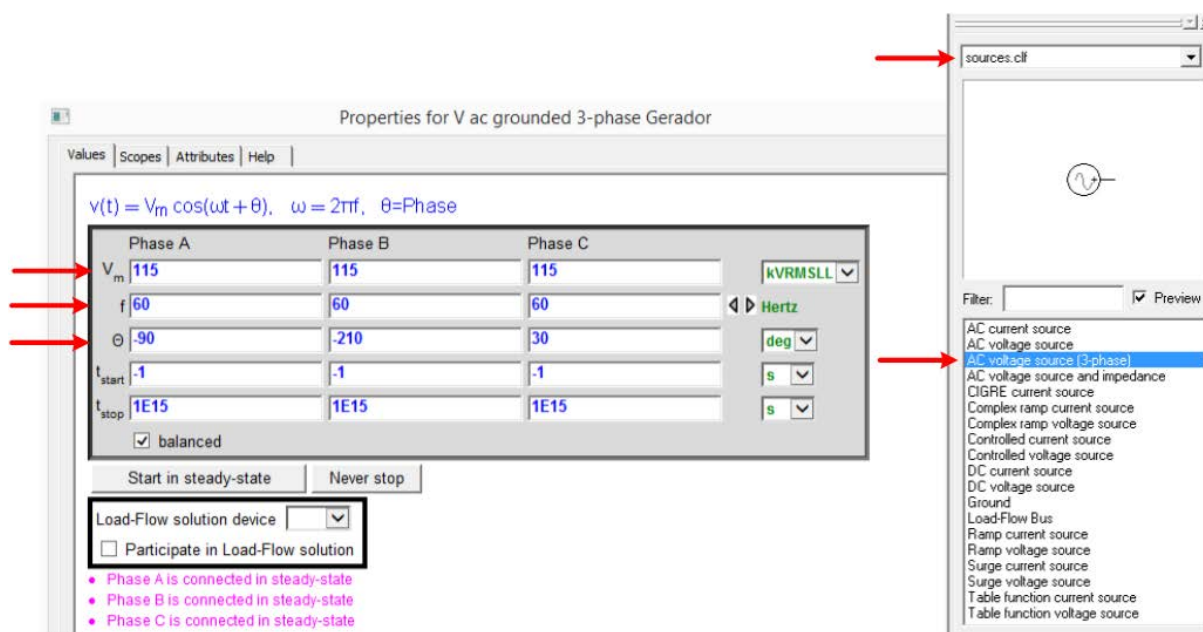
E.1 Modelagem da Alimentação

Para realizar a modelagem da alimentação trifásica da subestação principal no sistema de distribuição de energia elétrica, os seguintes dados são necessários:

- Valor eficaz da tensão de linha;
- Frequência nominal de operação;
- Defasagem angular entre as fases *a*, *b* e *c*.

A partir destes valores, seleciona-se o componente “AC voltage source (3-phase)” em “sources.clf”, preenchendo os respectivos campos, como mostra figura 20.

Figura 20 – Modelagem da alimentação trifásica do alimentador de distribuição



Fonte: Elaborada pelo autor.

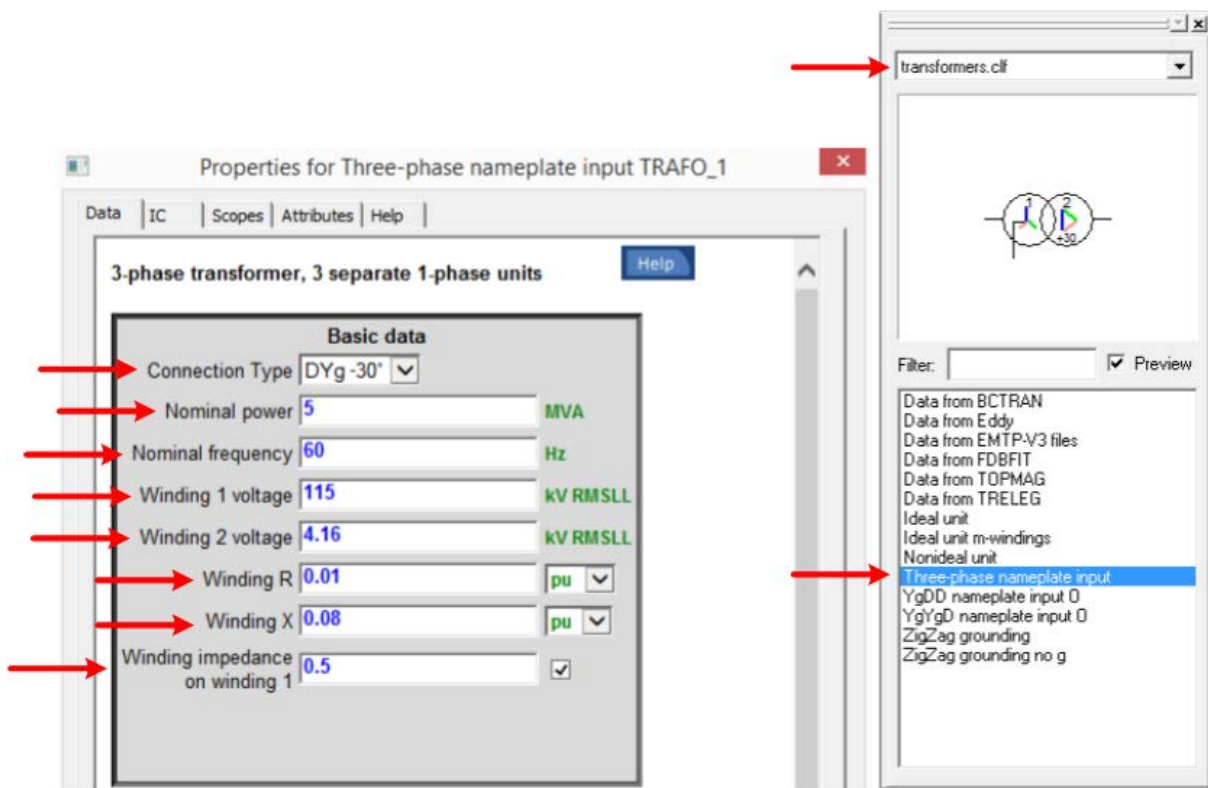
E.2 Modelagem do Transformador de Potência da Subestação Principal

Para realizar a modelagem do transformador de potência da subestação principal são necessárias as seguintes informações:

- Tipo de conexão e defasamento angular;
- Potência nominal do transformador;
- Frequência nominal de operação;
- Tensão eficaz de linha no enrolamento primário;
- Tensão eficaz de linha no enrolamento secundário;
- Resistência total dos enrolamentos;
- Reatância total dos enrolamentos;
- Porcentagem da impedância total referida ao primário.

A partir destes valores, seleciona-se o componente “Three-phase nameplate input” em “transformers.clf”, preenchendo os respectivos campos, como mostra figura 21.

Figura 21 – Modelagem do transformador de potência da subestação principal



Fonte: Elaborada pelo autor.

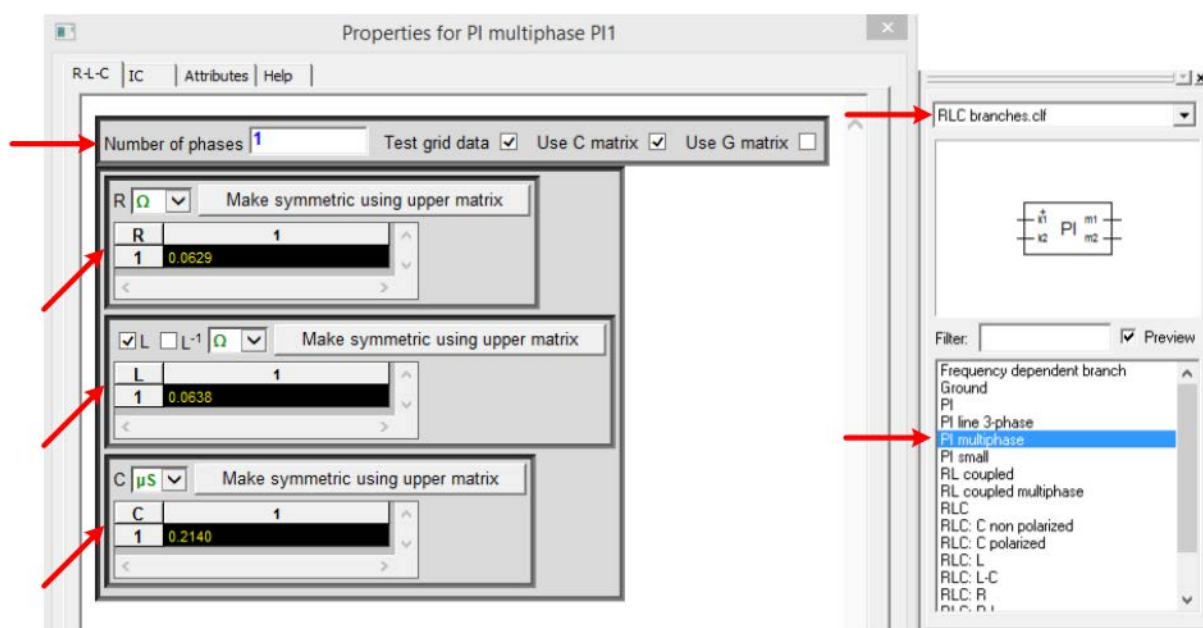
E.3 Modelagem das Linhas

Para realizar a modelagem das linhas do sistema de distribuição, *e.g.*, monofásica, bifásica e trifásica, são necessários os seguintes dados:

- Número de fases da linha;
- Comprimento da linha modelada;
- Matriz de resistência por unidade de comprimento;
- Matriz de reatância indutiva/indutância por unidade de comprimento;
- Matriz de capacitância/susceptância por unidade de comprimento.

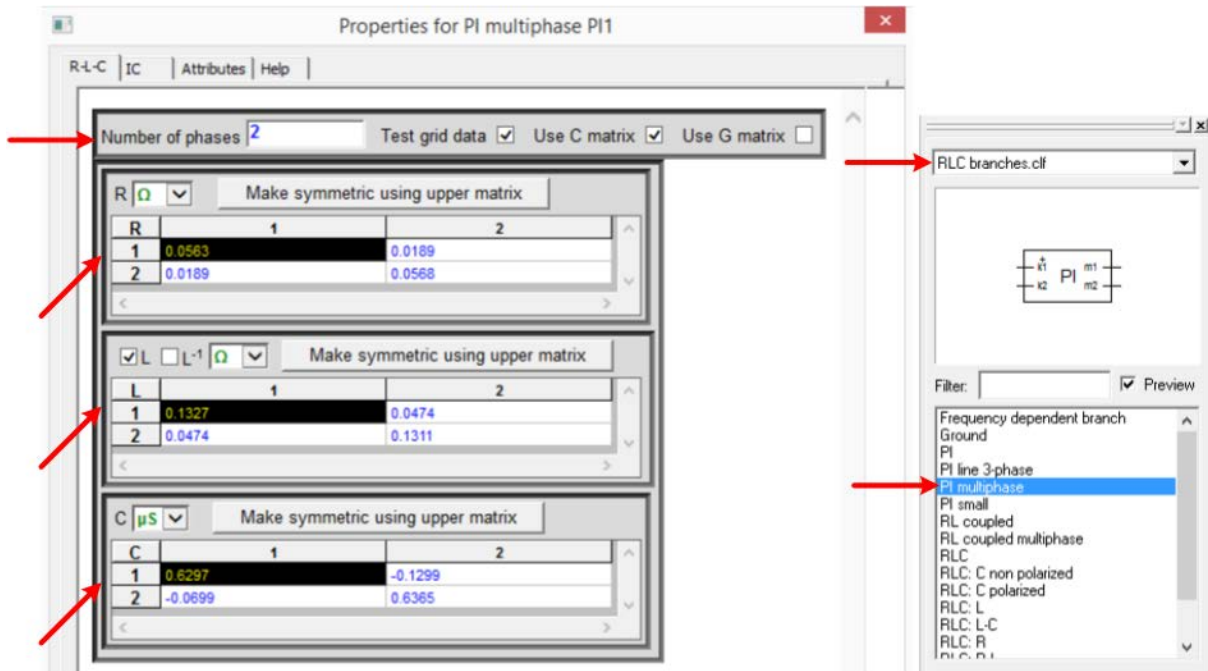
Antes de inserir os dados do componente, deve-se realizar a multiplicação de cada matriz por unidade de comprimento pelo valor total do comprimento da linha. Com isso, seleciona-se o componente “PI multiphase” em “RLC branches.clf”, preenchendo os respectivos campos. As figuras 22, 23 e 24 mostram os campos a serem preenchidos no caso de linhas monofásicas, bifásica e trifásicas, respectivamente.

Figura 22 – Modelagem de linhas monofásicas



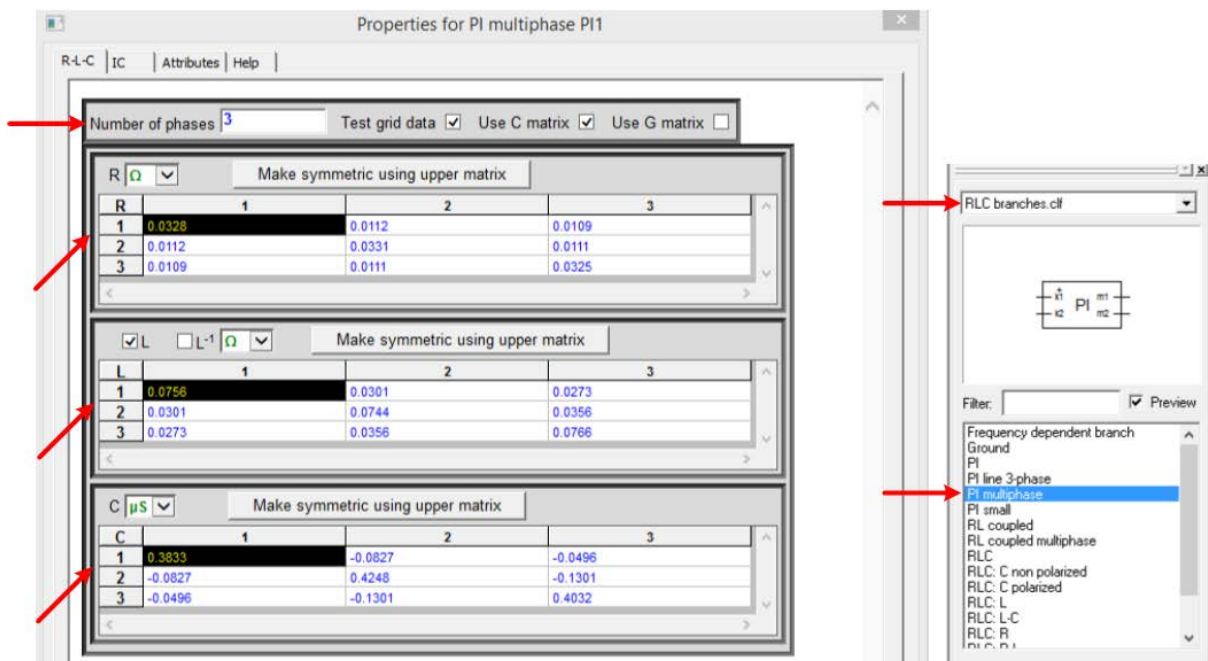
Fonte: Elaborada pelo autor.

Figura 23 – Modelagem de linhas bifásicas



Fonte: Elaborada pelo autor.

Figura 24 – Modelagem de linhas trifásicas



Fonte: Elaborada pelo autor.

E.4 Modelagem de Cargas

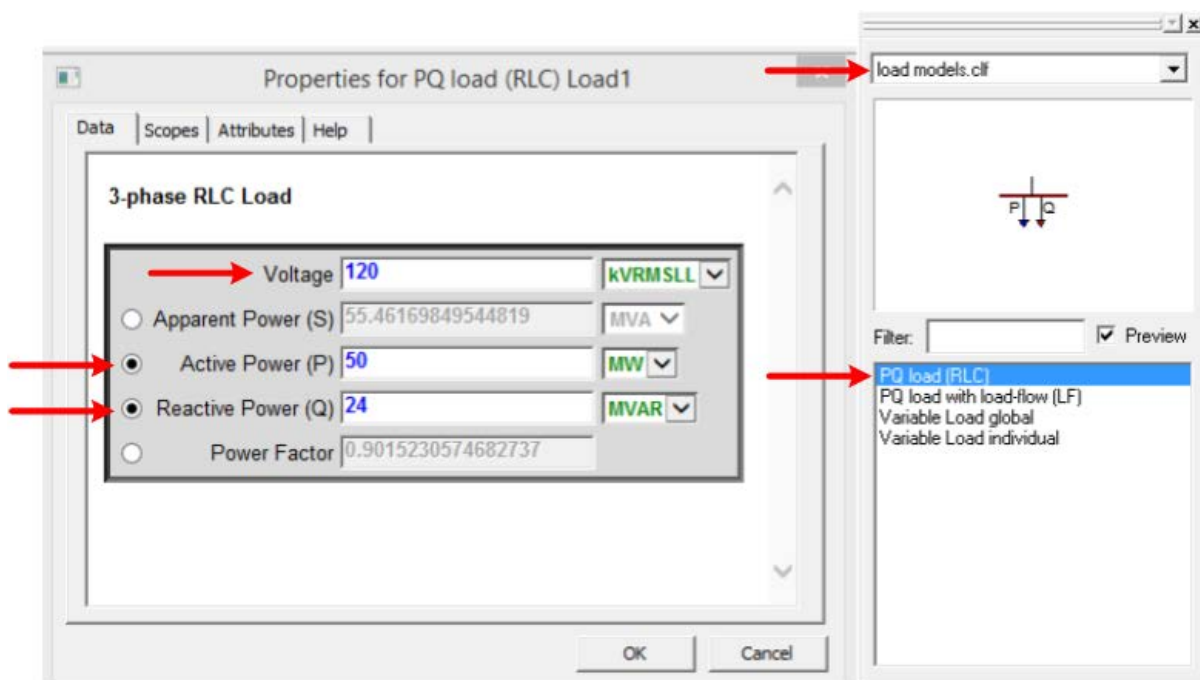
Para realizar a modelagem de cargas, necessitam-se dos seguintes dados:

- Fase em que carga está conectada;

- Tensão eficaz de linha nominal da carga;
- Potência ativa da carga;
- Potência reativa da carga.

Assim, seleciona-se o componente “PQ load (RLC)” em “load models.clf”, preenchendo os respectivos campos. Na figura 25 mostra-se os campos que devem ser preenchidos.

Figura 25 – Modelagem de cargas



Fonte: Elaborada pelo autor.

E.5 Aquisição das Oscilografias de Tensão e de Corrente

A análise dos sinais de tensão e de corrente só são possíveis se foram feitas aquisições ao longo do alimentador. Desta forma, devem-se selecionar os componentes “Voltage scope (1 pin)” e “Current scope and observe” em “meters.clf”. Esse dois componentes devem ser inseridos nos pontos do alimentador nos quais serão realizadas tais aquisições.

E.6 Definição dos Parâmetros de Simulação

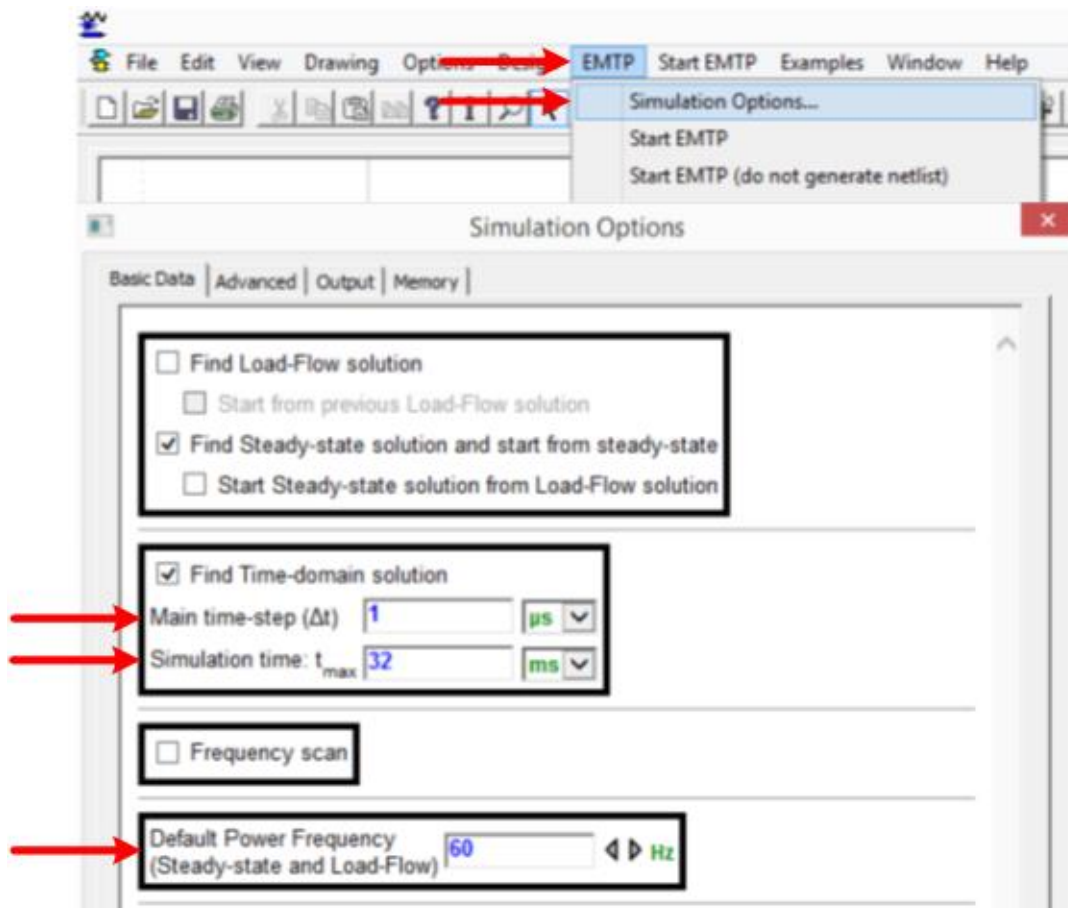
Antes de realizar simulações no sistema de distribuição de energia elétrica modelado, é necessária a definição de três importantes parâmetros:

- Intervalo de tempo entre as amostras dos sinais;
- Tempo total de simulação;

- Frequência nominal da simulação.

No *software*, o caminho para definição destes parâmetros, a partir da aba principal, é a seguinte: “EMTP e “Simulation Options”. Na figura a seguir apresenta-se o caminho para esta definição.

Figura 26 – Caminho para definição dos parâmetros de simulações

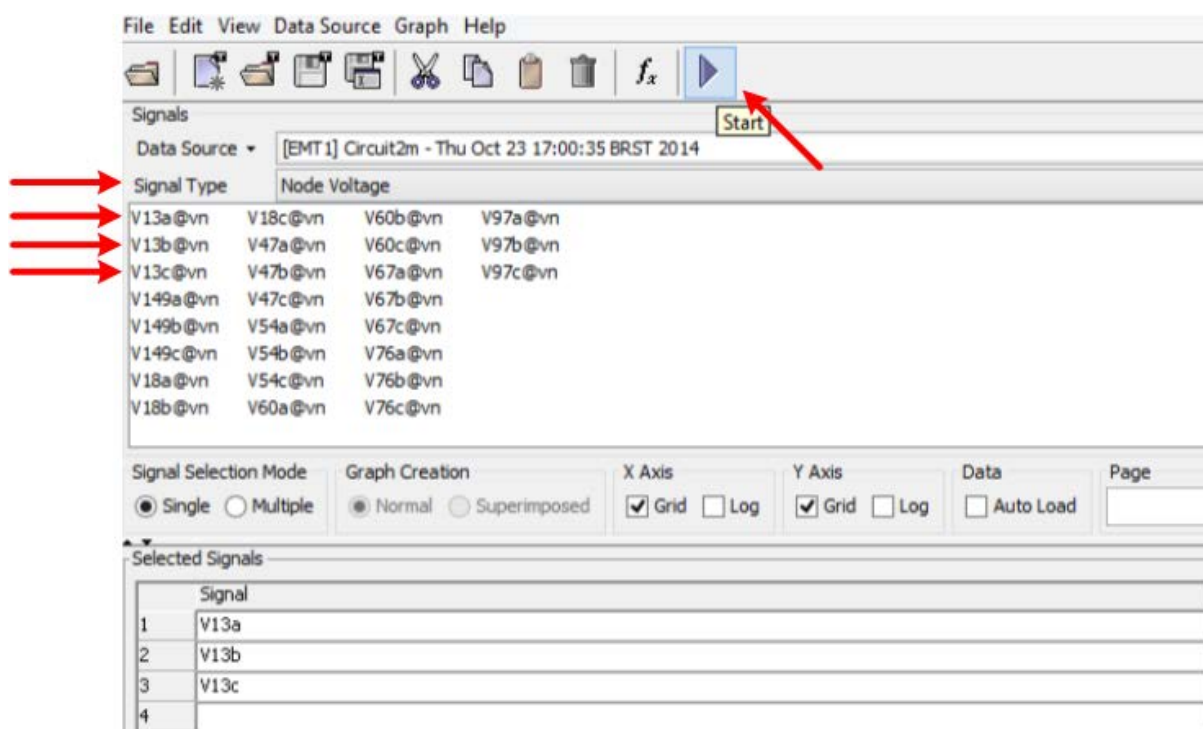


Fonte: Elaborada pelo autor.

E.7 Exportação de Oscilografias

A exportação das oscilografias é necessária por causa da utilização de outros *softwares*/formato de dados empregados na análise destas. O *software* EMTP-RV possui uma ferramenta, denominada ScopeView, que possibilita tal exportação. Para exportar as oscilografias, após o ScopeView ser executado, deve-se selecionar o tipo do sinal (*Signal Type*) e clicar no ícone *Start*, como mostrado na figura 27.

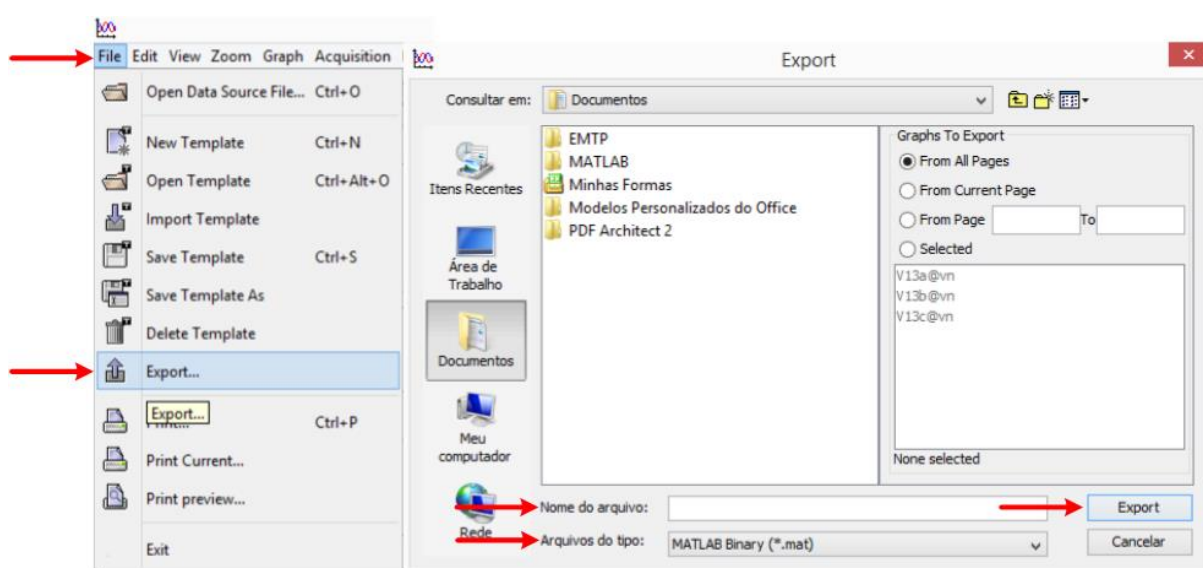
Figura 27 – Procedimentos para seleção das oscilografias



Fonte: Elaborada pelo autor.

Posteriormente, para realizar a exportação, o seguinte caminho, a partir do menu principal, deve ser obedecido: “File” e “Export”. Então, após selecionar o formato desejado, e.g., MATLAB Binary, as oscilografias são salvas. Na Figura 28 apresenta-se tais procedimentos.

Figura 28 – Procedimentos para exportação das oscilografias



Fonte: Elaborada pelo autor.

A partir a exportação, pode-se realizar a análise do comportamento de falhas simuladas e, também, a validação de metodologias desenvolvidas.

APÊNDICE F – TRABALHOS PUBLICADOS

Neste apêndice apresentam-se os artigos publicados no decorrer da pesquisa de doutorado.

F.1 Periódicos Internacionais

DECANINI, J. G. M. S.; TONELLI-NETO, M. S.; MINUSSI, C. R. Robust fault diagnosis in power distribution systems based on fuzzy ARTMAP neural network-aided evidence theory. **IET Generation, Transmission and Distribution**, Stevenage, v. 6, n. 11, p. 1112–1120, 2012.

F.2 Congressos

TONELLI-NETO, M. S.; DECANINI, J. G. M. S.; MINUSSI, C. R. Diagnóstico de faltas de alta impedância em sistemas de distribuição de energia elétrica via transformada wavelet e lógica fuzzy. In: SIMPÓSIO BRASILEIRO DE SISTEMAS ELÉTRICOS, 4., 2012, Goiânia. **Anais...** Goiânia: [s.n.], 2012. p. 1-5.

BARROS, A. C.; TONELLI-NETO, M. S.; DECANINI, J. G. M. S.; MINUSSI, C. R. Diagnóstico de distúrbios de tensão em sistemas de distribuição de energia elétrica usando uma rede neural ARTMAP euclidiana modificada com treinamento continuado. In: CONGRESSO BRASILEIRO DE AUTOMÁTICA, 19., 2012, Campina Grande. **Anais...** Campina Grande: [s.n.], 2012. p. 1-8.

TONELLI-NETO, M. S.; DECANINI, J. G. M. S.; BARROS, A. C.; MINUSSI, C. R. Diagnóstico de faltas de alta impedância em alimentadores de distribuição de energia elétrica via sistema de inferência fuzzy e teoria da evidência. In: SIMPÓSIO BRASILEIRO DE AUTOMAÇÃO INTELIGENTE, 11., 2013, Fortaleza. **Anais...** Fortaleza: [s.n.], 2013. p. 1-6.

BARROS, A. C.; TONELLI-NETO, M. S.; DECANINI, J. G. M. S.; MINUSSI, C. R. Detecção e classificação de distúrbios de tensão em sistemas de distribuição de energia elétrica usando uma rede neural ARTMAP euclidiana modificada com treinamento continuado. In: SIMPÓSIO BRASILEIRO DE AUTOMAÇÃO INTELIGENTE, 11., 2013, Fortaleza. **Anais...** Fortaleza: [s.n.], 2013. p. 1-6.