



UNIVERSIDADE ESTADUAL PAULISTA
"JÚLIO DE MESQUITA FILHO"
Câmpus de Ilha Solteira

Programa de Pós-Graduação em Engenharia Elétrica

ANA CLAUDIA BARROS

**Detecção e Classificação de Distúrbios de Tensão Usando
Redes Neurais ARTMAP Euclidiana Modificada com
Treinamento Continuado**

Ilha Solteira

2013.

ANA CLAUDIA BARROS

**Detecção e Classificação de Distúrbios de Tensão Usando Redes
Neurais ARTMAP Euclidiana Modificada com Treinamento
Continuado**

Tese apresentada à Faculdade de Engenharia
do Campus de Ilha Solteira - UNESP, como
parte dos requisitos para obtenção do título de
Doutora em Engenharia Elétrica.

Área de conhecimento: Automação.

Prof. DR. CARLOS ROBERTO MINUSSI
Orientador

Ilha Solteira

2013.

FICHA CATALOGRÁFICA

Desenvolvido pelo Serviço Técnico de Biblioteca e Documentação

B277d Barros, Ana Claudia.
Detecção e classificação de distúrbios de tensão usando redes neurais
ARTMAP Euclidiana modificada com treinamento continuado / Ana Claudia
Barros. -- Ilha Solteira: [s.n.], 2013
109 f. : il.

Tese (doutorado) - Universidade Estadual Paulista. Faculdade de Engenharia
de Ilha Solteira. Área de conhecimento: Automação, 2013

Orientador: Calos Roberto Minussi
Inclui bibliografia

1. Transformada wavelet. 2. Rede neural ARTMAP Euclidiana modificada
com treinamento continuado. 3. Diagnóstico de distúrbios. 4. Automação de
subestações. 5. Sistema de distribuição.



UNIVERSIDADE ESTADUAL PAULISTA
CAMPUS DE ILHA SOLTEIRA
FACULDADE DE ENGENHARIA DE ILHA SOLTEIRA

CERTIFICADO DE APROVAÇÃO

TÍTULO: Detecção e Classificação de Distúrbios de Tensão Usando Redes Neurais ARTMAP
Euclidiana Modificada com Treinamento Continuado

AUTORA: ANA CLAUDIA BARROS

ORIENTADOR: Prof. Dr. CARLOS ROBERTO MINUSSI

Aprovada 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


Profa. Dra. ANNA DIVA PLASENCIA LOTUFO

Departamento de Engenharia Elétrica / Faculdade de Engenharia de Ilha Solteira


Profa. Dra. MARA LÚCIA MARTINS LOPES

Departamento de Matemática / Faculdade de Engenharia de Ilha Solteira


Profa. Dra. FERNANDA CASEÑO LIMA TRINDADE

Departamento de Sistemas de Energia Elétrica / Universidade Estadual de Campinas


Prof. Dr. JOSE CARLOS DE MELO VIEIRA JUNIOR

Departamento de Engenharia Elétrica / Escola de Engenharia de São Carlos-Usp

Data da realização: 13 de dezembro de 2013.

DEDICO

*Aos meus pais, Benedito
e Tereza, que sempre
acreditaram em mim.*

AGRADECIMENTOS

Quero agradecer primeiramente a DEUS, pela paz nos momentos em que me encontrei incapaz de prosseguir.

Ao meu orientador, Prof. Dr. Carlos Roberto Minussi, por acreditar em mim e contribuir para o meu crescimento profissional e pessoal.

Agradeço aos meus pais, Tereza e Benedito, a minha irmã Angela e a minha sobrinha Gabrieli, que sempre me incentivaram e torceram pela minha vitória.

Ao meu grande amigo Mauro Tonelli Neto por jamais vacilar no apoio, incentivo e dedicação na realização deste trabalho, sendo exemplo de competência, garra, determinação e disciplina.

A Profa. Dra. Anna Diva por sempre me incentivar na busca do crescimento.

Aos colegas e amigos do laboratório SINTEL cuja convivência estimulou o trabalho e a dedicação à pesquisa.

Aos meus amigos Lucas Ramalho, José Guilherme, Carlos Antúnez, Fernando e Jaqueline que sempre estiveram presentes me aconselhando e incentivando com carinho e dedicação.

Às amigas de república, Carla, Julia, e Patrícia pela amizade e companheirismo nos momentos difíceis.

Agradeço, finalmente, a CAPES pela ajuda financeira proporcionada em todo o período de pós-graduação.

RESUMO

Apresenta-se, nesta pesquisa, uma metodologia para realizar a detecção e classificação de distúrbios de tensão em sistemas de distribuição de energia elétrica, usando como ferramenta, as análises estatística e direta multinível dos sinais de tensão no domínio *wavelet* para o processo de detecção e uma rede neural ARTMAP Euclidiana Modificada com Treinamento Continuado (ARTMAP-EMTC) para o processo de classificação. Com o auxílio destas duas ferramentas obtém-se maior precisão, segurança e confiabilidade na tomada de decisão para o restabelecimento das operações normais do sistema. A rede neural ARTMAP-EMTC é capaz de se adaptar às constantes mudanças que sofre o setor elétrico, *e.g.*, fornece o diagnóstico de um distúrbio desconhecido pela rede neural que possa surgir com o passar do tempo. Além disso, permite a inclusão de novos padrões na memória da rede neural sem a necessidade de reiniciar o treinamento, o que não ocorre com outros tipos de redes neurais. Trata-se, por conseguinte, de uma nova abordagem da aplicação de redes neurais onde é realizada, permanentemente, a extração do conhecimento do sistema sob análise, a partir de informações disponibilizadas na operação do sistema (resultado das análises, simulação, etc.). Os sinais de tensão, necessários para realizar os diagnósticos de distúrbios de tensão, foram obtidos por meio de simulações de um modelo de alimentador radial no *software* ATP (*Alternative Transients Program*) e Matlab, empregando-se a transformada *wavelet* discreta, análise multirresolução e o conceito de energia. Os resultados obtidos mostram a eficiência da metodologia proposta, o que possibilita sua aplicação, com sucesso, na proteção dos sistemas de distribuição, auxiliando os operadores no processo de decisão visando restabelecer o sistema e contribuindo, desta forma, para a melhoria da qualidade da energia elétrica fornecida aos consumidores.

Palavras-chave: Transformada *wavelet*. Rede neural ARTMAP Euclidiana Modificada com Treinamento Continuado. Diagnóstico de distúrbios. Automação de subestações. Sistema de distribuição.

ABSTRACT

This research presents a methodology to detect and classify voltage disturbances in electrical distribution systems using as tool, statistical and multilevel direct analysis of voltage signals in wavelet domain for the detection process and modified Euclidean ARTMAP neural network with continuous training for the classification (ARTMAP- MECT). These two tools provide velocity, security and reliability for decision making when it is necessary to restore the normal operations. The ARTMAP-MECT is able to adapt to continuous changes at the electrical system, e.g. to provide a diagnosis of unknown disturbances by the neural network. Furthermore, it allows the inclusion of new patterns in the memory of the neural network without reinitializing the training, which is not possible in other neural networks. It is a new approach of neural network application where the knowledge is permanently extracted from the system under analysis from information available in the system operation (results from analysis, simulation, etc.). The voltage signals that are necessary to execute the voltage disturbance diagnosis are obtained from simulations of a radial feeder using the ATP (*Alternative Transients Program*) and MATLAB using the discrete wavelet transform, multi-resolution analysis and energy concept. The obtained results show the efficiency of the proposed methodology allowing the application in distribution protection, aiding the operators in decision procedures to restore the system and contributing to improve the power quality provided to the users.

Keywords: Wavelet Transform. Modified Euclidian ARTMAP with continuous training. Voltage Disturbances. Substation Automation. Electric Distribution Systems.

LISTA DE FIGURAS

Figura 1 – Comportamento das tensões na presença de interrupção na fase <i>c</i>	20
Figura 2 – Comportamento das tensões na presença de afundamento de tensão na fase <i>a</i>	21
Figura 3 – Comportamento das tensões na presença de elevação de tensão na fase <i>b</i>	22
Figura 4 – Comportamento das tensões na presença de transitório oscilatório na fase <i>c</i>	23
Figura 5 – Comportamento das tensões na presença de harmônicos na fase <i>c</i>	24
Figura 6 – Comportamento das tensões na presença de afundamento com harmônicos na fase <i>a</i>	25
Figura 7 – Comportamento das tensões na presença de elevação com harmônicos na fase <i>b</i>	26
Figura 8 – Estrutura do sistema de diagnóstico de anomalia de tensão	28
Figura 9 – Análise multirresolução considerando dois níveis de decomposição	34
Figura 10 – <i>Wavelet</i> mãe de Haar	36
Figura 11 – <i>Wavelet</i> mãe de Daubechies	37
Figura 12 – <i>Wavelet</i> mãe de Symlet	37
Figura 13 – <i>Wavelet</i> mãe de Coiflet.	38
Figura 14 – Rede Neural ART- <i>Fuzzy</i>	41
Figura 15 – Fluxograma da Rede ART- <i>Fuzzy</i>	46
Figura 16 – Rede Neural ARTMAP- <i>Fuzzy</i>	47
Figura 17 – Fluxograma Rede Neural ARTMAP- <i>Fuzzy</i>	53
Figura 18 – Fluxograma Rede Neural ART Euclidiana Modificada	58
Figura 19 – Fluxograma Rede Neural ARTMAP Euclidiana Modificada	65
Figura 20 – Fluxograma Rede Neural ARTMAP Euclidiana Modificada com Treinamento Continuo	74
Figura 21 – Estrutura do sistema de diagnóstico de anomalia de tensão	76
Figura 22 – Alimentador de distribuição utilizado para simulação dos distúrbios	83
Figura 23 – Evolução da rede com o módulo de treinamento contínuo	88

LISTA DE TABELAS

Tabela 1 – Codificação de saída	82
Tabela 2 – Modelagem dos sinais de distúrbio	84
Tabela 3 – Parâmetros para detecção de distúrbio de tensão	86
Tabela 4 – Percentual de acerto sem treinamento continuado	87
Tabela 5 – Percentual de acerto com treinamento continuado de modo <i>on-line/off-line</i>	89
Tabela 6 – Percentual de acerto com treinamento continuado de modo <i>on-line</i>	90

LISTA DE SÍMBOLOS

Todas as variáveis e parâmetros estão postos no estilo itálico. Matrizes e vetores são expressos no estilo itálico e negrito.

Quando se tratar das redes neurais da Família ART (*Adaptive Resonance Theory*), os vetores são tratados como linhas e não como colunas como habitualmente denotados na literatura matemática.

V_a, V_b e V_c	: Tensão nas fases a, b e c , respectivamente
$\psi(t)$: Função <i>wavelet</i>
S	: Parâmetro de translação
R	: Parâmetro de escala
$\phi(t)$: Função-escala
$x[n_p]$: Amostras do sinal
N_p	: Número de pontos do sinal analisado
E	: Energia do sinal
α	: Parâmetro de escolha
β	: Taxa de treinamento
ρ	: Parâmetro de vigilância
ε	: Parâmetro de incremento
$NMIN$: Representa o número de padrões necessários para que um peso temporário se torne definitivo
η	: Responsável em verificar se há ou não a necessidade de atualização dos pesos da categoria definitiva vencedora
\bar{d}	: Média aritmética dos coeficientes de detalhe
var	: Variação dos coeficientes de detalhe
μ	: Parâmetro a ser especificado pelo operador
τ	: Índice indicativo do estado de operação do sistema
Ψ	: Vetor das características normalizadas
Φ	: Sinal de cada característica normalizada
ca	: Coeficientes de aproximação
cd	: Coeficiente de detalhe
h	: Filtro passa-baixa
g	: Filtro passa-alta

LISTA DE ABREVIATURA E SIGLAS

AMR	Análise Multirresolução
ART	Teoria da Ressonância Adaptativa (<i>Adaptive Resonance Theory</i>)
ART-EM	ART Euclidiana Modificada
ARTMAP-EM	ARTMAP Euclidiana Modificada
ARTMAP-EMTC	ARTMAP Euclidiana Modificada com Treinamento Continuado
ATP	<i>Alternative Transients Program</i>
coif N	<i>Wavelet</i> Coiflet de ordem N
db N	<i>Wavelet</i> Daubchies de ordem N
DP	Distribuição Primária
DS	Distribuição Secundária
LT	Linha de Transmissão
RMS	Valor Quadrático Médio
sym N	<i>Wavelet</i> Symlet de Ordem N
T1	Transformador 1
T2	Transformador 2
T3	Transformador 3
T4	Transformador 4
TW	Transformada <i>Wavelet</i>
TWC	Transformada <i>Wavelet</i> Contínua
TWD	Transformada <i>Wavelet</i> Discreta
SCADA	<i>Supervisory Control And Data</i>

SUMÁRIO

1	INTRODUÇÃO	11
1.1	OBJETIVO DO TRABALHO	12
1.2	ORGANIZAÇÃO DO TRABALHO	13
2	REVISÃO BIBLIOGRÁFICA	15
2.1	INTRODUÇÃO	15
2.2	REVISÃO	15
3	TIPOS DE DISTÚRBIOS ABORDADOS NESTA PESQUISA	19
3.1	INTERRUPÇÃO	19
3.2	AFUNDAMENTO DE TENSÃO	20
3.3	ELEVAÇÃO DE TENSÃO	21
3.4	TRANSITÓRIO OSCILATÓRIO	22
3.5	HARMÔNICOS	23
3.6	AFUNDAMENTO COM HARMÔNICOS	24
3.7	ELEVAÇÃO COM HARMÔNICOS	25
4	ESTRUTURA DA METODOLOGIA PROPOSTA	27
4.1	INTRODUÇÃO	27
4.2	ESTRUTURA DA METODOLOGIA	27
5	TRANSFORMADA WAVELET	29
5.1	INTRODUÇÃO	29
5.2	TRANSFORMADA WAVELET CONTÍNUA	29
5.3	TRANSFORMADA WAVELET DISCRETA	30
5.4	ANÁLISE MULTIRRESOLUÇÃO	31
5.5	FAMÍLIA WAVELETS	34
5.5.1	FAMÍLIA HAAR	35
5.5.2	FAMÍLIA DAUBECHIES	36

5.5.3	<i>FAMÍLIA SYMLET</i>	37
5.5.4	<i>FAMÍLIA COIFLET</i>	38
5.6	CONCEITO DE ENERGIA	38
6	TEORIA DA RESSONÂNCIA ADAPTATIVA	40
6.1	INTRODUÇÃO	40
6.2	REDE NEURAL ART-FUZZY	40
6.2.1	ALGORITMO ART-FUZZY	44
6.3	REDE NEURAL ARTMAP-FUZZY	47
6.3.1	ALGORITMO ARTMAP-FUZZY	50
6.4	REDE NEURAL ART EUCLIDIANA MODIFICADA	54
6.4.1	ALGORITMO ART EUCLIDIANA MODIFICADA	55
6.5	REDE NEURAL ARTMAP EUCLIDIANA MODIFICADA	59
6.5.1	ALGORITMO ARTMAP EUCLIDIANA MODIFICADA	61
6.6	REDE NEURAL ARTMAP EUCLIDIANA MODIFICADA COM TREINAMENTO CONTINUADO	66
6.6.1	ALGORITMO ARTMAP EUCLIDIANA MODIFICADA COM TREINAMENTO CONTINUADO	68
7	METODOLOGIA	75
7.1	INTRODUÇÃO	75
7.2	DETECÇÃO DE DISTÚRBO DE TENSÃO	76
7.2.1	ANÁLISE MULTINÍVEL	77
7.3	CLASSIFICAÇÃO DE DISTÚRBO DE TENSÃO	79
7.3.1	EXTRAÇÃO DAS CARACTERÍSTICAS DO SISTEMA	79
7.4	PROCESSAMENTO E CODIFICAÇÃO	81
7.5	SISTEMA-TESTE E SIMULAÇÕES	82
7.5.1	MODELO DO ALIMENTADOR SIMULADO	82
7.5.2	SISTEMA TESTE PARA O DIAGNÓSTICO DE ANOMALIAS DE TENSÃO	84

8	RESULTADOS OBTIDOS E DISCUSSÕES	86
8.1	INTRODUÇÃO	86
8.2	DIAGNÓSTICO DE DISTÚRBO DE TENSÃO	86
9	CONCLUSÃO E SUGESTÕES PARA TRABALHOS FUTUROS	92
9.1	CONCLUSÃO	92
9.2	SUGESTÕES PARA TRABALHOS FUTUROS	93
	REFERÊNCIAS	94
	APÊNDICE A - PUBLICAÇÕES	99

1 INTRODUÇÃO

Atualmente os consumidores vêm exigindo das concessionárias de energia elétrica um melhor fornecimento de energia. A energia fornecida aos clientes deve ser entregue com qualidade e confiabilidade, reduzindo as anormalidades de tensão no sistema e minimizando as interrupções causadas por distúrbios (FAN; BORLASE, 2009; MCDONALD, 2003). Dentre os distúrbios mais comuns, podem ser destacados os afundamentos de tensão (*sag*), *e.g.*, causados por curtos-circuitos, elevação de tensão (*swell*), *e.g.*, causado pelo chaveamento de bancos de capacitores, e harmônicos, *e.g.*, pela presença de equipamentos, com características não-lineares, conectados à rede elétrica.

A ocorrência destes distúrbios degrada a qualidade da energia, ocasionando a má operação de equipamentos ligados à rede elétrica, superaquecimento dos condutores, e atuação indevida de relés e sistemas de proteção. Neste contexto, as concessionárias têm aplicado grandes investimentos visando o desenvolvimento de novas técnicas que sejam capazes de detectar e classificar tais distúrbios de forma rápida, segura e eficiente, contribuindo para a automação do sistema de distribuição de energia (NORTHCOTE-GREEN; WILSON, 2007; KEZUNOVIC, 2004). Normalmente, a detecção de distúrbios é realizada via inspeção visual das oscilografias de tensão, por parte dos operadores, sendo necessária uma prévia experiência em análise e a tomada de decisão. Por ser dependente de operadores humanos, a prática de diagnóstico está susceptível a erros. Assim, a automação desta prática é de suma importância no contexto atual, sendo as técnicas baseadas na inteligência artificial ferramentas disponíveis no auxílio aos operadores na classificação de anormalidades.

Na literatura especializada têm sido propostas várias metodologias que objetivam a identificação de distúrbios de tensão de forma automática. As principais referências destacadas nesta pesquisa são: Panigrahi e Pandi (2009) (uso da transformada *wavelet*); Venkatesh *et al.* (2010) (uso da transformada-S e redes neurais artificiais), Granados-Lieberman *et al.* (2011) (tutorial sobre índices de qualidade de energia e classificação de distúrbios de tensão); Gaouda *et al.* (1999) (uso da transformada *wavelet*).

Nesta pesquisa de doutorado apresenta-se uma metodologia alternativa de diagnóstico de distúrbios de tensão em sistemas de distribuição de energia elétrica. Trata-se de um sistema simples, robusto e flexível, que utiliza uma rede neural da família ART,

ARTMAP Euclidiana Modificada (ARTMAP-EM) com treinamento continuado, para realizar a classificação dos distúrbios (MARCHIORI *et al.*, 2011). A rede neural empregada disponibiliza uma nova concepção, na qual o desempenho da mesma é aperfeiçoado com o passar do tempo, *i.e.*, à medida que novos conhecimentos são apresentados à rede, não necessitando, desta forma, reinicializar o processo de treinamento. O reforço deste conhecimento é feito em tempo real (*on-line*) e de maneira automática, uma vez que a rede apresenta parâmetros responsáveis em identificar a presença de novos conhecimentos e refinar o conhecimento previamente adquirido. Este módulo de treinamento continuado não requer esforço computacional elevado em comparação com outras configurações de redes neurais, *e.g.*, algoritmo retropropagação (*backpropagation*) (WERBOS, 1974).

O treinamento continuado pode ser realizado a partir dos dados destinados ao diagnóstico oriundo do sistema de aquisição de dados (SCADA) (BOYER, 2009) do sistema, além de bases obtidas via simulações que contemplem outras alterações na topologia da rede elétrica e outros tipos de distúrbios de tensão, característicos de distorções da forma de onda, inclusive outras anormalidades, *e.g.*, curtos-circuitos de baixa e de alta impedância (BARROS *et al.*, 2012).

A extração das características da forma de onda de tensão é realizada, empregando-se em conjunto, a transformada *wavelet* discreta (TWD) (DAUBECHIES, 1992), análise multirresolução (AMR) (GOMES, VELHO, 1999) e o conceito energia (OPPENHEIM; SCHAFER, 1975). Estas características correspondem aos vetores de entrada da rede neural ARTMAP-EM com treinamento continuado. Como saída a rede neural fornece uma codificação binária preestabelecida de forma a representar o tipo de distúrbio presente no alimentador.

1.1 OBJETIVO DO TRABALHO

Atualmente, vários investimentos têm sido aplicados no sistema de distribuição de energia elétrica com o objetivo de modernizar as técnicas e tecnologias empregadas nas suas instalações, contribuindo para a automação das subestações de energia elétrica (TONELLI-NETO, 2012).

A automação dos sistemas elétricos facilita a identificação de problemas manifestados no módulo e frequência da tensão e corrente, contribuindo desta forma, para o

aumento da segurança e da confiabilidade da energia entregue aos consumidores. Além disso, um sistema automatizado traz benefícios tanto para as concessionárias quanto aos consumidores, pois auxilia os operadores nas causas e consequências dos distúrbios ocorridos na rede elétrica, que por sua vez, restabelece o sistema em um menor espaço de tempo possível.

Esta pesquisa tem por objetivo apresentar um método alternativo para diagnóstico de distúrbios de tensão em subestações de energia elétrica, baseados em sistemas inteligentes (rede neural ARTMAP euclidiana com treinamento continuado), indicando qual o tipo de distúrbio. Os distúrbios que serão diagnosticados são: afundamento (*sag*), elevação (*swell*), interrupção (*outage*), harmônicos, elevação com harmônicos, afundamento com harmônicos e transitório oscilatório. Este projeto de automação utilizando a rede neural ARTMAP-EMTC, tem por finalidade viabilizar maior precisão e eficiência no diagnóstico de distúrbios de tensão, contribuindo dessa forma para melhorar a qualidade da energia elétrica.

1.2 ORGANIZAÇÃO DO TRABALHO

A seguir, é descrito de forma breve como o trabalho está organizado.

Apresenta-se, no Capítulo 2, um levantamento bibliográfico das principais referências associadas à detecção e classificação de distúrbios de tensão em sistemas de distribuição de energia elétrica.

No Capítulo 3 são abordados os conceitos sobre sistemas elétricos de potência, descrevendo as principais configurações de subestações, a importância de uma subestação automatizada e as definições de alguns distúrbios de tensão.

No Capítulo 4 apresenta-se a estrutura do sistema de diagnóstico de distúrbios de tensão

No Capítulo 5 são abordados os principais conceitos de transformada *wavelet* contínua e discreta, análise multirresolução, família *wavelet* e conceito de energia.

No Capítulo 6 aborda-se a Teoria da Ressonância Adaptativa, apresentando os principais conceitos e arquiteturas das redes neurais utilizada neste trabalho.

No Capítulo 7 é apresentada a metodologia desenvolvida neste trabalho para diagnóstico de distúrbios de tensão em subestação.

No Capítulo 8 apresentam-se os principais resultados obtidos.

No Capítulo 9 são apresentadas as conclusões.

2 REVISÃO BIBLIOGRÁFICA

2.1 INTRODUÇÃO

Neste Capítulo, serão discutidos os principais métodos disponibilizados na literatura para diagnóstico de distúrbios. A solução proposta para o diagnóstico de distúrbios de tensão será focada sob o ponto de vista da extração do conhecimento para detecção e classificação de distúrbios de tensão, empregando redes neurais, ou seja, a inclusão do treinamento continuado. O treinamento continuado deve ser entendido como uma nova habilidade, não observada na maioria dos tipos de redes neurais artificiais disponíveis na literatura, em que o aprendizado é realizado de forma contínua. Deste modo, pode-se incorporar o conhecimento considerando-se qualquer tipo de falta e mudanças topológicas da rede elétrica (por exemplo, entrada ou saída de operação de componentes elétricos).

2.2 REVISÃO

O problema-alvo desta pesquisa refere-se ao desenvolvimento de um método para a detecção e classificação de distúrbios de tensão em sistemas de distribuição de energia elétrica. O método proposto é constituído, basicamente, de duas partes: (1) detecção de distúrbios e (2) classificação de distúrbios. Na fase de detecção são usadas técnicas baseadas na teoria de *wavelets* (transformada *wavelet* discreta, análise multirresolução e norma entropia). A fase de classificação é executada empregando-se uma rede neural da família ART (ARTMAP Euclidiana Modificada). Visando dar maior suporte à extração do conhecimento, à rede neural é incluído um módulo que permite realizar o treinamento continuado, ou seja, não havendo a necessidade de reinicializar o treinamento da rede neural toda a vez que houver disponibilidade de novos padrões. Por conseguinte, trata-se de um procedimento em que a extração do conhecimento é realizada de forma contínua, mesmo durante a fase das análises. Esta abordagem possibilita a perfeita adaptação da rede neural às mudanças (topológicas, tipos diferentes de distúrbios, perfil de consumo, entre outros eventos) que acontecem nos sistemas de distribuição. Este item compreende a principal contribuição desta pesquisa.

A contribuição mais relevante desta pesquisa refere-se ao desenvolvimento de uma rede neural ART descendente com a inclusão do treinamento continuado. No que se refere à fase de detecção, usou-se uma versão dos métodos propostos por Decanini *et al.* (2011a), Decanini *et al.* (2011b) e Decanini (2012). Outros artigos também serviram de inspiração para esta tese de doutorado. Estas referências são discutidas na sequência.

Decanini *et al.* (2011a) apresenta um método para detecção e classificação de distúrbios de tensão utilizando as técnicas de processamentos de sinais e a rede neural ARTMAP-*Fuzzy*. As características são extraídas das oscilografias de tensão, por meio da transformada *wavelet* discreta, análise multirresolução e conceitos da norma entropia. Essas características são utilizadas como entrada da rede da ARTMAP-*Fuzzy*, que classifica o tipo de distúrbio.

Em Abdelsalam *et al.* (2012) é apresentada uma técnica híbrida para caracterização de distúrbios de qualidade de energia. Nesta técnica híbrida é usado filtro de Kalman juntamente com a transformada *wavelet* discreta para extração das características da forma de onda distorcida. Em seguida, a partir de uma base de regras, um sistema *fuzzy* especialista fornece como saída o tipo de distúrbio.

Uma nova abordagem para classificação de distúrbios de qualidade de energia empregando o modelo de Markov e a transformada *wavelet* é proposta em Dehghani *et al.* (2013). Por meio da aplicação da transformada *wavelet*, é calculada a distribuição de energia dos coeficientes, considerando cada nível de decomposição, dos distúrbios analisados. Por conseguinte, os índices extraídos inicializam a matriz de treinamento do modelo de Markov, de modo que a precisão da classificação seja maximizada. Além disso, o algoritmo de Dempster-Shafer é utilizado para obtenção de informações qualitativas adicionais a respeito do resultado.

Em Eristi e Demir (2012) é proposta uma metodologia para classificação de distúrbios de qualidade de energia utilizando um sistema de reconhecimento inteligente. Aplicando-se a transformada *wavelet* nos sinais de tensão trifásicos são extraídas as características que representam o distúrbio. Ademais, uma máquina de vetor suporte (VAPNIK, 2000) classificará o tipo de distúrbio presente no sistema de potência.

Com relação ao treinamento continuado, no contexto da plasticidade, que é inerente das redes neurais ART descendente, as propostas disponibilizadas na literatura são escassas.

Kenaya (2008) apresenta uma rede neural ART Euclidiana que utiliza, em seu algoritmo, a distância euclidiana para decidir se um novo padrão deve ou não ser incluído na memória da rede. Esta rede foi treinada a fim de testar o agrupamento de padrões em uma distribuição no plano. Os resultados obtidos por esse agrupamento foram utilizados no treinamento das redes ART *Fuzzy* e ART Euclidiana, visando a comparação do desempenho das redes em relação a ruídos.

Outras referências que abordaram o treinamento continuado, usando redes neurais da família ART, são as seguintes.

Moreno (2010) apresenta uma rede neural ART-ARTMAP *Fuzzy* Euclidiana modificada com treinamento continuado, para análise da estabilidade transitória, considerando um sistema elétrico composto por 10 máquinas síncronas, 45 barras e 73 linhas de transmissão. O módulo de treinamento continuado, inserido na rede ART euclidiana modificada, armazena novos conhecimentos na memória da rede neural sem a necessidade de realizar um novo treinamento. Além disso, se for apresentada a rede uma nova configuração (ocorrência da inclusão ou retirada de operação de um ou mais elementos da rede elétrica), a rede ativa um treinamento específico para que esta configuração seja incorporada definitivamente na rede. Os testes realizados mostram a eficiência da rede neural com treinamento continuado.

Marchiori *et al.* (2011) propõe uma modelo de rede neural ARTMAP Euclidiana na qual integra o sistema de treinamento continuado. Esta rede é aplicada para resolver problemas de análise estabilidade transitória considerando o sistema elétrico utilizado por Moreno (2010). O módulo de treinamento continuado incorporado na rede ARTMAP Euclidiana, baseia-se nos conceitos de detecção de novidade e de detecção de anomalias como critério para incluir na memória da rede um novo padrão. Os resultados obtidos mostram a eficiência do método utilizado.

Ressalta-se que o diferencial da pesquisa proposta, em relação às referências anteriormente citadas, é destacado a seguir.

Decanini *et al.* (2011a), Abdelsalam *et al.* (2012), Dehghani *et al.* (2013) e Eristi e Demir (2012) utilizam em seus trabalhos as seguintes ferramentas para classificação dos distúrbios de tensão: rede neural ARTMAP-*Fuzzy*, sistema *fuzzy* especialista, modelo de Markov, máquina de vetor suporte, respectivamente. Enquanto que, nesta pesquisa, para classificação dos distúrbios de tensão é empregada a rede ARTMAP-EM com treinamento

continuado. Todas as referências supracitadas, bem como esta pesquisa aplica-se, para a extração das características, a TW.

Kenaya (2008) apresenta a rede ART euclidiana, mas não utiliza treinamento continuado. O que diferencia o trabalho apresentado por Kenaya (2008), em relação a este trabalho, é que, além da inclusão do módulo de treinamento continuado a rede empregada é a ARTMAP-EM.

Moreno (2010) tem em comum com este trabalho a inclusão do modulo treinamento continuado, mas essa inclusão foi feita na rede ART-EM, enquanto que, neste trabalho o modulo de treinamento de continuado foi incluso na rede ARTMAP-EM. Já a relação de desigualdade do trabalho de Marchiori *et al.* (2011) com este, está no tipo de aplicação. Ou seja, em Marchiori *et al.* (2011) a aplicação se refere a um problema de análise de estabilidade transitória (de primeira oscilação) de sistemas multimáquinas. Esta pesquisa de doutorado destina-se ao diagnóstico de distúrbios de tensão de sistemas de distribuição de energia elétrica. Além disso, Marchiori *et al.* (2011) incluiu o módulo de treinamento continuado na rede ARTMAP-E, enquanto que, neste trabalho o módulo de treinamento continuado foi incluso na rede ARTMAP-EM.

As vantagens da metodologia proposta perante as demais técnicas - exceto as metodologias proposta por Moreno (2010) e Marchiori *et al.* (2011) - refere-se a inclusão da extração conhecimento de forma incremental. Ou seja, é um sistema neural que se aperfeiçoa com o passar do tempo, permitindo a inclusão de novos conhecimentos procedentes de distúrbios diferentes (dos aqui abordados) e mudanças da rede elétrica (inclusão e remoção de elementos da rede elétrica). Esta habilidade, a princípio, não se observa considerando-se a grande maioria das redes neurais disponíveis na literatura (*e.g.*, redes neurais *feedforwards* multicamadas com treinamento realizado via uso do algoritmo retropropagação (WERBOS, 1974), rede neural de Kohonen (HAYKIN, 2001), entre outras).

3 TIPOS DE DISTÚRBIOS ABORDADOS NESTA PESQUISA

O conceito de Qualidade da Energia está relacionado a um conjunto de distúrbios que podem ocorrer em diferentes pontos de uma rede elétrica, tanto dentro como fora de uma instalação consumidora (DUGAN *et al.*, 1996; MALANGE, 2010). Geralmente, tais distúrbios são divididos em diferentes categorias levando-se em conta o seu tempo de duração, seu conteúdo espectral e sua amplitude típica no sistema. Estes distúrbios podem provocar a má operação de equipamentos, acionamentos indevidos de relés, distorções em equipamentos de medições e a interrupção do fornecimento de energia, ocasionando prejuízos às concessionárias e consumidores (ARRUDA, 2003).


A seguir, serão apresentados de forma sucinta os distúrbios relacionados com essa pesquisa.

3.1 INTERRUPÇÃO

O distúrbio interrupção (*outage*) pode ser definido como uma queda na tensão com um valor menor que 0,1 pu com tempo de duração menor que 3 minuto. Podendo ocorrer de forma prevista, para fins de manutenção ou transferência de carga, ou de forma imprevista, no caso de defeitos. Esses defeitos podem ser causados por falhas de equipamentos e no sistema de energia elétrica, mau funcionamento dos sistemas e controle (FRANCO, 2013).

A Figura 1 mostra as formas de onda de um distúrbio interrupção.

Figura 1 – Comportamento das tensões na presença de interrupção na fase *c*



Fonte: Elaboração da própria autora.


3.2 AFUNDAMENTO DE TENSÃO

Um distúrbio referente ao afundamento temporário de tensão (*sag*) é definido como um decremento entre 0,1 e 0,9 pu do valor RMS (eficaz) da tensão ou corrente na frequência da rede, com tempo de duração entre 3 segundos e 3 minutos (ANEEL, 20012).

A ocorrência do afundamento de tensão está associada, principalmente, a curtos-circuitos ocorridos nas redes de distribuição, podendo, também, ser causado pela energização de grandes cargas, partida de grandes motores e pela corrente *inrush* de transformadores (OLIVEIRA, 2000). Geralmente, este distúrbio desaparece depois que o problema que o provocou é removido.

Na Figura 2 são mostradas as formas de onda de um distúrbio afundamento temporário de tensão.

Figura 2 – Comportamento das tensões na presença de afundamento de tensão na fase *a*



Fonte: Elaboração da própria autora.


3.3 ELEVAÇÃO DE TENSÃO

Um distúrbio elevação temporária de tensão (*swell*) é definido como um incremento entre 1,1 do valor RMS (eficaz) da tensão ou corrente na frequência da rede, com tempo de duração entre 3 segundos e 3 minutos (ANEEL, 20012).

O distúrbio referente à elevação de tensão pode ocorrer a partir de uma elevação temporária da tensão nas fases, causada por uma falta fase-terra. Este distúrbio pode também estar ligado à saída de grandes blocos de cargas ou à energização de grandes bancos de capacitores (FRANCO, 2013), sendo caracterizados pelas suas magnitudes (valores eficazes) e suas durações. Sua duração está associada aos ajustes dos dispositivos de proteção, à natureza da falta (permanente ou temporária) e à sua localização na rede elétrica (FRANCO, 2013).

A Figura 3 mostra as formas de onda de um distúrbio elevação.

Figura 3 – Comportamento das tensões na presença de elevação de tensão na fase *b*



Fonte: Elaboração da própria autora.

3.4 TRANSITÓRIO OSCILATÓRIO


O transitório oscilatório é uma mudança súbita na condição de estado estável da tensão, corrente, ou ambos, possuindo valores de polaridade positivo e negativo. Esta mudança súbita implica na elevação e queda de tensão do sinal de fornecimento de forma alternada e rápida (DUGAN, 1996).

O transitório oscilatório pode ocorrer como consequência da energização de linhas, cortes de carga, eliminação de faltas, chaveamento de bancos de capacitores e transformadores (FRANCO, 2013).

Na maioria dos casos, o tempo de duração de um transitório oscilatório é muito pequeno, porém de grande importância, uma vez que submetem equipamentos presentes nos sistemas elétricos a grandes solicitações de tensão e/ou corrente (FRANCO, 2013).

Na Figura 4 são mostradas as formas de onda de um distúrbio transitório oscilatório.

Figura 4 – Comportamento das tensões na presença de transitório oscilatório na fase *c*



Fonte: Elaboração da própria autora.


3.5 HARMÔNICOS

Harmônicos são tensões ou correntes senoidais, cuja frequência é um múltiplo inteiro da frequência fundamental na qual opera o sistema (normalmente 50 ou 60 Hz). Estes distúrbios distorcem as formas de onda da tensão ou corrente. Estas distorções originam de dispositivos e cargas com características não lineares no sistema de energia elétrica (DUGAN, 1996).

A distorção harmônica pode ocorrer por energização de linhas, corte de corrente indutiva, eliminação de faltas, chaveamento de bancos de capacitores e transformadores, etc. (FRANCO, 2013).

A Figura 5 mostra as formas de onda de um distúrbio harmônico.

Figura 5 – Comportamento das tensões na presença de harmônicos na fase *c*




Fonte: Elaboração da própria autora.

3.6 AFUNDAMENTO COM HARMÔNICOS

A Figura 6 mostra as formas de onda de um distúrbio referente ao afundamento com harmônicos em sinais de tensão.


Figura 6 – Comportamento das tensões na presença de afundamento com harmônicos na fase

a

Fonte: Elaboração da própria autora.

3.7 ELEVAÇÃO COM HARMÔNICOS

Na Figura 7 mostram-se as formas de onda de um distúrbio elevação com harmônicos.

Figura 7 – Comportamento das tensões na presença de elevação com harmônicos na fase *b*

Fonte: Elaboração da própria autora.

4 ESTRUTURA DA METODOLOGIA PROPOSTA

4.1 INTRODUÇÃO

Na metodologia proposta para diagnóstico automático de distúrbios de tensão, em subestações de energia elétrica, são utilizadas ferramentas de processamento de sinais e de inteligência artificial (redes neurais). As principais técnicas empregadas são: (1) aquisição e pré-processamento de dados; (2) transformada *wavelet* discreta; (3) análise multirresolução e norma entropia; (4) redes neurais da família ART em especial a rede neural ARTMAP euclidiana modificada com dispositivo que permite a inclusão do treinamento continuado.

4.2 ESTRUTURA DA METODOLOGIA

Na estrutura mostrada na Figura 8 são apresentados os módulos do sistema desenvolvido destinado à detecção e classificação de distúrbios de tensão. Este sistema pode ser modificado de acordo com as necessidades das concessionárias, acompanhando a constante evolução do sistema de energia elétrica.

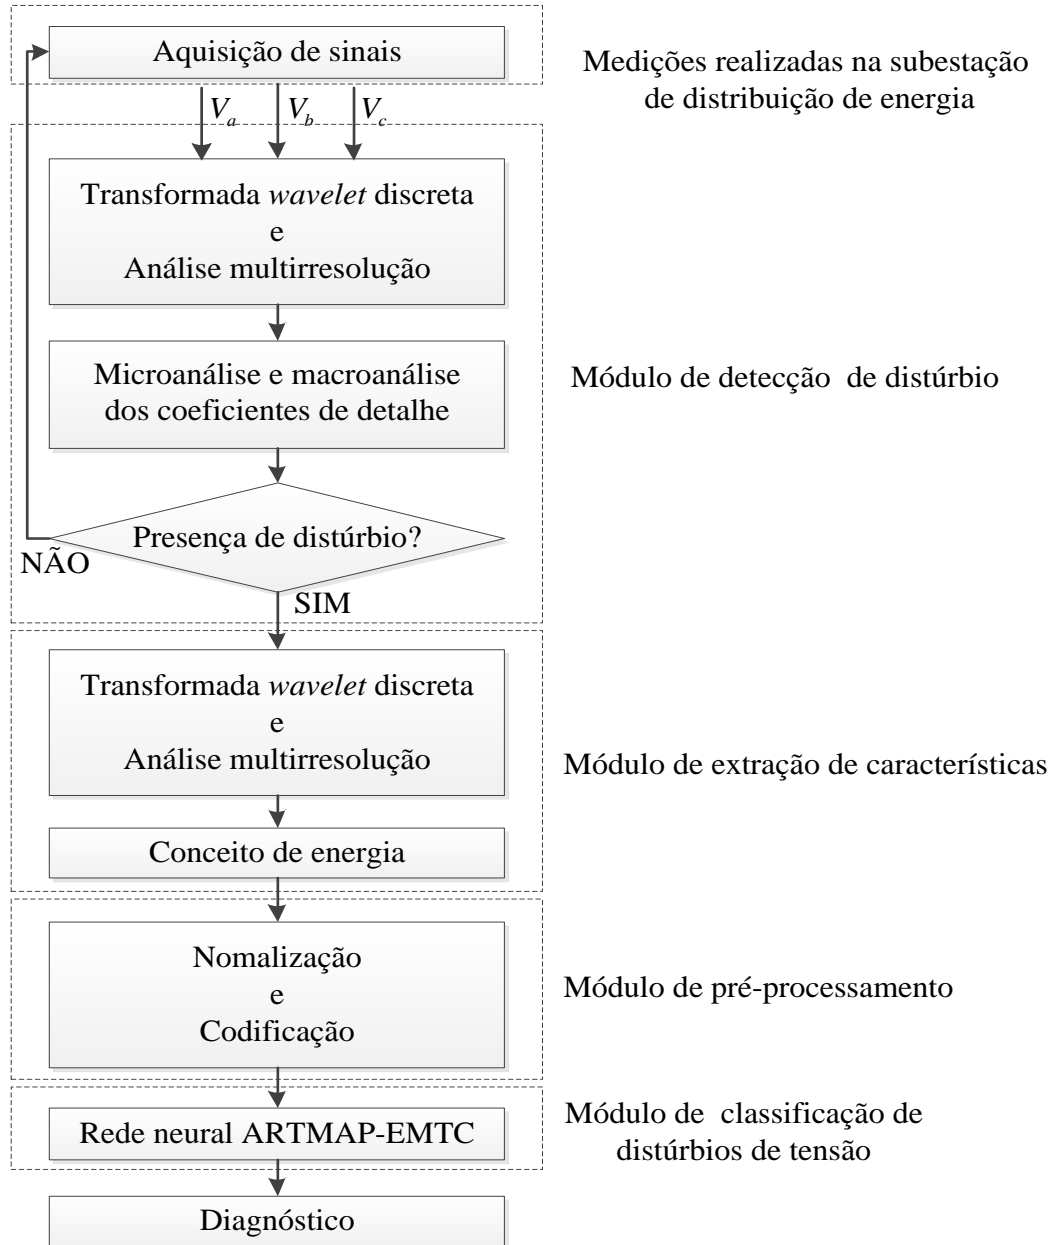
Os distúrbios utilizados no diagnóstico foram extraídos na saída do alimentador da subestação. A leitura e avaliação dos sinais de tensão são executadas de forma permanente.

Os sinais de tensão são processados através da transformada *wavelet* e da análise multirresolução para obter um diagnóstico, no domínio tempo-frequência, do comportamento do estado operativo do sistema. Em seguida, o sistema é avaliado por meio de um conjunto de regras que corresponde a macroanálise e a microanálise. Por meio da macroanálise busca-se conhecer o comportamento geral do sistema. Já a microanálise permite realizar uma análise ponto a ponto. Através dessa avaliação tem-se a detecção do distúrbio.

Detectada uma anomalia no sistema, inicia-se o processo de classificação do distúrbio. A extração das características do sistema é feita por meio das técnicas: transformada *wavelet* discreta, análise multirresolução e norma entropia. Os índices característicos são normalizados e codificados. Estes índices são os vetores de entrada de rede

neural ARTMAP-EMTC, a qual é destinada para classificar os tipos de distúrbios. Por fim, tem-se o registro dos resultados.

Figura 8 – Estrutura do sistema de diagnóstico de anomalia de tensão



Fonte: Elaboração da própria autora.

5 TRANSFORMADA WAVELET

5.1 INTRODUÇÃO

Na maior parte das aplicações onde é necessária a extração de características, são empregados métodos baseados na transformada de Fourier. Embora a transformada de Fourier seja uma ferramenta poderosa para diagnosticar distúrbios, esta não é adequada para a análise de sinais não-estacionários. Neste contexto, a transformada *wavelet* (TW) é um conceito disponível que supera as limitações das técnicas baseadas na transformada de Fourier, uma vez que ela fornece a evolução temporal dos transitórios de frequência (DECANINI *et al.*, 2011b). A transformada *wavelet* é uma transformada linear que utiliza uma série de funções oscilatórias com distintas frequências como funções de janelamento.

5.2 TRANSFORMADA WAVELET CONTÍNUA

Na Transformada *Wavelet* Contínua (TWC) é usada uma função-base que possui energia finita e valor médio nulo para decompor um sinal sob análise. Esta função, chamada de *wavelet* mãe, deve pertencer ao espaço $L^2(\mathbb{R})$. É definida pela Equação (1) (MALLAT, 2009; DAUBECHIES, 1992):

$$\int_{-\infty}^{+\infty} \psi(t) dt = 0 \quad (1)$$

A partir da dilatação e translação da função *wavelet* mãe, define-se um conjunto de funções ortogonais $\psi_{r,s}(t)$, usadas como base ortogonal para a representação dos sinais como descrito na Equação (2) (DAUBECHIES, 1992):

$$\psi_{r,s}(t) = \frac{1}{\sqrt{|r|}} \psi\left(\frac{t-s}{r}\right) \quad (2)$$

sendo: $s \in \mathbb{R}$ o parâmetro de translação e $r \in \mathbb{R}^+$ com $r \neq 0$ o parâmetro de escala. O fator de multiplicação $\frac{1}{\sqrt{|r|}}$ é para normalização da energia através das diferentes escalas.

A TWC de um sinal contínuo $f(t)$, com relação à *wavelet* mãe $\psi(t)$ é definida pela seguinte equação (DAUBECHIES, 1992):

$$\text{TWC}(r, s) = \frac{1}{\sqrt{|r|}} \int_{-\infty}^{+\infty} f(t) \psi\left(\frac{t-s}{r}\right) dt \quad (3)$$

Por meio da análise *wavelet*, obtém-se um conjunto de coeficientes, no qual, verifica-se o grau de semelhança entre o sinal original $f(t)$ e as *wavelet* mãe $\psi(t)$ utilizadas no processo de decomposição do sinal (TONELLI-NETTO, 2012).

5.3 TRANSFORMADA WAVELET DISCRETA

A Transformada *Wavelet* Discreta (TWD) permite a sua implementação em sistemas digitais. Para analisar oscilografias obtidas por equipamentos de aquisição de dados, é necessária a discretização dos parâmetros r e s . Sendo assim, faz-se (DAUBECHIES, 1992):

$$r = r_0^m \text{ e } s = ns_0r_0^m \quad (4)$$

com m e $n \in \mathbb{Z}$, $r_0 > 1$ e $s_0 > 0$.

sendo:

$s = ns_0r_0^m$: parâmetro de translação;

$r = r_0^m$: parâmetro de escala.

Por conseguinte, tem-se a TWD de um sinal amostrado $f[k]$ dada por (DAUBECHIES, 1992):

$$DWT_f = \langle f, \psi_{m,n} \rangle = \frac{1}{\sqrt{r_0^n}} \sum_k f[k] \psi\left(\frac{k - ns_0 r_0^n}{r_0^n}\right), k \in \mathbb{Z} \quad (5)$$

Observando a Equação (5), conclui-se que (SILVA, 2008):

- A TWD é definida somente para parâmetros escalares positivos ($r_0 > 1$);
- O parâmetro de translação é proporcional à escala ($s = ns_0 r_0^m$);
- Um conjunto finito de coeficientes *wavelet* ($DWT_f = \langle f, \psi_{m,n} \rangle$) é produzido;
- O processamento é realizado sobre o sinal contínuo.

5.4 ANÁLISE MULTIRRESOLUÇÃO

A análise multirresolução (AMR) consiste na decomposição de sinais em escalas. Por meio dessa decomposição, é possível obter uma aproximação do sinal original para cada escala j . A AMR tem sido considerada uma das técnicas mais apropriadas para a análise de sinais não estacionários (GOMES, VELHO, 1999; SOARES, 2006; DECANINI, 2012).

Para a aplicação dos conceitos da AMR é necessário determinar um conjunto de funções que formem uma base ortogonal para espaços ω_m , e ϖ_m . O conjunto de funções $\{\phi_{m,n}\}_{n \in \mathbb{Z}}$ forma uma base de ω_m . Já a base de ϖ_m é definida pelo conjunto de funções $\{\psi_{m,n}\}_{n \in \mathbb{Z}}$.

A função $\phi_{m,n}$, denominada função escala, é apresentada na Equação (6) em sua forma contínua.

$$\phi_{m,n}(t) = \frac{1}{\sqrt{2^m}} \phi\left(\frac{t - 2^m n}{2^m}\right) \quad (6)$$

Sua forma discreta é apresentada na Equação (7).

$$\phi_{m,n}[k] = \frac{1}{\sqrt{2^m}} \phi\left(\frac{k - 2^m n}{2^m}\right) \quad (7)$$

Considerando um sinal $f[k]$, a projeção deste sinal $f[k]$ no espaço ω_m é definida pela Equação (8) (TONELLI-NETTO, 2012).

$$ca_m[n] = \langle f, \phi_{m,n} \rangle \quad (8)$$

A função $\psi_{m,n}$, denominada função *wavelet*, é apresentada na Equação (9) em sua forma contínua:

$$\psi_{m,n}(t) = \frac{1}{\sqrt{2^m}} \psi\left(\frac{t - 2^m n}{2^m}\right) \quad (9)$$

Sua forma discreta é apresentada na Equação (10).

$$\psi_{m,n}[k] = \frac{1}{\sqrt{2^m}} \psi\left(\frac{k - 2^m n}{2^m}\right) \quad (10)$$

Considerando um sinal $f[k]$, a projeção deste sinal $f[k]$ no espaço ω_m é definida pela Equação (11) (TONELLI-NETTO, 2012):

$$cd_m[n] = \langle f, \psi_{m,n} \rangle \quad (11)$$

A AMR consiste no cálculo dos coeficientes ca_{m+1} e cd_{m+1} . Estes cálculos são realizados, usando a convolução discreta do sinal ca_m com um filtro passa-baixa (h), por meio da equação (12), e da convolução discreta do sinal ca_m com um filtro passa-alta (g), por meio da equação (13) (MALLAT, 2009).


$$ca_{m+1}[p] = \sum_n h[n-2p]ca_m[n] \quad (12)$$

$$cd_{m+1}[p] = \sum_n g[n-2p]ca_m[n] \quad (13)$$

Os coeficientes obtidos através da decomposição do sinal na saída do filtro passa-baixa (h) e na saída filtro passa-alta (g), são denominados coeficientes de aproximação ca_{m+1} e coeficiente de detalhe cd_{m+1} , respectivamente. Os coeficientes de aproximação são componentes de alta escala e baixa frequência do sinal. Já os coeficientes de detalhe são componentes de baixa escala e alta frequência (TONELLI-NETTO, 2012). Sendo que, as saídas desses filtros são subamostrados com um fator igual a dois a cada nível de resolução (TONELLI-NETTO, 2012; DECANINI, 2012).

A Figura 9 apresenta a decomposição de um sinal f em 2 níveis.

Figura 9 – Análise multirresolução considerando dois níveis de decomposição



Fonte: Elaboração da própria autora.

5.5 FAMÍLIA WAVELETS

Existem inúmeras funções *wavelets* mãe que normalmente recebem o nome do seu próprio criador. A escolha da *wavelets* mãe para a decomposição do sinal fica a critério do usuário, pois a escolha está associada ao tipo de aplicação.

A *wavelet* mãe deve apresentar as seguintes propriedades (MALLAT, 2009; TONELLI-NETTO, 2012):

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

O projeto da *wavelet* mãe deve ser ótimo, *i.e.*, sua aplicação na decomposição de um sinal $\langle f, \psi \rangle$ deve produzir um grande número de coeficientes próximos de zero (TONELLI-NETTO, 2012). A produção desses coeficientes depende:

- **regularidade da função ψ** : relacionada ao erro introduzido no sinal reconstruído pelos coeficientes *wavelets*;
- **ordem da *wavelet* mãe ou momentos nulos**: associado à ordem polinomial dos sinais que podem ser representados por uma determinada *wavelet* mãe;
- **tamanho do suporte**: intervalo para o qual está definida a *wavelet* mãe (fora deste intervalo a função é nula).

A seguir, serão apresentadas as principais famílias de *wavelets*. Sendo que, a primeira família proposta na literatura foi a Haar e, as mais empregadas para a resolução de problemas referente à qualidade de energia são a Daubechies, a Symlet e a Coiflet. A família *wavelet* empregada neste trabalho foi a de Daubechies com um filtro de quarta ordem (db4).


5.5.1 FAMÍLIA HAAR

A primeira e a mais simples família *wavelet* foi desenvolvida pelo matemático húngaro Alfred Haar, em 1910. A *wavelet* de Haar é uma função descontínua e semelhante a uma função degrau um. As Equações (14) e (15) definem as funções escala e *wavelet*, respectivamente (DAUBECHIES, 1992):

$$\phi(t) = \begin{cases} 1, & \text{se } 0 \leq t \leq 1 \\ 0, & \text{caso contrário} \end{cases} \quad (14)$$

$$\psi(t) = \begin{cases} 1, & \text{se } 0 \leq t \leq \frac{1}{2} \\ -1, & \text{se } \frac{1}{2} \leq t \leq 1 \\ 0, & \text{caso contrário} \end{cases} \quad (15)$$

A Figura 10 apresenta o comportamento das funções escala e *wavelet* da *wavelet* mãe de Haar.

Figura 10 – *Wavelet* mãe de Haar

Fonte: MATLAB (2011).


5.5.2 FAMÍLIA DAUBECHIES

As *wavelets* da família *daubchies*, propostas por Ingrid Daubechies (DAUBECHIES, 1992) consistem em um conjunto de bases ortogonais de *wavelet* com suporte compacto, cujas funções desta base ortogonal estão definidas no intervalo limitado, de modo que os coeficientes que não pertencem a este intervalo são nulos (MALLAT, 2009; DAUBECHIES, 1992; TONELLI-NETO, 2012).

As *wavelet* Daubchies são representadas pela expressão dbN , sendo N a ordem da *wavelet* mãe, Assim, a *wavelet* bdN apresenta sinais nos quais a ordem polinomial não ultrapasse $N-1$.

O tamanho do suporte da função também é expresso por meio do índice N . Na família de *Daubchies*, as funções de escala $\phi(t)$ e *wavelet* $\psi(t)$ possuem tamanho do suporte igual a $2N-1$. A Figura 11 apresenta o comportamento das funções, escala e *wavelet* da *wavelet* mãe de Daubechies.

Figura 11 – Wavelet mãe de Daubechies


a) Função escala $\phi(t)$ b) Função wavelet $\psi(t)$

Fonte: MATLAB (2011).

5.5.3 FAMÍLIA SYMLET

As *wavelets* da família symlet, propostas por Daubechies (DAUBECHIES, 1992), são quase simétricas. As symlets possuem propriedades semelhantes às *dbN* (daubechies), exceto a simetria que nas symlets são maiores (DAUBECHIES, 1992). Esta família possui suporte compacto, definido por $2N-1$. Geralmente as *wavelet* symlet são representadas pela expressão *symN*, sendo N a ordem da *wavelet* mãe. A Figura 12 apresenta o comportamento das funções, escala e *wavelet* da *wavelet* mãe *sym6*.

Figura 12 – Wavelet mãe de Symlet


a) Função escala $\phi(t)$ b) Função wavelet $\psi(t)$

Fonte: MATLAB (2011).

5.5.4 FAMÍLIA COIFLET

As *wavelets* da família Coiflet também foram propostas por Daubechies (DAUBECHIES, 1992). Geralmente, são representadas pela expressão $\text{coif}N$. Suas funções, escala e *wavelet* apresentam ordens distintas da *wavelet* mãe, *i.e.*, $2N-1$ e $2N$, respectivamente. Esta família possui grau de simetria maior que a $\text{db}N$ e, seu suporte é definido por $6N-1$. Na Figura 13 mostra-se o comportamento das funções, escala e *wavelet* da *wavelet* mãe $\text{coif}5$.

Figura 13 – *Wavelet* mãe de Coiflet.



Fonte: MATLAB (2011).

5.6 CONCEITO DE ENERGIA

O conceito de energia corresponde a uma ferramenta de *data fusion* que pode ser utilizada para agregar as informações extraídas de um sinal por meio de algum tipo de transformada. Em particular, este conceito é muito empregado nos coeficientes obtidos após a aplicação da TW. Um sinal analisado por meio da TW gera um número considerável de coeficientes e, caso sejam as entradas de um processo de diagnóstico, este pode se tornar lento e ineficiente, por demandar um elevado esforço computacional. Por conseguinte, a aplicação do conceito energia reduz a dimensão do vetor de entrada, uma vez que os coeficientes são agregados em escalares, tornando o procedimento mais rápido e confiável (OPPENHEIM; SCHAFER, 1975).

A energia pode ser calculada utilizando a seguinte equação:

$$E = \sum_{n_p=1}^Z |x[n_p]|^2 \quad (16)$$

sendo:

$x[n_p]$: amostras do sinal;

Z : número de pontos do sinal analisado;

E : energia do sinal.

6 TEORIA DA RESSONÂNCIA ADAPTATIVA

6.1 INTRODUÇÃO

Das diversas arquiteturas de redes neurais existentes, as que mais se destacam são as redes neurais da família ART (CARPENTER *et al.*, 1992). As redes neurais da família ART possuem uma topologia baseada na teoria da ressonância adaptativa (GROSSBERG, 1976a, 1976b). Esta teoria foi desenvolvida com o intuito de solucionar o dilema da estabilidade e plasticidade, as quais são características fundamentais das redes da família ART. Com essas características as redes aprendem através do ajuste dos pesos (estabilidade). Seguem aprendendo mesmo com a inclusão de novos padrões sem perder os conhecimentos adquiridos anteriormente no seu aprendizado (plasticidade). Essas redes foram desenvolvidas para codificar, de maneira estável, o reconhecimento de categorias em resposta à sequência arbitrária de padrões de entrada, através da auto-organização (CARPENTER; GROSSBERG, 1992). O algoritmo de aprendizado das redes da família ART pode ser supervisionado, bem como não-supervisionado. O aprendizado (treinamento) pode ser rápido ($\beta = 1$) ou lento ($0 < \beta < 1$).

Assim sendo, neste capítulo serão apresentados os principais conceitos sobre as redes neurais da família ART, em especial as rede neurais ART Euclidiana Modificada (ART-EM). A rede neural ART-EM é a arquitetura principal usada nesta pesquisa, ou seja, uma rede neural dotada de treinamento contínuo.

Neste Capítulo, serão abordadas as redes neurais ART-descendentes: ART-*Fuzzy* (CARPENTER; GROSSBERG, 1992); ARTMAP-*Fuzzy* (CARPENTER *et al.*, 1992); ART Euclidiana Modificada (MORENO, 2010); ARTMAP Euclidiana Modificada (MORENO 2010; BARRO *et al.*, 2012); e ARTMAP Euclidiana Modificada com treinamento contínuo.

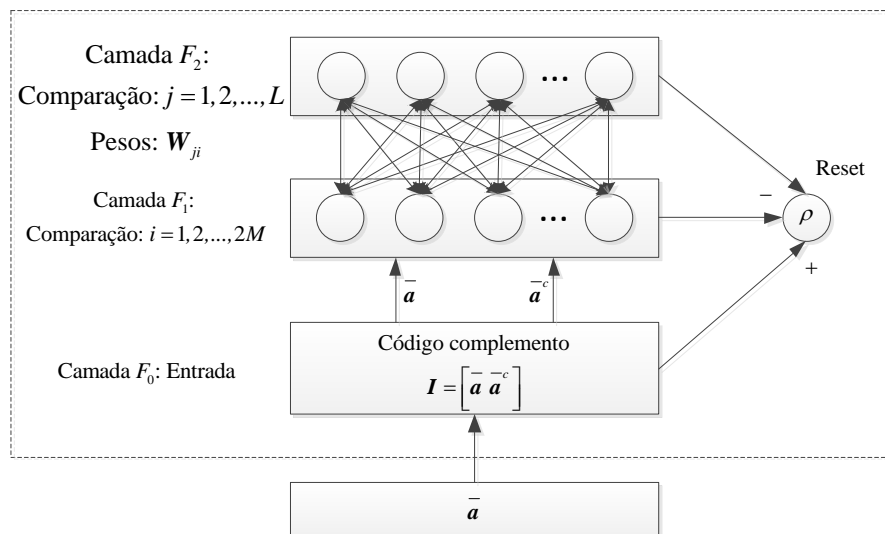
6.2 REDE NEURAL ART-FUZZY

Ressalta-se que a notação adotada dos vetores, nesta pesquisa, será por linha e não por coluna como habitualmente empregada na literatura matemática. Esta notação tem sido,

via de regra, usada nas publicações dos autores da proposição das redes neurais da família ART (CARPENTER; GROSSBERG, 1992).

O sistema ART-*Fuzzy* é composto pelas camadas F_0 , F_1 e F_2 , como é mostrado na Figura 14.

Figura 14 – Rede Neural ART-*Fuzzy*



Fonte: Lopes (2005).

sendo:

L : número de vetores de entrada.

Na rede neural ART-*Fuzzy* são empregados cálculos da teoria dos conjuntos *fuzzy* (ZADEH, 1965) em sistemas ART, o que a possibilita trabalhar com dados analógicos, assim como binários (CARPENTER; GROSSBERG, 1992; GEORGIPOULOS *et al.*, 1996; LOPES *et al.*, 2005). A diferença entre as redes neurais ART convencional e ART-*Fuzzy* está no operador utilizado para execução das operações de conjuntos. Na rede ART convencional é usado o operador de intersecção (\cap), enquanto que a rede ART-*Fuzzy* é usado o operador *fuzzy* AND (\wedge), definido por: $(\mathbf{p} \wedge \mathbf{q}) \equiv \min(p_i, q_i)$. O treinamento desta rede é não-supervisionado.

Os dados de entrada da rede são representados pelo vetor \mathbf{a} definido acordo com a Equação (17):

$$\mathbf{a} = [a_1 \ a_2 \ \dots \ a_M] \quad (17)$$

sendo:

M : dimensão do vetor \mathbf{a} ;

$a_i \in [0, 1], i = 1, 2, \dots, M$.

As entradas são normalizadas para evitar a proliferação de categorias de acordo com a Equação (18):

$$\bar{\mathbf{a}} = \frac{\mathbf{a}}{|\mathbf{a}|} \quad (18)$$

Em seguida, é efetuada a codificação do complemento através da Equação (19) (CARPENTER; GROSSBERG, 1992):

$$\bar{a}_i^c = 1 - \bar{a}_i \quad (19)$$

Desta forma, o vetor de entrada é denotado por (CARPENTER; GROSSBERG, 1992):

$$\mathbf{I} = \left[\begin{array}{cc} \bar{\mathbf{a}} & \bar{\mathbf{a}}^c \end{array} \right] = \left[\begin{array}{cccccc} \bar{a}_1 & \bar{a}_2 & \dots & \bar{a}_M & \bar{a}_1^c & \bar{a}_2^c & \dots & \bar{a}_M^c \end{array} \right] \quad (20)$$

Então, o vetor \mathbf{I} , do campo F_0 , será um vetor de dimensão igual a $2M$. A leitura do vetor \mathbf{I} é realizada na camada F_0 .

A camada F_1 recebe os sinais do padrão de entradas I , no sentido de baixo para cima, em F_0 , e os sinais dos vetores de pesos W_j (conexão entre a entrada a e o neurônio j na camada F_2) de cima para baixo de F_2 . Através dessa troca de sinal, tem-se a verificação da similaridade entre o padrão de entrada com o vetor de pesos selecionados como candidato ao aprendizado. O cálculo entre os vetores (I e W_j), enviados para a camada F_1 , são realizados por meio da função de escolha (T_j). A escolha da categoria vencedora (J) é determinada pelo maior valor de T_j . Se for encontrada mais de uma categoria ativa, a categoria escolhida será aquela que possuir o menor índice. Escolhida a categoria vencedora, verifica-se se ocorre a ressonância. A ressonância ocorre se for satisfeito o critério de vigilância. É nesta etapa que se verificam as similaridades entre os vetores (I e W_j). Caso o critério de vigilância não seja satisfeito, ativa-se o dispositivo o *reset*. No *reset*, a categoria vencedora (J), de F_2 , é excluída do processo de busca, ou seja, T_J assume valor igual a zero. Uma nova categoria deverá ser escolhida para o processo de ressonância. Este procedimento é executado até que a rede encontre uma categoria que satisfaça o critério de vigilância.

Terminado o processo de ressonância, é realizado o aprendizado. Nesta etapa, os padrões de entrada I são acomodados em categorias na camada F_2 , através da atualização dos pesos.

O treinamento da rede *ART-Fuzzy* depende, basicamente, da escolha dos parâmetros de acordo com (CARPENTER; GROSSBERG, 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 neural;
- Parâmetro de vigilância ($\rho \in [0,1]$) : controla a ressonância da rede.

Inicialmente, todos os pesos da rede possuem valores iguais a um, indicando que nenhuma categoria está ativa (CARPENTER; GROSSBERG, 1992):

$$W_{j,1}(0) = W_{j,2}(0) = \dots = W_{j,2M}(0) = 1 \quad (21)$$

A seguir, apresenta-se o algoritmo de treinamento de uma rede neural ART-Fuzzy para uma melhor compreensão desta arquitetura.

6.2.1 ALGORITMO ART-FUZZY

Passo 1: Leitura dos parâmetros da rede neural ART-Fuzzy (α , β e ρ);

Passo 2: Inicializar a matriz de pesos ($\mathbf{W} = \mathbf{U}_{L,M}$);

sendo:

$\mathbf{U}_{L,M}$: matriz de dimensão ($L \times M$), em que todos os seus elementos são iguais a 1.

Passo 3: Complemento do vetor de entrada \mathbf{I} ($\mathbf{I} = \begin{bmatrix} \bar{\mathbf{a}} & \bar{\mathbf{a}}^c \end{bmatrix}$);

Passo 4: Cálculo da função de escolha, T_j (CARPENTER; GROSSBERG, 1992):

$$T_j = \frac{|\mathbf{I} \wedge \mathbf{W}_j|}{\alpha + |\mathbf{W}_j|}, \text{ para } j = 1, 2, \dots, L.$$

sendo:

L : número de vetores de entrada empregados na fase de treinamento.

Passo 5: Escolha da categoria vencedora (CARPENTER *et al.*, 1991; HE *et al.*, 2002):

$$J = \arg\{\max T_j\}, \text{ para } j = 1, 2, \dots, L.$$

Passo 6: Verificar o critério de vigilância (CARPENTER; GROSSBERG, 1992):

$$\frac{|\mathbf{I} \wedge \mathbf{W}_J|}{|\mathbf{I}|} \geq \rho$$

Se sim, vá para o passo 8;

Senão, vá para o passo 7;

Passo 7: Ocorre o *reset* (CARPENTER; GROSSBERG, 1992):

Atribuir $T_j = 0$ e retornar para o passo 5;

Passo 8: Adaptação dos pesos:

$$\mathbf{W}_j^{(Novo)} = \beta \left(\mathbf{I} \wedge \mathbf{W}_j^{(Velho)} \right) + (1 - \beta) \mathbf{W}_j^{(Velho)}$$

Passo 9: Cálculo $\mathbf{Y} = [Y_1 \ Y_2 \ \dots \ Y_L]$ (VERZI *et al.*, 2003):

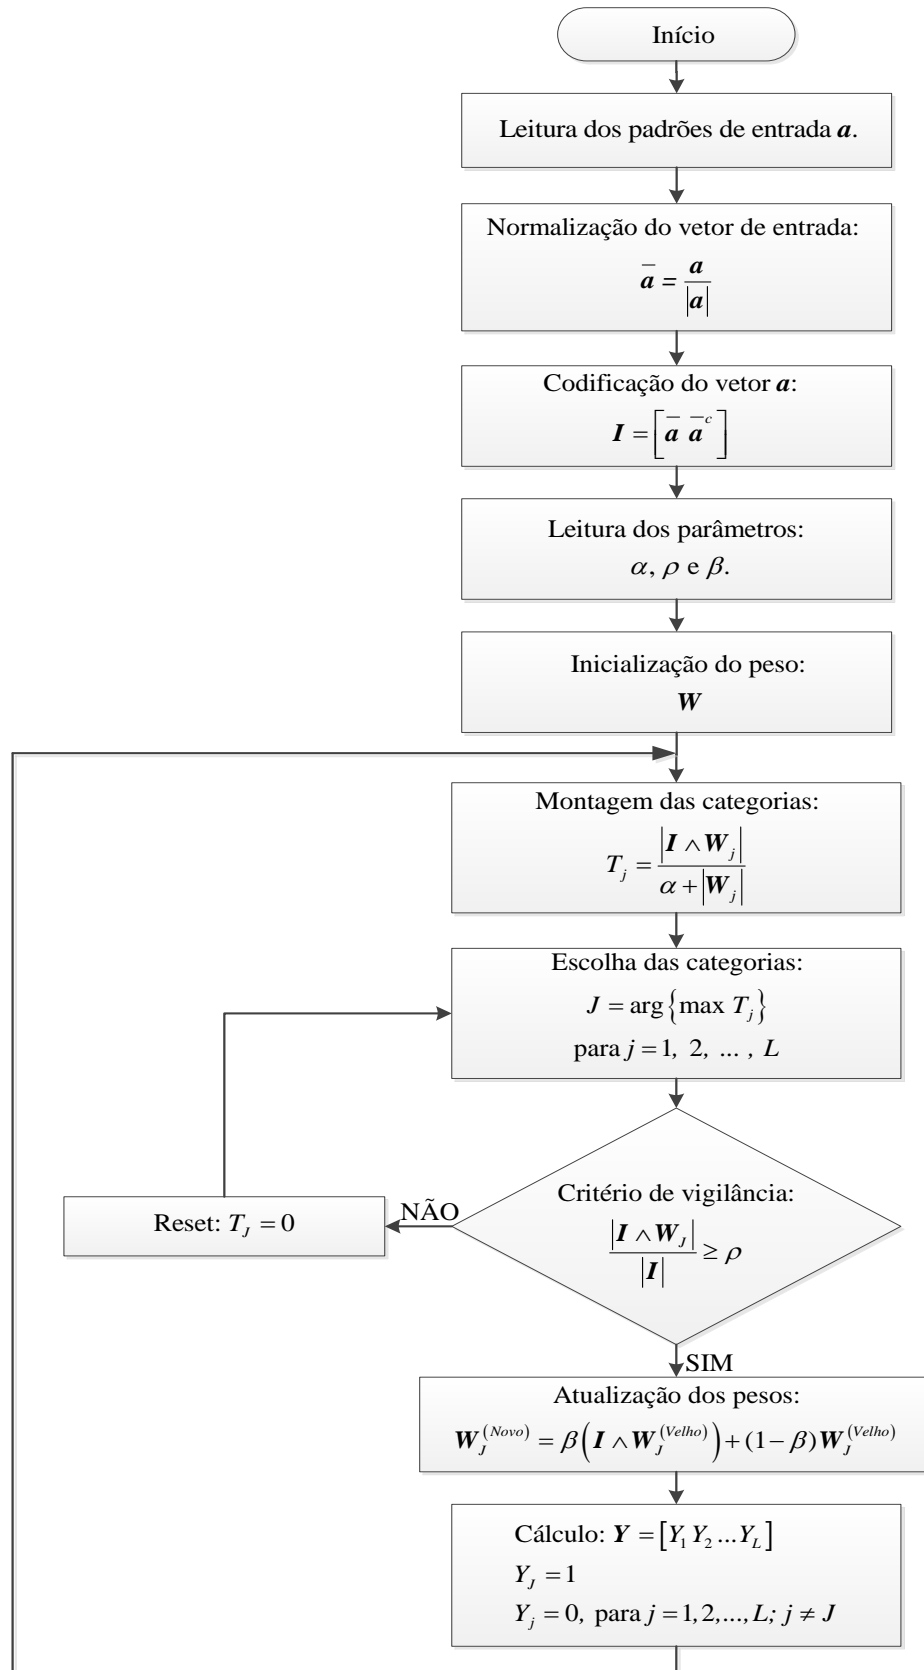
$$Y_j = 1$$

$$Y_j = 0, \text{ para } j = 1, 2, \dots, L; j \neq J.$$

Passo 10: Retornar para o passo 3.

O fluxograma apresentado na Figura 15 estabelece todos os procedimentos para o treinamento da rede neural ART-*Fuzzy*.

Figura 15 – Fluxograma da Rede ART-Fuzzy

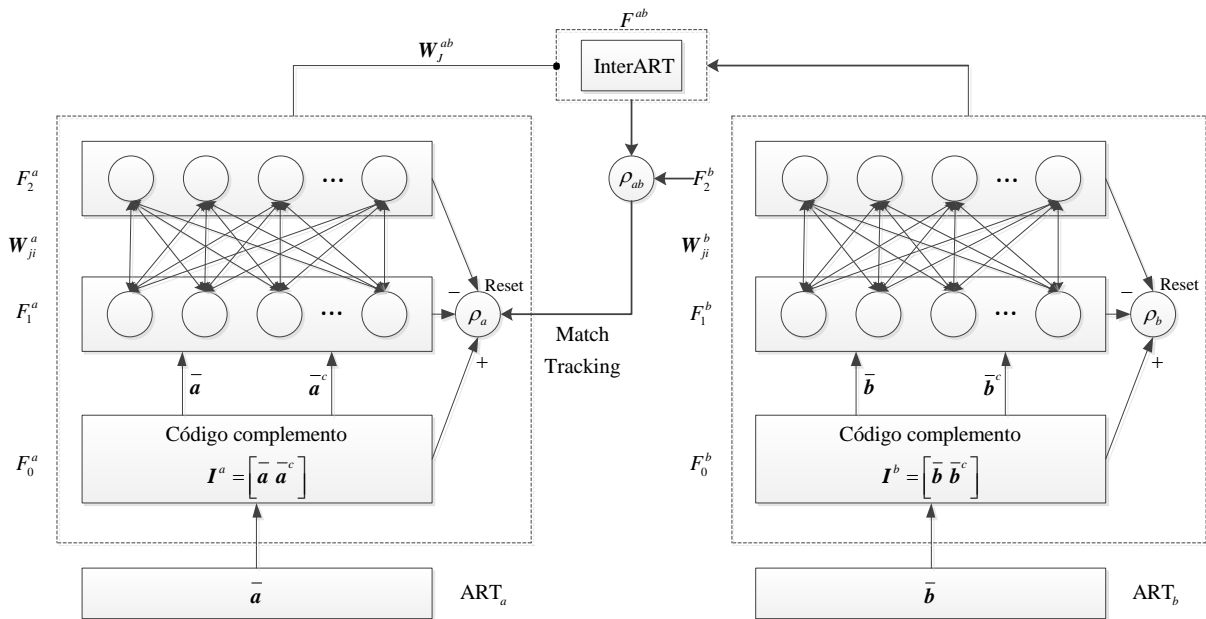


Fonte: Elaboração da própria autora.

6.3 REDE NEURAL ARTMAP-FUZZY

A rede neural ARTMAP-Fuzzy (CARPENTER *et al.*, 1992) é composta, basicamente, por 3 módulos: (1) ART_a-Fuzzy, (2) ART_b-Fuzzy e (3) Inter-ART, como mostra a Figura 16.

Figura 16 – Rede Neural ARTMAP-Fuzzy



Fonte: Lopes (2005).

Os módulos ART_a e ART_b são responsáveis pelo processamento dos dados de entrada e pelos dados de saída, respectivamente. Estes módulos funcionam de forma similar à rede ART-Fuzzy.

Os padrões de entrada e saída da rede ARTMAP-Fuzzy são representados por **a** e **b**, respectivamente, e definidos de acordo com as Equações (22) e (23):

$$\mathbf{a} = [a_1 \ a_2 \ \dots \ a_{M_a}] \tag{22}$$

$$\mathbf{b} = [b_1 \ b_2 \ \dots \ b_{Mb}] \quad (23)$$

sendo:

$$a_i \in [0,1], \ i = 1,2, \dots, Ma$$

$$b_j \in [0,1], \ j = 1,2, \dots, Mb$$

Ma :dimensão do vetor de entrada da rede neural ART_a-Fuzzy;

Mb :dimensão do vetor de entrada da rede neural ART_b-Fuzzy.

As entradas são normalizadas para evitar a proliferação de categorias de acordo com as Equações (24) e (25):

$$\bar{\mathbf{a}} = \frac{\mathbf{a}}{|\mathbf{a}|} \quad (24)$$

$$\bar{\mathbf{b}} = \frac{\mathbf{b}}{|\mathbf{b}|} \quad (25)$$

Em seguida, é efetuada a codificação do complemento através das Equações (26) e (27) (CARPENTER; GROSSBERG, 1992):

$$\bar{a}_i^c = 1 - \bar{a}_i \quad (26)$$

$$\bar{b}_i^c = 1 - \bar{b}_i \quad (27)$$

Desta forma, os vetores de entrada são denotados por:

$$\mathbf{I}^a = \left[\bar{\mathbf{a}} \ \bar{\mathbf{a}}^c \right] = \left[\bar{a}_1 \ \bar{a}_2 \ \dots \ \bar{a}_{Ma} \ \bar{a}_1^c \ \bar{a}_2^c \ \dots \ \bar{a}_{Ma}^c \right] \quad (28)$$

$$\mathbf{I}^b = \left[\bar{\mathbf{b}} \ \bar{\mathbf{b}}^c \right] = \left[\bar{b}_1 \ \bar{b}_2 \ \dots \ \bar{b}_{Mb} \ \bar{b}_1^c \ \bar{b}_2^c \ \dots \ \bar{b}_{Mb}^c \right] \quad (29)$$

O módulo inter-ART possui um mecanismo autorregulador interno, denominado *match-tracking*, o qual é usado para verificar se ocorre ou não o casamento da informação presente na entrada e na saída da rede. O *match-tracking* maximiza a generalização e minimiza o erro da rede. Então, uma vez identificadas as categorias vencedoras dos módulos $ART_a-Fuzzy$, e $ART_b-Fuzzy$ aciona-se o *match-tracking* para verificar se a categoria vencedora em $ART_a-Fuzzy$ corresponde à saída desejada (categoria vencedora) no módulo $ART_b-Fuzzy$ e, se ocorre a ressonância. A ressonância ocorre se for satisfeito o critério de vigilância. Caso o critério de vigilância não seja satisfeito ocorre o *reset*. No *reset*, a categoria vencedora (J) de $ART_a-Fuzzy$ é excluída do processo de busca, isto é, (T_j^a) assume valor igual a zero. Além disso, é feito um incremento (ε) temporário no parâmetro (ρ_a) para corrigir o erro no módulo $ART_b-Fuzzy$ (CARPENTER *et al.*, 1992; LIM; HARRISON, 1997; LOPES *et al.*, 2005; TONELLI-NETO, 2012). Em seguida é escolhida uma nova categoria em $ART_a-Fuzzy$ para o procedimento de ressonância. Este processo de busca é realizado até que a rede encontre uma categoria que satisfaça o critério de vigilância do módulo inter-ART.

O treinamento das redes neurais $ARTMAP-Fuzzy$ é realizado de modo supervisionado e auto-organizável.

Os parâmetros utilizados no processo de treinamento da rede neural $ARTMAP-Fuzzy$ são (CARPENTER *et al.*, 1991; GROSSBERG, 1976):

- Parâmetro de escolha : $\alpha > 0$;
- Taxa de treinamento : $\beta \in [0,1]$;
- Parâmetro de vigilância do módulo $ART_a-Fuzzy$: $\rho_a \in [0,1]$;
- Parâmetro de vigilância do módulo $ART_b-Fuzzy$: $\rho_b \in [0,1]$;
- Parâmetro de vigilância do módulo Inter-ART : $\rho_{ab} \in [0,1]$;
- Parâmetro de vigilância inicial (*baseline*) : $\underline{\rho}_a \in [0,1]$;
- Parâmetro de incremento : ε (número muito pequeno e positivo).

Inicialmente, todos os pesos da rede neural ART-*Fuzzy* [\mathbf{W}^a , \mathbf{W}^b e \mathbf{W}^{ab}] (inicialização das matrizes de pesos) possuem o valor igual a 1, indicando que nenhuma categoria está ativa (CARPENTER; GROSSBERG, 1992):

$$\mathbf{W}^a = \mathbf{U}_{L, Ma} \quad (30)$$

$$\mathbf{W}^b = \mathbf{U}_{L, Mb} \quad (31)$$

$$\mathbf{W}^{ab} = \mathbf{U}_{L, L} \quad (32)$$

A seguir, apresentam-se os passos do algoritmo de treinamento e o fluxograma de uma rede neural ARTMAP-*Fuzzy*.

6.3.1 ALGORITMO ARTMAP-FUZZY

Passo 1: Leitura dos parâmetros da rede neural ARTMAP-*Fuzzy* ($\alpha, \beta, \underline{\rho}_a, \rho_b, \rho_{ab}$ e ε);

Passo 2: Inicializar as matrizes de pesos [\mathbf{W}^a , \mathbf{W}^b e \mathbf{W}^{ab}];

Passo 3: Complemento dos vetores de entrada e saída \mathbf{I}^a e \mathbf{I}^b , respectivamente:

$$\mathbf{I}^a = \begin{bmatrix} \bar{a} & \bar{a}^c \end{bmatrix} \text{ e } \mathbf{I}^b = \begin{bmatrix} \bar{b} & \bar{b}^c \end{bmatrix};$$

Passo 4: Atribui $\rho_a = \underline{\rho}_a$;

Passo 5: Cálculo da função de escolha, T_k^b :

$$T_k^b = \frac{|\mathbf{I}^b \wedge \mathbf{W}_k^b|}{\alpha + |\mathbf{W}_k^b|}, \text{ para } k = 1, 2, \dots, L$$

Passo 6: Escolha da categoria vencedora do módulo ART_b:

$$K = \arg \left\{ \max T_k^b \right\} \text{ para } k = 1, 2, \dots, L$$

Passo 7: Verificar o critério de vigilância do módulo ART_b:

$$\frac{|\mathbf{I}^b \wedge \mathbf{W}_K^b|}{|\mathbf{I}^b|} \geq \rho_b$$

Se sim, vá para o passo 9;

Senão, vá para o passo 8;

Passo 8: Ocorre o *reset*:

Atribuir $T_K^b = 0$ e retornar para o passo 6;

Passo 9: Adaptação dos pesos do módulo ART_b:

$$\mathbf{W}_K^{b(Novo)} = \beta (\mathbf{I}^b \wedge \mathbf{W}_K^{b(Velho)}) + (1 - \beta) \mathbf{W}_K^{b(Velho)}$$

Passo 10: Cálculo de $\mathbf{Y}^b = [Y_1^b \ Y_2^b \ \dots \ Y_L^b]$:

$$Y_K^b = 1$$

$$Y_k^b = 0, \text{ para } k = 1, 2, \dots, L; k \neq K$$

Passo 11: Cálculo da função de escolha, T_j^a :

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

Observação: O valor de α é o mesmo para os dois módulos ART (ART_a e ART_b).

Passo 12: Escolha da categoria vencedora do módulo ART_a:

$$J = \arg \{ \max T_j^a \} \text{ para } j = 1, 2, \dots, L$$

Passo 13: Verificar o critério de vigilância do módulo ART_a:

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

Se sim, vá para o passo 15;

Senão, vá para o passo 14;

Passo 14: Ocorre o *reset*:

Atribuir $T_j^a = 0$ e retornar para o passo 12;

Passo 15: Verificar o critério de vigilância do módulo inter-ART (CAPENTER *et al.* 1992):

$$\frac{|\mathbf{Y}^b \wedge \mathbf{W}_j^{ab}|}{\mathbf{Y}^b} \geq \rho_{ab}$$

Se sim, vá para o passo 17;

Senão, vá para o passo 16;

Passo 16: Incrementar o parâmetro de vigilância ρ_a :

$$\rho_a = \frac{|\mathbf{I}^a \wedge \mathbf{W}_j^a|}{|\mathbf{I}^a|} + \varepsilon$$

Atribuir $T_j^a = 0$ e retornar para o passo 14;

Passo 17: Adaptação dos pesos do módulo ART_a:

$$\mathbf{W}_j^{a(Novo)} = \beta (\mathbf{I}^a \wedge \mathbf{W}_j^{a(Velho)}) + (1 - \beta) \mathbf{W}_j^{a(Velho)}$$

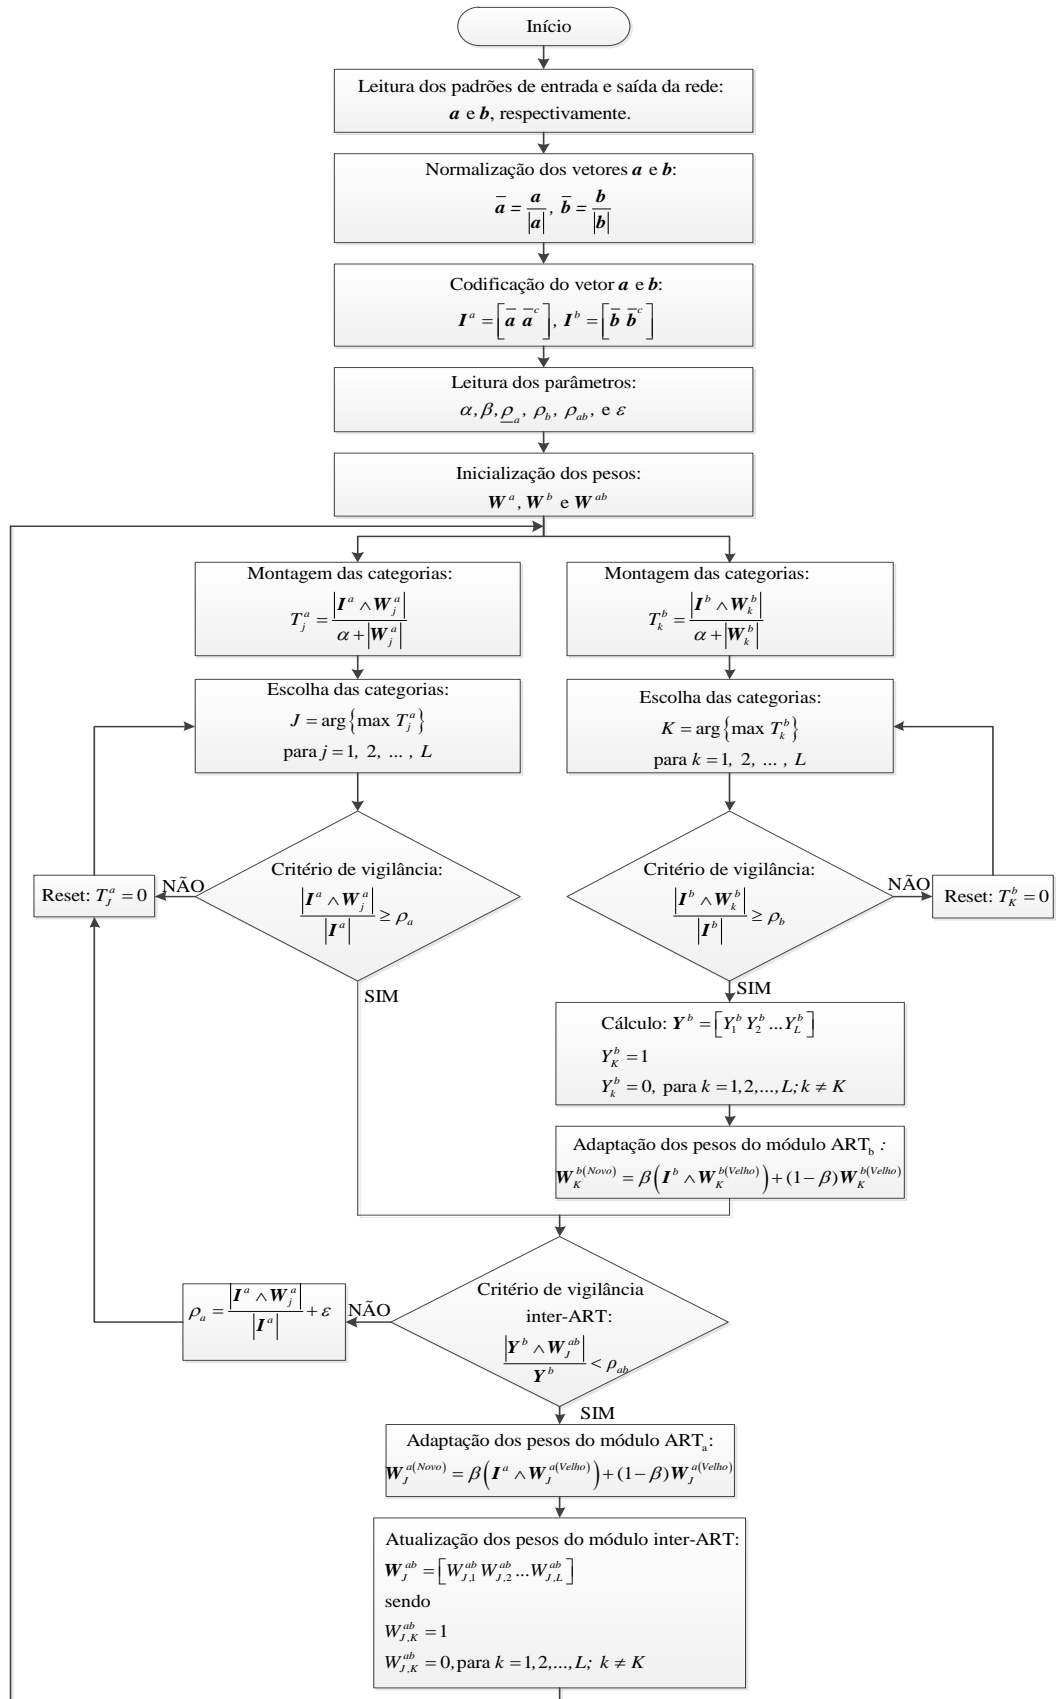
Passo 18: Adaptação dos pesos do módulo inter-ART:

$$W_{j,K}^{ab} = 1$$

$$W_{j,k}^{ab} = 0 \text{ para } k = 1, 2, \dots, L; k \neq K$$

Passo 19: Retornar para o passo 4;

Figura 17 – Fluxograma Rede Neural ARTMAP-Fuzzy



Fonte: Elaboração da própria autora.

6.4 REDE NEURAL ART EUCLIDIANA MODIFICADA

A rede neural ART Euclidiana Modificada (ART-EM) apresenta algumas diferenças em relação à rede neural ART-*Fuzzy*. Tais diferenças são: (1) não há necessidade da normalização dos vetores de entrada e de saída. Isto permite uma maior flexibilidade na representação destes vetores; (2) não duplicação [Equações (20), (28) e (29)] dos vetores padrões de entrada e de saída, ou seja, há uma natural redução do volume de informações a ser processado.

Esta rede possui um contador que indica quantas categorias estão ativas ($Ncat$) e, outro contador ($Ncont$) para criação de uma nova categoria ativa. O contador ($Ncont$) verifica se foi testada a similaridade entre o padrão de entrada atual com todas as categorias ativas existentes e, se não houver similaridade em nenhum dos casos uma nova categoria é ativada. Este contador ($Ncont$) é inicializado toda vez que um padrão é apresentado à rede (MORENO, 2010). Além disso, esta rede é utilizada, em seus cálculos, a distância euclidiana na função de escolha (T_j), ao invés do operador AND *fuzzy*, permitindo, assim, o aprendizado do sistema neural em resposta a padrões de entrada binários ou analógicos, pertencentes ao \mathbb{R}^+ ($[0, +\infty[$). A escolha da categoria vencedora (J) é determinada pelo menor valor de T_j .

A rede ART-EM é inicializada com apenas um neurônio ativo, *i.e.*, o primeiro padrão apresentado à rede. Em seguida, é apresentado o segundo padrão à rede neural. Calcula-se a função de escolha (T_j) apenas para uma categoria ativa. Caso o segundo padrão seja similar ao primeiro, ocorre a ressonância. Caso contrário, uma nova categoria é ativada com os dados deste segundo padrão e, quando o terceiro padrão é apresentado à rede, calculam-se duas funções de ativação. Então, quando for apresentado à rede neural o p -ésimo padrão, verifica-se a similaridade para p categorias ativas, com $p \leq L$ (MORENO, 2010).

O vetor de entrada (\mathbf{a}) da rede é representado e definido de acordo com a Equação (33):

$$\mathbf{a} = [a_1 \ a_2 \ \dots \ a_M] \quad (33)$$

sendo:

$$a_i \in [0,1], i=1,2, \dots, M$$

M : dimensão do vetor \mathbf{a} .

Uma vantagem desta rede refere-se a não necessidade da normalização e codificação complementar dos padrões de entrada, que duplica a dimensão do vetor de entrada, o que reduz o custo computacional (KENAYA, 2008), desta forma, é possível estabelecer a diferença entre os padrões de entrada e os vetores que não são múltiplos por constante um do outro, obtendo assim, uma classificação mais precisa dos padrões (MORENO, 2010).

Os parâmetros utilizados nesta rede são:

- Taxa de treinamento : $(\beta \in [0,1])$;
- Parâmetro de vigilância : $(\rho \in [0,1])$.

Os pesos da rede ART-EM são iniciados com apenas um neurônio ativo, *i.e.*, o primeiro padrão apresentado à rede de acordo com a Equação (34):

$$\mathbf{W}_1^a = \mathbf{a}_1 \tag{34}$$

A seguir são apresentados o algoritmo e o fluxograma da rede ART-EM.

6.4.1 ALGORITMO ART EUCLIDIANA MODIFICADA

Passo 1: Leitura dos parâmetros da rede neural ART-EM (β, ρ);

Passo 2: Inicializar as matrizes pesos ($\mathbf{W}_1 = \mathbf{a}_1$);

Passo 3: Inicializar os contadores de categorias ativas ($N_{cat} = 1$);

Passo 4: Inicializar os contadores para criação de uma nova categoria ativa ($Cont = 1$);

Passo 5: Cálculo da função de escolha, T_j (VUSKOVIC & DU, 2002):

$$T_j = \sqrt{\sum_{i=1}^M (a_i - W_{j,i})^2}, \text{ para } j = 1, 2, \dots, Ncat$$

Passo 6: Escolha da categoria vencedora:

$$J = \arg \{ \min T_j \} \text{ para } j = 1, 2, \dots, Ncat$$

Passo 7: Verificar o critério de vigilância:

$$\frac{T_J}{\max \left\{ \sum_{i=1}^M a_i^2, \sum_{i=1}^M (W_{J,i})^2 \right\}} < \rho$$

Se sim, vá para o passo 11;

Se não, vá para o passo 8;

Passo 8: Verifica-se o seguinte critério:

$$Ncat < Ncont$$

Se sim, vá para o passo 9;

Se não, vá para o passo 10;

Passo 9: Criação de uma nova categoria ativa:

$$Ncat^{(Novo)} = Ncat^{(Velho)} + 1$$

$$J = Ncat$$

$$\mathbf{W}_J = \mathbf{a}$$

Vá para o passo 13;

Passo 10: Ocorre o *reset*:

$$Ncont^{(Novo)} = Ncont^{(Velho)} + 1$$

Atribuir $T_j = 10^5$ (um número grande) e retornar para o passo 6;

Passo 11: Adaptação dos pesos:

$$\mathbf{W}_j^{(Novo)} = \beta(\mathbf{a}) + (1 - \beta)\mathbf{W}_j^{(Velho)}$$

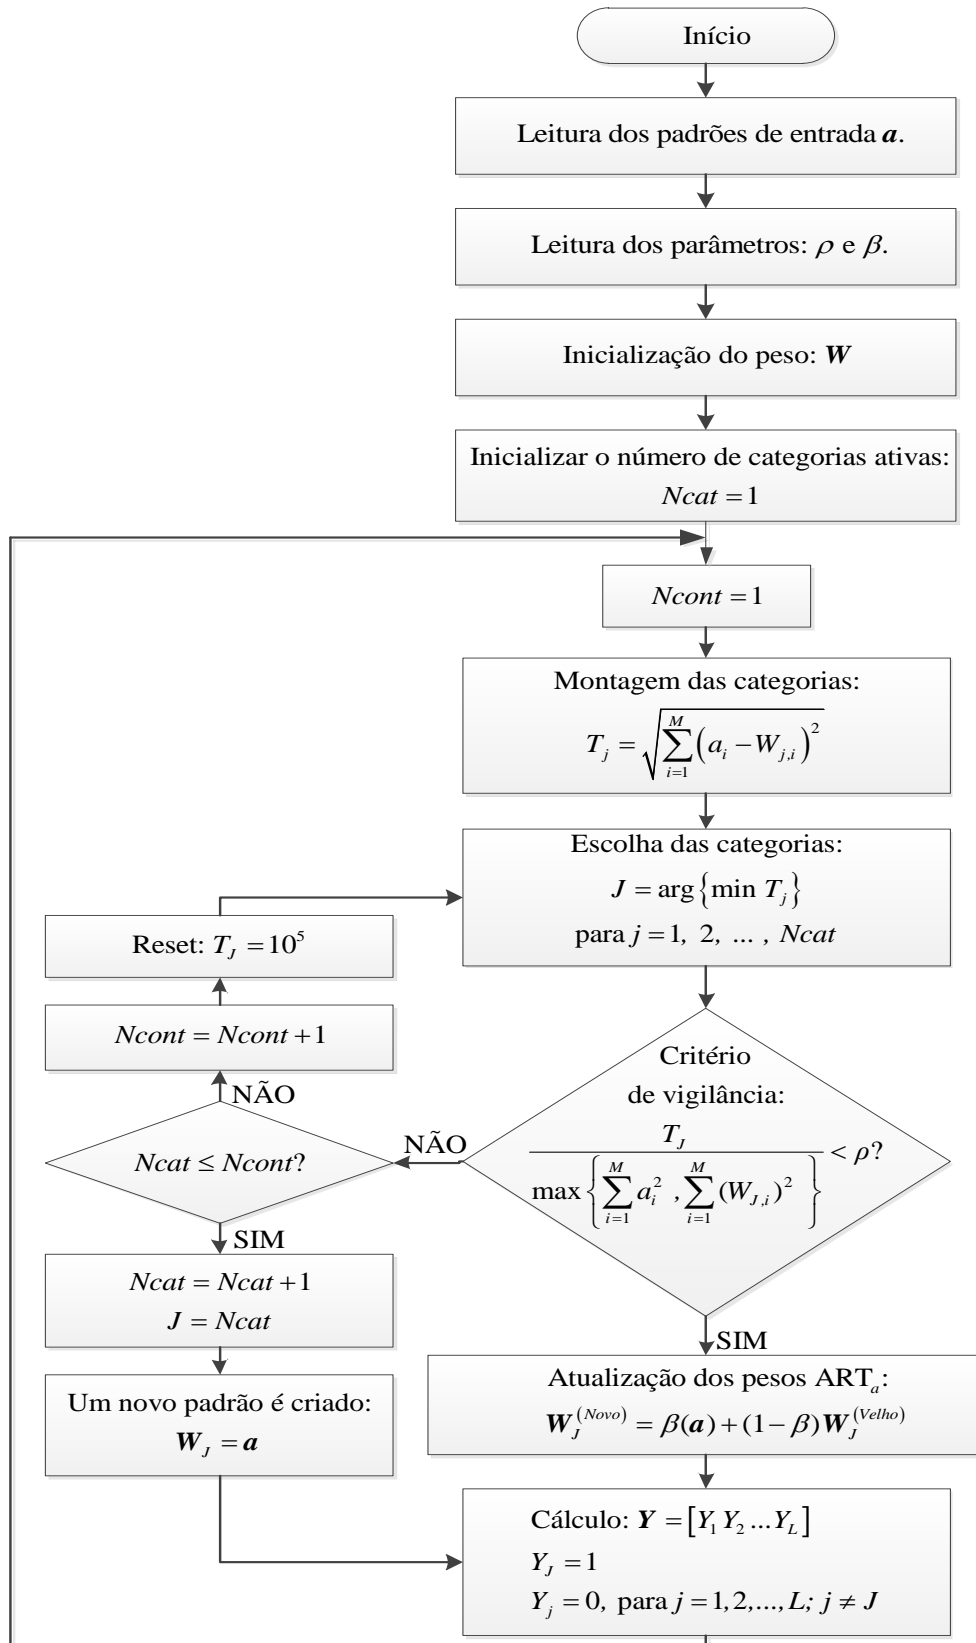
Passo 12: Cálculo $\mathbf{Y} = [Y_1 \ Y_2 \ \dots \ Y_L]$:

$$Y_j = 1$$

$$Y_j = 0, \text{ para } j = 1, 2, \dots, L; j \neq J$$

Passo 13: Retornar para o passo 5;

Figura 18 – Fluxograma Rede Neural ART Euclidiana Modificada



Fonte: Elaboração da própria autora.

6.5 REDE NEURAL ARTMAP EUCLIDIANA MODIFICADA

A rede neural ARTMAP-EM é uma concepção que visa proporcionar soluções com qualidade, e precisão (BARROS *et al.*, 2012). Como se usa uma geometria quadrática, a formação de classes é mais precisa, se comparada à formulação convencional da rede neural ARTMAP-*Fuzzy* (geometria retangular) (MARCHIORI *et al.*, 2011). Esta rede é um sistema de aprendizado auto-organizável e supervisionado, composto por um par de módulos ART euclidiano, ART_a e ART_b, interconectados por um módulo de memória associativa inter-ART.

No módulo inter-ART é executado o “casamento” entre a entrada e a saída, *e.g.*, é realizado o mapeamento que constitui a realização de funções matemáticas, como acontece na rede ARTMAP-*Fuzzy* (CAPENTER *et al.*, 1992). Caso não haja o casamento, deverá ocorrer o *reset*. No dispositivo *reset*, uma nova categoria do módulo ART_a é escolhida para ser introduzida no processo de ressonância. Além disso, um decremento (ϵ) temporário no parâmetro ρ_a é feito. Nesta rede, o critério de vigilância do módulo inter-ART somente é ativado quando nenhuma categoria for criada, tanto em ART_a como em ART_b.

Os vetores de entrada e saída da rede são representados por \mathbf{a} e \mathbf{b} , respectivamente, e definidos de acordo com as Equações (35) e (36):

$$\mathbf{a} = [a_1 \ a_2 \ \dots \ a_{Ma}] \quad (35)$$

$$\mathbf{b} = [b_1 \ b_2 \ \dots \ b_{Mb}] \quad (36)$$

sendo:

$$a_i \in [0,1], \ i = 1, 2, \dots, Ma$$

$$b_j \in [0,1], \ j = 1, 2, \dots, Mb$$

Ma : dimensão do vetor \mathbf{a} (entrada);

Mb : dimensão do vetor \mathbf{b} (saída);

Os parâmetros utilizados no processo de treinamento da rede neural ARTMAP-EM são (MORENO, 2010):

- Taxa de treinamento : $\beta \in [0,1]$;
- Parâmetro de vigilância do módulo ART_a : $\rho_a \in [0,1]$;
- Parâmetro de vigilância do módulo ART_b : $\rho_b \in [0,1]$;
- Parâmetro de vigilância do módulo Inter-ART : $\rho_{ab} \in [0,1]$;
- Parâmetro de decremento : ε (número muito pequeno e positivo).

Os pesos da rede ARTMAP-EM são iniciados com apenas um neurônio ativo, *i.e.*, primeiro padrão apresentado à rede de acordo com as Equações (37) e (38). Os pesos do módulo inter-ART possuem o valor igual a 1, como é mostrado na Equação (39).

$$\mathbf{W}_1^a = \mathbf{a}_1 \quad (37)$$

$$\mathbf{W}_1^b = \mathbf{b}_1 \quad (38)$$

$$W_{j,1}^{ab}(0) = W_{j,2}^{ab}(0) \dots W_{j,L}^{ab}(0) = 1 \quad (39)$$

sendo:

L : número de padrões de entrada e de saída.

A seguir, apresentam-se os passos do algoritmo de treinamento e o fluxograma de uma rede neural ARTMAP-EM.

6.5.1 ALGORITMO ARTMAP EUCLIDIANA MODIFICADA

Passo 1: Leitura dos parâmetros da Rede ARTMAP-EM (β , $\underline{\rho}_a$, ρ_b , ρ_{ab} e ε);

Passo 2: Inicializar as matrizes pesos ($\mathbf{W}_1^a = \mathbf{a}_1$, $\mathbf{W}_1^b = \mathbf{b}_1$ e $\mathbf{W}^{ab} = \mathbf{U}_{L,L}$);

Passo 3: Inicializar os contadores de categorias ativas ($NcatA = 1$, $NcatB = 1$);

Passo 4: Inicializar os contadores para criação de uma nova categoria ativa ($ContA = 1$, $ContB = 1$, $CriA = 0$ e $CriB = 0$);

Passo 5: Atribuir $\rho_a = \underline{\rho}_a$;

Passo 6: Cálculo da função de escolha, T_k^b :

$$T_k^b = \sqrt{\sum_{v=1}^{Mb} (b_v - W_{k,v}^b)^2}$$

Passo 7: Escolha da categoria vencedora do módulo ART_b:

$$K = \arg \left\{ \min T_k^b \right\} \text{ para } k = 1, 2, \dots, NcatB$$

Passo 8: Verificar o critério de vigilância do módulo ART_b:

$$\frac{T_K^b}{\max \left\{ \sum_{v=1}^{Mb} b_v^2, \sum_{v=1}^{Mb} (W_{K,v}^b)^2 \right\}} < \rho_b$$

Se sim, vá para o passo 12;

Se não, vá para o passo 9;

Passo 9: Verificar o seguinte critério:

$$NcatB < NcontB$$

Se sim, vá para o passo 10;

Se não, vá para o passo 11;

Passo 10: Um novo padrão é criado:

$$NcatB^{(Novo)} = NcatB^{(Velho)} + 1$$

$$K = NcatB$$

$$\mathbf{W}_K = \mathbf{b}$$

$$CriB = 1$$

Vá para o passo 14;

Passo 11: Ocorre o *reset*:

$$NcontB^{(Novo)} = NcontB^{(Velho)} + 1$$

Atribui $T_K^b = 10^5$ e retorna para o passo 7;

Passo 12: Cálculo $\mathbf{Y}^b = [Y_1^b \ Y_2^b \ \dots \ Y_L^b]$:

$$Y_{kw}^b = 1$$

$$Y_k^b = 0, \text{ para } k = 1, 2, \dots, L; k \neq kw$$

Passo 13: Adaptação dos pesos do módulo ART_b:

$$\mathbf{W}_K^{b(Novo)} = \beta(\mathbf{b}) + (1 - \beta)\mathbf{W}_K^{b(Velho)}$$

Passo 14: Cálculo a função de escolha, T_j^a :

$$T_j^a = \sqrt{\sum_{i=1}^{Ma} (a_i - W_{j,i}^a)^2}$$

Passo 15: Escolha da categoria vencedora do módulo ART_a:

$$J = \arg \left\{ \min T_j^a \right\} \text{ para } j = 1, 2, \dots, NcatA$$

Passo 16: Verificar o critério de vigilância do módulo ART_a:

$$\frac{T_J^a}{\max \left\{ \sum_{i=1}^{Ma} a_i^2, \sum_{i=1}^{Ma} (W_{J,i}^a)^2 \right\}} < \rho_a$$

Se sim, vá para o passo 20;

Se não, vá para o passo 17;

Passo 17: Verifica-se o seguinte critério:

$$NcatA < NcontA$$

Se sim, vá para o passo 18;

Se não, vá para o passo 19;

Passo 18: Verifica-se o seguinte critério:

$$NcatA^{(Novo)} = NcatA^{(Velho)} + 1$$

$$J = NcatA$$

$$W_J^a = \mathbf{a}$$

$$CriA = 1$$

Vá para o passo 20;

Passo 19: Ocorre o *reset*:

$$NcontA^{(Novo)} = NcontA^{(Velho)} + 1$$

Atribui $T_J^a = 10^5$ e retornar para o passo 16;

Passo 20: Verificar se foram criados padrões nos módulos ART_a e ART_b:

$$CriA = 0 \text{ e } CriB = 0$$

Se sim, vá para o passo 21;

Se não, vá para o passo 24;

Passo 21: Verificar o critério de vigilância do módulo inter-ART:

$$|\mathbf{Y}^b \wedge \mathbf{W}_J^{ab}| \geq \rho_{ab}$$

Se sim, vá para o passo 23;

Se não, vá para o passo 22;

Passo 22: Incrementar o parâmetro de vigilância ρ_a :

$$\rho_a = \frac{T_J^a}{\max \left\{ \sum_{i=1}^{Ma} a_i^2, \sum_{i=1}^{Ma} (W_{J,i}^a)^2 \right\}} - \varepsilon$$

$$ContA^{(Novo)} = ContA^{(Velho)} + 1$$

Atribui $T_J^a = 10^5$ e retorna para o passo 14;

Passo 23: Adaptação dos pesos do módulo ART_a:

$$\mathbf{W}_J^{a(Novo)} = \beta(\mathbf{a}) + (1 - \beta)\mathbf{W}_J^{a(Velho)}$$

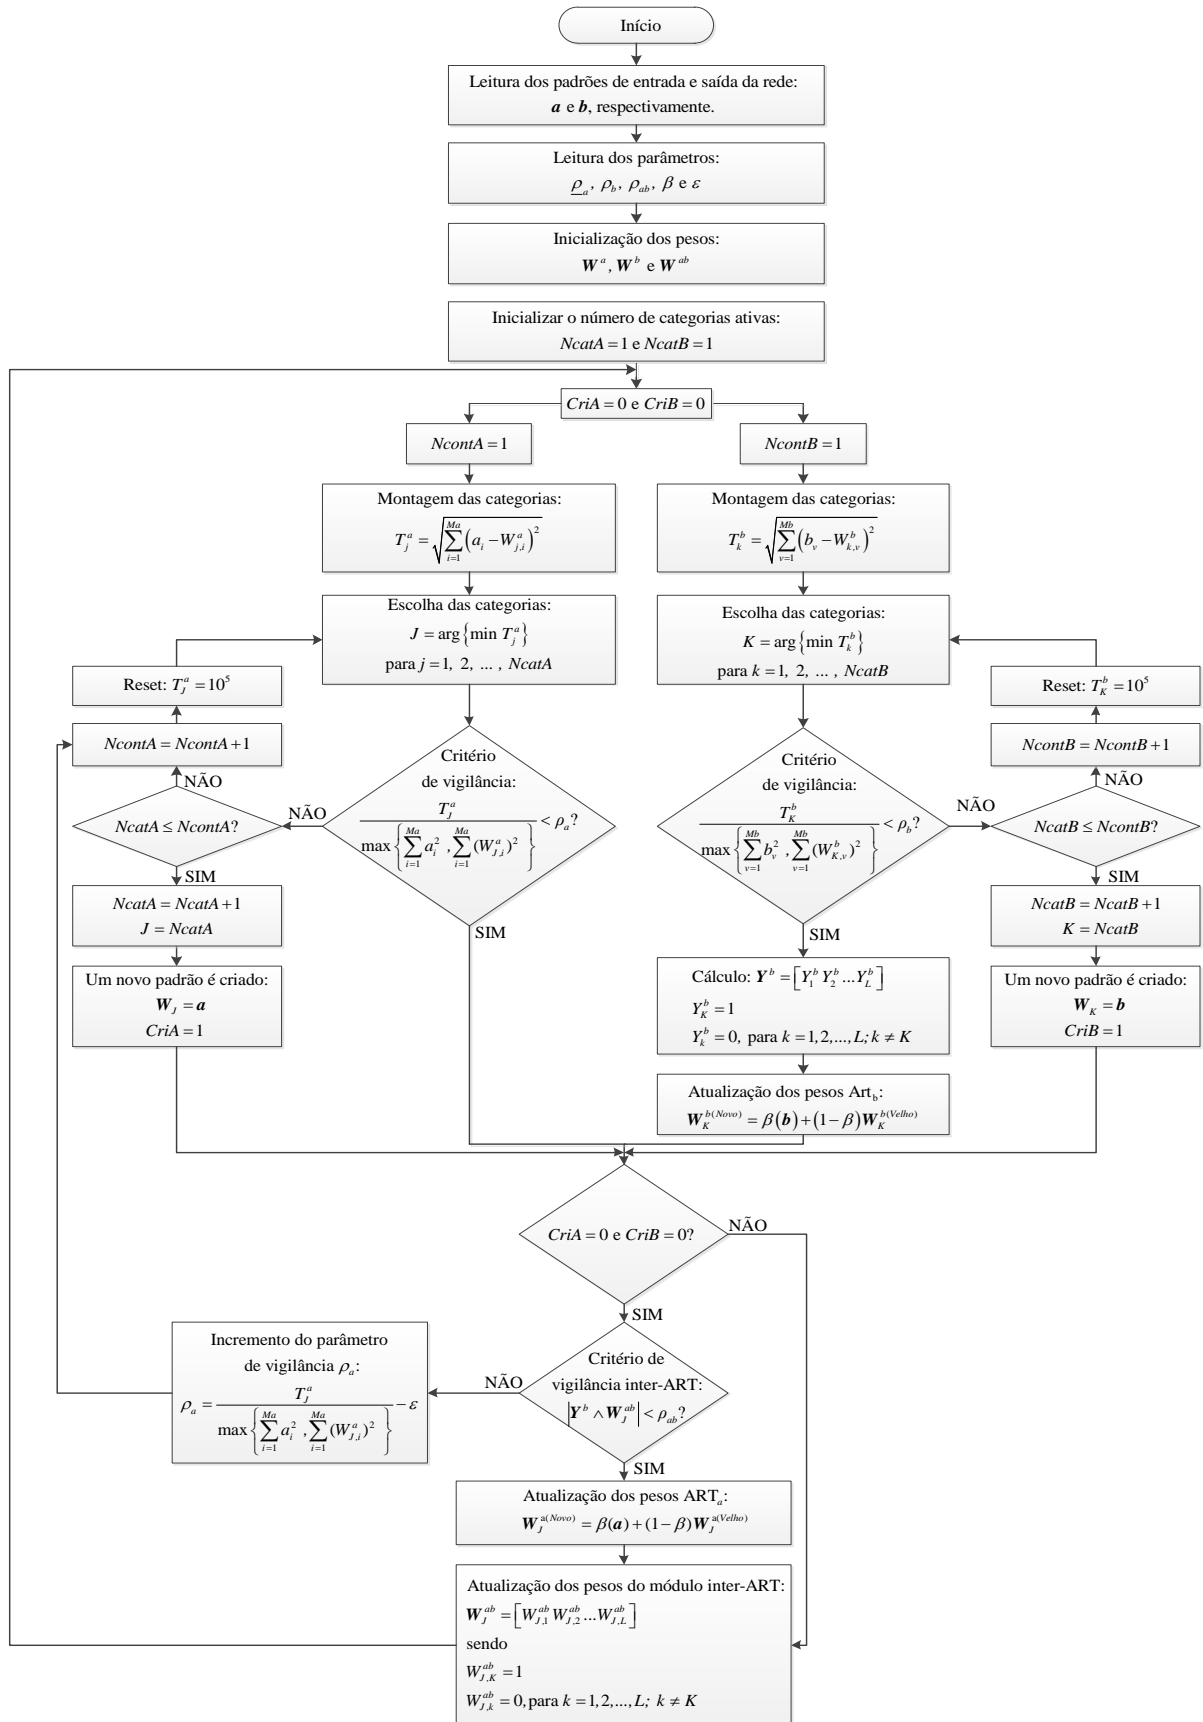
Passo 24: Adaptação dos pesos do módulo Inter-ART:

$$W_{J,K}^{ab} = 1$$

$$W_{J,k}^{ab} = 0 \text{ para } k = 1, 2, \dots, L; k \neq K$$

Passo 25: Retornar para o passo 5.

Figura 19 – Fluxograma Rede Neural ARTMAP Euclidiana Modificada



Fonte: Elaboração da própria autora.

6.6 REDE NEURAL ARTMAP EUCLIDIANA MODIFICADA COM TREINAMENTO CONTINUADO

A seguir apresenta-se a idealização do treinamento continuado a ser incorporado na rede neural ARTMAP-EM. Trata-se do desenvolvimento de um sistema que contempla o treinamento de forma contínua, *e.g.*, havendo a disponibilidade de novos padrões, *e.g.*, simulações ou oscilografias disponibilizadas pelo sistema de aquisição de dados, o treinamento não necessita ser reinicializado, diferente de como é abordado em outras redes neurais conhecidas na literatura (BARROS *et al.*, 2012). Na rede ARTMAP-EM, bem como em outras redes da família ART, a incorporação do módulo de treinamento continuado é possível por causa das características de estabilidade e plasticidade que a mesma possui, constituindo um sistema neural aperfeiçoado quando comparado à rede ARTMAP com treinamento incremental (MORENO, 2010; MARCHIORI *et al.*, 2011).

O treinamento continuado permite a inclusão de novos padrões à memória da rede de forma permanente. Deste modo, o treinamento e a análise (diagnóstico) se tornam procedimentos mais rápidos e eficientes. Para que este mecanismo funcione de forma correta, foram adicionados alguns elementos no algoritmo de treinamento da rede neural ARTMAP-EM (BARROS *et al.*, 2013).

A primeira modificação a ser feita é a inclusão de pesos temporários e definitivos no módulo ART_a . Isto se faz necessário para evitar a presença de categorias semelhantes na memória da rede. Sendo assim, no processo de escolha das categorias, existem categorias temporárias e categorias definitivas (MORENO, 2010). Logo, definem-se duas funções de escolha, uma para as categorias temporárias (T_v^t), e outra para as categorias definitivas (T_i^d).

A segunda modificação foi a inclusão de dois novos parâmetros: $NMIN$ e η . O parâmetro $NMIN$ ($NMIN \in \mathbb{N}$, com $NMIN > 1$) refere-se ao número de padrões necessários para que um peso temporário se torne definitivo (MORENO, 2010). Durante o treinamento da rede os padrões temporários semelhantes são contados e armazenados no vetor $ContT$, e quando atingem o valor $NMIN$ tornam-se definitivos (MORENO, 2010). O parâmetro η ($\eta > 0$) é responsável em verificar se há ou não a necessidade de atualização dos pesos da categoria definitiva vencedora, *i.e.*, informações redundantes apresentadas à rede neural são descartadas (MORENO, 2010). Desta forma, evita-se que classes de padrões semelhantes

sejam alocadas em categorias distintas, evitando, assim, o desnecessário sobrecarregamento da memória da rede.

Os vetores de entrada e saída da rede são representados por \mathbf{a} e \mathbf{b} , respectivamente, e definidos de acordo com as Equações (40) e (41):

$$\mathbf{a} = [a_1 \ a_2 \ \dots \ a_{Ma}] \quad (40)$$

$$\mathbf{b} = [b_1 \ b_2 \ \dots \ b_{Mb}] \quad (41)$$

sendo:

$$a_i \in [0,1], \ i = 1, 2, \dots, Ma$$

$$b_j \in [0,1], \ j = 1, 2, \dots, Mb$$

Na inicialização da rede a categoria temporária é iniciada com apenas um neurônio ativo, *i.e.*, primeiro padrão apresentado à rede (MORENO, 2010), Equação (42), e os pesos do módulo inter-ART temporário, são fixados em 1, Equação (43). Já os pesos definitivos dos módulos ART_a, ART_b e inter-ART definitivo são iguais aos pesos da rede ARTMAP-EM treinada de modo *off-line*, respectivamente, como mostra as Equações (44), (45) e (46):

$$\mathbf{W}_1^{at} = \mathbf{a}_1 \quad (42)$$

$$W_{j,1}^{abt}(0) = W_{j,2}^{abt}(0) \ \dots \ W_{j,L}^{abt}(0) = 1 \quad (43)$$

$$\mathbf{W}^{ad} = \mathbf{W}^a \quad (44)$$

$$\mathbf{W}^{bd} = \mathbf{W}^b \quad (45)$$

$$\mathbf{W}^{abd} = \mathbf{W}^{ab} \quad (46)$$

Além da rede ARTMAP-EMTC, onde o treinamento é realizado de modo *on-line/off-line*, desenvolveu-se uma rede neural ARTMAP-EMTC direta, ou seja, o treinamento desta rede é realizado somente de modo *on-line*. A diferença entre essas duas redes está apenas na inicialização dos pesos. Nas equações (47) a (51) encontra-se a inicialização dos pesos da rede ARTMAP-EMTC de modo *on-line*:

$$\mathbf{W}_1^{at} = \mathbf{a}_2 \quad (47)$$

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

$$\mathbf{W}^{bd} = \mathbf{a}_1 \quad (49)$$

$$\mathbf{W}^{bd} = \mathbf{b}_1 \quad (50)$$

$$W_{j,1}^{abd} (0) = W_{j,2}^{abd} (0) \dots W_{j,N}^{abd} (0) = 1 \quad (51)$$

Os parâmetros utilizados no modo *on-line / off-line* e no modo *on-line* são os mesmos.

A seguir, apresenta-se o algoritmo da rede neural ARTMAP-EMTC cujo treinamento é realizado de modo *on-line / off-line*.

6.6.1 ALGORITMO ARTMAP EUCLIDIANA MODIFICADA COM TREINAMENTO CONTINUADO

Passo 1: Leitura dos parâmetros da Rede ARTMAP-EMTC (β , $\underline{\rho}_a$, ρ_b , ρ_{ab} , ε e $NIMIN$);

Passo 2: Inicializar as matrizes pesos ($\mathbf{W}_1^t = \mathbf{a}_1$, $\mathbf{W}^d = \mathbf{W}^a$, $\mathbf{W}^{bd} = \mathbf{W}^b$, $\mathbf{W}^{abt} = \mathbf{U}$,
 $\mathbf{W}^{abd} = \mathbf{W}^{ab}$);

Passo 3: Inicializar os contadores de categorias ativos ($Nwt = 1$, $Nwd = NcatA$,
 $Nwb = NcatB$);

Passo 4: Inicializar o número de categorias temporárias similares ($ContT(1) = 1$);

Passo 5: Inicializar os contadores para criação de uma nova categoria ($ContA = 1$, $ContB = 1$, $CriA = 0$ e $CriB = 0$);

Passo 6: Atribui $\rho_a = \underline{\rho}_a$;

Passo 7: Calcular da função de escolha, T_k^b :

$$T_k^{bd} = \sqrt{\sum_{k=1}^{Nwb} (b_k - W_k^{bd})^2}$$

Passo 8: Escolha da categoria vencedora do módulo ART_b:

$$kw = \arg \left\{ \min T_k^{bd} \right\}, \text{ para } k = 1, 2, \dots, Nwb$$

Passo 9: Verificar o critério de vigilância do módulo ART_b:

$$\frac{T_{kw}^{bd}}{\max \left\{ \sum_{l=1}^{Mb} b_l^2, \sum_{l=1}^{Mb} (W_{kw,l}^b)^2 \right\}} < \rho_b$$

Se sim, vá para o passo 13;

Se não, vá para o passo 10;

Passo 10: Verificar o seguinte critério:

$$Nwb < ContB$$

Se sim, vá para passo o 11;

Se não, vá para passo o 12;

Passo 11: Um novo padrão é criado fazendo-se:

$$Nwb = Nwb + 1$$

$$kw = Nwb$$

$$W_{kw}^{bd} = \mathbf{b}$$

$$CriB = 1$$

Vá para o passo 13;

Passo 12: Ocorre o *reset*:

$$ContB^{(Novo)} = ContB^{(Velho)} + 1$$

Atribui $T_{kw}^{bd} = 10^5$ e retornar para o passo 8;

Passo 13: Calcular $\mathbf{Y}^b = [Y_1^b \ Y_2^b \ \dots \ Y_{Nv}^b]$:

$$Y_k^b = 0, \text{ para } k = 1, 2, \dots, Nv; k \neq kw$$

Passo 14: Adaptação dos pesos do módulo ART_b:

$$\mathbf{W}_{kw}^{bd(Novo)} = \beta \mathbf{b} + (1 - \beta) \mathbf{W}_{kw}^{bd(Velho)}$$

Passo 15: Calcular as funções de ativação T_v^t e T_i^d :

$$T_v^t = \sqrt{\sum_{v=1}^{Nwt} (a_v - W_{vw}^t)^2}$$

$$T_i^d = \sqrt{\sum_{i=1}^{Nwd} (a_i - W_{iw}^d)^2}$$

Passo 16: Escolha das categorias vencedoras, temporária e definitiva, do módulo ART_a:

$$vw = \arg \{ \min T_v^t \}, \text{ para } v = 1, 2, \dots, Nwt$$

$$iw = \arg \{ \min T_i^d \}, \text{ para } i = 1, 2, \dots, Nwd$$

Passo 17: Escolha da categoria vencedora do módulo ART_a:

$$T = \min \{ T_{vw}^t, T_{iw}^d \}$$

Passo 18: Verificar o critério de vigilância do módulo ART_a:

$$\frac{T}{\max \left\{ \sum_{j=1}^{Ma} a_j^2, \sum_{j=1}^{Ma} (W_{vw,j}^t)^2 \right\}} < \rho_a \text{ ou } \frac{T}{\max \left\{ \sum_{j=1}^{Ma} a_j^2, \sum_{j=1}^{Ma} (W_{iw,j}^d)^2 \right\}} < \rho_a$$

Se sim, vá para o passo 19;

Se não, vá para o passo 21;

Passo 19: Verificar se foram criadas categorias nos módulos ART_a e ART_b:

$$CriA = 0 \text{ e } CriB = 0$$

Se sim, vá para o passo 20;

Se não, vá para o passo 33;

Passo 20: Verifica-se qual categoria é vencedora (temporária ou definitiva):

$$T_{vw}^t < T_{iw}^d$$

Se sim, vá para o passo 25;

Se não, vá para o passo 35;

Passo 21: Verifica-se o seguinte critério:

$$ContA > Nwt + Nwd$$

Se sim, vá para o passo 22;

Se não, vá para o passo 24;

Passo 22: Atualização das seguintes variáveis:

$$Nwt^{(Novo)} = Nwt^{(Velho)} + 1$$

$$vw = Nwt$$

$$ContT(vw) = 1$$

Passo 23: Um novo padrão temporário é criado:

$$W_{(vw)}^t = a$$

$$CriA = 1$$

Vá para o passo 19;

Passo 24: Ocorre o *reset*:

$$ContA^{(Novo)} = ContA^{(Velho)} + 1$$

Atribuir $T = 10^5$ para a categoria vencedora no passo 17 (T_{vw}^t ou T_{iw}^d) e retornar para o passo 16;

Passo 25: Verificar o critério de vigilância do módulo inter-ART temporário:

$$|Y^b \wedge W_{vw}^{abt}| \geq \rho_{ab}$$

Se sim, vá para o passo 27;

Se não, vá para o passo 26;

Passo 26: Decrementar o parâmetro de vigilância ρ_a :

$$\rho_a = \frac{T_{vw}^t}{\max \left(\sum_j^{Ma} (a_j)^2, (W_{vw,j}^t)^2 \right)} - \varepsilon$$

$$ContA^{(Novo)} = ContA^{(Velho)} + 1$$

Atribui $T_{vw}^t = 10^5$ e retorna para o passo 16;

Passo 27: Adaptação dos pesos temporários do módulo ART_a:

$$W_{vw}^{t(Novo)} = \beta \mathbf{a} + (1 - \beta) W_{vw}^{t(Velho)}$$

Passo 28: Atualizar o contador para criação de uma nova categoria definitiva:

$$ContT^{(Novo)}(vw) = ContT^{(Velho)}(vw) + 1$$

Passo 29: Verificar se será criada uma categoria definitiva:

$$ContT(vw) = NMIN$$

Se sim, vá para o passo 30;

Senão, vá para o passo 33;

Passo 30: Atualizar o contador da categoria definitiva e do índice para criação de uma categoria definitiva:

$$Nwd^{(Novo)} = Nwd^{(Velho)} + 1$$

$$iw = Nwd$$

Passo 31: Criar um padrão definitivo:

$$W_{iw}^d = \mathbf{a}$$

Passo 32: Atualização dos padrões temporários:

$$Nwt^{(Novo)} = Nwt^{(Velho)} - 1$$

$$W_v^t = W_{v+1}^t, \text{ para } v = vw, \dots, Nwt$$

$$W_v^{abt} = W_{v+1}^{abt}, \text{ para } v = vw, \dots, Nwt$$

$$ContT(v) = ContT(v+1), \text{ para } v = vw, \dots, Nwt$$

Vá para o passo 39;

Passo 33: Adaptação dos pesos do módulo inter-ART_a temporário:

$$W_{vw,kw}^{abt} = 1$$

$$W_{vw,k}^{abt} = 0, \text{ para } k = 1, 2, \dots, Nv; k \neq kw$$

Passo 34: Retornar para o passo 5;

Passo 35: Verificar o critério de vigilância do módulo inter-ART definitivo:

$$|Y^b \wedge W_{iw}^{abd}| \geq \rho_{ab}$$

Se sim, vá para o passo 37;

Se não, vá para o passo 36;

Passo 36: Decrementar o parâmetro de vigilância ρ_a :

$$\rho_a = \frac{T_{iw}^d}{\max \left(\sum_j^{Ma} (a_j)^2, (W_{iw,j}^d)^2 \right)} - \varepsilon$$

$$ContA^{(Novo)} = ContA^{(Velho)} + 1$$

Atribuir $T_{iw}^d = 10^5$ e retorna para o passo 16;

Passo 37: Verificar se a entrada classificada como definitivo apresenta novidade:

$$T_{iw}^d < \eta$$

Se sim, vá para o passo 38;

Se não, vá para o passo 39;

Passo 38: Adaptação dos pesos definitivo do módulo ART_a:

$$W_{iw}^{d(Novo)} = \beta a + (1 - \beta) W_{iw}^{d(Velho)}$$

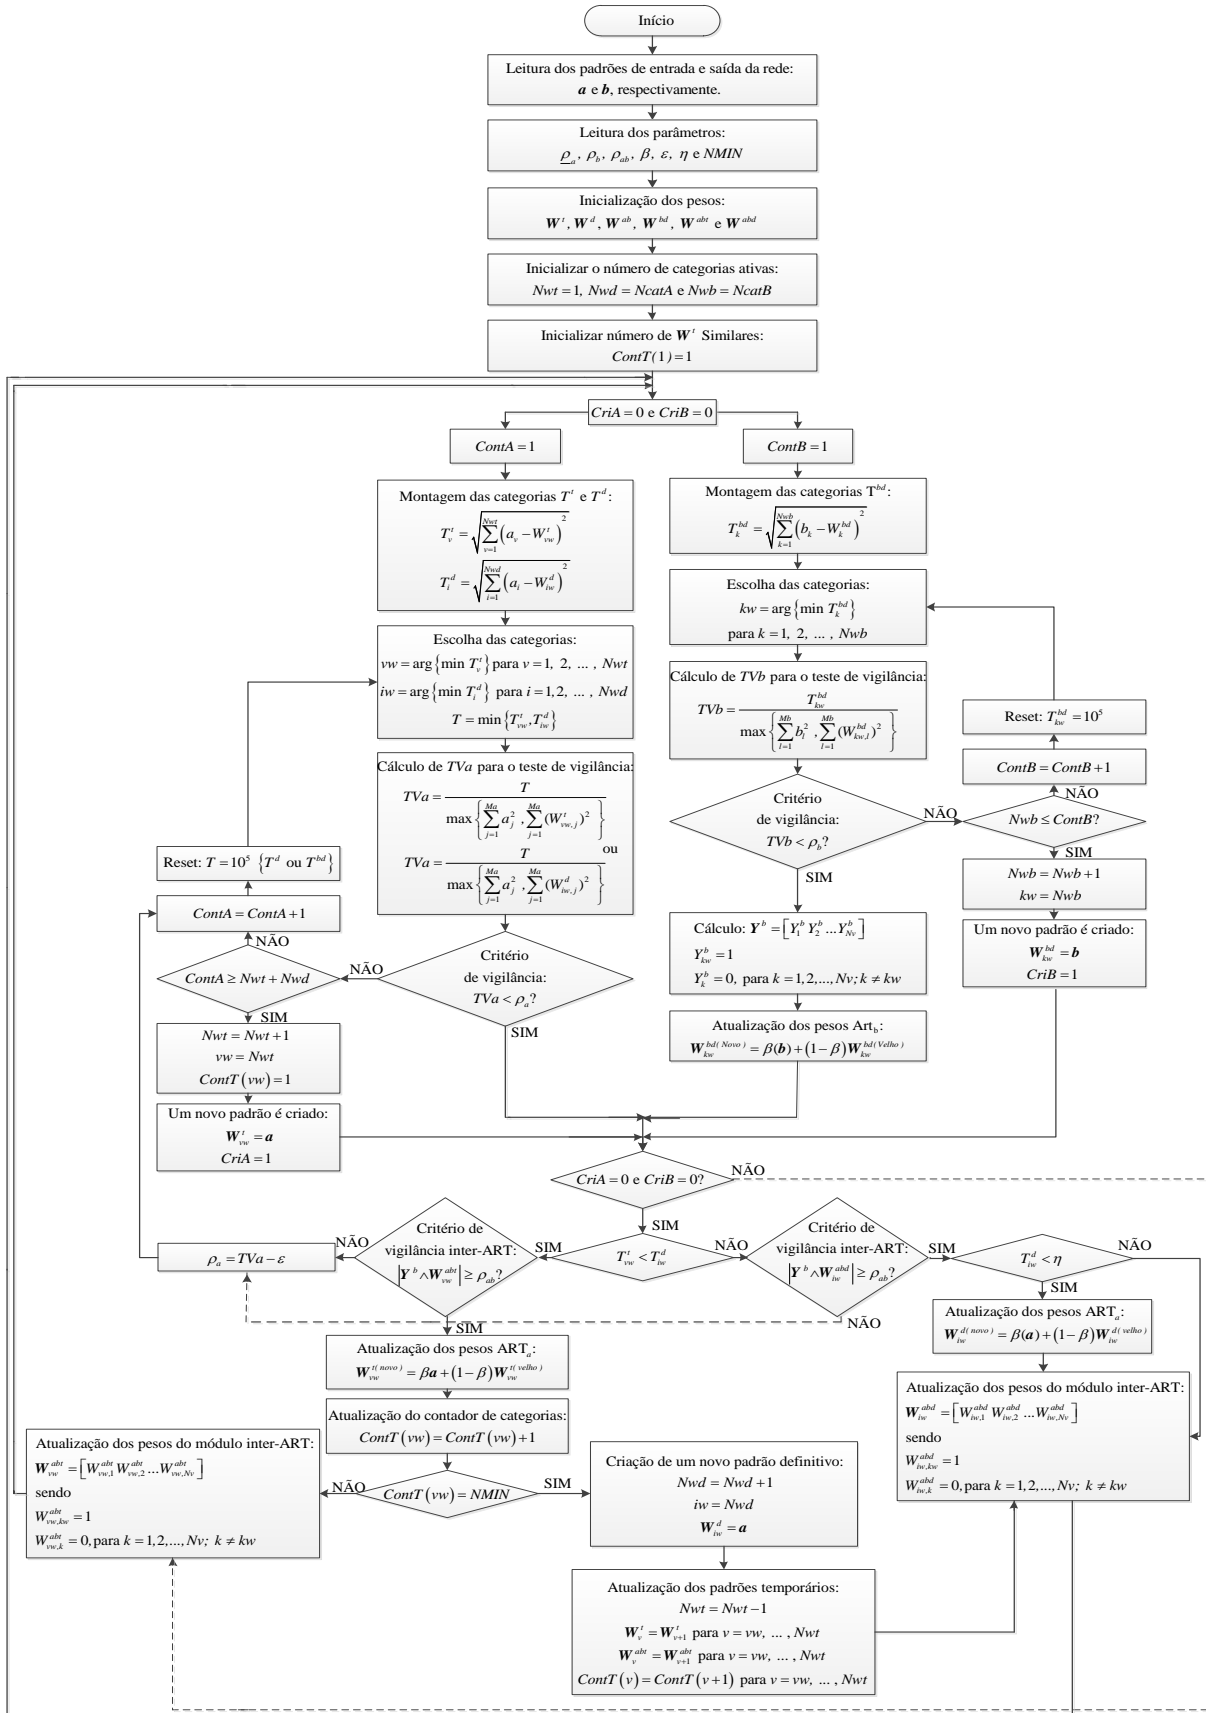
Passo 39: Adaptação dos pesos do módulo inter-ART_a definitivo:

$$W_{iw,kw}^{abd} = 1$$

$$W_{iw,k}^{abd} = 0, \text{ para } k = 1, 2, \dots, Nv; k \neq kw$$

Passo 40: Retornar para o passo 5;

Figura 20 – Fluxograma Rede Neural ARTMAP Euclidiana Modificada com Treinamento Continuado



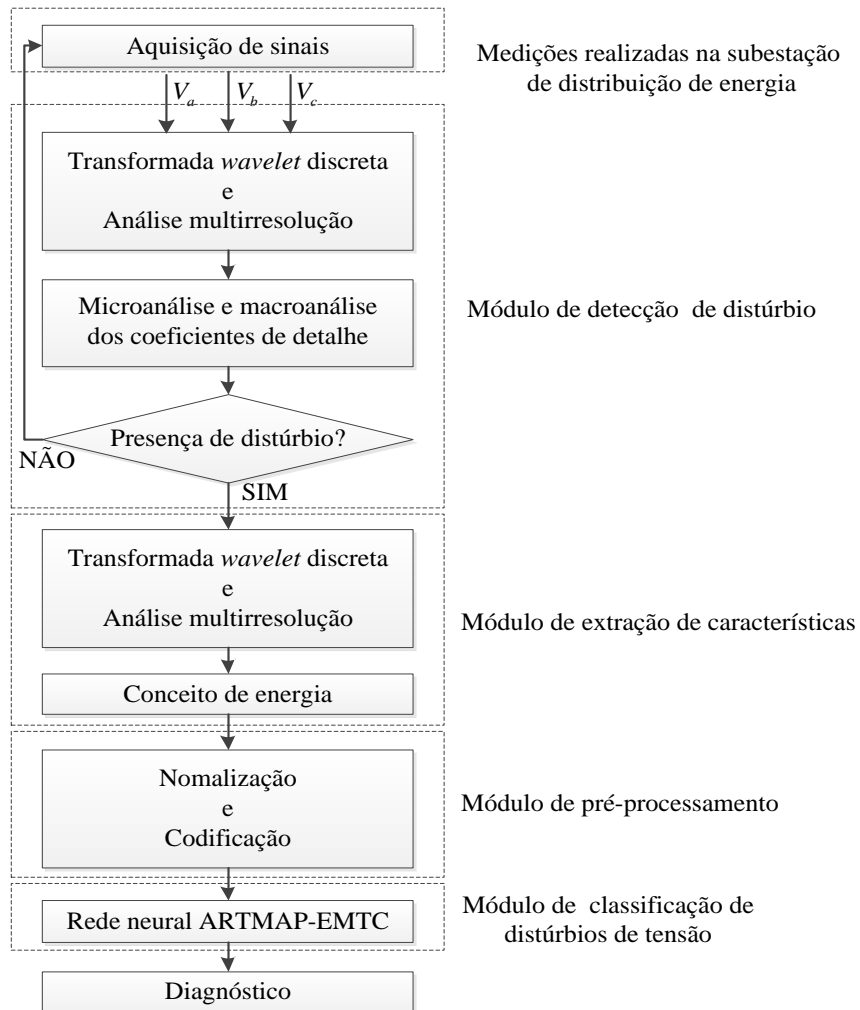
Fonte: Elaboração da própria autora.

7 METODOLOGIA

7.1 INTRODUÇÃO

Neste capítulo será abordado o método proposto para diagnóstico de distúrbios de tensão em sistemas de distribuição de energia elétrica. Apresentam-se, de forma detalhada, os procedimentos para detecção, extração das características e classificação dos distúrbios de tensão. A Figura 8 (Estrutura proposta para o diagnóstico de anomalia de tensão), por se encontrar alocada distante (página 26 / Capítulo 4) deste capítulo e, como consequência, visando facilitar o entendimento da metodologia proposta, ela será reproduzida a seguir designando-a Figura 21.

Figura 21 – Estrutura do sistema de diagnóstico de anomalia de tensão



Fonte: Elaboração da própria autora.

7.2 DETECÇÃO DE DISTÚRBIO DE TENSÃO

O módulo de detecção de distúrbios de tensão foi idealizado levando-se em conta a constante evolução das tecnologias empregadas nas subestações e o dinamismo inerente aos sistemas de energia elétrica, *e.g.*, distintos carregamentos, ângulos de inserção do distúrbio e localização nas oscilografias, com o intuito de se obter uma metodologia robusta, flexível e eficiente.

7.2.1 ANÁLISE MULTINÍVEL

A detecção de distúrbios é realizada pela análise das oscilografias de tensão obtidas no medidor alocado na saída da subestação principal. Nesta etapa define-se o janelamento do sinal, *i.e.*, dois ciclos, e o passo em análise, *i.e.*, um ciclo. Assim, aplica-se a AMR para decomposição do sinal de cada uma das fases em dois níveis de resolução. Em seguida, calcula-se a média aritmética do valor absoluto dos coeficientes de detalhe (previamente definidos na equação (12)) de cada nível de decomposição da oscilografia sob análise (DECANINI *et al.*, 2011b):

$$\bar{d}_{ij} = \frac{\sum_{k=1}^{N_j} |cd_{ij}^k|}{N_j} \quad (52)$$

sendo:

i : oscilografia em análise, *i.e.*, Va , Vb e Vc ;

j : nível de decomposição, *i.e.*, 1, e 2;

N_j : número de coeficientes de detalhe do nível j ;

k : k -ésimo coeficiente de detalhe do nível j referente à oscilografia i ;

\bar{d}_{ij} : média aritmética dos coeficientes de detalhe do nível j referente à oscilografia i .

Posteriormente, computa-se a variação em relação à média aritmética obtida para cada coeficiente de detalhe através da Equação (53) (DECANINI *et al.*, 2011b):

$$var_{ij}^k = |cd_{ij}^k - \bar{d}_{ij}| \quad (53)$$

sendo:

var_{ij}^k : variação do k -ésimo coeficiente de detalhe em relação à média aritmética destes coeficientes para o nível j referente à oscilografia i .

Concomitantemente, obtém-se o desvio padrão do valor absoluto dos coeficientes de detalhe sob avaliação (DECANINI *et al.*, 2011b):

$$\sigma_{ij} = \sqrt{\frac{\sum_{k=1}^{N_j} (|cd_{ij}^k| - \overline{d_{ij}})^2}{N_j - 1}} \quad (54)$$

sendo:

σ_{ij} : desvio padrão dos coeficientes de detalhe do nível j referente à oscilografia i .

O processo de detecção de distúrbios de tensão é baseado em dois conjuntos de regras apresentados nas Equações (55) e (56), sendo cada regra dividida em duas partes: macroanálise e microanálise. Macroanálise compara a máxima variação dos coeficientes de detalhe a um percentual do desvio padrão, proporcionando maior imunidade à presença de ruídos nas oscilografias em análise. Microanálise confronta o maior coeficiente de detalhe com o limite preestabelecido pelo operador (DECANINI *et al.*, 2011b):

$$máx[\mathbf{var}_{ij}] > 1,25\sigma_{ij} \text{ e } máx[|cd_{ij}|] > \mu_{ij}, \text{ então } \tau_{ij} = 1 \quad (55)$$

indica a existência de anormalidade no sistema;

$$máx[\mathbf{var}_{ij}] \leq 1,25\sigma_{ij} \text{ e } máx[|cd_{ij}|] \leq \mu_{ij}, \text{ então } \tau_{ij} = 0 \quad (56)$$

indica operação normal do sistema.

sendo:

μ_{ij} : parâmetro a ser especificado baseando-se na filosofia de proteção do sistema e experiência do operador;

τ_{ij} : índice indicativo do estado de operação do sistema.

7.3 CLASSIFICAÇÃO DE DISTÚRBO DE TENSÃO

Detectada qualquer anormalidade no sistema, ativa-se a etapa de classificação. A extração dos índices característicos, representativos do distúrbio, é realizada por meio da TWD, AMR e conceito energia. Estes índices comportamentais compõem o vetor de entrada da rede ARTMAP-EMTC, responsável pela classificação do distúrbio.

7.3.1 EXTRAÇÃO DAS CARACTERÍSTICAS DO SISTEMA

O módulo de classificação seleciona dois ciclos pré-distúrbio e em distúrbio das oscilografias de tensão a partir do instante de ocorrência determinado no processo de detecção. Estes ciclos são decompostos pela AMR em quatro níveis de resolução.

As características do estado de operação do sistema são baseadas nos coeficientes de detalhe do terceiro e quarto nível, e nos coeficientes de aproximação do quarto nível (DECANINI *et al.*, 2011a). Logo, a energia dos coeficientes de detalhe e de aproximação dos ciclos pré-distúrbio, considerando cada uma das fases, é calculada conforme as Equações (57) e (58):

$$Eca_j^{f,pré} = \sum_{n=1}^{N_j} |ca_j^{f,pré}[n]|^2 \quad (57)$$

$$Ecd_j^{f,pré} = \sum_{n=1}^{N_j} |cd_j^{f,pré}[n]|^2 \quad (58)$$

sendo:

j : nível de decomposição, *i.e.*, terceiro e quarto nível de detalhe, e quarto nível de aproximação;

f : fase da oscilografia analisada, *i.e.*, Va , Vb e Vc ;

N_j : número de coeficiente do nível;

$ca^{pré}[n]$: valor do n -ésimo coeficiente de aproximação dos ciclos pré-distúrbio;

$cd^{pré}[n]$: valor do n -ésimo coeficiente de detalhe dos ciclos pré-distúrbio.

Similarmente, aplica-se o mesmo procedimento para os coeficientes dos ciclos em distúrbio.

$$Eca_j^f = \sum_{n=1}^{N_j} |ca_j^f [n]|^2 \quad (59)$$

$$Ecd_j^f = \sum_{n=1}^{N_j} |cd_j^f [n]|^2 \quad (60)$$

sendo:

j : nível de decomposição, *i.e.*, terceiro e quarto nível de detalhe, e quarto nível de aproximação;

f : fase da oscilografia analisada, *i.e.*, Va , Vb e Vc ;

N_j : número de coeficiente do nível;

$ca[n]$: valor do n -ésimo coeficiente de aproximação dos ciclos em distúrbio;

$cd[n]$: valor do n -ésimo coeficiente de detalhe dos ciclos em distúrbio.

Com isso, definem-se os vetores característicos para os ciclos pré e em distúrbio:

$$\mathbf{A}_{distúrbio}^{pré} = \left[E_{d_3}^{Va,pré} \ E_{d_4}^{Va,pré} \ E_{a_4}^{Va,pré} \ E_{d_3}^{Vb,pré} \ E_{d_4}^{Vb,pré} \ E_{a_4}^{Vb,pré} \ E_{d_3}^{Vc,pré} \ E_{d_4}^{Vc,pré} \ E_{a_4}^{Vc,pré} \right] \quad (61)$$

$$\mathbf{A}_{distúrbio} = \left[E_{d_3}^{Va} \ E_{d_4}^{Va} \ E_{a_4}^{Va} \ E_{d_3}^{Vb} \ E_{d_4}^{Vb} \ E_{a_4}^{Vb} \ E_{d_3}^{Vc} \ E_{d_4}^{Vc} \ E_{a_4}^{Vc} \right] \quad (62)$$

Em seguida, do vetor característico em distúrbio, subtrai-se o vetor característico pré-distúrbio. Isto se faz necessário para obter uma análise mais completa do tipo de distúrbio, incorporando na metodologia uma referência de operação do sistema, *i.e.*, operação normal (DECANINI *et al.*, 2011a).

$$\mathbf{\Gamma} = \mathbf{A}_{distúrbio} - \mathbf{A}_{distúrbio}^{pré} \quad (63)$$

Após a análise do tipo de distúrbio, o vetor Γ é normalizado e codificado para se obter maior generalização de projeto e manutenção da informação do sinal (positivo e negativo) (DECANINI *et al.*, 2011a).

7.4 PROCESSAMENTO E CODIFICAÇÃO

O vetor de entrada da rede ARTMAP-EMTC (\mathbf{a}) é definido por (DECANINI *et al.*, 2011b):

$$\mathbf{a} = [\Psi \Phi] \quad (64)$$

sendo:

$$\Psi = [\Psi_1 \Psi_2 \dots \Psi_9]$$

com:

$$\Psi_i = \frac{|\Gamma_i|}{\Gamma_{max}}$$

$$|\Gamma_{max}| = \max \{ |\Gamma_i| \}, i = 1, \dots, 9$$

Os componentes do vetor Φ são definidos como:

$$\begin{cases} \Psi_i > 0 \rightarrow \Phi_i = 1 \\ \Psi_i \leq 0 \rightarrow \Phi_i = 0 \end{cases}, i = 1, \dots, 9 \quad (65)$$

sendo:

Ψ : vetor das características normalizadas;

Φ : sinal de cada característica normalizada.

A saída da rede neural, definida pelo vetor (\mathbf{b}), fornece o tipo de distúrbio de tensão presente no sistema. Esta saída é codificada como mostra a Tabela 1

Tabela 1 – Codificação de saída

Distúrbios de tensão	Codificação de saída
Elevação (<i>swell</i>)	[0 0 0 1]
Afundamento (<i>sag</i>)	[0 0 1 0]
Interrupção (<i>outage</i>)	[0 0 1 1]
Harmônicos	[0 1 0 0]
Elevação com harmônicos	[0 1 0 1]
Afundamento com harmônicos	[0 1 1 0]
Transitório oscilatório	[0 1 1 1]

Fonte: Elaboração da própria autora.

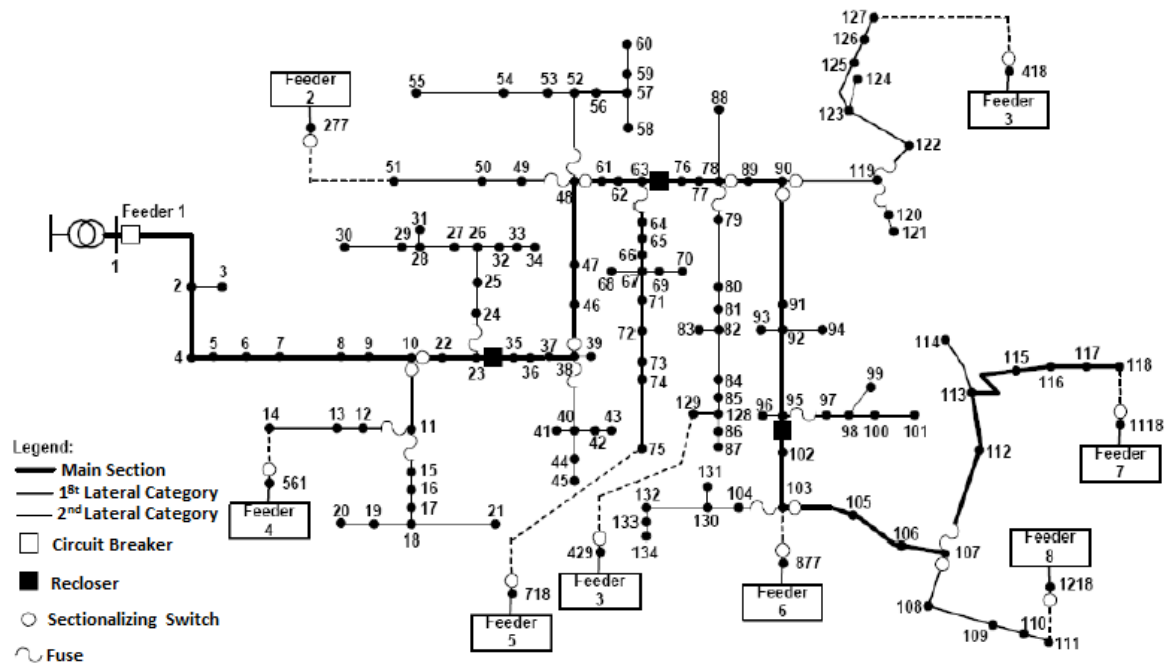
7.5 SISTEMA-TESTE E SIMULAÇÕES

Normalmente, os centros de pesquisas e as concessionárias não possuem um banco de dados representativos do sistema de distribuição operando na presença de distúrbios. Por causa da escassez destes registros, torna-se necessário a utilização de sistemas-testes para a simulação de distúrbios, possibilitando a extração de informações pertinentes e validação de metodologias de diagnóstico de distúrbios.

7.5.1 MODELO DO ALIMENTADOR SIMULADO

Assim, neste trabalho, utilizou-se o alimentador de 134 barras de uma concessionária brasileira. O alimentador de distribuição de energia elétrica real possui as seguintes características: aéreo, trifásico, ramificado, 13,8 kV, 7,065 MVA, fator de potência das cargas igual a 0,92 e mutuamente acoplado (UNESP, 2011). O diagrama unifilar deste alimentador é apresentado na Figura 22.

Figura 22 – Alimentador de distribuição utilizado para simulação dos distúrbios



Fonte: Adaptado de UNESP (2011).

Para obtenção dos dados de distúrbios de tensão, o alimentador, mencionado anteriormente, foi modelado com o auxílio do software ATP (*Alternative Transients Program*) (ATP, 2007).

As simulações dos distúrbios de tensão foram obtidas através de um modelo teórico que corresponde a um conjunto de equações apresentadas na tabela 2, por meio da rotina *models* do ATP, na qual foram implementadas as fontes de alimentação com os distúrbios abordados neste trabalho. Em cada simulação utilizou-se uma frequência de amostragem de 15,36 kHz, correspondente a 256 amostras por ciclo.

Para implementação da metodologia de detecção e classificação foi utilizado o Fortran 4.0 (CRISTO, 2003).

7.5.2 SISTEMA TESTE PARA O DIAGNÓSTICO DE ANOMALIAS DE TENSÃO

Os distúrbios de tensão foram obtidos através da variação de alguns parâmetros nas equações proposta por (ABDEL-GALIL *et al.*, 2004) - por meio do uso do dispositivo MODELS do aplicativo ATP (*Alternative Transients Program*) (ATP, 2007) - juntamente como o *software* Matlab 7.8 (MATLAB, 2011). Estas equações encontram-se na Tabela 2. Esta modelagem é bastante útil para a geração de exemplos para a fase de treinamento, de forma complementar, aos exemplos gerados no aplicativo ATP.

Tabela 2 – Modelagem dos sinais de distúrbio

Distúrbio	Parâmetros	Equação
Operação Normal	-	$V(t) = A \text{ sen}(wt)$
Elevação	$0,1 \leq \alpha \leq 0,8; T \leq (t2 - t1) \leq 12T$	$V(t) = A \{ 1 + \alpha [u(t2) - u(t1)] \} \text{ sen}(wt)$
Afundamento	$0,1 \leq \alpha \leq 0,9; T \leq (t2 - t1) \leq 12T$	$V(t) = A \{ 1 - \alpha [u(t2) - u(t1)] \} \text{ sen}(wt)$
Harmônicos	$\alpha_1 = 1$ $0,05 \leq \alpha_3 \leq 0,15; 0,05 \leq \alpha_5 \leq 0,15;$ $0,05 \leq \alpha_7 \leq 0,15$	$V(t) = A \{ \alpha_1 \text{ sen}(wt) + \alpha_3 \text{ sen}(3wt) +$ $+ \alpha_5 \text{ sen}(5wt) + \alpha_7 \text{ sen}(7wt) \}$
Interrupção	$0,9 \leq \alpha \leq 1; T \leq (t2 - t1) \leq 12T$	$V(t) = A \{ 1 - \alpha [u(t2) - u(t1)] \}$
Afundamento com harmônicos	$0,1 \leq \alpha \leq 0,9; T \leq (t2 - t1) \leq 12T$ $\alpha_1 = 1$ $0,05 \leq \alpha_3 \leq 0,15; 0,05 \leq \alpha_5 \leq 0,15$	$V(t) = A \{ 1 - \alpha [u(t2) - u(t1)] \} \times$ $[\alpha_1 \text{ sen}(wt) + \alpha_3 \text{ sen}(3wt) + \alpha_5 \text{ sen}(5wt)]$
Elevação com harmônicos	$0,1 \leq \alpha \leq 0,8; T \leq (t2 - t1) \leq 12T$ $\alpha_1 = 1$ $0,05 \leq \alpha_3 \leq 0,15; 0,05 \leq \alpha_5 \leq 0,15$	$V(t) = A \{ 1 + \alpha [u(t2) - u(t1)] \} \times$ $[\alpha_1 \text{ sen}(wt) + \alpha_3 \text{ sen}(3wt) + \alpha_5 \text{ sen}(5wt)]$
Transitório Oscilatório	-	$V(t) = A \{ \text{sen}(wt) + \sigma e^{-\gamma(t-t1)} \times$ $\text{sen}[w_{tr}(t-t1)] \}$

Fonte: (ABDEL-GALIL *et al.*, 2004).

sendo:

$V(t)$: forma da onda de tensão;

A : amplitude da onda de tensão;

t : tempo (s);

w : velocidade da onda (radianos elétricos/s)

$$= 2 \pi f$$

f : frequência (Hz);

$u(t) = 0$, para $t < 0$;

$= 1$, para $t \geq 0$;

$$W_{tr} = 2 \pi f_{tr};$$

$t_2 > t_1$;

$$2 \leq \sigma \leq 2;$$

$$50 \leq \gamma \leq 100;$$

$$500\text{Hz} \leq f_{tr} \leq 1500\text{Hz}.$$

8 RESULTADOS OBTIDOS E DISCUSSÕES

8.1 INTRODUÇÃO

A metodologia desenvolvida para o diagnóstico de distúrbios de tensão em alimentadores de distribuição de energia elétrica tem como principais características a robustez, eficiência e capacidade de aprendizado ao longo do tempo.

8.2 DIAGNÓSTICO DE DISTÚRPIO DE TENSÃO

No processo de detecção de distúrbios empregou-se a *wavelet* mãe Daubechies com um filtro de quarta ordem (db4). Os valores dos parâmetros limite utilizados pelo operador para verificação do estado operativo do sistema são apresentados na Tabela 3. Este módulo apresentou um desempenho de 100% de acerto na identificação de situações anormais, caracterizadas por distúrbios de tensão, com alto desempenho computacional.

Tabela 3 – Parâmetros para detecção de distúrbio de tensão

Parâmetro	Nível de Decomposição	
	Primeiro	Segundo
μ	0,005	0,07

Fonte: Elaboração da própria autora.

O parâmetro μ é definido de forma experimental (tentativa e erro).

Detectada qualquer operação anormal no sistema de distribuição, e após ser identificado o instante no qual iniciou o distúrbio, são selecionados dois ciclos em distúrbio e dois ciclos pré-distúrbio. Estes são analisados em quatro níveis de resolução por meio da AMR e agregados através do conceito energia. Nesta etapa, a *wavelet* mãe empregada foi também a Daubechies com um filtro de quarta ordem (db4). Para a composição do vetor de entrada do módulo ARTMAP-EM (treinamento *off-line*), a energia referente aos coeficientes *wavelets* dos ciclos pré-distúrbio foram tomadas como referência da operação normal do

sistema, sendo esta subtraída da energia dos coeficientes de detalhe e aproximação dos ciclos em distúrbio.

Na etapa de classificação de distúrbios, do total de 3024 vetores de distúrbios de tensão, foram selecionados 524 padrões para treinamento do módulo ARTMAP-EM e 2500 para teste. Deve-se ressaltar que esta seleção foi realizada de forma pseudoaleatória (uso de uma semente prefixada). Além disso, os 432 distúrbios da classe “harmônicos” foram todos incluídos no conjunto de padrões para teste. Deste modo é possível visualizar a capacidade do módulo de treinamento continuado em adquirir novos conhecimentos, mostrando a melhoria nos resultados com o passar do tempo. Estes 524 padrões, usados na fase de treinamento, são contabilizados os 7 tipos de distúrbios (elevação de tensão, afundamento de tensão, etc.), perfazendo, na média, 75 padrões por distúrbios. Trata-se de uma quantidade bastante pequena de padrões, principalmente, por se tratar de casos em que se deve trabalhar com vários perfis de carga. Contudo, este reduzido número de padrões foi estabelecido visando evidenciar a extração do conhecimento, de forma incremental, quando se dispõem de novos padrões, sem destruir o conhecimento anteriormente adquirido. A Tabela 4 apresenta a taxa de acerto do módulo ARTMAP-EM sem o treinamento continuado.

Tabela 4 – Percentual de acerto sem treinamento continuado

Distúrbios de tensão	Padrões de teste	Acerto (%)
Elevação	346	83,51
Afundamento	338	54,73
Interrupção	338	81,95
Harmônicos	432	0
Elevação com harmônicos	359	93,31
Afundamento com harmônicos	346	54,33
Transitório oscilatório	341	99,70
Total	2500	64,56


Fonte: Elaboração da própria autora.

Analisando a taxa de acerto referente ao distúrbio harmônico, observa-se que ela foi zero. Isto se deve ao fato de que este distúrbio não possui nenhum padrão no conjunto de padrões de treinamento, *i.e.*, a rede ARMAP-EM treinada não conhece o distúrbio harmônico.

Além disso, obteve-se uma taxa de acerto baixa para os distúrbios afundamento e afundamento com harmônicos. Os erros na classificação destes distúrbios são ocasionados pelo comportamento dos índices característicos, já que para os distúrbios afundamento, elevação e afundamento com harmônicos eles se distinguem somente em amplitude. Desta forma, os distúrbios afundamento e afundamento com harmônicos são classificados como elevação pelo módulo de classificação.



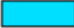




Posteriormente, na etapa de treinamento *off-line*, ativa-se o módulo de treinamento continuado. Cada um dos padrões de teste utilizados na ARTMAP-EM são apresentados separadamente, *i.e.*, um a um, para a rede ARTMAP-EMTC. Como resultado a rede ARTMAP-EMTC fornece um novo diagnóstico à medida que novos padrões são apresentados à ela. Então, considerando todos os padrões de teste, a rede fornecerá ao operador 2500 distintos diagnósticos. Na Figura 23 é apresentada a evolução da taxa de acerto após a inclusão de cada um dos padrões de teste no processo de treinamento continuado.

Figura 23 – Evolução da rede com o módulo de treinamento continuado



Fonte: Elaboração da própria autora.

sendo:

	Elevação
	Afundamento
	Interrupção
	Hamônico
	Elevação com Harmônico
	Afundamento com Harmônico
	Oscilatório Transitório

A Tabela 5 mostra o resultado final depois da inclusão dos 2500 padrões no treinamento continuado. Já a Tabela 6 mostra o resultado do treinamento direto, ou seja, a rede neural não possui treinamento de modo *off-line*.

Tabela 5 – Percentual de acerto com treinamento continuado de modo *on-line/off-line*

Distúrbios de tensão	Padrões de teste	Acerto (%)
Elevação	346	100
Afundamento	338	72,18
Interrupção	338	97,33
Harmônicos	432	99,53
Elevação com harmônicos	359	98,32
Afundamento com harmônicos	346	71,38
Transitório oscilatório	341	99,70
Total	2500	91,20

Fonte: Elaboração da própria autora.

Tabela 6 – Percentual de acerto com treinamento continuado de modo *on-line*

Distúrbios de tensão	Padrões de teste	Acerto (%)
Elevação	346	100
Afundamento	338	73,37
Interrupção	338	98,22
Harmônicos	432	99,53
Elevação com harmônicos	359	98,05
Afundamento com harmônicos	346	69,65
Transitório oscilatório	341	99,70
Total	2500	91,21

Fonte: Elaboração da própria autora.

Comparando-se as tabelas 5 e 6 com a Tabela 4, observa-se que houve uma melhoria na etapa de classificação, *i.e.*, a rede neural, com a inclusão do treinamento continuado, foi capaz de classificar de forma correta distúrbios que anteriormente ela classificava erroneamente. Também se observa que o distúrbio harmônico, de zero, atingiu 99,53% de acerto, o que mostra a eficiência e a robustez ao dinamismo inerente ao sistema de energia elétrica, isto porque os distúrbios foram detectados e classificados em diversos níveis de carregamento do sistema de distribuição. Este processo de melhoria é observado à medida que a rede neural executa o diagnóstico de maneira simultânea ao treinamento continuado. Os parâmetros utilizados nas fases de treinamento e teste da rede de modo *on-line/off-line* e modo *off-line* foram:

- Taxa de treinamento : $\beta = 1$;
- Parâmetros de vigilância : $\rho_a = 0,15$; $\rho_b = 0,0$ e $\rho_{ab} = 0,95$;
- Decremento do parâmetro de vigilância : $\varepsilon = 0,01$;
- Índice de novidade : $\eta = 2$;
- Parâmetro de similaridade : $MNIN = 2$.

Os testes realizados contemplam o treinamento continuado de modo *off-line* e *on-line*. São duas estratégias que podem ser usadas, de acordo com o interesse do usuário. Contudo, a estratégia *on-line* é a mais adequada para implementação em sistemas, por exemplo, *smart grids*, tendo em vista que há maior diversidade de informações. Estas informações, em grande quantidade, requerem a atualização do conhecimento de modo contínuo.

9 CONCLUSÃO E SUGESTÕES PARA TRABALHOS FUTUROS

9.1 CONCLUSÃO

O trabalho desenvolvido consiste de uma estrutura neural com treinamento continuado, aplicada à classificação de distúrbios de tensão em sistemas de distribuição de energia elétrica. Esta ferramenta de apoio para tomada de decisão auxilia o processo de automação de subestação, tornando a restauração da operação normal do sistema mais rápida, flexível e robusta. O módulo de diagnóstico de distúrbios de tensão foi projetado com o objetivo de atender as necessidades das concessionárias, levando em consideração a situação econômica atual do setor elétrico, podendo ser facilmente implementado no sistema e com custo reduzido, uma vez que para esta implementação, necessita-se de equipamentos de aquisição e processamento de dados.

Através do uso combinado de técnicas de processamento de sinais e metodologias baseadas na inteligência artificial, o sistema de diagnóstico apresentou alta capacidade de generalização, flexibilidade e eficiência, características imprescindíveis no auxílio à tomada de decisão no ambiente das subestações de energia elétrica. O processo de detecção foi capaz de identificar todas as situações anormais de operação. Assim, identificada a presença de distúrbios de tensão, as oscilografias de tensão são analisadas por meio da AMR e do conceito energia, gerando índices característicos representativos dos distúrbios detectados. Por conseguinte, estes índices são apresentados à rede neural ARTMAP-EMTC, fornecendo ao operador o tipo de distúrbio de tensão. Além disso, por utilizar uma concepção de treinamento diferente, o módulo neural, a cada diagnóstico, melhora ou adquire novos conhecimentos.

Então, a vantagem da rede ARTMAP-EMTC em relação às outras redes neurais encontradas na literatura especializada, é que esta permite o aperfeiçoamento contínuo das categorias existentes de modo que o aprendizado seja realizado permanentemente sem a necessidade de reinicialização do processo de treinamento. Esta importante característica permite a aplicação da rede neural em questão em modernos sistemas de energia elétrica, *e.g.*, *smart grids*, pois, tem a capacidade de aprender em tempo real.

9.2 SUGESTÕES PARA TRABALHOS FUTUROS

Os resultados desta pesquisa podem ser considerados satisfatórios (no contexto da precisão na obtenção das soluções), conforme argumentado anteriormente. Porém, sugerem-se algumas melhorias e procedimentos que podem ser implementados com o propósito de tornar este procedimento mais eficiente:

- a) Implementação em sistemas de distribuição reais;
- b) Inclusão de mudanças topológicas (inclusão ou retirada de elemento(s) de operação da rede elétrica) e operacionais dos sistemas de distribuição;
- c) Desenvolvimento de metodologia voltada para as aplicações em sistemas *smart grids*;
- d) Inclusão mais diversidade de informações, em especial as procedentes do sistema de aquisição de dados (SCADA);
- e) Implementação de melhorias no programa computacional, bem como o uso de outras linguagens de programação mais eficientes, se existirem;
- f) Desenvolvimento de novos métodos de técnicas inteligente, *e.g.*, sistemas imunológicos artificiais, com estratégias mais eficientes, se comparadas às disponíveis na literatura especializada (seleção negativa, algoritmo de seleção clonal, etc.).

REFERÊNCIAS

ABDEL-GALIL, T. K. *et al.* Power quality disturbance classification using inductive the inference approach. **IEEE Transactions on Power Delivery**, Piscataway, v. 19, n. 4, p. 1812-1818, 2004.

ABDELSALAM, A. A. *et al.* Characterization of power quality disturbances using hybrid technique of linear Kalman filter and fuzzy-expert system. **Electric Power Systems Research**, Lausanne, v. 83, n. 1, p. 41-50, 2012.

ACKERMAN, W. J. Fundamentals of automation systems and current trends in substations. substation automation tutorial sponsored. **IEEE Power Engineering Society**, São Paulo, v. 1, n. 1, p. 15, 2006.

ALTERNATIVE TRANSIENTS PROGRAM– ATP. **RuleBook**. Oslo: EMTP-ATP Users Group/SINTEF Energy Research, 2007.

AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA– ANEEL. **Elétrica PRODIST**: procedimentos de distribuição de energia elétrica no sistema elétrico nacional. Revisão-4, Resolução Normativa nº 469/2011. Brasília, 2012. Módulo 8 - Qualidade de Energia.

ARRUDA, E. F. D. **Análise de distúrbios relacionados com a qualidade da energia elétrica utilizando a transformada wavelet**. 2003. 136 f. Dissertação (Mestrado em Engenharia Elétrica) - Escola de Engenharia de São Paulo, Universidade de São Paulo, São Paulo, 2003.

BARROS, A. C. *et al.* 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.

BARROS, A. C. *et al.* 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.

BOYER, S. A. **SCADA**: supervisory control and data acquisition. 2. ed. Durham: ISA - The Instrumentation, Systems, And Automation Society, 2009.

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

CARPENTER, G. A. *et al.* Fuzzy ART: fast stable learning and categorization of analog patterns by an adaptive resonance system. **Neural Network**, New York, v. 4, n. 1, p. 759-771, 1991.

CARPENTER, G. A. *et al.* Fuzzy ARTMAP: a neural network architecture for incremental supervised learning of analog multidimensional maps. **IEEE Transactions on Neural Networks**, New York, v. 3, n. 5, p. 698-713, 1992.

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

DECANINI, J. G. M. S. **Detecção classificação e localização de faltas de curto-circuito em sistemas de distribuição de energia elétrica usando sistemas inteligentes**. 2012. 169 f. Tese (Doutorado em Engenharia Elétrica) – Faculdade de Engenharia, Universidade Estadual Paulista, Ilha Solteira, 2012.

DECANINI, J. G. M. S. *et al.* Detection and classification of voltage disturbances using a fuzzy-ARTMAP-wavelet network. **Electric Power Systems Research**, Lausanne, v. 81, n. 12, p. 2057-2065, 2011a.

DECANINI, J. G. M. S. *et al.* 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, 2011b.

DEHGHANI, H. *et al.* Power quality disturbance classification using a statistical and wavelet-based Hidden Markov Model with Dempster–Shafer algorithm. **Electric Power Systems Research**, Lausanne, v. 47, p. 368-377, 2013.

DUGAN, R. C. *et al.* **Electrical power systems quality**. New York: McGraw-Hill, 1996.

ERISTI, H.; DEMIR, Y. Automatic classification of power quality events and disturbances using wavelet transform and support vector machines. **IET Generation, Transmission and Distribution**, Stevenage, v. 6, n. 10, p. 968-976, 2012.

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

FRANCO, E. **Qualidade de energia: causas, efeitos e soluções**. Salvador: ENGECOMP, 2005. Disponível em: <https://www.google.com.br/?gws_rd=cr&ei=oAVOUuzNE4-M9ATih4HICw#q=FRANCO%2C+E%3B+ENGECOMP+TECNOLOGIA+EM+AUTOMA%3C%87%3C%83O+E+CONTROLE+LTDA>. Acesso em: 3 out. 2013.

CRISTO, H. P. **Programação em linguagem FORTRAN: guia básico em linguagem FORTRAN 4.0**. Belo Horizonte: [s. n.], 2003.

GAOUDA, A. M. *et al.* Power quality detection and classification using wavelet-multiresolution signal decomposition. **IEEE Transactions on Power Delivery**, New York, v. 14, n. 4, p. 1469-1476, 1999.

GEORGIOPOULOS, M. *et al.*, Order of search in fuzzy ART and fuzzy ARTMAP: effect of the choice parameter. **Neural Networks**, Oxford, v. 9, n. 9, p. 1541-1559, 1996.

GOMES, F. V. Introdução às instalações elétricas de baixa tensão. In: UNIVERSIDADE FEDERAL DE JUIZ DE FORA. Faculdade de Engenharia. **Material Instalações Elétricas I**.

Juiz de Fora, 2013. Cap. 1. Disponível em:

<http://www.ufjf.br/flavio_gomes/files/2011/03/Material_Curso_Instalacoes_I.pdf> Acesso em: 25 out. 2013.

GOMES, J.; VELHO, L. From fourier analysis to wavelets. In: SIGGRAPH'99 COURSE NOTES, 1998, Los Angeles. **Proceedings...** Los Angeles: [s. n.], 1999. p. 1-196.

GRANADOS-LIEBERMAN, D. *et al.* Techniques and methodologies for power quality analysis and disturbances classification in power systems: a review. **IET Generation, Transmission and Distribution**, Stevnage, v. 5, n. 4, p. 519-529, 2011.

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

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

HAYKIN, S. **Redes neurais: princípios e práticas**. 2. ed. Porto Alegre: Bookman, 2001.

HE, J. et al. ART-C: a neural architecture for self-organization under constraints. In: INTERNATIONAL JOINT CONFERENCE ON NEURAL NETWORKS, 2002, Honolulu. **Proceedings...** Piscataway: IEEE, 2002. p. 2550-2555.

KENAYA, R. Euclidean ART neural networks. In: WORLD CONGRESS ON ENGINEERING AND COMPUTER SCIENCE, 2008, San Francisco. **Proceedings...** San Francisco: Newswood, 2008. p. 1-6.

KEZUNOVIC, M. Intelligent applications in substations: disturbance analysis. Proc. **IEEE Power Engineering Society General Meeting**, New York, , v.1, p. 719–723, 2004.

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.

LIYANAGE, K.M. *et al.* Intelligent systems for distribution automation. In: IEEE INTERNATIONAL CONFERENCE ON SYSTEMS, MAN, AND CYBERNETICS , 1994, San Antonio. **Proceedings...** San Antonio: [s.n.], 1994. v. 2, p. 1103.

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

LOPES, M. L. M. *et al.* Electric load forecasting using a *fuzzy* ART&ARTMAP neural network. **Applied Computing**, New York, v. 5, n. 2, p. 235-244, 2005.

MALANGE, F. C. V. **Rede neuro-fuzzy-wavelet para detecção e classificação de anomalias de tensão em sistemas elétricos de potência**. 2010. 128 f. Tese (Doutorado em

Engenharia Elétrica) – Faculdade de Engenharia, Universidade Estadual Paulista, Ilha Solteira, 2010.

MALLAT, S. **A wavelet tour of signal processing: the sparse way**. 3. ed. Burlington: Academic Press, 2009.

MARCHIORI, S. C. et al. Neural network based an adaptive resonance theory with continuous training for multi-configuration transient stability analysis of electric power systems. **Applied Soft Computing**, New York, v. 11, n. 1, p. 706-715, 2011.

MATLAB 7.8 version. [S. l.]: MathWorks Company, 2011.

McDONALD, J. D. **Electric power substations engineering**. Boca Raton: CRC Press, 2003.

MEIRELES, D. **Aplicabilidade de subestação compactas isoladas a gás em grandes centros urbanos**: proposta de procedimento aplicado à expansão do sistema Elétrico. 2010. 85 f. Dissertação (Mestrado em Engenharia Elétrica) – Escola de Engenharia, Universidade Federal de Minas Gerais, Belo Horizonte, 2010.

MORENO, L. A. **Análise da estabilidade transitória via rede neural ART-ARTMAP Fuzzy euclidiana modificada com treinamento continuado**. 2010. 144 f. Tese (Doutorado em Engenharia Elétrica) –, Faculdade de Engenharia, Universidade Estadual Paulista, Ilha Solteira, 2010.

NORTHCOTE-GREEN, J.; WILSON, R. **Control and automation of electrical power distribution systems**. Boca Raton: CRC/Taylor and Francis, 2007.

OLIVEIRA, J. C. **Qualidade da energia elétrica**: definição e análise dos itens de qualidade. Uberlândia: Universidade Federal de Uberlândia, Centro de Ciências Exatas e Tecnologia, Departamento de Engenharia Elétrica, Grupo de Qualidade e Racionalização da Energia Elétrica, 2000. Projeto SIDAQEE. Cap. II.

OPPENHEIM, A. V.; SCHAFER, R. W. **Digital signal processing**. Englewood Cliffs: Prentice Hall, 1975.

PANIGRAHI, B. K.; PANDI, V. R. Optimal feature selection for classification of power quality disturbances using wavelet packet-based fuzzy k-nearest neighbour algorithm. **IET Generation, Transmission and Distribution**, Stevenage, v. 3, n. 3, p. 296-306, 2009.

SILVA, J. F. D. **Sistema de Armazenamento de imagens comprimidas através da transformada Wavelet**. 2008. 100 f. Dissertação (Mestrado em Engenharia Elétrica) – Faculdade de Engenharia, Universidade Estadual Paulista, Ilha Solteira, 2008.

SILVA, M. S. **Modelagem das funções de uma subestação automatizada empregando modelos orientados a objeto**. 2002. 169 f. Dissertação (Mestrado em Engenharia Elétrica) – Escola Politécnica, Universidade de São Paulo, São Paulo, 2002.

SOARES, L. R. **Projeto de novos sistemas-wavelet com aplicações na análise de sinais do sistema elétrico**. 2006. 223 f. Tese (Doutorado em Engenharia Elétrica) – Centro de Tecnologia e Geociências, Universidade Federal de Pernambuco, Recife, 2006.

SOUZA, F. A. **Detecção de falhas em sistema de distribuição de energia elétrica usando dispositivos programáveis**. 2008. 119 f. Dissertação (Mestrado em Engenharia Elétrica) – Faculdade de Engenharia, Universidade Estadual Paulista, Ilha Solteira, 2008.

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

UNIVERSIDADE ESTADUAL PAULISTA – UNESP. Faculdade de Engenharia de Ilha Solteira. Laboratório de Planejamento de Sistemas de Energia Elétrica – LAPSEE. **Practical 134 bus feeder data**. Ilha Solteira, 2011.

VAPNIK, V. N. **The nature of statistical learning theory**: information Science and Statistics. [S. l.]: Springer, Verlag, 2000.

VENKATESH, C., SARMA, D. V. S. S., SYDULU, M. Classification of voltage sag, swell and harmonics using S-transform based modular neural network. In: INTERNATIONAL CONFERENCE CONFERENCE ON HARMONICS AND QUALITY OF POWER, 14., 2010, [S. l.]. **Proceedings...** [S. l.]: IEEE, 2010. p. 1-7.

VERZI, S. I. *et al.* 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.

VUSKOVIC, M.; DU, S.; Classification of prehensile EMG patterns with simplified *fuzzy* ARTMAP. In: INTERNATIONAL JOINT CONFERENCE ON NEURAL NETWORKS, 2002, [S. l.]. **Proceedings...** [S. l.]: IEEE, 2002. p. 2539-2544.

WERBOS, P. J. **Beyond regression**: new tools for prediction and analysis in the behavioral sciences, PHD. Thesis (Doctorate) - Harvard University, 1974.

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

APÊNDICE A - PUBLICAÇÕES

A seguir, relacionam-se os artigos completos apresentados e publicados, em eventos científicos, relacionados ao tema desta tese de doutorado.

TONELLI-NETO, M. S.; DECANINI, J. G. M. S.; BARROS, A. C.; MINUSSI, C. R. Diagnóstico de Falhas 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.

LIMA, F. A.; BARROS, A. C.; MINUSSI, C. R. Detecção e Classificação de Distúrbios de Tensão em Sistemas de Distribuição de Energia Elétrica Utilizando Sistemas Imunológicos Artificiais. In: CONGRESSO BRASILEIRO DE AUTOMÁTICA, 19., 2012 Campina Grande. **Anais...** Campina Grande: [s.n.], 2012, p. 1-8.

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.