



UNIVERSIDADE FEDERAL DO CEARÁ
CENTRO DE TECNOLOGIA
DEPARTAMENTO DE ENGENHARIA ELÉTRICA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

ARYFRANCE ROCHA ALMEIDA

**O USO DE ANÁLISE DE COMPONENTES INDEPENDENTES NA EXTRAÇÃO DE
CARACTERÍSTICAS DOS SINAIS TRANSITÓRIOS DE FALTAS EM LINHAS DE
TRANSMISSÃO DE ENERGIA ELÉTRICA**

FORTALEZA

2017

ARYFRANCE ROCHA ALMEIDA

O USO DE ANÁLISE DE COMPONENTES INDEPENDENTES NA EXTRAÇÃO DE
CARACTERÍSTICAS DOS SINAIS TRANSITÓRIOS DE FALTAS EM LINHAS DE
TRANSMISSÃO DE ENERGIA ELÉTRICA

Tese apresentada ao Programa de Pós-Graduação em Engenharia Elétrica do Centro de Tecnologia da Universidade Federal do Ceará, como requisito parcial à obtenção do título de doutor em Engenharia Elétrica. Área de Concentração: Sistemas de Energia Elétrica

Orientador: Prof. Dr. Otacílio da Mota Almeida

FORTALEZA

2017

Dados Internacionais de Catalogação na Publicação
Universidade Federal do Ceará
Biblioteca Universitária
Gerada automaticamente pelo módulo Catalog, mediante os dados fornecidos pelo(a) autor(a)

- A444u Almeida, Aryfrance Rocha.
O Uso de Análise de Componentes Independentes na Extração de Características dos Sinais Transitórios de Faltas em Linhas de Transmissão de Energia Elétrica / Aryfrance Rocha Almeida. – 2017.
97 f. : il. color.
- Tese (doutorado) – Universidade Federal do Ceará, Centro de Tecnologia, Programa de Pós-Graduação em Engenharia Elétrica, Fortaleza, 2017.
Orientação: Prof. Dr. Otacílio da Mota Almeida.
1. Análise de Componentes Independentes. 2. Localização de Faltas. 3. Classificação de faltas. I. Título.
CDD 621.3
-

ARYFRANCE ROCHA ALMEIDA

O USO DE ANÁLISE DE COMPONENTES INDEPENDENTES NA EXTRAÇÃO DE
CARACTERÍSTICAS DOS SINAIS TRANSITÓRIOS DE FALTAS EM LINHAS DE
TRANSMISSÃO DE ENERGIA ELÉTRICA

Tese apresentada ao Programa de Pós-Graduação em Engenharia Elétrica do Centro de Tecnologia da Universidade Federal do Ceará, como requisito parcial à obtenção do título de doutor em Engenharia Elétrica. Área de Concentração: Sistemas de Energia Elétrica

Aprovada em: 01 de Setembro de 2017

BANCA EXAMINADORA

Prof. Dr. Otacílio da Mota
Almeida (Orientador)
Universidade Federal do Ceará (UFC)

Prof. Dr. Mário Oleskovicz
Universidade Federal do Ceará (UFC)

Profa. PhD. Ruth Pastôra Saraiva Leão
Universidade Federal do Ceará (UFC)

Prof. Dr. Hermes Manoel Galvão Castelo
Branco
Universidade Estadual do Piauí (UESPI)

Prof. Dr. Arthur Plínio de Souza Braga
Universidade Federal do Ceará (UFC)

A Deus, aos meus pais, José de Arimatéia e Francilene. Ao meu irmão, Arylson. A minha sobrinha, Rafaela.

AGRADECIMENTOS

A Deus, por tudo!

Aos meus pais, pelo amor e dedicação a minha vida.

Ao professor Dr. Otacílio da Mota Almeida, pela oportunidade e excelente orientação.

Aos amigos e professor Me. Francisco Carlos Moreira Abreu e Eng. Me. Saulo Cunha Araújo pela amizade e parceria na condução dessa pesquisa.

Aos colegas da turma de Mestrado e Doutorado da UFC, pela reflexões, críticas e sugestões recebidas.

Aos professores Dr. Arthur Plínio de Souza Braga e Dr. Allan Kardec Barros pelos ensinamentos e amizade.

Aos professores participantes da banca examinadora pelo tempo e valiosas colaborações e sugestões.

Aos meus amigos e professores da UFPI, Me. Fabíola Linard e Dr. Bartolomeu Ferreira por momentos de descontração durante essa jornada.

A Universidade Federal do Piauí- UFPI e a Fundação de Amparo a Pesquisa do Estado do Piauí - FAPEPI, pela liberação da minhas atividades de professor quando necessário e pelo apoio financeiro com a manutenção da bolsa de auxílio.

“Seja quem você for, seja qualquer posição; que você tenha na vida, do nível altíssimo ao mais baixo social, tenha sempre como meta: muita força, muita determinação e sempre faça tudo com muito amor e com muita fé em Deus, que um dia você chega lá, de alguma maneira você chega lá.”

(Ayrton Senna)

RESUMO

Vários métodos para localização e classificação de faltas em linhas de transmissão energia elétrica, utilizando técnicas convencionais, inteligência computacional e técnicas de processamento digital de sinais têm sido propostas, de forma intensiva, na literatura nas últimas décadas. Esses métodos têm melhorado o processo de caracterização das faltas em vários aspectos. No entanto, mesmo os métodos baseados em Transformada Wavelet (TW), Redes Neurais Artificiais (RNA) e outras técnicas advindas da computação inteligente, não têm tratado de forma conveniente e sistemática as faltas em sistemas de transmissão cujos dados são contaminados por ruído. Partindo desta evidência, este trabalho propõe combinações de métodos que utilizam a Análise de Componentes Independentes (ACI), a Teoria das Ondas Viajantes (TOV) e Máquina de Vetores de Suporte (MVS) em abordagens eficientes para a extração de características dos sinais transitórios de falta mesmo diante de sinais consideravelmente contaminados por ruído. A abordagem foi aplicada para localizar e reconhecer as faltas, em uma linha de transmissão de alta tensão de 500 kV que interliga a subestação de Presidente Dutra - Ma à subestação de Boa Esperança -PI. O experimento foi realizado para diferentes tipos de faltas que ocorrem em diferentes localizações. A utilização destes métodos aplicados a um modelo real de linha de transmissão tem comprovado que os métodos propostos, de forma combinada, resultam em desempenho superior na localização e classificação de faltas. Os erros obtidos são inferiores a 1% para a localização com acurácia de 100% para a classificação de faltas com ruído. O desempenho da abordagem proposta tem apresentado melhores resultados quando comparados às principais técnicas convencionais, assim quando comparados às técnicas que utilizam Redes Neurais Artificiais e outras técnicas de inteligência computacional.

Palavras-chave: Análise de Componentes Independentes. Localização de faltas. Classificação de faltas. Máquina de Vetores de Suporte.

ABSTRACT

Several methods for localization and classification of faults in electric power transmission lines, using conventional techniques, computational intelligence and digital signal processing techniques have been proposed, intensively, on literature in the last three decades. These methods have improved the process of characterization of faults in various aspects. However, even the methods based on Wavelet Transform (WT), Artificial Neural Networks (ANN) and other techniques derived from smart Computing, do not have convenient and systematic way treaty faults in transmission systems whose data are contaminated by noise. Based on this evidence, this paper proposes a combination of methods using Independent Component Analysis (ICA), the Theory of the Travelling Waves (TTW) and Support Vector Machine (SVM) effective approaches to extracting characteristics of transient signals of fault even before signs considerably contaminated by noise. The approach was applied to locate and recognize faults in a transmission line 500 kV high voltage that connects the substation of President Dutra - MA to the substation of Boa Esperança - PI. The experiment was carried out for different types of faults that have occurred in different locations. The use of these methods applied to a real transmission line model has proven that the proposed methods, in combination, result in superior performance on location and classification of faults. The obtained errors are less than 1% to the location and accuracy of 100% for the classification of faults with noise. The proposed approach has shown performance best when compared to major conventional techniques, as well as when compared to techniques using Artificial Neural Networks and other computational intelligence techniques.

Keywords: Independent Component Analysis. Fault Location. Fault Classification. Support Vector Machine.

LISTA DE FIGURAS

Figura 1 – Evolução do Número de Perturbações e do Impacto sobre o Atendimento às Cargas do SIN	17
Figura 2 – Registro oscilográfico real de uma falta na Fase C em uma linha de 230 kV para tensão (a) e corrente (b)	24
Figura 3 – Esquema de janelamento aplicado a um sinal de corrente	25
Figura 4 – Diagrama de reflexões de uma falta no ponto F de uma LT	26
Figura 5 – Modelo de LT a parâmetros concentrados. (a) linhas curtas ($\ell < 80 \text{ km}$); (b) linhas médias ($80 \leq \ell \leq 250 \text{ km}$).	34
Figura 6 – Modelo de LT a parâmetros distribuídos	35
Figura 7 – Ondas progressivas e regressivas	36
Figura 8 – Modelo da LT a parâmetros distribuídos para a i -ésima componente simétrica	37
Figura 9 – Duas fontes sonoras são gravadas simultaneamente por microfones distintos de modo que a saída de cada microfone seja uma mistura de duas fontes. A partir dessas duas misturas, a ACI consegue isolar as duas fontes.	43
Figura 10 – Comparação entre a ACP e a ACI. Na ACP as componentes são ortogonais e no ACI são independentes.	44
Figura 11 – Distribuição conjunta das componentes independentes de s_1 e s_2 com distribuição uniforme. Eixo horizontal s_1 e vertical s_2	51
Figura 12 – Distribuição conjunta das misturas observadas de x_1 e x_2 . Eixo horizontal x_1 e vertical x_2	51
Figura 13 – Distribuição conjunta das misturas observadas de x_1 e x_2 branqueadas. Eixo horizontal x_1 e vertical x_2	52
Figura 14 – Diagrama de <i>Lattice</i>	57
Figura 15 – Diagrama unifilar do Sistema de Transmissão.	59
Figura 16 – Modelagem do Sistema de Transmissão usando o ATP.	59
Figura 17 – Parâmetros da Torre e da LT de 500 kV, $f = 60\text{Hz}$	60
Figura 18 – Sinal Transitório de Falta.	61
Figura 19 – Sinal Transitório de Falta adicionado com ruído.	62
Figura 20 – Diagrama de blocos do modelo de ACI para extração de características.	64
Figura 21 – ACI para extração de características dos sinais transitórios de faltas.	64
Figura 22 – Negentropia.	66

Figura 23 – Detalhes da função base da ACI.	67
Figura 24 – Representação de uma falta utilizando o modelo ACI. Cada coluna da matriz A é uma característica e cada S_i é um coeficiente de características.	67
Figura 25 – Conceito de Subespaço Independente (a) - Supondo que a ACI retorne 10 funções base que caracterizam a mistura dada; (b) - Dois subespaços que descrevem cada uma das fontes (vetor fonte S) do sinal que estão contidos na mistura.	68
Figura 26 – Fluxograma proposto.	73
Figura 27 – Localização de faltas usando as funções base de ACI.	76
Figura 28 – Espectro de energia da TWD.	79
Figura 29 – Comparação entre ACI x TWD.	80
Figura 30 – Mapa Dimensional usando a LibSVM com MDS	83
Figura 31 – MVS usando kernel linear	83
Figura 32 – MVS usando kernel Sigmóide	84
Figura 33 – MVS usando kernel RBF	84

LISTA DE TABELAS

Tabela 1 – Distribuição do percentual de ocorrências de faltas em um sistema de transmissão de 500 kV.	18
Tabela 2 – Resumo da revisão bibliográfica referente a localização de faltas em LT	40
Tabela 3 – Legenda	40
Tabela 4 – Resumo da revisão bibliográfica referente a detecção de transitórios	41
Tabela 5 – Estudo de casos definidos para a LT de 500 kV	60
Tabela 6 – Resultados iniciais na localização de faltas usando as funções bases da ACI	76
Tabela 7 – Localização de uma FMT para uma distância real de 10 km usando 50 funções bases da ACI.	77
Tabela 8 – Localização de uma FMT para uma distância real de 90 km usando 50 funções bases da ACI.	77
Tabela 9 – Localização de uma FMT para uma distância real de 155 km usando 250 funções bases da ACI	78
Tabela 10 – Localização de faltas usando funções bases para todos os casos	78
Tabela 11 – E.M (%) para os diferentes tipos de falta	78
Tabela 12 – Resultados de classificação de faltas usando a LibSVM	85
Tabela 13 – Classificação de faltas usando estratégias OAO e OAA.	86
Tabela 14 – Comparação de desempenho entre as técnicas de localização e classificação de faltas	86
Tabela 15 – Relação entre a ACI e Wavelet.	87

LISTA DE ABREVIATURAS E SIGLAS

ACI	Análise de Componentes Independentes
ACP	Análise de Componentes Principais
AIEE	American Institute of Electrical Engineers
ATP	Alternative Transient Program
ATPdraw	Interface gráfica do software ATP
FMT	Falta monofásica-terra
FB	Falta bifásica
FBT	Falta bifásica-terra
FT	Falta trifásica-terra
LT	Linhas de transmissão
LibSVM	Library for Support Vector Machine
MDS	Escalonamento Multidimensional
MVS	Máquina de Vetores de Suporte
ONS	Operador Nacional do Sistema Elétrico
RDPs	Registradores Digitais de Perturbações
RNA	Redes Neurais Artificiais
SEP	Sistema Elétrico de Potência
SIN	Sistema Interligado Nacional
TOV	Teoria da Ondas Viajantes
TW	Transformada Wavelet
TWD	Transformada Wavelet Discreta
TWDR	Transformada Wavelet Discreta Redundante

LISTA DE SÍMBOLOS

$\%$	Porcentagem
c	Capacitância em derivação da linha por unidade de comprimento
g	Condutância em derivação da linha por unidade de comprimento
r	Resistência série da linha por unidade de comprimento
l	Indutância série da linha por unidade de comprimento
ℓ	Comprimento da linha
R_L	Resistência série da linha
R_F	Resistência de Falta
V_S	Tensão no terminal emissor da linha
V_R	Tensão no terminal receptor da linha
v_S	Velocidade de propagação das ondas viajantes que se propagam na direção da Barra S
v_R	Velocidade de propagação das ondas viajantes que se propagam na direção da Barra R
X_L	Reatância indutiva série da linha
Y_L	Admitância em derivação da linha
Z_L	Impedância série da linha
Z_c	Impedância característica
Z_P	Impedância própria da linha
Z_M	Impedância mútua da linha
Z_{L0}	Impedância série de sequência zero da linha
Z_{L1}	Impedância série de sequência positiva da linha
d	Distância da falta
f	Frequência fundamental (dada em Hz)
Ω	Ohm
ω	Frequência angular fundamental (dada em rad/s)
γ	Constante de propagação

SUMÁRIO

1	INTRODUÇÃO	16
1.1	Objetivos	19
1.2	Contribuições da Pesquisa	20
1.3	Organização do Texto	21
2	PANORAMA DA LOCALIZAÇÃO DE FALTAS EM LT	23
2.1	Introdução	23
2.2	Variações de Tensões e Correntes Envolvidas nos Distúrbios em LT	23
2.3	Fundamentos para os Métodos de Localização e Classificação de Falhas em LT	24
2.3.1	<i>Fundamentos da Análise de Componentes de Frequência Fundamental</i>	24
2.3.2	<i>Fundamentos da Análise de Transitórios de Falta</i>	26
2.4	Classificação dos Métodos de Localização e Detecção de Falhas	28
2.4.1	<i>Métodos baseados em Componentes de Frequência Fundamental - CF</i>	28
2.4.2	<i>Métodos baseados em Componentes de Alta Frequência - AF</i>	30
2.4.3	<i>Métodos baseados em Inteligência Computacional - IC</i>	30
2.4.4	<i>Métodos baseados em Ondas Viajantes - OV</i>	31
2.5	Modelagem das Linhas de Transmissão sob Diferentes Condições de Falta	32
2.6	Modelos de Linha de Transmissão	33
2.6.1	<i>Modelos à Parâmetros Concentrados</i>	33
2.6.2	<i>Modelos à Parâmetros Distribuídos</i>	34
2.7	Técnicas para Detecção de Transitórios	38
2.8	Considerações Finais do Capítulo	41
3	ANÁLISE DE COMPONENTES INDEPENDENTES	42
3.1	Introdução	42
3.2	Definição da ACI	42
3.3	Independência Estatística e Não Correlação de Variáveis	44
3.4	Estimação das Componentes Independentes	45
3.5	Negentropia como Medida de Não Gaussianidade	46
3.6	Pré - processamento da ACI	48
3.6.1	<i>Centralização</i>	48

3.6.2	<i>Branqueamento</i>	49
3.7	Algoritmo <i>FastICA</i>	52
3.7.1	<i>FastICA para mais de um componente independente</i>	54
3.8	Algoritmos da ACI	55
3.9	Considerações Finais do Capítulo	56
4	ACI PARA EXTRAÇÃO DE CARACTERÍSTICAS DOS SINAIS TRANSITÓRIOS DE FALTAS EM LT	57
4.1	Introdução	57
4.2	Teoria das Ondas Viajantes - TOV	57
4.3	Modelagem do Sistema de Transmissão Teste	58
4.4	Transitórios em Sistemas Elétricos	60
4.5	Extração de Característica usando ACI	62
4.5.1	<i>Aplicação da ACI na Extração de Características para a Localização de Faltas</i>	63
4.5.2	<i>Aplicação da ACI na Extração de Características para a Classificação de Faltas</i>	68
4.5.3	<i>Máquina de Vetores de Suporte - MVS</i>	70
4.5.4	<i>Escalonamento Multidimensional - MDS</i>	72
4.5.5	<i>Aplicações do MDS</i>	73
4.6	Considerações Finais do Capítulo	74
5	RESULTADOS E DISCUSSÃO	75
5.1	Introdução	75
5.2	Localização de Faltas	75
5.3	Classificação de Faltas	81
5.4	Considerações Finais	87
6	CONCLUSÃO	88
6.1	Prospecção de Novas Aplicações	90
	REFERÊNCIAS	91

1 INTRODUÇÃO

Em um Sistema Elétrico de Potência (SEP), as linhas de transmissão (LT) se destacam como uma das partes mais importantes, pois possibilitam o transporte de energia elétrica desde a geração até os grandes consumidores. No Sistema Interligado Nacional (SIN), as unidades geradoras, seja de natureza hidráulica, térmica e nuclear são distribuídas de forma dispersas e interligadas percorrendo longas distâncias até os grandes centros consumidores. Assim, para permitir a transmissão de energia elétrica até os locais mais remotos, sempre se utilizam de LT longas, as quais devido às suas grandes extensões são mais susceptíveis à queda dos condutores, devido principalmente a intempéries, e outros problemas de natureza elétrica.


Nas últimas décadas, observa-se um crescimento dos SEPs resultando em um aumento no número de LTs, segundo dados do Operador Nacional do Sistema Elétrico (ONS), totalizando mais de 100.000 km de extensão espalhadas por todo o Brasil (ONS, 2015). Para uma noção comparativa, o comprimento total de LTs seria suficiente para dar duas voltas e meia no planeta Terra. Em geral, quanto maiores as LTs, maiores são as susceptibilidades à ocorrência de distúrbios devido a causas naturais, dentre as quais se destacam os curtos-circuitos, popularmente denominados por faltas, que são normalmente classificados como severos para o SEP.

Recentemente, o ONS informou que no período de 2010 a 2014 o número de perturbações no sistema elétrico brasileiro oscilou, por ano, entre 2.670 a 2.972, sendo ilustrado na Figura 1(ONS, 2017).

Dentre essas perturbações, destaque especial para as faltas em LT que são causadas por condições climáticas adversas, seguidas de queimadas, curto-circuitos e desligamentos não programados, ocasionando apagões, envolvendo grande quantidade de carga no SIN em diversas regiões do Brasil. Como exemplo, no dia 28 de agosto de 2013, uma queimada na fazenda Santa Clara, na cidade de Canto do Buriti, no Piauí, provocou um curto circuito que desligou duas linhas de transmissão paralelas que totalizou um corte de carga de 10.900 MW, atingindo todo sistema de energia elétrica do Nordeste. Em algumas localidades, o apagão durou mais de quatro horas, causando diversos problemas para a população desses Estados (GLOBO, 2013).

No dia 2 de fevereiro de 2014, uma falha na LT, que liga o Norte ao Nordeste do país, provocou falta de energia em todos os Estados do Sudeste, Sul e Centro-Oeste, além do Tocantins, na Região Norte. Ao menos onze Estados tiveram o fornecimento de eletricidade comprometido, provocando a interrupção do fornecimento de cerca de 5.000 MW (GLOBO, 2014).

Figura 1 – Evolução do Número de Perturbações e do Impacto sobre o Atendimento às Cargas do SIN



Fonte: (ONS, 2017).

Nos SEPs, as faltas podem ocorrer em diversos componentes, dentre os quais destacam-se as LTs como o elemento mais susceptível, especialmente se forem consideradas suas dimensões físicas, complexidade funcional e o ambiente em que se encontram, apresentando assim, maior dificuldade para manutenção e monitoramento. Como pode ser observado na Tabela 1, em meio à maioria das faltas provocadas por curtos-circuitos em um SEP, cerca de 82 % ocorrem em LTs (COURY *et al.*, 2007).

As falhas que ocorrem nas LTs são classificadas em dois grupos (DALLBELLO *et al.*, 2007). O primeiro grupo é aquele que se relaciona às ocorrências de curtos-circuitos e são denominadas faltas elétricas. Os curtos-circuitos podem ocorrer em consequência de queimadas

Tabela 1 – Distribuição do percentual de ocorrências de faltas em um sistema de transmissão de 500 kV.

Equipamentos Faltosos	% de Faltas
Linhas de Transmissão	82%
Circuitos Disjuntores	4%
Transformadores	7%
Barramentos	1%
Geradores	1%
Erros Humanos	5%

Fonte:(COURY *et al.*, 2007)

na faixa de serviço da LT, descargas atmosféricas, de rompimento e queda de cabos e/ou torres devido a condições climáticas desfavoráveis como, vento forte e chuvas.

O segundo grupo é aquele que engloba diversos tipos de defeitos que poderão também conduzir à ocorrência de uma falta com possível desligamento da linha de transmissão e são chamados defeitos. Como exemplos, têm-se a cadeia de isoladores com um ou mais isoladores defeituosos (perfuração interna, trinca) e cabo apresentando condutores parcialmente rompidos provocados por vibrações eólicas. Os defeitos mencionados anteriormente irão se manifestar através de efeitos térmicos, ruídos sonoros e eletromagnéticos com o passar do tempo (DALLBELLO *et al.*, 2007).

Ao longo dos anos, a busca de meios para minimizar a duração de desligamentos decorrentes de faltas no SEP tem motivado várias pesquisas no desenvolvimento de métodos de localização de faltas, os quais têm sido cada vez mais utilizados por empresas atuantes na transmissão e distribuição de energia elétrica. Normalmente, após uma primeira estimativa do local do defeito, calculada por dispositivos de localização instalados no SEP, as concessionárias utilizam vias terrestres e/ou helicópteros para chegar até o ponto exato da falta, procedimento este que pode ser dispendioso na maioria dos casos. Portanto, é importante a localização de falta a partir de uma estimativa inicial confiável do local do defeito.

Em se tratando da análise de faltas a partir dos defeitos e ou faltas em LT, alguns autores demonstram a existência de correlação entre o ruído e os defeitos nas linhas de transmissão, que com o tempo, culminaram em falhas. Estes estudos apontam para a importância de se investigar a influência do ruído em condições de faltas (DALLBELLO *et al.*, 2007); (BIRLASEKARAN; LI, 2000).

Considerando as suposições acima pode-se justificar o tema deste trabalho. Na região norte e nordeste, por exemplo, a ocorrência de queimadas muito próximas às linhas de

transmissão (problema recorrente e referenciado anteriormente), devido a longos períodos de seca, geram ruídos característicos que uma vez detectados e caracterizados podem ser utilizados no contexto da manutenção e supervisão da proteção do sistema elétrico.

Atualmente, os dispositivos para a localização de faltas não são capazes de identificar, separar e classificar faltas com a presença de sinais ruidosos nos dados de oscilografia. Desta forma, faltas passíveis de caracterização a partir da influência dos ruídos nos dados da oscilografia padrão, por exemplo, faltas geradas a partir de falhas em isoladores e queimadas sob as linhas de transmissão de energia, que geram ruídos correlatos passam despercebidos (DALLBELLO *et al.*, 2007).

Supondo esta situação, esta pesquisa sistematizou o estado da arte dos principais estudos sobre o tema, observando a ausência de estudos sobre a aplicação de técnicas de separação de sinais, mais especificamente em relação a Análise de Componentes Independentes (ACI) para a extração de características dos sinais transitórios de faltas em linhas de transmissão. Desta forma combinou-se a ACI com as técnicas convencionais da Teoria da Ondas Viajantes (TOV), para a detecção e localização de faltas em uma LT real. Para a classificação das faltas com e sem a presença do ruído, foi utilizado a técnica de ACI, combinada com técnicas de classificação, baseadas em Máquina de Vetores de Suporte (MVS). Para uma visualização gráfica da técnica utilizou-se o Escalonamento Multidimensional (MDS). A linha de transmissão de 500 kV, que interliga as subestação de Presidente Dutra-MA à subestação de Boa Esperança-PI da Companhia Hidro Elétrica do São Francisco (CHESF), foi utilizada como objeto de estudo e teste das técnicas propostas.

1.1 Objetivos

O objetivo geral desta pesquisa foi o de propor novas abordagens para detectar, localizar e classificar faltas a partir dos dados com e sem a presença de ruídos, na linha de transmissão que interliga a subestação de Presidente Dutra-MA à subestação de Boa Esperança-PI, a partir da combinação de técnicas, como a ACI com a TOV, a MVS e MDS. Portanto, os objetivos específicos são:

1. Desenvolver uma estratégia para o uso da ACI na extração das características dos sinais transitórios de faltas em linhas de transmissão de energia elétrica combinado com a TOV para detectar, localizar e classificar faltas com e sem a presença do ruído através da combinação da MVS e MDS.

2. Realizar uma análise comparativa entre a ACI e métodos de detecção e localização de faltas tradicionais (Transformada Wavelet Discreta - TWD) e de classificação de faltas (Redes Neurais Artificiais - RNA, Lógica Fuzzy) sob a influência do ruído no sinal transitório de falta.

1.2 Contribuições da Pesquisa

As principais contribuições desta pesquisa podem ser destacadas como:

1. Aplicação da ACI, TOV e MVS para separar ruídos e dados presentes nos sinais de tensão em linhas de transmissão incluindo os gerados durante condições de faltas. Embora a correlação entre os ruídos e a causa da falta não tenha sido objeto deste trabalho;
2. Introdução de uma abordagem que combina a aplicação da ACI, TOV e MVS para localizar e reconhecer as faltas em linhas de transmissão de alta tensão quando os sinais de falta são significativamente ruidosos;
3. Estratégia que combina ACI com MVS, como uma fase para a classificação de faltas, enquanto ACI associado com a TOV e são aplicada para a localização de faltas. Na abordagem proposta os dados muito ruidosos podem ser adequadamente filtrados e separados;
4. Aplicação da teoria do MDS para a representação gráfica e a demonstração da eficácia da MVS em relação a classificação de faltas com e sem a presença de ruído para distintos tipos de faltas. Este tipo de representação gráfica pode servir como suporte para uma boa visualização e classificação de padrões no espaço de características dos sinais de falta e ruído.

Em relação à divulgação dos resultados obtidos neste trabalho, enumeram-se a seguir, em ordem cronológica, as principais publicações:

Artigos publicados em anais de conferências nacionais e internacionais:

1. **ARYFRANCE R. ALMEIDA**, OTACÍLIO M. ALMEIDA, FRANCISCO C. M. ABREU, JAYNNE PESSOA SILVA, MARCOS HENRIQUE S. ALVES. Localização de faltas em sistemas de transmissão de alta tensão a partir de registros oscilográficos usando análise de componentes independentes. Simpósio Brasileiro de Sistemas Elétricos (SBSE 2014), Foz do Iguaçu - PR.
2. SAULO C. A. DE SOUZA, **ARYFRANCE R. ALMEIDA**, ARTHUR P. S. BRAGA, OTACÍLIO M. ALMEIDA, FRANCISCO C. M. ABREU, JOSÉ S. A. JUNIOR. Localização de faltas em linhas de transmissão usando redes neurais artificiais e ondas viajantes.

Congresso Brasileiro de Automática (CBA 2014), Belo Horizonte - MG.

3. SAULO C. A. DE SOUZA, **ARYFRANCE R. ALMEIDA**, ARTHUR P. S. BRAGA, OTACÍLIO M. ALMEIDA, FRANCISCO C. M. ABREU. Uso da Transformada de Stockwell e Ondas Viajantes na Localização de faltas em linha de transmissão. IEEE INDUSCOM 2014, Juiz de Fora - MG.
4. MARCOS HENRIQUES S. ALVES, OTACÍLIO M. ALMEIDA, **ARYFRANCE R. ALMEIDA**, JOSÉ G. S. CARVALHO, BARTOLOMEU F. S. JUNIOR, FRANCISCO C. M. ABREU. Teoria das ondas viajantes e filtragem adaptativa de sinais para localização de faltas em linhas de transmissão. CONGRESSO BRASILEIRO DE INTELIGÊNCIA COMPUTACIONAL (CBIC-2015), Curitiba - PR.
5. SAULO C. A. DE SOUZA, **ARYFRANCE R. ALMEIDA**, ARTHUR P. S. BRAGA, RUTH P. S. LEÃO, OTACÍLIO M. ALMEIDA, FRANCISCO C. M. ABREU. Uso de Redes Neurais e Transformada de Stockwell na Localização de faltas em linha de transmissão. SIMPÓSIO BRASILEIRO DE AUTOMAÇÃO INTELIGENTE - SBAI 2015, Natal - RN.

Artigo publicado em periódico internacional:

A.R. Almeida, O.M. Almeida, B.F.S. Junior, L.H.S.C. Barreto, A.K. Barros, *ICA feature extraction for location and classification of faults in high-voltage transmission lines. ELECTRIC POWER SYSTEM RESEARCH, JCR, v.148, p.254-263, 2017.* Disponível em: <http://dx.doi.org/10.1016/j.epsr.2017.03.030>

1.3 Organização do Texto

Esta Tese está organizada, de acordo com a seguinte estrutura:

No capítulo 2, apresenta-se o estado atual da pesquisa e desenvolvimento quanto a localização de faltas em linhas de transmissão, abordando alguns dos principais conceitos sobre modelos de linhas de transmissão encontrados na literatura e sobre as abordagens requeridas pelos métodos de localização de faltas para esta pesquisa. No capítulo 3 descreve-se a fundamentação teórica da técnica de separação de sinais, ACI. Nos capítulos 4 e 5, respectivamente, descrevem-se a aplicação e os resultados da ACI com a TOV para a extração de características dos sinais transitórios de falta. Além disto, a ACI e TOV são utilizadas para a localização de faltas, e a aplicação da ACI combinando com MVS e MDS para classificação de faltas com e sem ruído. Por fim, são apresentadas as análises e conclusões finais, usando a ACI na extração de características

dos sinais transitórios de falta para localização e classificação de faltas em linhas de transmissão com e sem a presença de ruído.

2 PANORAMA DA LOCALIZAÇÃO DE FALTAS EM LT

2.1 Introdução

Neste capítulo faz-se uma revisão da literatura sobre as faltas em linhas de transmissão abordando os seus fundamentos, modelos de LT, métodos de localização de faltas, técnicas para detecção de transitórios de faltas em LT e as considerações finais para o desenvolvimento da pesquisa.

2.2 Variações de Tensões e Correntes Envolvidas nos Distúrbios em LT

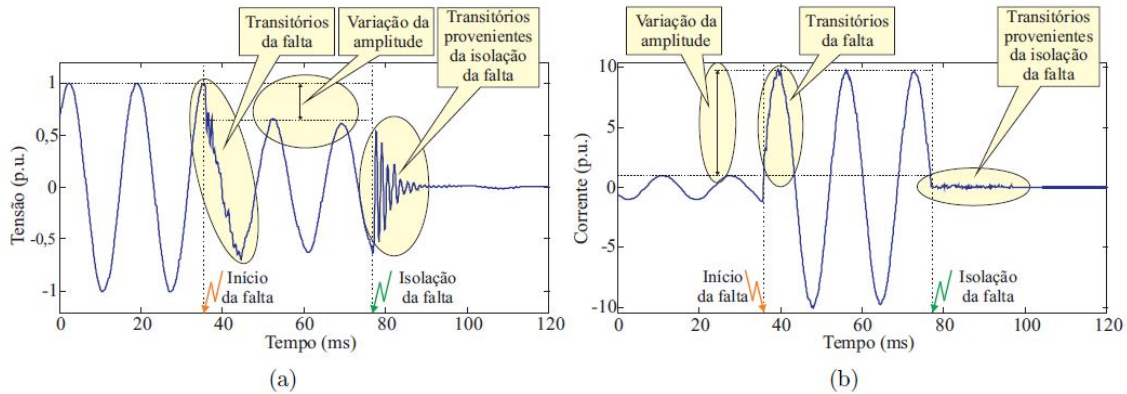
Dentre os possíveis distúrbios que podem ocorrer em um SEP, as faltas são um dos mais preocupantes, visto que ocasionam desligamentos não programados dos sistemas. Dependendo do número de fases envolvidas no distúrbio, as faltas são geralmente denominadas de Falta monofásica-terra (FMT), Falta bifásica (FB), Falta bifásica-terra (FBT) e Falta trifásica-terra (FT). Os tipos mais comuns são as faltas monofásicas e bifásicas, as quais se apresentam no sistema de transmissão com 68% e 25% do total de faltas que ocorrem respectivamente (SOUZA, 2004).

As condições climáticas e a vegetação da região podem gerar curtos-circuitos nas LTs, que provocam modificações relevantes nos parâmetros de configuração das LTs, apresentando grandes variações de magnitude na tensões e correntes e no seu ângulo de fase gerando transitórios com sobretensões, cujas amplitudes dependem das características do tipo de falta e do aterramento do SEP em questão (ZANETTA, 2003).

Na Figura 2, apresenta-se um registro oscilográfico real no qual são destacadas as variações nas formas de onda da tensão e da corrente em uma das fases do SEP monitorado devido à ocorrência e isolação da falta.

As mudanças no comportamento das grandezas elétricas do SEP durante e após curtos-circuitos possuem informações intrínsecas relacionadas às características do distúrbio. Desta forma, analisando-se os transitórios provenientes da isolação da falta é possível estimar o local do defeito (FAYBISOVICH *et al.*, 2010). E para completar, analisando as variações de tensões e correntes em um SEP polifásico, pode-se caracterizar o tipo de falta (SAHA *et al.*, 2010). Portanto, pode-se dizer que a análise das variações nas tensões e correntes de um SEP durante e/ou após curto-circuitos é a base dos métodos de localização e caracterização de faltas.

Figura 2 – Registro oscilográfico real de uma falta na Fase C em uma linha de 230 kV para tensão (a) e corrente (b)



Fonte: (LOPES, 2011).

2.3 Fundamentos para os Métodos de Localização e Classificação de Falhas em LT

Na literatura, os algoritmos de localização de falta são classificados em duas grandes classes: **Àqueles relacionados à análise de componente de frequência fundamental e aqueles provenientes da análise dos transitórios de falta** (SAHA *et al.*, 2010).

2.3.1 Fundamentos da Análise de Componentes de Frequência Fundamental

A análise das componentes de frequência fundamental é utilizada em vários métodos de localização de faltas e se baseia no cálculo dos fasores fundamentais do SEP, os quais viabilizam a avaliação das variações de módulo e fase das tensões e/ou corrente durante um curto-circuito. Geralmente para determinar os fasores, são utilizados os algoritmos de estimação de fasores, já que, a priori apenas as amostras dos sinais avaliados são conhecidas. Portanto, uma vez calculados, os fasores fundamentais podem ser utilizados como entradas dos algoritmos de localização de faltas, cujas formulações, conforme mencionado anteriormente, dependem do modelo da LT considerado, (parâmetros concentrados ou distribuídos).


Com a difusão do uso da tecnologia digital na implementação de sistemas de proteção, foram propostos, em meados da década de 70, os primeiros algoritmos para estimação de fasores, os quais, a princípio, eram empregados principalmente no âmbito da proteção de SEP que operam em regime de corrente alternada. Basicamente, esses algoritmos são capazes de estimar módulo e fase de sinais periódicos, a partir de um conjunto de amostras do sinal avaliado. Dentre os métodos disponíveis na literatura, destacam-se os baseados na teoria dos mínimos quadrados (SACHDEV; BARIBEAU, 1979); (AJAEI; SANAYE-PASAND, 2008); os Filtros de Fourier

(JOHNS; SALMAN, 1995);(PHADKE; THORP, 2009); o filtro cosseno modificado (HART *et al.*, 2000); os algoritmos baseados na Transformada Wavelet (TW) (LIANG; JEYASURYA, 2004),(SILVA *et al.*, 2008) e alguns outros desenvolvidos a partir de modificações dos Filtros de Fourier (SIDHU *et al.*, 2003); (GUO *et al.*, 2003); (LEE *et al.*, 2008).

Embora os algoritmos de estimação de fasores apresentem equacionamentos distintos, todos requerem a digitalização e posterior janelamento dos sinais analógicos a serem estimados. A primeira etapa do processo de digitalização dos sinais analógicos é a limitação da banda de frequência do sinal avaliado, o que é realizado com o objetivo de evitar erros na conversão analógico-digital (A/D) devido à sobreposição de espectros (PHADKE; THORP, 2009). Para tanto, são normalmente empregados filtros analógicos passa-baixas, denominados filtros *anti-aliasing*, cuja frequência de corte, segundo o teorema de *Nyquist*,(PHADKE; THORP, 2009) deve ser menor que a metade da frequência de amostragem considerada no processo de conversão A/D dos sinais avaliados.

Uma vez disponíveis as amostras das formas de onda sob análise, inicia-se o processamento de janelamento dos sinais. Esta etapa é imprescindível para a estimação do módulo e fase de componentes de frequência fundamental. Basicamente, a cada instante de amostragem, a janela de dados se desloca em uma posição de tal forma que uma nova amostra é incluída em seu conteúdo e a amostra mais antiga é descartada (PHADKE; THORP, 2009). Esse processo é ilustrado na Figura 3 para um dado sinal de corrente durante os períodos de pré-falta e de falta.

Figura 3 – Esquema de janelamento aplicado a um sinal de corrente



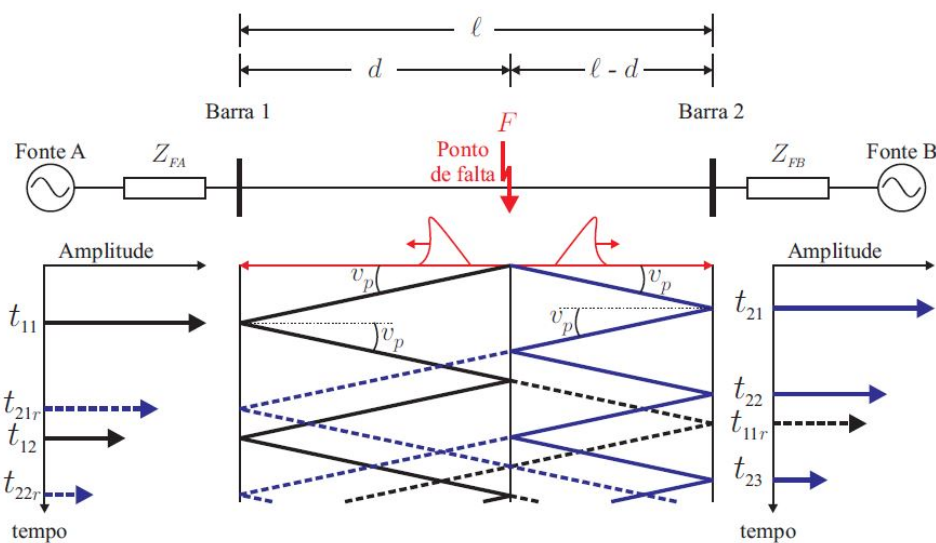
Fonte: (LOPES, 2011).

A cada deslocamento da janela de dados, a estimação do módulo e da fase do fasor na frequência fundamental relativo ao sinal avaliado é realizada. Deve-se observar que durante o regime permanente as janelas possuem apenas dados do sinal sem falta, enquanto, após o início do distúrbio, inicia-se uma fase de transição, a qual consiste no período em que as janelas possuem amostras do sinal com e sem falta, e cuja duração depende do tamanho da janela utilizada. Assim, os fasores calculados durante o período de transição não devem ser utilizados como entradas dos métodos de localização de faltas baseados na análise de componentes de frequência fundamental, o que tem motivado nas últimas décadas a elaboração de técnicas de estimação de fasores em janelas curtas, para as quais o período de transição das janelas de dados é menor (MANN; MORRISON, 1971);(PHADKE; THORP, 2009).

2.3.2 Fundamentos da Análise de Transitórios de Falta

A análise de transitórios provenientes da incidência e isolamento de curto-circuitos em LT é a base dos localizadores de faltas baseados na teoria das ondas viajantes e na análise de componentes de alta frequência. Os transitórios nas tensões e correntes em um dado ponto de uma LT se propagam como ondas eletromagnéticas a uma velocidade muito próxima à velocidade da luz ($v_c = 300.000km/s$), as quais, por sua vez, são popularmente conhecidas como ondas viajantes (BEWLEY, 1931) ; (NAIDU, 1985).

Figura 4 – Diagrama de reflexões de uma falta no ponto F de uma LT



Fonte: (LOPES, 2011).

Para melhor compreender o princípio das análises requeridas por esses métodos, ilustra-se na Figura 4 o diagrama de reflexões das ondas progressivas e regressivas referentes a uma falta ocorrida no ponto F de uma LT de comprimento ℓ , localizada a uma distância d da Barra 1. Nas laterais, na Figura 4, são ilustrados os instantes de chegada das ondas incidentes (t_{11} e t_{21}), refletidas (t_{12} , t_{22} e t_{23}) e refratadas no ponto de falta (t_{21r} , t_{22r} e t_{11r}) às barras 1 e 2. Para simplificar o entendimento do diagrama, uma mesma velocidade de propagação v_p é considerada para as ondas progressivas e regressivas.

Da literatura, sabe-se que os métodos baseados na teoria das ondas viajantes são elaborados a partir de treliças formadas pelos gráficos que representam a propagação dos transitórios ao longo da LT. De fato, destacando-se os instantes de incidência das ondas viajantes aos terminais monitorados, conhecendo-se o comprimento da linha, e sabendo-se que a velocidade de propagação das ondas é aproximadamente a velocidade da luz, torna-se possível obter expressões matemáticas que permitem relacionar a distância d do ponto de falta aos instantes de chegada das ondas viajantes às extremidades da LT (GALE *et al.*, 1993).

Assim, o procedimento crucial para a aplicação dos métodos baseados na teoria das ondas viajantes é a detecção dos transitórios de falta no domínio do tempo. Nesse contexto, sabe-se que quanto mais confiável for o valor estimado do instante de incidência das ondas viajantes nos terminais da linha, mais confiável é o método de localização de faltas, o que tem motivado inúmeros trabalhos no sentido de encontrar soluções robustas para a detecção rápida dos transitórios (LIN *et al.*, 2008), (SILVA *et al.*, 2008), (COSTA *et al.*, 2008); (COSTA, 2014), (LOPES, 2011)(LOPES *et al.*, 2011), (LOPES *et al.*, 2012), (LOPES *et al.*, 2013).

Observa-se da Figura 4 que quanto mais próxima for a falta do terminal monitorado, maior é o número de reflexões das ondas viajantes entre o ponto de medição e o ponto de falta, resultando em uma maior frequência dominante dos transitórios provenientes do distúrbio e de sua isolação. Este fenômeno requer a elaboração de expressões matemáticas que relacionem a distância d do ponto de falta com as frequências dominantes das ondas viajantes, conforme escrito em (FAYBISOVICH *et al.*, 2010), (SAHA *et al.*, 2010). Nesse caso, é nítido o fato de que o procedimento fundamental para a localização da falta por meio dos métodos baseados na análise de componentes de alta frequência é a análise espectral dos transitórios durante e/ou após o distúrbio, o que pode limitar o uso desses métodos em aplicações em tempo real.

Por fim, vale salientar que os métodos de localização de faltas baseados em inteligência computacional tem como procedimento fundamental o reconhecimento de padrões nos sinais

de tensão e corrente, sejam eles relacionados aos transitórios ou relacionados às componentes fundamentais no período de falta. Dessa forma, as análises requeridas por esses métodos são semelhantes às apresentadas ao longo deste capítulo. Na próxima seção, apresenta-se uma revisão bibliográfica sobre alguns dos métodos de localização e detecção de transitórios mais relevantes encontrados na literatura.

2.4 Classificação dos Métodos de Localização e Detecção de Falhas

Atualmente, pode ser encontrada na literatura uma vasta gama de técnicas que utilizam diferentes análises e conceitos para localizar o ponto de ocorrência de curtos-circuitos em LT, os quais geralmente são classificadas em quatro grupos principais (SAHA *et al.*, 2010): **Métodos baseados em componentes de frequência fundamental (C.F)**, **Métodos baseados em componentes de alta frequência (A.F)**(FAYBISOVICH *et al.*, 2010), (IURINIC, 2013), **Métodos baseados em Inteligência Computacional (I.C)** (CHEN; MAUN, 2000), (DAVOUDI *et al.*, 2012), (TAKAGI *et al.*, 1982), (JOHNS; JAMALI, 1990) e **Métodos baseados em Ondas Viajantes (O.V)** (GALE *et al.*, 1993), (LOPES *et al.*, 2013).

2.4.1 Métodos baseados em Componentes de Frequência Fundamental - CF

Os algoritmos baseados na análise de componentes de frequência fundamental são os mais utilizados pelas concessionárias de energia elétrica e mais difundidos na literatura, visto que são relativamente simples, baratos, requerem taxas de amostragem baixa e em geral, pouco esforço computacional. Nesta categoria, os métodos de um terminal de monitoramento foram os primeiros a surgir, cuja maior vantagem é a independência de sistemas de comunicação e da sincronização de dados.

Entre os métodos que utilizam um terminal para localização de falhas, destaca-se o proposto por Takagi *et al.* (1982). Embora este método tenha sido bastante empregado, apresenta a deficiência por assumir impedâncias de falhas puramente resistivas o que, dependendo da natureza do distúrbio, pode resultar em fontes de erros. Além disso, o algoritmo é baseado na versão mais simples do modelo de LT a parâmetros concentrados em que o ramo *shunt* capacitivo é desconsiderado. Assim, os efeitos capacitivos dos condutores não são considerados, o que ocasionam maiores erros nas localizações estimadas para falhas distantes do terminal monitorado.

Visando superar as deficiências apresentadas quando da utilização de somente um

terminal de monitoramento, Tziouvaras *et al.* (2001) propuseram técnicas considerando dois e três terminais de monitoramento, as quais respondem a partir de dados não sincronizados e sincronizados. Dentre as abordagens apresentadas, o método de dois terminais se destaca pela precisão e simplicidade, o que o fez ser, na última década, muito referenciado na literatura e utilizado em campo por várias concessionárias. A técnica faz uso de componentes simétricas de sequência negativa, evitando problemas com o fluxo de potência de pré-falta e com acoplamento mútuo de sequência zero entre fases. Por outro lado, o conhecimento dos parâmetros das LTs e das fontes equivalentes conectadas nas extremidades da linha monitorada são requeridos, o que limita a aplicação da técnica quando estes dados não se encontram disponíveis ou têm precisão duvidosa.

Recentemente, outros algoritmos de um terminal foram propostos, visando contornar as limitações acima relatadas (SALIM *et al.*, 2011). Os autores citados apresentaram um algoritmo que considera o efeito capacitivo da LT. Embora idealizado originalmente para sistemas de distribuição, este algoritmo pode ser aplicado também em LT sem perda de confiabilidade.

Visando minimizar a influência de imprecisões nos parâmetros da LT, várias técnicas foram propostas nos últimos anos (PRESTON *et al.*, 2011a); (HE *et al.*, 2011); (DAWIDOWSKI; IZYKOWSKI, 2011); (PRESTON *et al.*, 2011b). Essas abordagens foram formuladas para não requerer o conhecimento dos parâmetros do sistema. Esses métodos foram desenvolvidos de forma a promover o cancelamento ou o cálculo on-line dos parâmetros da LT necessários para localizar a falta, o que os tornam bastante robustos. No entanto, embora não necessitem dos parâmetros da LT, esses métodos ainda dependem da sincronização de dados, característica esta que limita a aplicação de tais técnicas em sistemas desprovidos de uma referência de tempo comum ou mesmo em casos nos quais o sinal desta referência é perdido.

Para contornar a necessidade da sincronização de dados, vários algoritmos têm sido propostos para localizar faltas em LT por meio de dados não sincronizados provenientes de dois ou mais terminais (GIRGIS *et al.*, 1992), (YU, 2010), (IZYKOWSKI *et al.*, 2011), (SAHA *et al.*, 2011). A grande maioria dessas soluções faz uso de processos iterativos para o cálculo dos ângulos de sincronismo entre as medições nos terminais local e remoto. Assim, embora permitam localizar faltas de forma muito precisa usando dados não sincronizados, os algoritmos são mais complexos e lentos, o que limita seu uso em aplicações em tempo real. No entanto, da literatura, sabe-se que já existem soluções não-iterativas para a localização de faltas via dados não sincronizados (IZYKOWSKI *et al.*, 2010), as quais são mais simples e requerem menor

esforço computacional, sendo passíveis de aplicação em tempo real.

2.4.2 Métodos baseados em Componentes de Alta Frequência - AF

Os métodos baseados em componentes de alta frequência fazem uso da extração de características do distúrbio por meio da análise espectral dos transitórios no período de falta ou logo após a sua isolação. De fato, quanto mais próximo forem os terminais monitorados da descontinuidade na LT, menor é o tempo de propagação das ondas viajantes entre o ponto de medição e a falta e, conseqüentemente, maior é a frequência dos sinais medidos. Assim, identificando-se a frequência dominante dos transitórios, torna-se possível estimar a localização da falta. Outras abordagens com essa mesma fundamentação utilizam a análise da frequência dominante dos sinais medidos nos terminais da LT após a injeção de pulsos elétricos nos condutores com defeito.

Algoritmos de monitoramento de um e dois terminais, baseados na identificação das frequências dominantes dos transitórios, foram propostos por Faybisovich *et al.* (2010), enquanto algoritmos que utilizam a injeção de pulsos elétricos na linha após o isolamento do defeito podem ser encontrados em Shi *et al.* (2010). Em se tratando de um terminal, Iurinic (2013) propôs um algoritmo na identificação da frequência dominante dos transitórios, durante o período de falta. Dentre as potencialidades desses métodos, destaca-se a possibilidade do uso de registros não sincronizados. Porém, é fácil perceber que são métodos mais apropriados para aplicações *off-line*, visto que requerem o conhecimento das tensões e correntes durante todo o período de falta e, além disso, são técnicas complexas e que necessitam de altas taxas de amostragem para a representação confiável das altas frequências e, em geral, requerem grande esforço computacional durante a análise espectral dos transitórios.

2.4.3 Métodos baseados em Inteligência Computacional - IC

Com o objetivo de superar fontes de erros típicos dos métodos clássicos de localização de faltas baseados na análise de componentes fundamentais, vários algoritmos que utilizam inteligência computacional têm sido apresentados nos últimos anos. Esses algoritmos são também conhecidos como métodos baseados no conhecimento e são fundamentados, basicamente, no reconhecimento de padrões em registros oscilográficos de faltas.

Como exemplos de algoritmos que utilizam a inteligência computacional, podem ser citados as redes neurais artificiais proposta por Chen e Maun (2000), Sadinezhad e Agelidis

(2009), os algoritmos genéticos (EL-NAGGAR, 2001), (DAVOUDI *et al.*, 2012) e a lógica nebulosa (lógica Fuzzy) (REDDY; MOHANTA, 2008). Embora apresentem bons desempenhos, esses métodos possuem aplicação restrita em campo, principalmente por consistirem em técnicas complexas com alto esforço computacional associado. Além disso, estes métodos são bastante dependentes das características do sistema monitorado e, portanto, requerem, em sua grande maioria, a atualização desses algoritmos sempre que ocorrem alterações na configuração do SEP sob análise.

2.4.4 Métodos baseados em Ondas Viajantes - OV

O uso da TOV para fins de diagnóstico de distúrbios elétricos é antigo (BEWLEY, 1931). Conforme mencionado pela American Institute of Electrical Engineers (AIEE), os primeiros trabalhos que fundamentaram métodos desse tipo são da década de 1930, os quais motivaram inúmeras outras pesquisas nas décadas seguintes.

Em 1978, foram apresentados os primeiros conceitos de proteção, associados à análise de transitórios eletromagnéticos, em forma de ondas viajantes, geradas pela própria falta (DOMMEL, 1996). No entanto, por necessitarem de altas taxas de amostragem, para medição apropriada dos transitórios, essas técnicas se popularizaram apenas em anos recentes, após o advento da tecnologia digital e a inclusão de técnicas de processamentos digitais de sinais, que resultou no aumento das taxas de amostragens dos Registradores Digitais de Perturbação (RDP) e relés digitais.

Em 1993, foram apresentados os métodos baseados na TOV, classificados em grupos, dentre os quais as principais diferenças são relativas à utilização de ondas refletidas no ponto de falta, ao número de terminais monitorados e à utilização de pulsos elétricos para a localização do defeito (GALE *et al.*, 1993). Estes autores afirmam que, embora não necessitem da sincronização de dados, métodos de um terminal de monitoramento são mais susceptíveis a erros, uma vez que dependem da detecção, no ponto de falta, de ondas refletidas, as quais, em alguns casos, podem ser confundidas com ondas refratadas em pontos remotos do SEP.

Portanto, mesmo fazendo-se necessária a sincronização de dados, os métodos de dois terminais baseados nos transitórios de falta, ou seja, que não requerem o uso de pulsos elétricos, são referenciados como sendo os mais simples, robustos e menos susceptíveis a erros, pois necessitam apenas da detecção do instante de chegada das primeiras ondas eletromagnéticas aos terminais da LT.

Na década de 1990, os métodos baseados na TOV consolidaram-se através de vários trabalhos (JIAN *et al.*, 1998). Um novo equacionamento para métodos de dois terminais de monitoramento, nos quais são consideradas a velocidade de propagação distinta para as ondas viajantes progressivas e regressivas foi proposto.

Esse equacionamento se baseia na realização de uma análise espectral dos sinais medidos nos dois terminais da LT, através da qual são identificadas as frequências dominantes das ondas viajantes analisadas. Em seguida, uma vez conhecidos os parâmetros da LT, as velocidades de propagação para os trechos antes e depois do curto-circuito são estimadas separadamente, viabilizando a obtenção de estimativas mais precisas do ponto de falta. Como limitação do algoritmo, pode-se destacar o uso dos parâmetros da LT no cálculo das velocidades de propagação, bem como a realização da análise espectral dos sinais monitorados, que consistem em um procedimento geralmente lento, que neste caso, torna o algoritmo mais apropriado para aplicação *off-line*.

Visando superar as limitações apresentadas no equacionamento das análises espectrais, foi proposto por Gilany *et al.* (2007) um método de dois terminais para o monitoramento, sem requerer o conhecimento da velocidade de propagação das ondas viajantes. Porém, no algoritmo se faz necessária a detecção das ondas viajantes refletidas no ponto de falta, o que o torna tão susceptível a erros quanto à sua aplicação como técnica de um terminal.

Visando eliminar a utilização da velocidade de propagação da onda no cálculo do local do defeito, Feng *et al.* (2008) propuseram um eficiente algoritmo que embora preciso, necessita da utilização de registros oscilográficos de vários terminais. A análise de registros oscilográficos, provenientes de três pontos distintos do SEP pode se tornar um procedimento de localização de faltas mais complexo e lento, visto que os Registradores Digitais de Perturbações (RDPs) e relés digitais encontram-se geralmente, em subestações distantes entre si, dificultando a concentração das informações necessárias para a localização da falta.

Um esforço significativo tem sido dedicado nos últimos tempos ao desenvolvimento do método baseado na teoria das ondas viajantes para a localização e classificação de faltas em linhas de transmissão de energia (HASHEMINEJAD *et al.*, 2016);(ZHANG *et al.*, 2016).

2.5 Modelagem das Linhas de Transmissão sob Diferentes Condições de Falta

Esta seção tem como objetivo descrever os principais modelos de linhas de transmissão de alta tensão para a localização de falta. Os modelos serão apresentados com o objetivo de

ressaltar as características relevantes das LTs para a localização e identificação das faltas.

2.6 Modelos de Linha de Transmissão

O processo de desenvolvimento dos métodos de localização de faltas possuem relação direta com os modelos de LTs. De fato, estes métodos podem representar os fenômenos associados à transmissão de energia elétrica de forma mais completa ou simplificada, de tal maneira que, dependendo do modelo tomado como base para a elaboração do método, o processo de localização de faltas pode apresentar mais ou menos precisão. Neste contexto, sabe-se que os métodos de localização disponíveis na literatura se baseiam predominantemente, em dois modelos de LTs: **Modelos à parâmetros concentrados e Modelos à parâmetros distribuídos** (SAHA *et al.*, 2010), cujos fundamentos básicos são descritos a seguir.

2.6.1 Modelos à Parâmetros Concentrados

Quando utilizado o modelo da LT a parâmetros concentrados, em sua versão mais simples, a linha é representada apenas por sua impedância série Z_L , a qual é calculada para uma dada frequência que, normalmente, é a frequência fundamental do SEP. Com isso, o efeito capacitivo da LT é desprezado, de forma que este modelo é considerado adequado apenas para a representação de LTs curtas, com comprimentos menores que 80 km (GLOVER *et al.*, 2009).

Como se sabe, a impedância série da LT é composta por uma resistência R_L e por uma reatância indutiva X_L , conforme ilustrado na Figura 5 (a), em que V_S e V_R são as tensões nos terminais S e R da LT, I_S e I_R são as correntes nos terminais S e R da LT, r e l são respectivamente, a resistência e indutância série da LT por unidade de comprimento, ℓ é o comprimento da LT e ω é a frequência angular fundamental do SEP (DOMMEL, 1996). Para sistemas trifásicos balanceados, Z_L é geralmente representada por uma matriz 3x3.


$$Z_L = \begin{bmatrix} Z_{aa} & Z_{ab} & Z_{ac} \\ Z_{ba} & Z_{bb} & Z_{bc} \\ Z_{ca} & Z_{cb} & Z_{cc} \end{bmatrix} = \begin{bmatrix} Z_P & Z_M & Z_M \\ Z_M & Z_P & Z_M \\ Z_M & Z_M & Z_P \end{bmatrix}. \quad (2.1)$$

Em que Z_P e Z_M são as indutâncias próprias e mútuas da LT que, para sistemas perfeitamente balanceados, são dados por: $Z_M = (Z_{L0} - Z_{L1})/3$, $Z_P = (Z_M + Z_{L1})$, sendo Z_{L0} e Z_{L1} as impedâncias de sequência zero e positiva da LT, respectivamente.

Para linhas de comprimento médio (tipicamente entre 80 e 250 km), é comum a inserção de admitâncias em derivação no modelo à parâmetros concentrados da LT. Geralmente as condutâncias dessas admitâncias são desprezadas, restando apenas as reatâncias capacitivas em derivação para representação do efeito capacitivo dos condutores. Uma prática comum é dividir a admitância em duas parcelas iguais, as quais são postas nas extremidades da LT, conforme ilustrado na Figura 5(b), onde Y_L representa a referida admitância, sendo g e c a condutância e a capacitância em derivação, respectivamente, por unidade de comprimento.

Vale destacar que neste modelo de LT, por serem considerados parâmetros concentrados, variações no terminal S da linha, são instantaneamente percebidos no terminal R, o qual não ocorre na prática, visto que as variações nas formas de onda medidas em uma extremidade da LT levam um determinado tempo para se propagarem ao longo dos condutores até que sejam percebidas no terminal oposto. Assim, para linhas com pequena extensão, esse tempo de propagação é muito pequeno, podendo ser na maioria dos casos desconsiderado, conforme realizado no modelo de LT a parâmetro concentrados. No entanto, para LT longas, faz-se necessário o uso de modelo mais precisos que contemplem essas propagações, a exemplo do modelo à parâmetros distribuídos apresentados a seguir.

Figura 5 – Modelo de LT a parâmetros concentrados. (a) linhas curtas ($\ell < 80 \text{ km}$); (b) linhas médias ($80 \leq \ell \leq 250 \text{ km}$).




Fonte: (ZANETTA, 2003).

2.6.2 Modelos à Parâmetros Distribuídos

Nos modelos a parâmetros distribuídos, a influência do comprimento dos condutores é considerada, incluindo-se, portanto, o efeito do tempo de propagação da LT, mencionado anteriormente. Assim, para calcular as tensões e correntes ao longo da LT, deve-se conhecer além das tensões e correntes, em pelo menos uma das extremidades da linha, a distância do ponto para o qual estão sendo calculadas as referidas grandezas elétricas (SAHA *et al.*, 2010).

Para ilustrar esse modelo, apresenta-se na Figura 6 o circuito equivalente de uma LT longa de comprimento ℓ , composto por vários elementos incrementais de uma LT monofásica de comprimento Δx , onde r , l e c representam respectivamente, a resistência série, a indutância série e capacitância em derivação, por unidade de comprimento. Na Figura 6, destaca-se o ponto X de medição a ser analisado, o qual se encontra localizado a uma distância x do terminal S e no qual é verificada uma tensão $v(x,t)$ e uma corrente $i(x,t)$.

Figura 6 – Modelo de LT a parâmetros distribuídos



Fonte: (ZANETTA, 2003).

Para um único elemento incremental da LT, a tensão $v(x,t)$ e a corrente $i(x,t)$ podem ser relacionadas aos parâmetros da LT por meio das expressões a seguir (NAIDU, 1985).

$$-\frac{\partial v(x,t)}{\partial x} = r.i(x,t) + l.\frac{\partial i(x,t)}{\partial x}. \quad (2.2)$$

$$-\frac{\partial i(x,t)}{\partial x} = g.v(x,t) + c.\frac{\partial v(x,t)}{\partial x}. \quad (2.3)$$

A solução das equações (2.2) resultam em um conjunto de expressões equivalentes popularmente conhecidas como equações telegráficas, que ditam as variáveis de $v(x,t)$ e $i(x,t)$ no espaço e tempo:

$$-\frac{\partial^2 v(x,t)}{\partial x^2} = rg.v(x,t) + (rc + lg).\frac{\partial v(x,t)}{\partial t} + lc.\frac{\partial^2 v(x,t)}{\partial t^2}. \quad (2.4)$$

$$-\frac{\partial^2 i(x,t)}{\partial x^2} = rg.i(x,t) + (rc + lg).\frac{\partial i(x,t)}{\partial t} + lc.\frac{\partial^2 i(x,t)}{\partial t^2}. \quad (2.5)$$

Para uma LT sem perdas (ou seja, $r = g = 0$), pode-se obter das expressões (2.3):

$$-\frac{\partial^2 v(x,t)}{\partial x^2} = lc \cdot \frac{\partial^2 v(x,t)}{\partial t^2}. \quad (2.6)$$

$$-\frac{\partial^2 i(x,t)}{\partial x^2} = lc \cdot \frac{\partial^2 i(x,t)}{\partial t^2}. \quad (2.7)$$

As quais são conhecidas como equações de ondas e correntes.

A solução geral do sistema de equações representado pelas expressões (2.4) pode ser representada de forma simplificada por:


$$v(x,t) = f_1\left(t - \frac{x}{v_p}\right) + f_2\left(t + \frac{x}{v_p}\right). \quad (2.8)$$

$$i(x,t) = \frac{1}{Z_c} \left[f_1\left(t - \frac{x}{v_p}\right) - f_2\left(t + \frac{x}{v_p}\right) \right]. \quad (2.9)$$

Em que $Z_c = \sqrt{\frac{l}{c}}$ e $v_p = \sqrt{\frac{1}{lc}}$ são a impedância e a velocidade de propagação das ondas, respectivamente para uma LT sem perdas.

Diante do exposto percebe-se que as expressões (2.5) representam a superposição de duas ondas, sendo as funções f_1 e f_2 interpretadas como ondas eletromagnéticas que viajam em sentidos opostos ao longo da LT. Considerando então que f_1 se propaga no sentido do terminal S para o R (aqui considerado sentido positivo de x) e f_2 no sentido do terminal R para o S (sentido negativo de x), f_1 e f_2 são denominados, respectivamente, de ondas progressivas e ondas regressivas, cuja polaridade e sentido de propagação são ilustrados na Figura 7.

Figura 7 – Ondas progressivas e regressivas




Fonte: (ZANETTA, 2003).

As variações nas tensões e correntes no ponto X da LT se propagam em forma de ondas eletromagnéticas ao longo dos condutores, o que explica o fato destas variações não serem percebidas instantaneamente nos terminais da LT monitorada. Conseqüentemente, quando analisadas LT longas, faz-se necessário o uso do modelo de linha à parâmetros distribuídos para contemplar tais características.

A análise de componentes de frequência fundamental em LT longas pela avaliação das grandezas desacopladas foi proposta por Glover *et al.* (2009). Para tais análises, o circuito equivalente apresentado na Figura 6 é geralmente substituído pelo circuito ilustrado na Figura 8.

Figura 8 – Modelo da LT a parâmetros distribuídos para a i -ésima componente simétrica



Fonte: (ZANETTA, 2003).

Na análise do circuito da Figura 8, a i -ésima componente é considerada na análise proposta por Saha *et al.* (2010), sendo $i = 2$ a sequência negativa, $i = 0$ a sequência zero, γ_i a constante de propagação da LT para i -ésima componente de sequência:

$$\gamma_i = \sqrt{(r_i + j\omega l_i)(g_i + j\omega c_i)}. \quad (2.10)$$

A impedância característica da LT para a i -ésima componente de sequência é dada por:

$$Z_{ci} = \sqrt{\frac{r_i + j\omega l_i}{g_i + j\omega c_i}}. \quad (2.11)$$

Sendo r_i , l_i , g_i e c_i a resistência série, indutância série, condutância em derivação e capacitância em derivação, respectivamente, por unidade de comprimento, para i -ésima componente de sequência.

Para uma LT perfeitamente transposta, usando o modelo de linha ilustrado na Figura 8, as componentes fundamentais de tensão e corrente no ponto X podem ser calculadas a partir

da medições no terminal S usando o modelo abaixo, conforme (GLOVER *et al.*, 2009).

$$\begin{bmatrix} V_{xi} \\ I_{xi} \end{bmatrix} = \begin{bmatrix} \cosh(\gamma i_x) & -Z_{ci} \sinh(\gamma i_x) \\ \frac{-1}{Z_{ci}} \sinh(\gamma i_x) & \cosh(\gamma i_x) \end{bmatrix} \begin{bmatrix} V_{Si} \\ I_{Si} \end{bmatrix}. \quad (2.12)$$

Sendo V_{xi} e I_{xi} os fasores das componentes fundamentais das tensões e correntes respectivamente, a uma distância x do terminal S (ponto X) para i -ésima componente de sequência.

Conforme mencionado anteriormente, as tensões e correntes no ponto X dependem da distância x do terminal S . Portanto, por meio desse modelo de LT de parâmetros distribuídos é possível avaliar as tensões e correntes do sistema monitorado sem desprezar os efeitos dos parâmetros da linha, cuja representação é imprescindível para o estudo de faltas em LT longas. Por isso, os principais modelos de linhas apresentados nesta subseção têm sido essenciais para a modelagem das técnicas de detecção de transitórios das LTs dessa pesquisa.

2.7 Técnicas para Detecção de Transitórios

Dentre as técnicas existentes para detecção de transitórios, a Transformada Wavelet Discreta (TWD) (SAHA *et al.*, 2010), e sua versão denominada Transformada Wavelet Discreta Redundante (TWDR), têm sido largamente utilizadas para detecção de transitórios de faltas em SEP (PERCIVAL; WALDEN, 2000). Em 2010, foi apresentada uma interessante análise da aplicabilidade da TWD e TWDR como ferramentas de suporte para o diagnóstico de distúrbio em SEP (COSTA, 2010). Embora a TWD seja mais popular, a TWDR foi a técnica mais adequada para detecção de transitórios, visto que esta não utiliza o processo de subamostragem de 2 (redução do número de coeficientes Wavelet gerados pela metade) requeridas pela TWD, a qual resulta em perdas na resolução dos sinais no tempo (COSTA, 2014). Ainda assim, independentemente das peculiaridades de cada técnica, a TWD e a TWDR superam algumas limitações verificadas em técnicas convencionais, pois permitem a análise de sinais digitais em diferentes níveis de resolução no tempo e na frequência (SAHA *et al.*, 2010).

Recentemente, a combinação de métodos tais como TW com Máquina de Vetores de Suporte (MVS) tem sido proposta para decompor sinais de tensões e correntes, associados aos sinais de falta (MALATHI *et al.*, 2010). Em se tratando de eficiência, estes métodos apresentam erros de estimação da localização de faltas entre 1% a 6%. Outros métodos usando a TW combinados com redes neurais, abordados por Ekici *et al.* (2008), no seu melhor desempenho, usando o critério da energia e entropia das wavelets no sinal de falta, apresentaram erros inferiores

a 1%. A fim de obter melhores resultados, a entropia wavelet tem sido adotada para reduzir o tamanho do vetor dos coeficientes de detalhe como um estágio de preparação para a classificação e localização da falta (EKICI, 2012). A TW combinada com Redes Neurais Artificiais (RNA) e Support Vector Regression (SVR) também tem se destacado com boa acurácia na localização de faltas com erros inferiores a 1% (JAMIL *et al.*, 2014); (YUSUFF *et al.*, 2014).

Além da TW, encontram-se também na literatura outras soluções para a detecção de transitórios e a localização de faltas, as quais são: baseadas na análise dos coeficientes de correlação entre os registros de um, dois ou mais terminais (JAMALI; GHEZELJEH, 2004); (LIN *et al.*, 2008); no uso de filtro digitais (ZIMATH *et al.*, 2010); e no uso de técnicas baseadas em inteligência artificial (FUKUYAMA; UEKI, 1993), (KEZUNOVIC; RIKALO, 1996). Nesse contexto, sabe-se que a detecção de transitórios baseada no uso de filtros digitais tem apresentado desempenhos satisfatórios em campo (ZIMATH *et al.*, 2010). Porém, além de requerer o monitoramento em separado das fases do sistema, os filtros digitais apresentam atrasos e respostas em frequência com largura de banda limitada, o que pode comprometer, em alguns casos, o desempenho dos localizadores de faltas.

Embora muitos trabalhos sobre a detecção, localização e classificação de faltas em linhas de transmissão baseadas na TW tenham sido introduzidos na última década (FERREIRA *et al.*, 2016), apenas alguns dos trabalhos abordados empregam a Transformada de Stockwell (TS) com lógica Fuzzy, que efetivamente permitem uma análise detalhada dos sinais de falta com ruído (SAMANTARAY, 2013). Já as demais técnicas são pouco populares e têm apresentado aplicação limitada em campo, devido a complexidade e alto esforço computacional associado.

Nas Tabelas 2 a 4 são apresentados os resumos de alguns dos principais métodos de localização de faltas e de detecção de transitórios analisados nesta revisão bibliográfica, destacando-se as características mais relevantes de cada um.

Tabela 2 – Resumo da revisão bibliográfica referente a localização de faltas em LT

Referência	Método	NTM			Parâmetros da LT	Procedimento utilizado				Aplicação	
		1	2	3		PI	DT	AE	RP	RÑS	TR
(TAKAGI <i>et al.</i> , 1982)	CF	✓			✓					✓	✓
(SALIM <i>et al.</i> , 2011)	CF	✓			✓	✓				✓	
(JOHNS; JAMALI, 1990)	CF		✓		✓						✓
(GIRGIS <i>et al.</i> , 1992)	CF		✓		✓						✓
(TZIOUVARAS <i>et al.</i> , 2001)	CF		✓		✓					✓	✓
(YU, 2010)	CF		✓		✓	✓				✓	✓
(IZYKOWSKI <i>et al.</i> , 2010)	CF		✓		✓					✓	✓
(PRESTON <i>et al.</i> , 2011b)	CF		✓								✓
(HE <i>et al.</i> , 2011)	CF		✓								✓
(IZYKOWSKI <i>et al.</i> , 2011)	CF		✓		✓	✓				✓	
(DAWIDOWSKI; IZYKOWSKI, 2011)	CF		✓								✓
(SAHA <i>et al.</i> , 2011)	CF		✓		✓	✓				✓	
(GALE <i>et al.</i> , 1993)	OV		✓				✓				
(JIAN <i>et al.</i> , 1998)	OV		✓		✓		✓	✓			
(GILANY <i>et al.</i> , 2007)	OV		✓				✓				
(FENG <i>et al.</i> , 2008)	OV			✓			✓				
(COSTA <i>et al.</i> , 2008)	OV		✓				✓				✓
(LOPES <i>et al.</i> , 2013)	OV		✓				✓			✓	✓
(HASHEMINEJAD <i>et al.</i> , 2016)	OV		✓				✓			✓	✓
(ZHANG <i>et al.</i> , 2016)	OV		✓				✓			✓	✓
(FAYBISOVICH <i>et al.</i> , 2010)	AF	✓						✓		✓	
(SHI <i>et al.</i> , 2010)	AF	✓						✓		✓	
(IURINIC, 2013)	AF	✓						✓		✓	
(CHEN; MAUN, 2000)	IC	✓			✓				✓	✓	
(EL-NAGGAR, 2001)	IC	✓			✓				✓	✓	
(REDDY; MOHANTA, 2008)	IC	✓			✓				✓	✓	
(SADINEZHAD; AGELIDIS, 2009)	IC	✓			✓				✓	✓	
(DAVOUDI <i>et al.</i> , 2012)	IC		✓		✓				✓	✓	

Fonte: Autor próprio

Tabela 3 – Legenda

Legenda	
CF = Métodos baseados em componentes fundamentais	OV = Métodos baseados em Ondas viajantes
AF = Métodos baseados em componentes de alta frequência	IC = Inteligência Computacional
RÑS = Registros Oscilográficos não sincronizados	AE = Análise Espectral de Sinais
NTM = Número de terminais monitorados	PI = Processos Iterativos
RP = Reconhecimento de Padrões	TR = Tempo Real
DT = Detecção de Transitórios	

Fonte: Autor próprio

Tabela 4 – Resumo da revisão bibliográfica referente a detecção de transitórios

Referência	Técnica Empregada
(COSTA, 2010)	TWD e TWDR
(COSTA <i>et al.</i> , 2008)	TWD + Energias Janeladas
(COSTA, 2014)	(TWD e TWDR) + Energias Janeladas
(LOPES <i>et al.</i> , 2011)	TDQ
(LOPES <i>et al.</i> , 2013)	TDQ + Energias Janeladas
(JAMALI; GHEZELJEH, 2004)	Coeficiente de correlação
(LIN <i>et al.</i> , 2008)	Coeficiente de correlação
(ZIMATH <i>et al.</i> , 2010)	Filtros digitais
(FUKUYAMA; UEKI, 1993)	Inteligência Artificial
(KEZUNOVIC; RIKALO, 1996)	Inteligência Artificial
(MALATHI <i>et al.</i> , 2010)	TW + MVS
(EKICI <i>et al.</i> , 2008)	TW + Inteligência Artificial

Fonte: Autor Próprio

2.8 Considerações Finais do Capítulo

Neste capítulo foram apresentados os métodos de detecção e localização de faltas, bem como modelos de linhas de transmissão, abordando os aspectos mais importantes para a aplicação dos algoritmos de detecção de faltas discutidos. Sabe-se da literatura e, como foi constante neste trabalho, que a presença de ruídos pode ser decisivo no sucesso dos métodos aplicados.

Embora não representado matematicamente nos modelos da LT, ou nos sinais apresentado no capítulo, sabe-se que existe uma parcela do sinal relacionado ao ruído que necessita de consideração. A presença de ruídos de natureza elétrica e ruídos não correlacionados com o sinal de falta podem ocasionar a detecção errônea dos transitórios para a localização de falta. Motivado por essa limitação dos métodos atuais com relação a presença do ruído no tratamento dos sinais de faltas, conforme apresentado na revisão bibliográfica, resumido nas Tabelas 2 e da Tabela 4.

Para superar a falta de métodos que tratem adequadamente a questão dos dados ruidosos, é proposto no próximo capítulo, a utilização de uma técnica de separação de sinais (Análise de Componentes Independentes - ACI) para a extração de características dos sinais transitórios de falta na localização e classificação de faltas em linhas de transmissão com e sem a presença do ruído nos dados.

3 ANÁLISE DE COMPONENTES INDEPENDENTES

3.1 Introdução

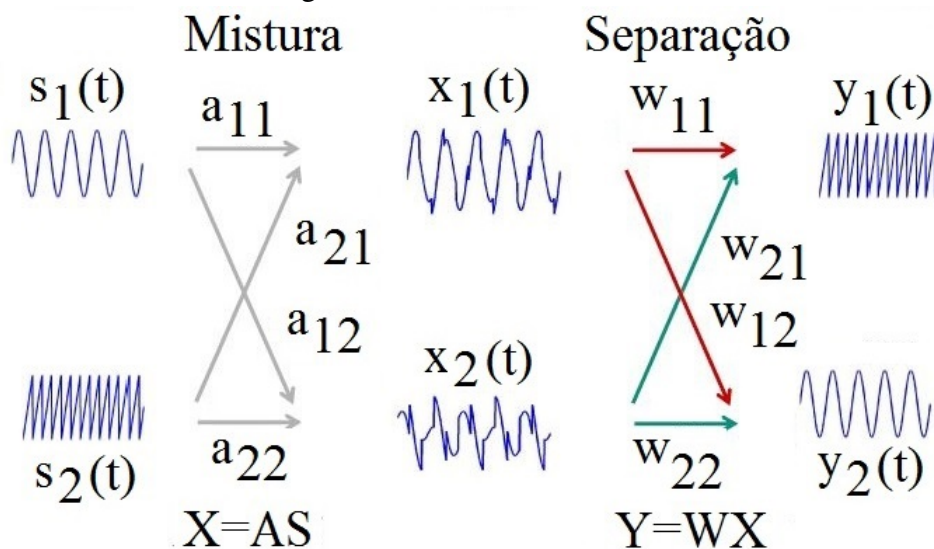
Neste capítulo são introduzidos os conceitos associados à Análise de Componentes Independentes ACI, fornecendo o suporte teórico e de terminologia ao longo do texto para o desenvolvimento e sua aplicabilidade no tratamento de sinais de faltas em LT. Na seção 3.2, aborda-se o conceito de ACI no contexto de separação cega de sinais. Na seção 3.3 apresenta-se o modelo estatístico sobre o qual a ACI se assenta, as ambiguidades e suas consequências. O processo de estimação das componentes independentes é abordado na seção 3.4. Na seção 3.5 analisa-se a negentropia como medida de não gaussianidade para a separação de sinais. Tendo em conta os conceitos apresentados nas seções anteriores, apresenta-se na seção 3.6, o pré-processamento da ACI, abordando do ponto de vista da teoria da informação e estimação. Na seção 3.7, estabelece-se o pré-processamento da ACI com suas propriedades, onde são revistos os conceitos de Análise de Componentes Principais (ACP) e ACI com técnicas estatísticas de projeções. Finalmente, as seções 3.8 e 3.9 abordam o algoritmo *FastICA* e outros tipos de algoritmos da ACI. Por fim, abordam-se as considerações finais para a aplicação da ACI, na extração de características dos sinais transitórios de faltas em linhas de transmissão.

3.2 Definição da ACI

A ACI (HYVARINEM *et al.*, 2001) refere-se a um conjunto de métodos de análise estatística, que se baseia na separação cega de sinais (*blind souce separation*), é uma generalização da ACP. O objetivo da ACI é separar sinais de diferentes fontes, todos misturados, em componentes independentes. A ACI vem sendo aplicada no cancelamento de ruído em aplicações da engenharia biomédica, de processamento digital de imagens e de extração de características de sinais para reconhecimento de padrões (CICHOCKI; AMARI, 2003). O exemplo clássico para ilustrar o problema de separação de sinais é conhecido como *cocktail party problem* (CICHOCKI; AMARI, 2003). Supondo que várias pessoas estão conversando em um salão de festa e, além disso, há música ambiente, pergunta-se: É possível separar cada uma das vozes e também a música da mistura sonora? Embora o cérebro humano consiga separar as fontes facilmente e identificar as diferentes origens, a tarefa não é tão simples e se trata de um problema no contexto de processamento digital de sinais.

O *cocktail party problem* pode ser solucionado usando-se ACI, desde que o número de microfones no ambiente seja, pelo menos, igual ao número total das fontes sonoras. Por exemplo, se em uma sala existem quatro pessoas, todas elas falando ao mesmo tempo e mais uma música ambiente, então, se houver pelo menos cinco microfones colocados em lugares aleatórios da sala, é possível separar os cinco sinais, analisando-se a saída dos cinco microfones. A Figura 9 ilustra o modelo da ACI.

Figura 9 – Duas fontes sonoras são gravadas simultaneamente por microfones distintos de modo que a saída de cada microfone seja uma mistura de duas fontes. A partir dessas duas misturas, a ACI consegue isolar as duas fontes.




Fonte: Autor Próprio

A ACI diferencia-se da ACP porque procura por componentes não-gaussianas que sejam estatisticamente independentes. Enquanto que a ACP minimiza a covariância do conjunto de amostras (dependência de segunda ordem), a ACI minimiza também dependências de ordem mais elevada. A Figura 10 apresenta uma comparação entre a ACI e a ACP em duas dimensões. A premissa básica da ACI é que as variáveis de interesse são independentes, ou seja, se duas ou mais variáveis são independentes entre si, então o valor de uma não diz nada a respeito do valor das outras, e, portanto, não há qualquer correlação entre elas. Em situações práticas é mais provável encontrar uma representação na qual as variáveis são dependentes, mas é possível encontrar componentes que são os mais independentes possíveis entre si.

O objetivo da ACI é decompor um dado sinal em uma combinação linear de sinais desconhecidos e independentes. Então, seja S o vetor de sinais desconhecidos e X o vetor de observação desses sinais. Se A é a matriz desconhecida, responsável pela mistura dos sinais

Figura 10 – Comparação entre a ACP e a ACI. Na ACP as componentes são ortogonais e no ACI são independentes.



Fonte: (HYVARINEM *et al.*, 2001)

(matriz de mistura), então $X = AS$. Supõe-se que os sinais desconhecidos são independentes e a matriz A é invertível. Baseando-se nessas suposições, a ACI tenta encontrar a matriz A ou matriz de separação W , tal que $Y = WX = WAS$. Em resumo, o objetivo deste modelo da ACI é permitir que se possa estimar a matriz de mistura A (ou funções bases), bem como a matriz de componentes independentes Y , somente observando X .

O modelo da ACI apresenta, no entanto, algumas ambiguidades no que diz respeito as componentes independentes:

- Não se pode determinar suas variâncias.
- Não se pode determinar sua ordem.

Tais ambiguidades se devem ao fato de A e S serem desconhecidos. Como consequência destas ambiguidades, não é possível determinar as energias ou amplitudes dos sinais, nem tampouco os sinais ou a ordem S_n .

3.3 Independência Estatística e Não Correlação de Variáveis

Duas variáveis são consideradas independentes quando o valor de uma não fornece informação acerca do valor da outra. Consideremos duas variáveis x_1 e x_2 . Essas variáveis são ditas independentes se, e somente se, x_1 não fornece nenhuma informação de x_2 e vice-versa. Matematicamente são descritas como:

$$p(x_1, x_2) = p(x_1) \cdot p(x_2). \quad (3.1)$$

Ou em outras palavras, a probabilidade conjunta de x_1 e x_2 é igual ao produto das

densidades marginais $p(x_1)$ e $p(x_2)$.

Duas variáveis x_1 e x_2 são descorrelacionadas se a sua covariância for igual a zero:

$$\text{cov}_{x_1, x_2} = E[(x_1 - u_1) \cdot (x_2 - u_2)] = 0. \quad (3.2)$$

Sendo u_1 e u_2 as médias das variáveis x_1 e x_2 , respectivamente.

3.4 Estimação das Componentes Independentes

A estimação das componentes independentes pode ser obtida através da matriz de mistura A . Utilizando notação matricial, pode-se reescrever a equação como:

$$S = A^{-1}X. \quad (3.3)$$

Sendo a matriz A desconhecida, a ideia principal por trás da ACI consiste em considerar que os sinais observáveis estão relacionados com os sinais originais, através de uma relação linear. Assim, os sinais originais podem ser obtidos a partir de uma transformação linear. Supondo, dessa forma, uma combinação linear de x_i , de tal modo que:

$$y = b^T X. \quad (3.4)$$

Sendo $X = AS$, pode-se escrever:

$$y = b^T AS. \quad (3.5)$$

Em que b corresponde a uma das linhas da inversa de A . Então y será uma das componentes independentes, e neste caso, apenas um dos elementos de b será igual a um, e todos os outros serão iguais a zero. No entanto, sendo X conhecido, b não pode ser determinado exatamente, porém pode-se estimar seu valor.

Uma forma de determinar y é variar os coeficientes em b e verificar como a distribuição de $y = b^T S$ muda. Como pelo Teorema do Limite Central (HYVARINEM *et al.*, 2001), a soma de duas variáveis aleatórias independentes é mais gaussiana que as variáveis originais, y é mais gaussiana que qualquer uma das s_n e menos gaussiana quando é igual a uma das s . Assim,

apenas um elemento q_i de q é diferente de zero. Na prática, os valores de q são desconhecidos, através das equações (3.4) e (3.5) tem-se que:

$$b^T X = q^T S. \quad (3.6)$$

Pode-se variar b e observar a distribuição de $b^T X$.

Dessa forma, pode-se tomar como b um vetor que maximiza a não gaussianidade de $b^T X$, sendo $q = A^T S$, contendo apenas uma de suas componentes diferentes de zero. Isso significa que a equação (3.4) é igual a uma das componentes independentes e a maximização da não-gaussianidade de $b^T X$ permite encontrar uma das componentes.

3.5 Negentropia como Medida de Não Gaussianidade

A entropia de uma variável aleatória está relacionada com a quantidade de informação que essa variável possui, sendo maior quanto mais for imprevisível a variável. Em se tratando de variáveis aleatórias, é denominada entropia diferencial. Se y é um vetor aleatório com a função densidade de probabilidade $f(y)$, a sua entropia diferencial é dada por:

$$H(y) = - \int f(y) \log f(y) dy. \quad (3.7)$$

Sabe-se que uma variável gaussiana tem a maior entropia dentre todas as variáveis aleatórias de igual variância (HYVARINEM *et al.*, 2001), uma versão modificada da entropia diferencial pode ser usada como medida de não gaussianidade. Tal medida é denominada negentropia, definida por:

$$H(y) = H(y_{gauss}) - H(y). \quad (3.8)$$

Sendo y_{gauss} , uma variável aleatória da mesma matriz de covariância que y , a negentropia é sempre não-negativa, e pode assumir zero se, e somente se, y tem distribuição gaussiana e é invariante para transformações lineares inversíveis.

Apesar de permitir que se possa medir a não-gaussianidade, a negentropia é de difícil estimação, sendo necessária sua estimação por aproximações através de momentos de alta ordem.

Assim:

$$J(y) \approx \frac{1}{12} E\{y^3\}^2 + \frac{1}{48} kurt(y)^2. \quad (3.9)$$

Sendo $Kurt(y)$ a curtose de y , definida como o momento de quarta ordem da variável aleatória y , expressa por:

$$kurt(y) = E\{y^4\} - 3(E\{y^2\})^2. \quad (3.10)$$

A variável aleatória y é assumida por ter média zero e variância unitária. Contudo, a validade de cada aproximação pode ser muito limitada. Em particular, essas aproximações sobre a falta de robustez encontrada com a curtose.

Para evitar os problemas encontrados com as aproximações de negentropia, novas aproximações foram desenvolvidas (HYVARINEM *et al.*, 2001). Essas aproximações foram baseadas no princípio da máxima entropia, obtendo-se a seguinte aproximação:

$$J(y) \approx \sum_{i=1}^p k_i [E\{G_i(y)\} - E\{G_i(v)\}]^2. \quad (3.11)$$

Sendo k_i constantes positivas e v uma variável gaussiana de média zero e variância unitária (normalizada). Também assume-se que a variável y tem média zero e variância unitária e as funções G_i são algumas funções não-quadráticas. Observando que mesmo nesse caso a aproximação não é muito precisa, a equação (3.11) pode ser utilizada para produzir uma medida de não gaussianidade que é consistente no sentido de que é sempre não-negativa e igual a zero se y tiver uma distribuição gaussiana.

$$J(y) \approx [E\{G_i(y)\} - E\{G_i(v)\}]^2. \quad (3.12)$$

Para praticamente qualquer função não-quadrática, G é claramente uma generalização da aproximação baseada em momentos estatísticos na equação (3.9), se y é simétrica. Fazendo $G(y) = y^4$, obtém-se exatamente a equação (3.12), isto é, a aproximação baseada em curtose.

Mas a questão é que escolhendo-se G de forma inteligente, pode-se obter aproximações da negentropia que são muito melhores que a dada pela equação (3.9). Escolhendo-se G de

modo que não cresça muito rápido, obtêm-se estimadores mais robustos. A seguinte escolha de G tem-se mostrado muito útil:

$$G_1(u) = \frac{1}{a_1} \log \cosh a_1 u, \quad G_2(u) = -\exp(-u^2/2). \quad (3.13)$$

Sendo $1 \leq a_1 \leq 2$ uma constante adequada. Então, pode-se obter aproximações de negentropia que permitem um melhor compromisso entre as propriedades das duas clássicas medidas de não-gaussianidade, curtose e negentropia. Elas são simples, rápidas de calcular e têm propriedades estatísticas atraentes, especialmente a robustez. Portanto, pode-se utilizar estas funções nos algoritmos da ACI.

3.6 Pré - processamento da ACI

Antes dos algoritmos da ACI serem aplicados nos dados é extremamente útil algum pré-processamento. A utilização destas técnicas torna o problema de estimação da ACI mais simples e mais bem condicionada.

3.6.1 Centralização

O pré-processamento mais básico, que, porém, tem uma boa contribuição na simplificação da teoria envolvida para o algoritmo da ACI, é a centralização da variável observada x .

Sem perda de generalidade, pode-se assumir que as componentes independentes de x tem média zero. Esta centralização é feita subtraindo o valor do vetor média $m = Ex$, dessa forma fazendo x ter média zero. Isto implica que S também terá média zero, como pode ser visto:

$$E\{S\} = A^{-1}E\{x - m\}. \quad (3.14)$$

Este procedimento é feito somente para simplificar os algoritmos da ACI, o que não significa que a média não pode ser estimada. Depois que a matriz de mistura A é estimada com o dado centralizado, pode-se então completar a estimação adicionando o vetor média de S de volta para o vetor estimado de S centralizado. O vetor média de S é dado por $A^{-1}m$, onde m é a média que foi subtraída no pré-processamento.

3.6.2 Branqueamento

Outro pré-processamento útil para a ACI é o branqueamento das variáveis observadas. Embora seja um pouco mais complexo de ser calculado do que a etapa de centralização, é simples de ser implementado e ajuda a reduzir consideravelmente a complexidade da ACI.

Antes da aplicação do algoritmo da ACI, e depois da centralização, deve-se transformar o vetor observado x linearmente de forma que se obtém um novo vetor, seus componentes são descorrelacionados e suas variâncias iguais a um. Em outras palavras, a matriz de covariância de \tilde{x} é igual à matriz identidade.

$$E\{\tilde{x}\tilde{x}^T\} = I. \quad (3.15)$$

A transformação do branqueamento é sempre possível. Um método popular de realizar o branqueamento é utilizar a decomposição por autovalor (EVD, do inglês *Eigenvalue Decomposition*) da matriz de covariância.

$$E\{xx^T\} = EDE^T. \quad (3.16)$$

Em que E é a matriz ortogonal de autovetores de $E\{xx^T\}$ e D é a matriz diagonal de autovalores $D = \text{diag}(d_1, \dots, d_n)$. Nota-se que $E\{xx^T\}$ pode ser estimada de um modo padrão da amostra disponível x_1, \dots, x_T . O branqueamento pode agora ser feito por:

$$\tilde{x} = ED^{-1/2}E^T x. \quad (3.17)$$

$D^{-1/2}$ é calculada por uma simples operação aplicada a cada elemento, como $D^{-1/2} = \text{diag}(d_1^{-1/2}, \dots, d_n^{-1/2})$. Então é fácil verificar que agora $E\{xx^T\} = I$.

O branqueamento transforma a matriz de mistura em uma nova, \tilde{A} ortogonal. Isto pode ser visto em:

$$\tilde{x} = ED^{-1/2}E^T A s = \tilde{A} s. \quad (3.18)$$

A utilidade do branqueamento está no fato da nova matriz de mistura \tilde{A} ser ortogonal. Isto pode ser visto em:

$$E\{xx^T\} = \tilde{A} E\{ss^T\} \tilde{A}^T = \tilde{A} \tilde{A}^T = I. \quad (3.19)$$

O branqueamento então reduz o número de parâmetros a serem estimados. Em vez de ter que estimar n^2 parâmetros que são os elementos da matriz de mistura A , somente é necessário estimar os parâmetros da nova matriz de mistura ortogonal \tilde{A} . Uma matriz ortogonal contém $n(n-1)/2$ graus de liberdade. Em duas dimensões, uma transformação ortogonal é determinada por um simples ângulo. Em dimensões maiores, uma matriz ortogonal contém somente metade do número de parâmetros de uma matriz arbitrária. Então, pode-se dizer que o branqueamento resolve metade dos problemas de ACI. Por ser muito simples e um procedimento padrão, é bem mais simples do que qualquer algoritmo da ACI e, uma boa maneira de reduzir a complexidade do problema.

Para exemplificar a técnica do branqueamento (HYVARINEM *et al.*, 2001), será apresentada uma ilustração gráfica do efeito do branqueamento, considerando duas componentes independentes que tem a seguinte distribuição uniforme:

$$p(S_i) = \begin{cases} \frac{1}{2\sqrt{3}} & \text{se } |S_i| \leq \sqrt{3}, \\ 0 & \text{caso contrário.} \end{cases} \quad (3.20)$$

A faixa de valores da distribuição uniforme foi escolhida de modo que tivesse média zero e variância igual a 1. A função densidade de probabilidade de s_1 e s_2 é então um quadrado uniforme, como pode ser visto na Figura 11, mostrando os dados aleatoriamente desenhados da distribuição.

Agora, misturando essas duas componentes independentes, utilizando a seguinte matriz de mistura:


$$A_0 = \begin{bmatrix} 2 & 3 \\ 2 & 1 \end{bmatrix}. \quad (3.21)$$

Gera-se então duas variáveis misturadas, x_1 e x_2 . Essa mistura tem uma distribuição uniforme no formato de um paralelogramo, visto na Figura 12. Essas variáveis aleatórias agora não são mais independentes, isso é facilmente percebido, de forma que é possível determinar o valor de uma pela outra. Em outras palavras, se x_1 atinge seus valores de máximo ou mínimo, é completamente possível determinar o valor de x_2 (o que não é o caso para as variáveis s_1 e s_2 na Figura 11, onde pode ser visto que, conhecendo o valor de s_1 , não existe nenhum modo de determinar o valor de s_2).

O problema da ACI é determinar a matriz A_0 , utilizando somente a informação contida das misturas x_1 e x_2 . Na Figura 12, observa-se um modo intuitivo de estimar a matriz A : as bordas do paralelogramo são as direções das colunas de A . Então o problema seria estimar a função densidade de probabilidade de x_1 e x_2 e, então, localizar as bordas.


Após um branqueamento das variáveis misturadas x_1 e x_2 têm-se como resultados a Figura 13, uma distribuição com formato quadrado que é claramente uma versão rotacionada da distribuição original na Figura 11. Tudo o que tem que ser feito, então, é estimar um simples ângulo, que gerou essa rotação.

Figura 11 – Distribuição conjunta das componentes independentes de s_1 e s_2 com distribuição uniforme. Eixo horizontal s_1 e vertical s_2 .



Fonte: (HYVARINEM *et al.*, 2001)

Figura 12 – Distribuição conjunta das misturas observadas de x_1 e x_2 . Eixo horizontal x_1 e vertical x_2 .



Fonte: (HYVARINEM *et al.*, 2001)

Figura 13 – Distribuição conjunta das misturas observadas de x_1 e x_2 branqueadas. Eixo horizontal x_1 e vertical x_2 .



Fonte: (HYVARINEM *et al.*, 2001)

Em determinadas aplicações, onde a quantidade de dados observáveis é muito grande, um pré-processamento que pode ser feito é a redução de dimensão dos dados, ao mesmo tempo em que é feito o branqueamento. Observando os autovalores d_j da matriz de covariância $C = E\{xx^T\}$, descarta-se aqueles muito pequenos, como é feito na técnica de análise de componentes principais. Uma das utilidades desse pré-processamento é que se tem uma redução do efeito do ruído.

3.7 Algoritmo *FastICA*

O algoritmo *FastICA* usa a técnica ACI através de iterações que buscam direções do vetor unitário w , nas quais as projeções $w^T x$ maximizam a não-gaussianidade (HYVARINEM *et al.*, 2001). A medida da não-gaussianidade é feita pela aproximação da negentropia $J(w^T x)$ dada pela equação (3.12). Lembra-se que a variância de $w^T x$ deve ser unitária, para o branqueamento, isto é, equivalente a fazer a norma de w ser unitária.

O algoritmo pode ser definido por uma aproximação do método de Newton (HYVARINEM *et al.*, 2001), chamando de g a derivada da função não-quadrática G usada na equação (3.12), como exemplo, as derivadas das funções na equação (3.13):

$$g_1(u) = \tanh(a_1 u). \quad (3.22)$$

$$g_2(u) = u \exp(-u^2/2). \quad (3.23)$$

Sendo $1 \leq a_1 \leq 2$ uma constante adequada. Frequentemente faz-se $a_1 = 1$. O algoritmo básico *FastICA* é mostrado a seguir:

Algoritmo: FastICA

- 1:** Define-se valores iniciais para o vetor peso w (geralmente de forma aleatória)
 - 2:** Seja: Sendo: $w^+ \leftarrow E\{xg(w^T x)\} - E\{g'(w^T x)\}w$.
 - 3:** Sendo: $w \leftarrow w^+ / \|w^+\|$.
 - 4:** Se não convergir, volta para o passo **2**.
-

Pode-se notar que a convergência significa que os valores antigos e os novos de w apontam na mesma direção, ou seja, o produto interno é igual a 1. A mesma direção não significa necessariamente o mesmo ponto, pois w e $-w$ apontam para a mesma direção. Este fato, é novamente causado porque as componentes independentes podem ser definidas somente sem certeza do valor original do escalonamento, ou seja, estima-se apenas o valor absoluto, sem certeza do sinal e de alguma possível constante multiplicativa. Também é assumido que o sinal é branqueado.

Observa-se que a máxima aproximação da negentropia de $w^T x$ pode ser obtida de $E\{G(w^T x)\}$. De acordo com as condições de *Kuhn-Tucker* (HYVARINEM *et al.*, 2001), o valor ótimo de $E\{G(w^T x)\}$ sob o contraste $E\{(w^T x)^2\} = \{|w^2| = 1\}$ pode ser obtido no ponto onde:

$$E\{xg(w^T x)\} - \beta w = 0. \quad (3.24)$$

Tentando resolver esta equação pelo método de Newton, chamando a função do lado esquerdo da equação (3.24) de F , pode-se obter sua matriz Jacobiana $JF(w)$ como:

$$JF(w) = E\{xx^T g'(w^T x)\} - \beta I. \quad (3.25)$$

Para simplificar a inversão da matriz, faz-se então uma aproximação do primeiro termo na equação (3.25).

Desde que o dado é esférico, uma aproximação razoável pode ser: $E\{xx^T g'(w^T x)\} \approx E\{xx^T\}E\{g'(w^T x)\} = E\{g'(w^T x)\}$. Então a matriz Jacobiana torna-se diagonal e pode ser facilmente inversível. Dessa forma, pode-se obter a seguinte aproximação da iteração de Newton:

$$w^+ = w - [E\{xg\}(w^T x) - \beta w] / [E\{g'(w^T x)\} - \beta]. \quad (3.26)$$

Este algoritmo pode ser simplificado multiplicando ambos os lados da equação (3.26) por $\beta - E\{g'(w^T x)\}$, levando, depois de algumas simplificações algébricas, à iteração do *FastICA*. Na prática, as esperanças estatísticas em *FastICA* devem ser substituídas por suas estimações. As estimações naturais correspondem a médias amostradas. Idealmente, todo o dado disponível deve ser usado. Contudo isto não é uma boa alternativa devido o custo computacional. Então, um modo de estimar as médias é utilizar uma pequena amostra, cujo tamanho tem um considerável efeito na precisão das estimativas finais. Os pontos de amostra devem ser escolhidos separadamente em cada iteração. Se a convergência não for satisfatória, pode-se então incrementar o tamanho da amostra.

3.7.1 *FastICA para mais de um componente independente*

O algoritmo anterior calcula somente uma componente independente. Também é possível fazer o cálculo de todas as componentes independentes, executando o *FastICA*, tantas vezes quanto for o número de componentes independentes com vetores peso w_1, \dots, w_n . Porém, há o risco de diferentes vetores convergirem para o mesmo máximo local. Para evitar esse risco, devem-se descorrelacionar as saídas $w_1^T x, \dots, w_n^T x$ depois de cada iteração. A seguir são apresentados três métodos para realizar esta operação.

Um modo simples de se fazer a descorrelação é a ortogonalização deflacionária, baseada na descorrelação de Gram-Schmidt (HYVARINEM *et al.*, 2001). Então, pode-se estimar os componentes independentes um por um. Tendo que ser estimado p componentes independentes, ou p vetores w_1, \dots, w_p , executa-se o algoritmo de ponto fixo *FastICA* para w_{p+1} e depois, de cada etapa de iteração, subtrai-se de w_{p+1} as projeções $w_{p+1}^T w_j w_j$, $j = 1, \dots, p$ dos vetores p estimados anteriormente e então renormaliza-se w_{p+1} :

Algoritmo: *FastICA* para mais de um componente independente

1: Seja: $w_{p+1} = w_{p+1} - \sum_{j=1}^p w_{p+1}^T w_j w_j$.

2: Seja: $w_{p+1} = w_{p+1} / \sqrt{w_{p+1}^T w_{p+1}}$.

Contudo, em certas aplicações pode ser desejado utilizar uma descorrelação simétrica, onde nenhum vetor é privilegiado (HYVARINEM *et al.*, 2001). Pode-se fazer isso por métodos

clássicos, envolvendo raízes quadradas de matriz.

$$\text{Seja } W = (WW^T)^{-1/2}W. \quad (3.27)$$

W uma matriz $(w_1, \dots, w_n)^T$ de vetores, a raiz quadrada inversa $(WW^T)^{-1/2}$ é obtida da decomposição de autovalores de $WW^T = FDF^T$ como $(WW^T)^{-1/2} = FD^{-1/2}F^T$. Uma alternativa simples, de um algoritmo iterativo é apresentado no que segue (HYVARINEM *et al.*, 2001).

Algoritmo: *FastICA* para mais de um componente independente

1: Seja: $W = W / \sqrt{\|WW^T\|}$.

Repete o passo **2:** até a convergência

2: Seja: $W = \frac{3}{2}W - \frac{1}{2}WW^TW$.

A norma no passo 1 pode ser praticamente qualquer norma matricial, em geral norma 2 ou o somatório da maior linha absoluta (ou coluna) (menos a norma de Frobenius).

3.8 Algoritmos da ACI

Os atuais algoritmos de ACI podem ser divididos em duas categorias. Os algoritmos da primeira categoria baseiam-se em computação *batch*, minimizando ou maximizando alguns relevantes critérios das funções (HYVARINEM *et al.*, 2001).

A segunda categoria inclui os algoritmos adaptativos, frequentemente baseados no método do gradiente estocástico, cuja estrutura pode ser alterada ou ajustada de tal forma que o comportamento ou o desempenho satisfaça algum critério desejado, podendo ser treinado para executar uma filtragem específica e tomar decisões. Uma maneira de estimar o método da ACI é encontrar uma transformação que minimize a informação mútua entre as componentes, onde a informação mútua é uma medida natural de dependência entre as variáveis aleatórias.

Após escolher um princípio de estimação para ACI, necessita-se de um método prático para sua execução. Muitos são os algoritmos para ACI com características distintas, baseadas na estabilidade e na velocidade de convergência. Alguns exemplos são: algoritmo

Héralten-Jutten; algoritmo de descorrelação linear, algoritmo para máxima probabilidade ou estimação *informax*; e algoritmos adaptativos (CICHOCKI; AMARI, 2003).

3.9 Considerações Finais do Capítulo

Neste capítulo estabeleceu-se a base teórica necessária para a implementação do algoritmo da ACI. A literatura necessária para a representação do método proposto foi discutida e os resultados da aplicação da ACI para extração de características dos sinais transitórios de falta na localização e classificação de faltas em linhas de transmissão serão apresentados nos próximos capítulos com as diferentes etapas que compõem a aplicação. Os dados de oscilografias de faltas e de um banco de dados de faltas simuladas em linhas de transmissão simuladas usando-se o software Alternative Transient Program (ATP) em que serão utilizados como caso de estudo para aplicação da TOV e do algoritmo *FastICA*.

O algoritmo *FastICA* foi implementado no Matlab para extrair as características dos sinais transitórios de faltas usando as funções bases da ACI. Para a localização das faltas as funções base da ACI foram combinadas com a TOV. Para a classificação das faltas utilizou-se ainda as funções bases da ACI combinadas com a MVS da biblioteca Library for Support Vector Machine (LibSVM) e a teoria do MDS aplicados aos sinais das faltas com e sem a presença do ruído.

4 ACI PARA EXTRAÇÃO DE CARACTERÍSTICAS DOS SINAIS TRANSITÓRIOS DE FALTAS EM LT

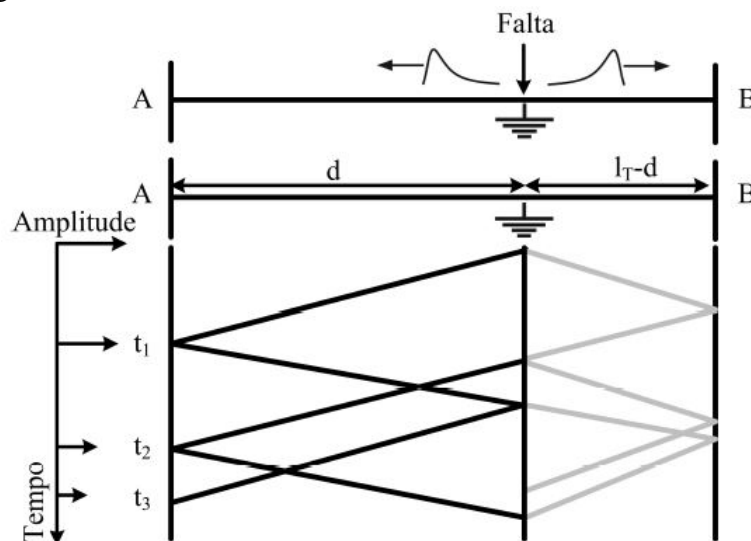
4.1 Introdução

Este capítulo tem como objetivos mostrar a aplicação da ACI com a TOV para a extração de características dos sinais transitórios de faltas na localização de faltas e a combinação da ACI com MVS e MDS na classificação de faltas em linhas de transmissão com e sem a presença do ruído.

4.2 Teoria das Ondas Viajantes - TOV

A TOV mostra que uma falta numa linha de transmissão produz ondas de tensão que se propagam a partir do ponto de falta nos dois sentidos da linha (NGU; RAMAR, 2011). Ao encontrar uma descontinuidade, essas ondas se refletem e retornam ao ponto de falta, onde haverá novas reflexões. Uma maneira prática de abordar o problema é através do diagrama de *Lattice*, como apresentado na Figura 14

Figura 14 – Diagrama de *Lattice*.



Fonte: (NGU; RAMAR, 2011)

O caminho de cada onda viajante pode ser facilmente seguida ao longo de sua trajetória de reflexão e refração. Assim, as características das ondas viajantes podem ser definidas em qualquer ponto da linha e instante de tempo (ABUR; MAGNAGO, 2000). Se a falta ocorrer na primeira metade da linha de transmissão em relação ao terminal de medição A, a distância

estimada entre o ponto de falta para o terminal de medição de um terminal é dado por:

$$d = \frac{v_c(t_2 - t_1)}{2}. \quad (4.1)$$

Se a falta ocorrer na segunda metade da linha, a distância entre o ponto de falta para o terminal de medição é dado por:


$$d = l_t - \frac{v_c(t_2 - t_1)}{2}. \quad (4.2)$$

Em que l_t é o comprimento total da linha de transmissão, enquanto t_1 e t_2 representam os intervalos de tempo da onda viajante da localização de falta para o terminal de medição e v_c é a velocidade de propagação das ondas viajantes, que é muito próximo a velocidade da luz, ou seja, 3×10^8 m/s, que é considerado para efeito de cálculo. Os modos de propagação podem ser separados usando a Transformada de Clarke ou Whedepohl (CLARKE, 1993).

4.3 Modelagem do Sistema de Transmissão Teste


Um banco de dados de tensão de faltas em linhas de transmissão foi adquirido de um oscilógrafo, instalado em uma linha de transmissão de energia elétrica. A linha de transmissão de alta tensão (500 kV, $f = 60\text{Hz}$) faz parte do sistema elétrico brasileiro da CHESF que, neste cenário, foi usado para modelagem dos sinais transitórios de faltas usados no estudo da pesquisa. A linha de transmissão em estudo é responsável por conectar a subestação de Presidente Dutra (PDT) e Boa Esperança (BEA). O comprimento total da linha de transmissão é de 200 km, cuja topologia consiste num arranjo de dois terminais, ou seja, terminal de medição (PDT) e o terminal remoto (BEA). As Figuras 15 e 16 representam, respectivamente, o diagrama esquemático do modelo adotado na análise de faltas na primeira metade da linha (F_1) e na segunda metade da linha (F_2), bem como a modelagem equivalente do sistema de transmissão usando a interface gráfica do software ATP (ATPdraw) (L; HOIDALEN, 2000).

Figura 15 – Diagrama unifilar do Sistema de Transmissão.



Fonte: (ONS, 2014)

Figura 16 – Modelagem do Sistema de Transmissão usando o ATP.



Fonte: Autor próprio


Na modelagem do sistema de transmissão com o uso do ATP foram inseridos os seguintes valores para a parametrização da linha e da torre de transmissão: $5,65mH/m$ para as reatâncias de sequência positiva e zero dos Geradores (G_1 e G_2) das subestações PDT e BEA; os parâmetros de indutância e capacitância de sequência positiva da linha de transmissão foram, respectivamente, $L_1 = 1,075mH/km$ e $C_1 = 10,805nF/km$, enquanto outros parâmetros da torre se encontram ilustrados na Figura 17.

A linha do sistema de transmissão foi modelada, usando o modelo de parâmetros distribuídos dependentes da frequência (modelo *Jmartí*) (MARTI, 1982) e a rotina LCC (Linhas e cabos constantes) do software ATP para a geração de um banco de dados com 7.680 situações de faltas considerando os principais tipos: Faltas monofásicas-terra (FMT), Bifásicas (FB), Bifásicas-terra (FBT) e Trifásicas (FT), com o objetivo de servir como dados de entrada para teste e treinamento, bem como para avaliação e desempenho do método proposto na pesquisa.

Os sinais transitórios de tensão do banco de dados de faltas foram amostrados na frequência de 200 kHz. Foram utilizados diferentes valores de distância de falta entre o ponto

Figura 17 – Parâmetros da Torre e da LT de 500 kV, $f = 60\text{Hz}$.

Arranjo das Fases	Configuração horizontal da Torre
Condutor Fase	
Altura da torre	24 m
Altura dos isoladores	12 m
Espaçamento entre as fases	11 m
Número de pára-raios	2
Raio dos sub-condutores	1.257 cm
Espaçamento dos sub-condutores	40 cm
Resistência DC	0.08998 Ω/km
Condutor Pára-raio	
Altura da torre	33 m
Altura dos isoladores	20 m
Espaçamento	16 m
Raio	0.4572 cm
Resistência DC	4.188 Ω/km



Fonte: (ONS, 2014)

de falta e o terminal de medição PDT, assim como diferentes valores de ângulos de incidência, resistência de falta, conforme apresentados na Tabela 5. O ruído foi adicionado ao sinal original da falta, a fim de verificar a robustez do método proposto. Considerando que os transformadores de corrente (TC) e potencial (TP) filtram os sinais de falta, o ruído foi adicionado ao sinal de falta no terminal PDT após a medição (TPC/TC). A relação sinal-ruído (SNR) do sinal de falta foi considerado entre 30 e 75 dB, dada por:

$$SNR(\text{dB}) = 10 \log \left(\frac{P_s}{P_n} \right). \quad (4.3)$$

P_s é a variação de potência do sinal e P_n é a potência de ruído. A fim de obter o banco de dados de faltas, foram utilizadas as condições descritas na Tabela 14.

Tabela 5 – Estudo de casos definidos para a LT de 500 kV

Tipo de Falta	FMT - FBT - FB e FT
Distância real (km)	10 - 16 - 45 - 84 - 90 - 128 - 147 - 155
Resistência de falta (Ω)	20 - 50 - 80 - 120 - 150 - 180 - 200 - 240
Ângulo de incidência (θ)	0° - 45° - 90° - 135° - 180° - 225° - 270° - 315°
SNR (dB)	30 - 35 - 40 - 45 - 50 - 55 - 60 - 65 - 70 - 75

Fonte: Autor Próprio


4.4 Transitórios em Sistemas Elétricos

Durante a falta, o relé é acionado isolando o trecho de ocorrência da falta. Os esquemas de proteção atuais permitem uma localização da falta com uma boa acurácia. Sabe-se

que os parâmetros de linha mudam durante a ocorrência da falta. Neste caso, três parâmetros que influenciam na localização da falta foram considerados, sendo eles: o ângulo de incidência de falta, a resistência de falta e a forma de onda das TOV (NGU; RAMAR, 2011).

A Figura 18 apresenta o sinal transitório de tensão de falta que ocorreu a 90 km do terminal de medição PDT. Neste caso particular, temos um falta FMT com ângulo de incidência de 90° e resistência de falta de 120Ω , representada na Figura 18 por uma janela de dados com um ciclo (16,67 ms) para uma frequência de amostragem de 200 kHz, onde os instantes dos picos de propagação das ondas viajantes, correspondentes a t_1 e t_2 , são evidenciados.

Figura 18 – Sinal Transitório de Falta.



Fonte: Autor próprio

Aplicando a equação (4.1) da TOV é possível determinar a distância da falta do ponto de falta ao terminal de medição PDT.

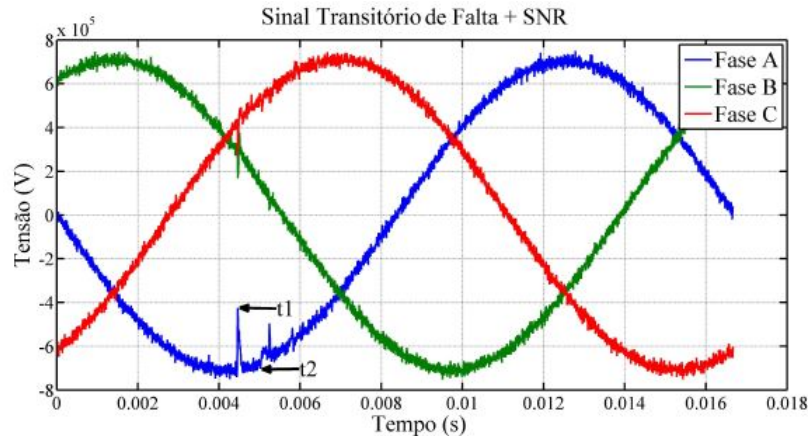
$$d = \frac{3 \times 10^8 \times (5.185 \times 10^{-3} - 4.4575 \times 10^{-3})}{2}. \quad (4.4)$$

$$d = 91,5 \text{ km}. \quad (4.5)$$

Este simples exemplo mostra que a TOV pode ser usada para determinar a localização da falta com relativa precisão com ausência de ruído no sinal transitório de falta.

No entanto, o problema geralmente se torna mais complexo com os dados de faltas corrompidos por ruídos. A Figura 19 ilustra esta situação.

Figura 19 – Sinal Transitório de Falta adicionado com ruído.



Fonte: Autor próprio

Aplicando novamente a equação (4.1) da TOV, observa-se que não foi possível determinar a distância com boa precisão, visto que os instantes dos picos t_1 e t_2 foram corrompidos devido à presença de ruído no sinal transitório de falta na estimação da falta, gerando uma localização de falta com baixa precisão da distância do ponto de falta ao terminal de medição PDT.

$$d = \frac{3 \times 10^8 \times (5.125 \times 10^{-3} - 4.46 \times 10^{-3})}{2}. \quad (4.6)$$

$$d = 99,75 \text{ km}. \quad (4.7)$$

Para superar esse problema, propõe-se nesta pesquisa a aplicação da ACI com a TOV para a extração de características dos sinais transitórios de falta para a localização de faltas e a aplicação de ACI com MVS e MDS para a classificação de faltas com e sem ruído.

4.5 Extração de Característica usando ACI

Por se tratar de processamento de sinais com ruído, técnicas baseadas em análise estatística devem ser utilizadas aplicando o conceito de **codificação eficiente** (HYVARINEM *et al.*, 2001).

O objetivo computacional da **codificação eficiente** é estimar, a partir das estatísticas do conjunto de padrões, um código compacto que reduza a redundância nos dados com uma

perda mínima da informação. Os dados são transformados por um conjunto de filtros lineares W em uma saída S na forma matricial:

$$S = WX. \quad (4.8)$$

Equivalentemente, em termos da matriz das bases $X = W^{-1}S = AS$, em que S é uma estimação das componentes independentes. Métodos para derivar o código eficiente no modelo da equação (4.8) podem ser obtidos pela análise de componentes independentes que é um modelo de distribuição estatística de um conjunto de padrões, sendo utilizada para encontrar as características (ou funções bases).

4.5.1 Aplicação da ACI na Extração de Características para a Localização de Falhas

O modelo de ACI é similar ao modelo de codificação eficiente de acordo com a equação (4.8). De forma geral, consideremos que x_i é uma mistura dos elementos com N observações, que são modeladas como uma combinação linear de s_{ji} , cujas funções base a_m são:

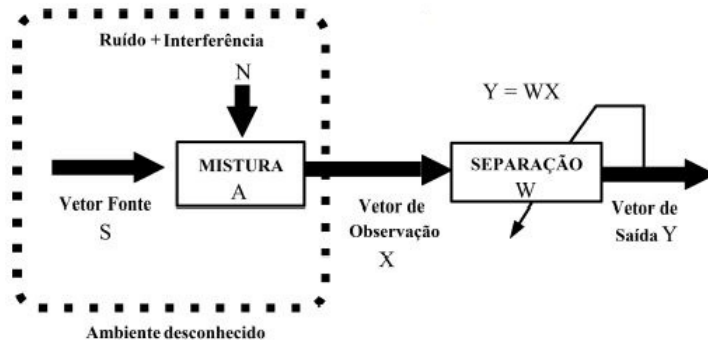
$$x_i = a_1s_{1i} + a_2s_{2i} + a_3s_{3i} + \dots + a_ms_{ji}. \quad (4.9)$$

Em que $j = 1 \dots m$ e s_{ji} é um vetor aleatório conhecido como vetor fonte. O vetor s_{ji} é aplicado a um sistema de mistura, cuja caracterização de entrada e saída é definida por uma matriz de mistura A . O sistema compreende o vetor fonte S e a matriz de mistura A que são completamente desconhecidos para o observador. Usando a notação de definição matricial, a equação (4.9) pode ser reescrita da seguinte forma:

$$X = AS. \quad (4.10)$$

Este modelo descreve como os dados são gerados desde o processo de mistura com os componentes independentes. O modelo simplificado visa estimar a matriz de mistura A , bem como as componentes independente S , simplesmente observando X . O modelo de ACI é baseada no problema de separação cega fonte (CICHOCKI; AMARI, 2003). O diagrama de bloco da Figura 20 descreve a computação da ACI, onde um ambiente desconhecido contém um conjunto de sinais fonte S sujeitos à ação do sistema de mistura A .

Figura 20 – Diagrama de blocos do modelo de ACI para extração de características.

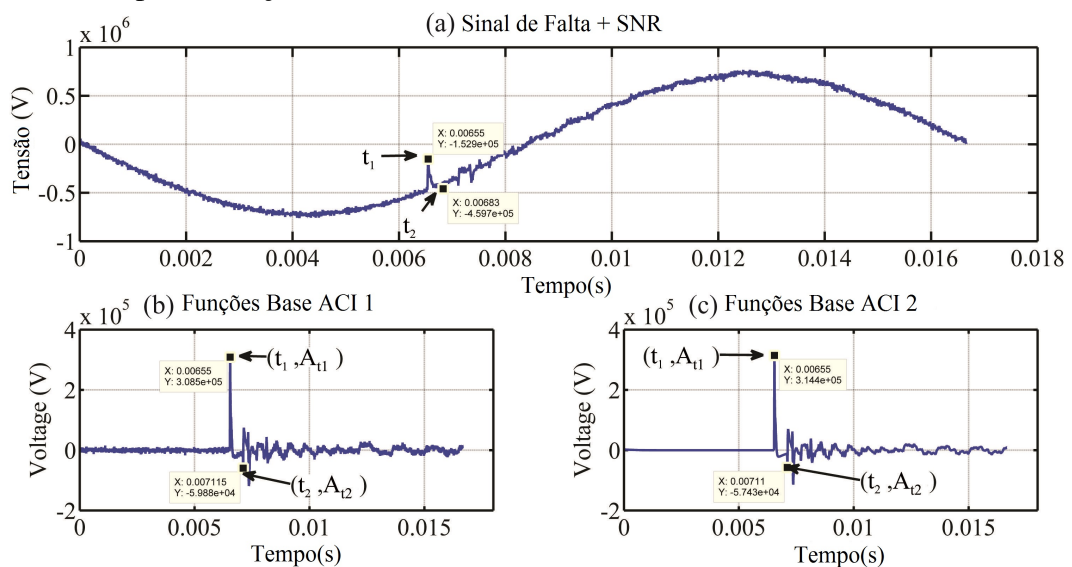


Fonte: (HYVARINEM *et al.*, 2001)

Da matriz de mistura A , é fornecido apenas o vetor de observação X e N que corresponde ao ruído adicionado ao processo, sendo o principal objetivo é estimar a matriz de separação W . Se a matriz de separação W é inversível, a estimação da ACI pode ser obtida $X = W^{-1}S$, que é equivalente a $X = AS$. Nesse caso, aplicando o algoritmo *FastICA* durante a sua execução, a saída do sistema Y deve ser capaz de fornecer as fontes do sinal com erros mínimos, ou seja, a saída deve ser determinada com $Y = WX$.

A Figura 21 apresenta graficamente o resultado da aplicação do algoritmo *FastICA* para a extração de características dos sinais transitórios de faltas para a localização de faltas.

Figura 21 – ACI para extração de características dos sinais transitórios de faltas.



Fonte: Autor próprio

O procedimento de extração das características dos sinais transitórios de faltas, usando o *FastICA* é explicado nos seguintes passos:

Algoritmo: Aplicação da ACI para extração de características dos sinais transitórios de faltas

1: O vetor de observação X é usado como entrada do algoritmo *FastICA*, que corresponde a uma falta FMT na fase A, com distância de falta de 84 km, ângulo de incidência de 135° , resistência de falta de 200Ω com ruído adicionado ao sinal transitório de falta de 30 dB de acordo com as condições listada na Tabela 14. De acordo com a Figura 21(a), os tempos de propagação são $t_1 = 0.00655s$ e $t_2 = 0.00683s$. Usando a equação (4.1), a localização da falta estimada foi de 42 km, com péssima precisão acima de 20%.

2: A aplicação do algoritmo *FastICA* com duas funções base da ACI para a detecção e extração de informações sobre as magnitudes do primeiro e segundo pico A_{t1} e A_{t2} , respectivamente e t_1 e t_2 , respectivamente.

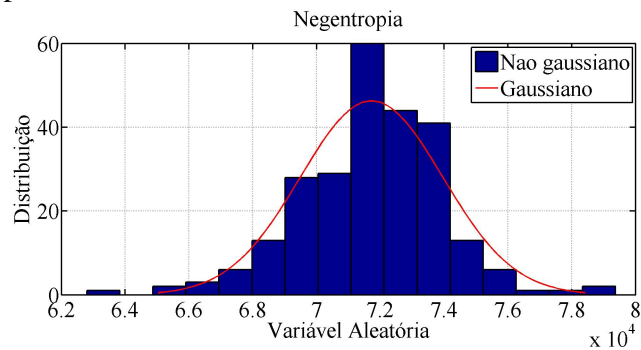
3: De acordo com a função base ACI 1, ilustrada na Figura 21(b), onde $t_1 = 0.00655s$ e $t_2 = 0.007115s$, aplicando a equação (4.1), ela nos fornece a localização da falta estimada de 84,75 km, apresentando uma boa precisão abaixo de 1% neste caso e verificou também que a extração de t_1 e t_2 ficaram bem evidentes apesar da presença do ruído no sinal transitório de falta.

4: De acordo com a função base ACI 2, ilustrada na Figura 21(c), onde $t_1 = 0.00655s$ e $t_2 = 0.00711s$, aplicando a equação (4.1), ela nos fornece a localização da falta estimada de 84 km, apresentando também uma excelente precisão, cujo valor é igual ao valor real da localização.

Na Figura 21 pode ser visto que as funções base da ACI são capazes de fornecer a magnitude do sinal transitório de falta. Isto se deve ao fato de que a negentropia é usada como critério de separação de sinais com distribuição super-gaussianos ($g(y) = \tanh(y)$) e sub-gaussianos ($g(y) = y - \tanh(y)$) obtidos durante o passo 2 do algoritmo *FastICA* para mais de uma componente independente que corresponde às funções bases estimadas. Nesse caso as funções bases atuam como um filtro para a separação de sinais do ruído. A Figura 22 ilustra a negentropia como critério de separação destes sinais apresentados na Figura 21.

Como a negentropia é uma medida estatística de alta ordem, abordado no capítulo 3, ela nos fornece o grau de informação contida numa variável aleatória, sendo usada, como uma estimativa de medição de não gaussianidade do sinal, que no caso em questão é o ruído adicionado ao sinal transitório de falta, que pode corromper o sinal original de falta. Portanto, para poder realizar a separação de sinais gaussianos e não gaussianos, o algoritmo *FastICA* deve ser executado repetidamente (ou seja, até que a dimensionalidade do banco de dados seja reduzido), para poder estimar a localização de falta com boa precisão em função do número de funções bases da ACI.

Figura 22 – Negentropia.



Fonte: Autor próprio

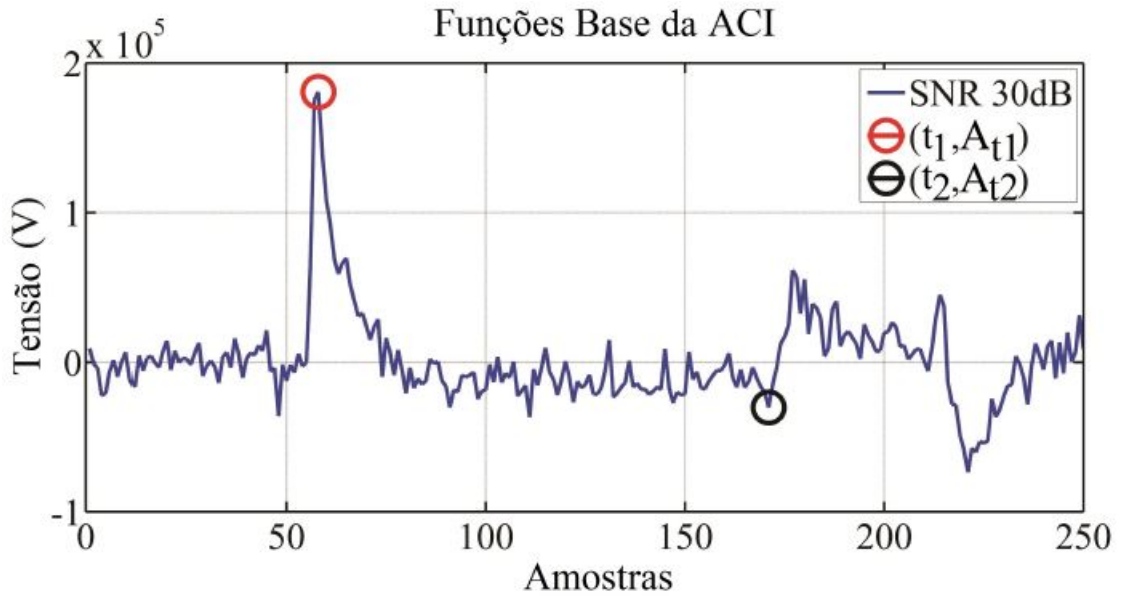
As funções bases da ACI são representadas pela matriz de mistura A determinada pelo algoritmo *FastICA*, que são compostas por cinco atributos usados para a extração de características dos sinais transitórios de falta na localização e na classificação. Nesta pesquisa, as funções de base ACI foram usadas com o conceito de **codificação eficiente** para reduzir a dimensionalidade do banco de dados de faltas de 7.680 para 250 padrões de sinais de falta. Portanto, a matriz de mistura A apresenta uma nova dimensão de 250×5 , sendo representada vetorialmente por:

$$A = [t_{1n} \ t_{2n} \ A_{t1} \ A_{t2} \ SNR]. \quad (4.11)$$

Onde os atributos característicos extraídos pelas funções bases da ACI são t_{1n} que representa o instante do primeiro pico da TOV, t_{2n} o instante do segundo pico reverso da TOV, A_{t1} a magnitude da amplitude do primeiro pico, A_{t2} a magnitude da amplitude do segundo pico e, finalmente, a SNR que representa o ruído do sinal. Na Figura 23 é ilustrada em detalhes t_1 , t_2 , A_{t1} , A_{t2} do vetor padrão características da função base da ACI para um sinal de falta FMT.


Seja X o vetor de observação, representando o banco de dados dos sinais de faltas com ruído e cada coluna na matriz A corresponde a uma determinada característica do sinal de falta. Cada elemento de S é um coeficiente que quantifica a importância de X . Usando X como entrada de treinamento, ACI aprende as funções bases das colunas da matriz A para fins de extração de características para que cada coeficiente do vetor S seja mutuamente, estatisticamente independente. Esta é principal vantagem da ACI. A **codificação eficiente** na extração de característica, ilustrada na Figura 24, corresponde ao espaço de características expandido do modelo matemático da ACI para a extração de características dos sinais de faltas para a localização de faltas.

Figura 23 – Detalhes da função base da ACI.



Fonte: Autor próprio

Figura 24 – Representação de uma falta utilizando o modelo ACI. Cada coluna da matriz A é uma característica e cada S_i é um coeficiente de características.



Fonte: Autor próprio

Observa-se na Figura 24, que as funções bases da ACI representam combinações de um conjunto representativo de funções no domínio do tempo e da frequência, que descrevem as características dos sinais transitórios de faltas (vetor fonte S) que compõem a mistura A de acordo o diagrama de blocos do modelo da ACI para extração de características visto na Figura 20. Por fim, a ACI visa obter as componentes independentes, em que uma única função base é capaz de extrair toda a informação necessária para a separação e detecção de sinais transitórios de faltas para realizar a localização de faltas em LT.

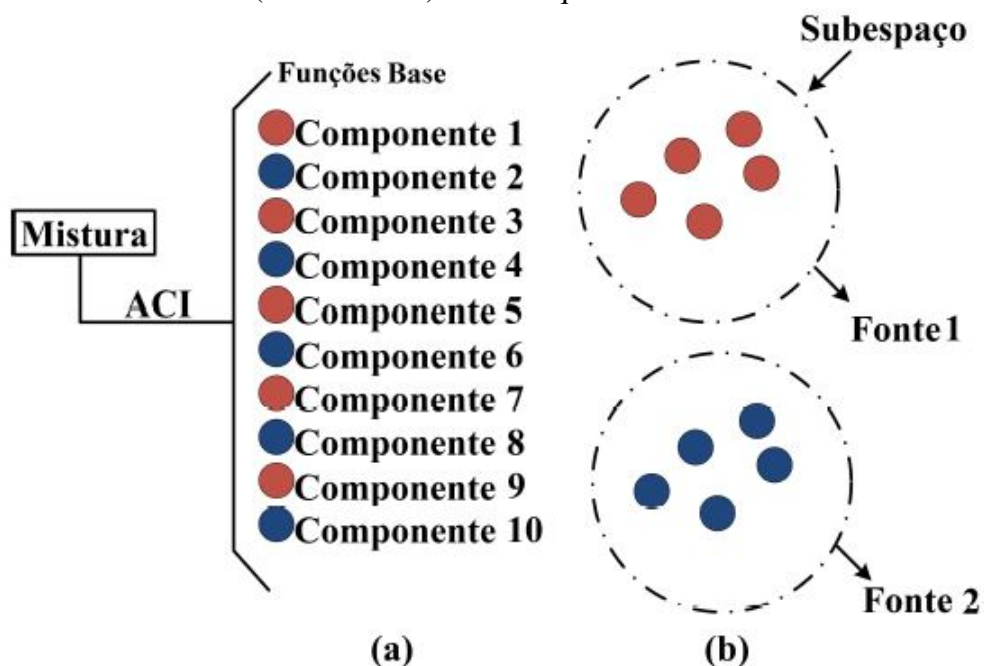
4.5.2 Aplicação da ACI na Extração de Características para a Classificação de Falhas

De acordo com a seção anterior, a ACI está relacionada com a **codificação eficiente** que reduz a redundância nos padrões com mínima perda da informação. Portanto, ela garante a eficácia associada à fase de extração de características dos sinais transitórios de falhas e de fornecer uma representação adequada dos dados originais, para então facilitar a tarefa de classificação de falhas.

Antes de executar a classificação de falhas com e sem a presença do ruído, precisa-se realizar então uma projeção das funções bases da ACI em subespaço, pois sabe-se que, o vetor fonte que compõe a mistura A precisa ser independente, conforme abordado na seção anterior. A independência agora é uma característica atribuída a um novo conceito chamado de subespaços independentes.

Um subespaço independente é um conjunto gerado pelas funções bases retornado pela ACI, o qual descreve o vetor fonte S (HYVARINEM *et al.*, 2001). Em outras palavras, as componentes resultantes da ACI podem ser agrupadas de forma que cada grupo gere subespaços diferentes. A Figura 25 demonstra a explicação de subespaço independente com um exemplo.

Figura 25 – Conceito de Subespaço Independente (a) - Supondo que a ACI retorne 10 funções base que caracterizam a mistura dada; (b) - Dois subespaços que descrevem cada uma das fontes (vetor fonte S) do sinal que estão contidos na mistura.



A Figura 25 representa um exemplo onde os subespaços independentes são usados como entradas para o classificador através de uma simples projeção do produto interno entre o vetor de observação X , usado no modelo da ACI que são o banco de sinais com ruído (X_{treino} e X_{teste}) e as suas funções bases da ACI. Do resultado dessa projeção foram obtidos novos vetores de treinamento e teste, que são, respectivamente, \tilde{X}_{treino} e \tilde{X}_{teste} , dados pelas equações (4.12) e (4.13), respectivamente.

$$\tilde{X}_{treino} = AX_{treino}. \quad (4.12)$$

$$\tilde{X}_{teste} = AX_{teste}. \quad (4.13)$$

Os novos parametros são:

$$\tilde{X}_{treino} = (x_{t1n}, x_{t2n}, x_{At1}, x_{At2}, x_{SNR}, \dots, x_M), \quad x_M \in R^M. \quad (4.14)$$

$$\tilde{X}_{teste} = (x_{t1n}, x_{t2n}, x_{At1}, x_{At2}, x_{SNR}, \dots, x_N), \quad x_N \in R^N. \quad (4.15)$$

M e N são características que descrevem uma assinatura específica para amostras que pertencem ao sinal fonte 1 (Classe 1) ou ao sinal fonte 2 (Classe 2).

Os vetores $x_{t1n}, x_{t2n}, x_{At1}, x_{At2}, x_{SNR}$ são: o instante do primeiro pico da TOV, o instante do segundo pico da TOV, amplitude do primeiro pico e segundo pico, o ruído e o número de amostras, respectivamente. Além disso, as amostras correspondem aos vetores normalizados X_{norm} que incluiu em $[0,1]$, sendo este um padrão característico para o tipo de falta, adotado para o treinamento e teste da entrada do classificador LibSVM (CHANG; LIN, 2001). Finalmente, a saída é representada por $Y_{out} = (+1, -1)$ onde $+1$ ou -1 indicam se a falta está sem e com a presença do ruído, respectivamente. O processo de normalização é realizado usando a equação (4.16).

$$X_{norm} = \frac{X_a - X_{min}}{X_{max} - X_{min}}. \quad (4.16)$$

X_a é uma determinada variável, enquanto X_{max} e X_{min} são os valores máximos e mínimos dos atributos característicos da falta, respectivamente. A tarefa de classificação da falta é realizada de acordo com os valores comentados, fornecidos pela biblioteca do algoritmo LibSVM.

4.5.3 Máquina de Vetores de Suporte - MVS

A Máquina de Vetores de Suporte - MVS é uma técnica muito útil para problemas de classificação e regressão de dados. Essa técnica, primeiramente proposta por Vapnik (1998), tem sido usada em muitas áreas relacionadas com muitos problemas de estimação, reconhecimento de padrão, regressão e previsão de dados, dentre outras áreas.

A MVS tem alto potencial para lidar com espaços de características muito grande, pois é robusta diante de objetos de grandes dimensões, como, por exemplo, imagens, e possuem uma base teórica bem estabelecida dentro da matemática e estatística.

Classificadores baseados em MVS são caracterizados por ter propriedades de boa capacidade de generalização, comparadas com classificadores convencionais, porque na etapa de treinamento do classificador MVS, o risco de erros de desclassificação é minimizado, considerando que classificadores tradicionais, geralmente, são treinados para que eventuais riscos empíricos sejam minimizados.

Para a solução de problemas de classificação não linear, a MVS pode ser aplicada usando as funções de Kernel. Para essa finalidade, os dados não lineares são mapeados em um espaço de alta característica dimensional onde a classificação linear seja possível.

O espaço de transformação não linear de entrada x para o espaço de características $\phi(x)$ é dado por:

$$\phi(x) = \phi_1(x), \phi_2(x), \dots, \phi_m(x). \quad (4.17)$$

Para mapear o vetor n -dimensional de entrada x para o espaço m dimensional de características, a decisão linear na forma dual é dada por:

$$f(x) = \sum_{j=1}^m \alpha_j y_j \phi^T(x_j) \phi(x). \quad (4.18)$$

Em que α_j é o multiplicador de Lagrange e y_j é o vetor de saída usando uma dada componente j .

Observa-se que na equação (4.18) os produtos internos são usados. Uma função que retorna como produto o mapeamento do espaço de características dos pontos de dados originais é chamada de função de Kernel $K(x, z) = \phi^T(x) \phi(z)$.

A aprendizagem no espaço de características não requer produtos internos onde uma função de Kernel é aplicada. Usando uma função de Kernel, a função de decisão pode ser escrita como:

$$f(x) = \sum_{j=1}^m \alpha_j y_j K(x_i, x). \quad (4.19)$$

Na literatura, há diferentes funções de Kernel onde o Teorema de Mercer afirma que uma matriz simétrica definida positiva pode ser considerada como uma matriz de Kernel. Nesta pesquisa, foram aplicadas as principais funções de Kernel da MVS como:

- I - Função linear: $K(x_i, x) = x_i^T x$.
- II - Função polinomial: $K(x_i, x) = (\gamma x_i^T x + r)^d, \gamma > 0$.
- III - Função de base radial (RBF): $K(x_i, x) = \exp(-\frac{\|x_i - x\|^2}{2\sigma^2})$.
- IV - Função de Sigmoid : $K(x_i, x) = \tanh(\gamma x_i^T x + r)$.

Onde σ é a largura da função gaussiana e γ, r, d são parâmetros de Kernel. A acurácia de classificação é calculada pela Taxa de Classificação (T.C) do modelo de MVS como:

$$(T.C) = \frac{\text{Dados corretamente preditos}}{\text{Dados de teste}} \times 100\%. \quad (4.20)$$

Na literatura, muitos softwares, usando o algoritmo da MVS têm sido desenvolvidos, tais como LibSVM, LightSVM, Ls-SVM entre outros. A LibSVM é considerada como a biblioteca mais eficiente de algoritmo MVS, sendo largamente aplicada em classificação de padrões, como descrito em (CHANG; LIN, 2001).

Nesta pesquisa, a LibSVM foi usada na classificação de faltas durante as etapas de treinamento e teste de cada novo subespaço (\tilde{X} treino e \tilde{X} teste) obtidos com as funções bases de ACI usando também a **codificação eficiente**. O objetivo há de melhorar a velocidade de processamento da MVS e da extração de características. Sabe-se na prática, que há muitos problemas no vetor de características, devido a alta dimensão e muitas variáveis de entrada, provocando um maior tempo de processamento na velocidade da MVS.

Portanto, vários métodos de extração de características têm sido propostos na literatura para resolver este problema, tais como a análise de componente principal (ACP), mapas auto-organizáveis, entre outros (JOLLIFFE, 2002)(MATSOPOULOS, 2010). Nesta pesquisa, propõe-se também a aplicação da ACI como extrator de características com a técnica do MDS combinada com a LibSVM para ter uma melhor visualização gráfica dos dados de faltas durante

as etapas de treinamento e teste, para poder então realizar a classificação de faltas com e sem ruído (BORG; GROENEN, 2005).

4.5.4 Escalonamento Multidimensional - MDS

A técnica do MDS é um tipo de representação gráfica de dados multivariáveis para representar em 2D ou 3D, a matriz de proximidade (semelhança ou dissemelhança) entre uma série de dados de modo que possam ser mais facilmente visualizados. A técnica MDS consiste de um método de otimização não linear que faz um mapeamento de dados em alta dimensão para baixa dimensão (BORG; GROENEN, 2005). O método se baseia em técnicas de representar um conjunto de observações por um conjunto de pontos em um espaço vetorial euclidiano real de baixa dimensão, para que as observações que são semelhantes às outras sejam representadas por pontos ou *clusters* que estão próximos, sendo que a informação de proximidade entre os dados é determinada com base em funções de distância euclidianas. O método pode ser descrito matematicamente da seguinte forma:

Dado um conjunto de n objetos $D = x_1, x_2, \dots, x_n, x_i \in R^N (i = 1, 2, \dots, n)$ no qual a função de distância é definida como $\delta_{i,j}$, a matriz de distância dos objetos n pode ser definida por:

$$\Delta := \begin{bmatrix} \delta_{1,1} & \delta_{1,2} \dots & \delta_{1,n} \\ \delta_{2,1} & \delta_{2,2} \dots & \delta_{2,n} \\ \delta_{n,1} & \delta_{n,2} \dots & \delta_{n,n} \end{bmatrix}. \quad (4.21)$$

$\delta_{i,j}$ é a distância euclidiana entre x_i e x_j , e o objetivo do MDS é encontrar Δ , para n vetores $p_1, \dots, p_n \in R^L (L \leq N)$, para a minimização do *STRESS* ou *SSTRESS*. A definição de *STRESS* ou *SSTRESS* é da seguinte forma:

$$\sigma(P) = \sum_{i < j} w_{i,j} (d_{i,j}(P) - \sigma_{i,j})^2. \quad (4.22)$$

$$\sigma(P) = \sum_{i < j} w_{i,j} ((d_{i,j}(P))^2 - \sigma_{i,j})^2. \quad (4.23)$$

$1 \leq i < j \leq n$, $w_{i,j}$ é um valor peso ($w_{i,j} > 0$); $d_{i,j}(P)$ é a distância euclidiana entre os resultados do mapeamento de p_i e p_j , que pode ser uma função de distância arbitrária ou

métrica. Em outras palavras, a técnica MDS tenta encontrar uma interpolação de objetos de n em R^L tal que as distâncias são preservadas.

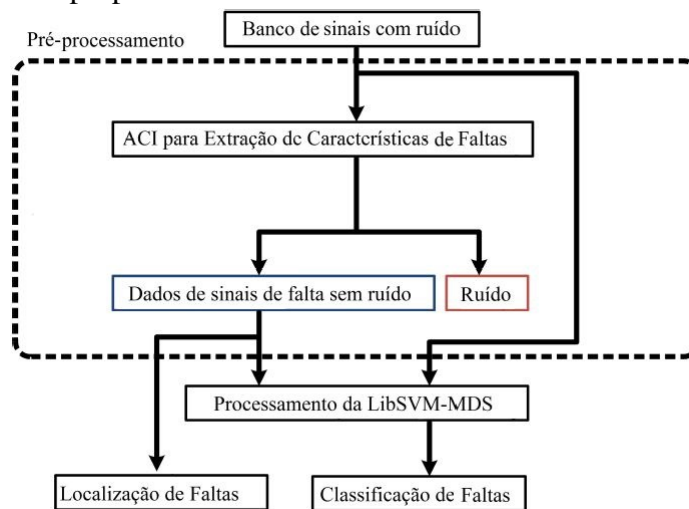
4.5.5 Aplicações do MDS

O MDS pode ser aplicado para a análise de dados de proximidade nas seguintes áreas (CHOI *et al.*, 2010):

1. Ciências sociais: dados de proximidade que assumam a forma de índices de similaridade para pares de estímulos como cores, sons, etc;
2. Arqueologia: Na semelhança de locais de escavação encontrados em sítios arqueológicos.
3. Problemas de classificação: Na classificação de um grande número de classes, taxas de erro de classificação emparelhada produzem matrizes de confusão que podem ser analisadas com dados de similaridade, como, por exemplo, taxas de confusão de fonemas para problemas de reconhecimento de padrão para voz, etc.

Nesta pesquisa, a LibSVM foi combinada com MDS utilizando o software Matlab para uma melhor visualização gráfica usando *clusters* de agrupamento com distâncias euclidianas para dados de treinamento e teste obtidos pelas funções bases da ACI para realizar a classificação de faltas com e sem a presença do ruído. Com base na aplicação da ACI para a extração de características na localização e classificação de faltas, foi proposto um algoritmo de acordo com o fluxograma da Figura 26.

Figura 26 – Fluxograma proposto.



Fonte: Autor próprio

No algoritmo proposto da Figura 26 são apresentadas as etapas de processamento para a extração de características, sendo as mesmas: I- Geração do banco de sinais transitórios de falta com ruído que será usado para treinamento, teste e validação dos resultados com dados de oscilografia reais de faltas; II - Aplicação da ACI para a extração de características dos sinais transitórios de faltas onde ocorre a separação dos sinais transitórios de falta e do ruído para realizar a localização da falta, e III - Depois da etapa de separação dos sinais, realiza-se então o processamento da LibSVM com MDS para a classificação dos sinais de falta com e sem ruído.

4.6 Considerações Finais do Capítulo

Neste capítulo foi abordado como foi realizada a aplicação de ACI para extração de características dos sinais transitórios de falta na localização e classificação de faltas em linhas de transmissão através das suas funções bases da ACI combinadas com a TOV para a localização de faltas, e também a combinação das funções bases de ACI com a MVS e MDS para a classificação de faltas com e sem a presença de ruído. No próximo capítulo serão apresentados os resultados e a discussão da pesquisa.

5 RESULTADOS E DISCUSSÃO

5.1 Introdução

Neste capítulo serão apresentados os resultados e discussão de acordo com o Fluxograma proposto da Figura 26. Os resultados encontrados e discutidos no capítulo são divididos em duas partes. A primeira parte envolve os resultados da ACI na extração de características do sinais transitórios de falta com a TOV para a localização de faltas. Já na segunda parte são apresentados os resultados da aplicação da ACI com a MVS e MDS para a classificação de faltas com e sem a presença do ruído.

5.2 Localização de Faltas

Os estudos de caso apresentados na Tabela 5 são usados para testar o desempenho do método proposto. Antes de que as estratégias possam ser avaliadas, é necessário definir índices de desempenho capazes de generalizar os resultados. Dois parâmetros foram usados: o erro relativo - Erro(%) e o erro relativo médio - E.M (%), que são definidos por:

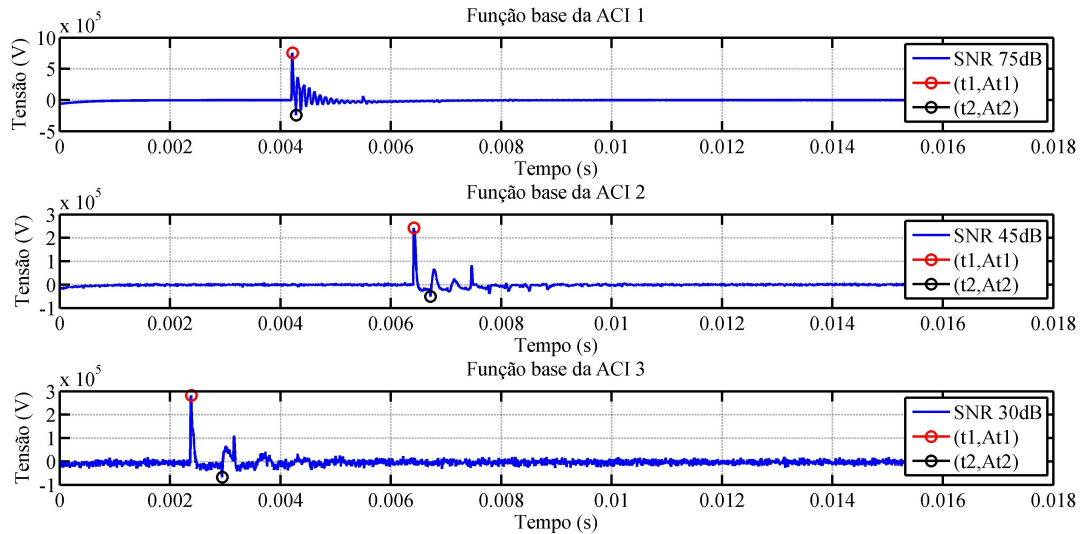
$$Erro(\%) = \frac{|D_E - D_R|}{l_t} \times 100\%. \quad (5.1)$$

$$E.M(\%) = \frac{\sum^N Erro(\%)}{N_s}. \quad (5.2)$$

D_E e D_R são a distância estimada e a distância real, respectivamente e l_t , N_s são o comprimento total da linha e o número de amostra para os casos de teste, respectivamente.

Na Figura 27 são apresentados os primeiros resultados usando as funções bases na localização de falta, cujos tempos de propagação das TOV estimados para cada caso teste encontram-se na Tabela 6.

Figura 27 – Localização de faltas usando as funções base de ACI.



Fonte: Autor próprio

Tabela 6 – Resultados iniciais na localização de faltas usando as funções bases da ACI

Funções bases	Distância Real (km)	ângulo de incidência (θ)	Resistência de falta (Ω)	t_1	t_2	Distância Estimada (km)
Função base ACI 1	10	45°	10	0,00421 s	0,00428 s	9,75
Função base ACI 2	45	90°	80	0,006415 s	0,0067172 s	45,33
Função base ACI 3	84	30°	240	0,002375 s	0,00294 s	84,75

Fonte: Autor Próprio

Os resultados com os desempenhos da localização de falta sob a influência dos diferentes valores de SNR, ângulos de incidência de falta, resistência de falta e das funções bases da ACI, são apresentados nas Tabelas 7, 8, 9 e 10.

Vários estudos de caso, considerando diferentes valores listados na Tabela 5 foram avaliados a fim de testar o desempenho do método proposto. Os resultados têm se mostrados promissores para todos os tipos de faltas que se encontram na Tabela 11. Mesmo em situações sem ruído, a abordagem proposta apresentou excelentes resultados os quais podem ser comparados com as principais técnicas de localização de falta.

Tabela 7 – Localização de uma FMT para uma distância real de 10 km usando 50 funções bases da ACI.

SNR (dB)	Distância Estimada (km)	Erro (km)	Erro (%)
30	9.75	0.25	0.125
35	9.75	0.25	0.125
40	9.75	0.25	0.125
45	9.75	0.25	0.125
50	9.75	0.25	0.125
55	9.75	0.25	0.125
60	9.75	0.25	0.125
65	9.75	0.25	0.125
70	9.75	0.25	0.125
75	9.75	0.25	0.125

Fonte: Autor Próprio

Tabela 8 – Localização de uma FMT para uma distância real de 90 km usando 50 funções bases da ACI.

Ângulo de incidência (θ)	Distância Estimada (km)	Erro (km)	Erro (%)
0°	90.15	0.15	0.075
45°	90.15	0.15	0.075
90°	90.15	0.15	0.075
135°	90.15	0.15	0.075
180°	90.15	0.15	0.075
225°	90.15	0.15	0.075
270°	90.15	0.15	0.075
315°	90.15	0.15	0.075

Fonte: Autor Próprio

Tabela 9 – Localização de uma FMT para uma distância real de 155 km usando 250 funções bases da ACI

Resistência de falta (Ω)	Distância Estimada (km)	Erro (km)	Erro (%)
20	155.33	0.33	0.165
50	155.33	0.33	0.165
80	155.33	0.33	0.165
120	155.33	0.33	0.165
150	155.33	0.33	0.165
180	155.33	0.33	0.165
200	155.33	0.33	0.165
240	155.33	0.33	0.165

Fonte: Autor Próprio

Tabela 10 – Localização de faltas usando funções bases para todos os casos

Distância Real (km)	Distância Estimada (km)	Funções bases da ACI	Erro (km)	Erro (%)
10	9.75	50	0.25	0.125
16	15.95	50	0.005	0.025
45	45.33	70	0.33	0.165
84	84.17	115	0.17	0.085
90	90.15	115	0.15	0.075
128	128.56	115	0.56	0.280
147	147.67	250	0.67	0.335
155	155.33	250	0.33	0.165

Fonte: Autor Próprio

Tabela 11 – E.M (%) para os diferentes tipos de falta

Tipo de falta	10 km	16 km	45 km	84 km	90 km	128 km	147 km	155 km
FMT	0.01	0.01	0.01	0.02	0.02	0.05	0.09	0.10
FBT	0.01	0.01	0.02	0.02	0.02	0.05	0.08	0.10
FB	0.01	0.01	0.02	0.02	0.02	0.05	0.08	0.10
FT	0.01	0.01	0.01	0.02	0.02	0.05	0.09	0.11

Fonte: Autor Próprio

Da análise dos resultados das Tabelas 7 a 11, pode ser visto que a precisão na determinação da localização de faltas não é influenciada pelos diferentes valores de SNR, altos valores de resistência de falta e baixo valores de ângulos de incidência. Isto se deve ao fato de que as funções bases da ACI dividem o espaço de dados em dois subespaços novos, contendo dados com e sem a presença de ruído no sinal original de falta. Sendo este fato uma das principais características das funções bases da ACI, atuando como um filtro. Para a avaliação do método

proposto, foi ainda realizada uma comparação com uma das principais técnicas usualmente aplicada ao problema; a Transformada Wavelet Discreta (TWD) (MALATHI *et al.*, 2010), usando como critério de detecção e localização de falta o espectro de energia dos coeficientes wavelets.


A energia dos coeficientes da TWD pode ser definida por:

$$E_{jk} = |D_{j(k)}|^2. \quad (5.3)$$

E_{jk} é o espectro de energia dos coeficientes da TWD na escala j e instante k . O espectro de energia da Wavelet corresponde à soma dos quadrados dos coeficientes de detalhe obtidos na TWD. O espectro de energia varia em diferentes escalas, de acordo com o sinal de entrada, no qual é possível obter a extração de características dos sinais transitórios de falta, usando o seu espectro de energia para a detecção e localização da falta.

As Figuras 28(a) e (b) apresentam o espectro de energia da TWD usado na detecção e localização de falta, para as mesmas condições do sinal de falta obtido na Figura 21, sendo que foi utilizada a Wavelet daubechies db4 com dois níveis de escala na sua detecção e localização da falta.

Figura 28 – Espectro de energia da TWD.



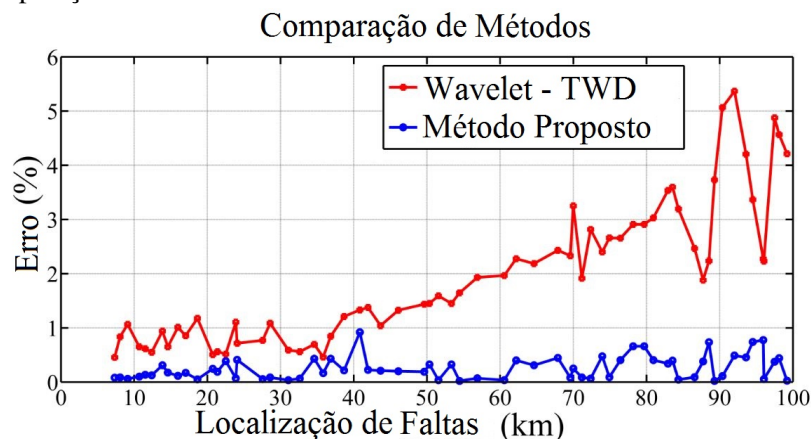
Fonte: Autor próprio

A Figura 28(a) ilustra o resultado do espectro de energia da TWD 1 que emprega a primeira escala da daubechie db4 para detectar e localizar as magnitudes do primeiro e do segundo pico, E_{t1} e E_{t2} , respectivamente, bem como os tempos de propagação $t_1 = 0.006535s$ e $t_2 = 0.00712s$. Aplicando a equação (4.1), a distância estimada da falta foi de 87,75 km, cujo Erro (%) ficou acima de 1%. Além disso, ambos os valores estimados de E_{t1} e t_2 são corrompidos, devido à influência do ruído.

A Figura 28(b) ilustra o espectro de energia da TWD 2 que emprega a segunda escala da daubechies db4 detectando os tempos de propagação $t_1 = 0.006535s$ e $t_2 = 0.007105s$. Aplicando a equação (4.1), a distância estimada da falta foi de 85,5 km, apresentando boa precisão na localização da falta. Mas quando comparamos os resultados do espectro de energia às funções bases da Figura 21, conclui-se que as funções bases da ACI apresentaram melhores resultados e são insensíveis ao ruído.

Para fins de comparação, foi realizado um teste comparativo do método proposto considerando o espectro da TWD com o objetivo de verificar o desempenho de ambas as técnicas para uma FMT que ocorreu na primeira metade da linha (F1), nas seguintes condições: variação da distância real da falta entre 7,34 km e 99,2 km, resistência de falta entre 20 Ω e 240 Ω , ângulo de incidência entre 0° e 315° e SNR entre 30 e 75 dB. Os resultados encontram-se representados na Figura 29.

Figura 29 – Comparação entre ACI x TWD.



Fonte: Autor próprio

Os resultados encontrados mostram que os comportamento das curvas estiverem de acordo com a análise teórica e prática abordadas nesta seção, visto que o Erro(%) em relação a estimativa da distância da falta, usando o método proposto é sempre menor que 1 % nas

condições de teste adotadas. Por outro lado, a TWD apresenta um Erro(%) na localização da falta superior a 1 % a partir da distância de 40 km, demonstrando, assim, que a ACI apresenta desempenho melhor que as TWD, servindo então para a detecção e localização de faltas.

5.3 Classificação de Faltas

De acordo com o fluxograma proposto da Figura 26, depois da aplicação da ACI com a TOV para a localização da falta, o próximo passo consiste na identificação do tipo de falta, usando ACI combinando com MVS e MDS para a classificação de faltas com e sem a presença do ruído, cujos resultados desta aplicação são apresentados nesta seção.

Embora os dados de falta e ruído tenham sido separados, quando usou-se a ACI, o banco de dados original de faltas foi contaminado pelo ruído e considerado para fins de análise para validar a eficácia da MVS e MDS ao lidar com dados de sinais de falta com ruído. Além disso, vale mencionar que a MDS é aplicada como uma ferramenta de representação gráfica e análise dos resultados.

O banco de dados dos sinais transitórios de falta utilizado nesta pesquisa é composto por quatro tipos de faltas (FMT, FB, FBT e FT), sendo divididos em dois conjuntos rotulados como dados de treinamento (\tilde{X}_{treino}) e de teste (\tilde{X}_{teste}) com 600 e 150 padrões de falta, respectivamente, correspondendo aos dados de entrada da LibSVM. Por outro lado, a saída da LibSVM é $Y_{out} = (+1, -1)$, sendo representada graficamente pela MDS para faltas sem e com ruído, respectivamente. Usando esse banco de dados de sinais de falta, o processo de classificação de falta pode ser resumido nos seguintes passos:

1. Pre-processamento das amostras dos dados. Este passo consiste na minimização dos dados enquanto ocorre o mapeamento do baixo espaço dimensional. A representação gráfica da MDS é muito importante para a análise do processo de classificação de falta, bem como a visualização dos resultados.
2. Método de classificação binária MVS para problemas de multi-classificação: um contra um (OAO - *One Against One*) e um contra todos (OAA - *One Against All*) são as estratégias utilizadas para determinar os melhores parâmetros de Kernel, onde C é a constante de regularização e σ é a largura da função gaussiana. Foi usada a biblioteca da LibSVM para executar a validação cruzada para realizar a classificação da falta com e sem a presença do ruído para os tipos de falta abordados nesta pesquisa.

Para aplicar a MVS multi-classificação com N tipos de faltas, são necessários

$N(N - 1)/2$ classificadores binários. Alguns classificadores binários podem ser usados para essa finalidade, por exemplo o (OAO) e (OAA), que são usados para distinguir o sinal de falta e ruído. Ambos os métodos (OAO) e (OAA) foram usados nesta tese, sendo que o método (OAO) foi o que apresentou melhores resultados para a classificação.

As Figuras 30, 31, 32 e 33, ilustram os resultados obtidos com a LibSVM combinado, com a MDS, sendo representado por um mapa gráfico dimensional. Para explicar o processo de classificação de falta, foi usado uma FMT com ruído de 30 dB, sendo que os resultados são devidamente classificados de acordo com o grau de acurácia de I para VIII, em que foi adotada a seguinte legenda de classificação de faltas usando a combinação de LibSVM com MDS: Faltas sem ruído - I; Faltas com ruído - II; Faltas sem ruído classificada incorretamente - III; Faltas com ruído classificada incorretamente - IV; Falta com ruído usada no processo de treinamento - V; Faltas sem ruído usada no processo de treinamento - VI; Faltas com ruído classificadas corretamente - VII; e Faltas sem ruído classificadas corretamente - VIII.

Depois que o banco de dados de sinais transitórios de falta foi processado pelo o algoritmo FastICA, foram gerados dois subespaços de saída, representando assim dados com e sem a presença de ruídos. Os subespaços mencionados são ilustrados na Figura 30, usando a abordagem MDS para a representação gráfica através do mapa dimensional. Este gráfico representa o tempo de propagação da TOV (t_{TOV}), a amplitude da TOV (A_{TOV}), bem como o SNR, correspondendo aos resultados da saída válida para uma FMT. Os dados de falta sem ruído (*Cluster* azul - I) e com ruído (*Cluster* vermelho - II) são representados na Figura 30. A fim de estabelecer uma comparação de desempenho adequada, a entrada da LibSVM é definida após a fase de pré-processamento de acordo com a Figura 26.

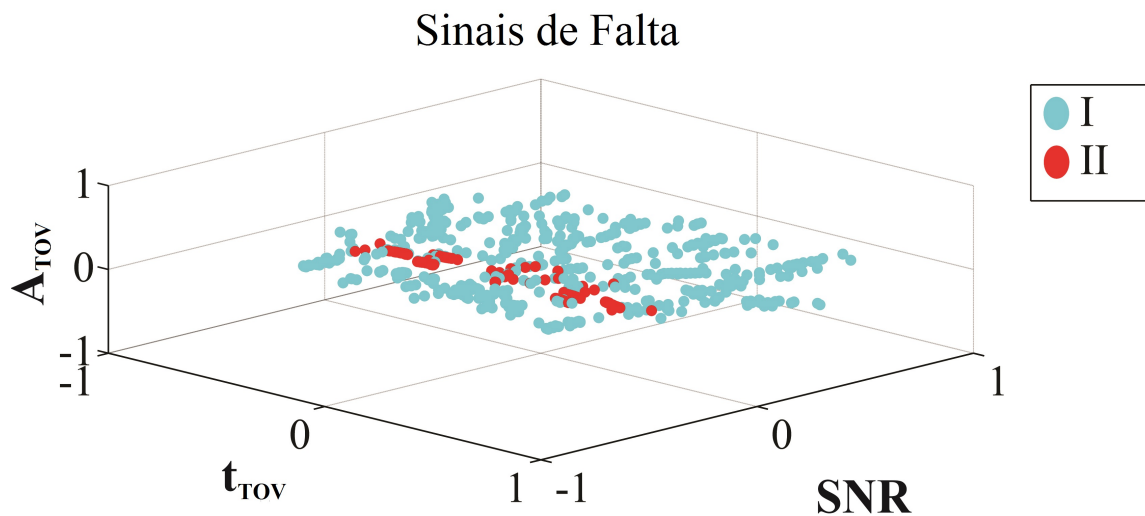
Dados de faltas com e sem a presença de ruído são utilizados para a etapa de treinamento (\tilde{X}_{treino}) e teste (\tilde{X}_{teste}) e são definidos como entradas da LibSVM, onde três tipos de Kernel da MVS foram usados nesta pesquisa, sendo o Kernel linear, o Kernel Sigmóide e o Kernel RBF para diferentes valores de SNR variando de 30 a 75 dB.

A Figura 31 apresenta os resultados obtidos, usando a Kernel linear para classificar 150 casos sobre uma falta FMT. De acordo com os resultados, pode ser visto que é bastante difícil classificar a falta neste tipo de Kernel, pois somente 86 dentre os 150 casos foram classificados corretamente. Além disso existem dois problemas significativos: sinais de falta sem ruído classificados incorretamente - III; e sinais de falta com ruído classificados incorretamente - IV. Em outras palavras, pode ser observado que a aplicação do Kernel linear não teve uma boa taxa

de classificação de falta.

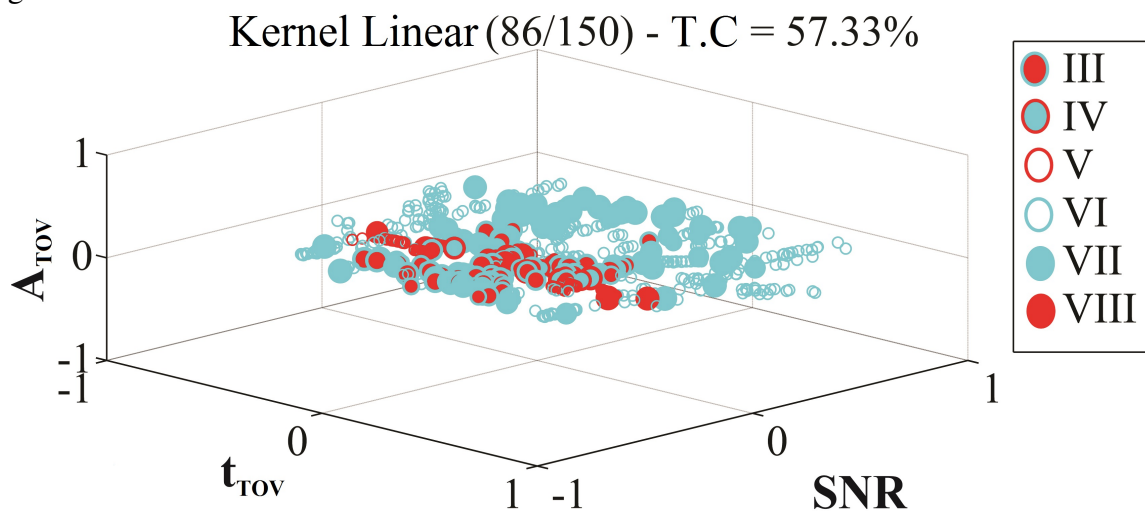
De acordo com a Figura 32, usando o Kernel sigmóide apenas 131 entre 150 casos foram classificados corretamente e um problema significativo foi encontrado: sinais de falta com ruído classificados incorretamente - IV. A Figura 33 apresenta os melhores resultados, usando o Kernel RBF apresentando uma taxa de classificação de 100%. Ou seja, ambos os sinais de falta com e sem a presença do ruído são classificados corretamente, neste caso.

Figura 30 – Mapa Dimensional usando a LibSVM com MDS



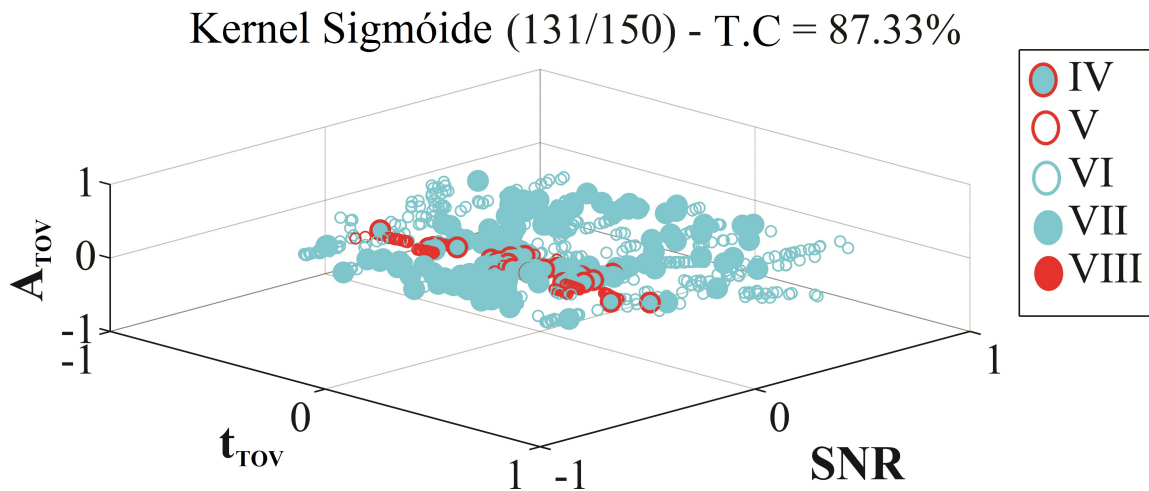
Fonte: Autor próprio

Figura 31 – MVS usando kernel linear




Fonte: Autor próprio

Figura 32 – MVS usando kernel Sigmóide



Fonte: Autor próprio

Figura 33 – MVS usando kernel RBF



Fonte: Autor próprio

A fim de realizar a multi-classificação MVS com N tipos de faltas, $N(N-1)/2$, classificadores binários são necessários, usando a LibSVM com a estratégia (OAO) como um padrão binário de classificação de falta com e sem a presença do ruído.

A acurácia da classificação de falta, usando a LibSVM foi encontrada através dos parâmetros envolvidos (C e σ), que foram obtidos de acordo com o teste de validação cruzada. Depois de três validações cruzadas, durante o processamento da LibSVM, os melhores valores de (C e σ) foram respectivamente 1000 e 1, conforme resultado de classificação de falta apresentado na Tabela 12.

Tabela 12 – Resultados de classificação de faltas usando a LibSVM

SNR (dB)	FMT		FBT		FB		FT		Total		T.C (%)	Nº VS
	C	I	C	I	C	I	C	I	C	I		
30	150	0	147	3	148	2	149	1	594	6	99	40
35	150	0	148	2	148	2	149	1	595	5	99.1	20
40	150	0	149	1	150	0	149	1	598	2	99.6	20
45	150	0	150	0	150	0	149	1	599	1	99.8	20
50	150	0	150	0	150	0	150	0	600	0	100	17
55	150	0	150	0	150	0	150	0	600	0	100	17
60	150	0	150	0	150	0	150	0	600	0	100	15
65	150	0	150	0	150	0	150	0	600	0	100	15
70	150	0	150	0	150	0	150	0	600	0	100	15
75	150	0	150	0	150	0	150	0	600	0	100	15

Fonte: Autor Próprio

A Tabela 12 representa os resultados de teste para a LibSVM aplicada na classificação de falta. A coluna C e I indicam que a classificação foi executada corretamente e incorretamente, respectivamente. Considerando a primeira linha da Tabela 12, onde o SNR é de 30 dB, pode ser visto que a MVS apresenta uma classificação de 100 % quando se trata de 150 casos para uma FMT. Os melhores resultados de classificação foram alcançados com SNR de 50 dB para uma acurácia de 100 % para todos os tipos de faltas abordados.

Por outro lado, para os resultados que correspondem a 30 dB, vale apenas mencionar que os dados de falta foram fortemente corrompidos pelo ruído neste caso, mesmo apresentando uma T.C de 99 %, a acurácia é considerada satisfatória. Portanto, é possível concluir que ACI combinada com MVS e MDS fornece uma ferramenta adequada para a classificação de faltas quando se usam dados ruidosos de faltas. A Tabela 13 apresenta valores suplementares com a variação de C e σ para dois problemas distintos de multi-classificação: Estratégias (OAO) e (OAA).

De acordo com os resultados encontrados na Tabela 12, a abordagem do método proposto nesta pesquisa apresenta valores de acurácia na classificação de faltas de 100 % para vários valores de SNR (50 a 75 dB). Além disso, apresenta um desempenho superior se comparada com as técnicas descritas na Tabela 14.

Dos trabalhos apontados na Tabela 14, as estratégias usando Wavelet e MVS com RNA abordaram apenas a classificação de faltas sem a presença do ruído, apesar de apresentarem boa precisão na localização da falta. No trabalho relacionado à aplicação da Wavelet com a lógica Fuzzy, a combinação de técnicas foi apenas satisfatória para SNR de 20 dB, evidenciando

Tabela 13 – Classificação de faltas usando estratégias OAO e OAA.

Tipo de Falta	Acurácia
<i>Estratégia OAO</i>	
FMT ($C = 2000$ and $\sigma = 0.09$)	99,1%
FBT ($C = 100$ and $\sigma = 0.7$)	98%
FB ($C = 2000$ e $\sigma = 0.01$)	97,7%
FT ($C = 100$ e $\sigma = 0.6$)	96,3%
<i>Estratégia OAA</i>	
FMT ($C = 100$ and $\sigma = 0.05$)	93,1%
FBT ($C = 10$ e $\sigma = 0.1$)	86,19%
FB ($C = 100$ e $\sigma = 0.04$)	80,1 %
FT ($C = 10$ e $\sigma = 1.2$)	87,56%

Fonte: Autor Próprio

Tabela 14 – Comparação de desempenho entre as técnicas de localização e classificação de faltas

Referência	Método proposto	Erro (%)	Acurácia (%)
(MALATHI <i>et al.</i> , 2010)	<i>Wavelet e MVS</i>	1%	99,11%
(EKICI <i>et al.</i> , 2008)	<i>Wavelet e RNA</i>	2,05%	—
(EKICI, 2012)	<i>Wavelet e MVS</i>	1%	99%
(JAMIL <i>et al.</i> , 2014)	<i>Wavelet e RNA</i>	2%	—
(YUSUFF <i>et al.</i> , 2014)	<i>Wavelet e SVR</i>	1%	100%
(SAMANTARAY, 2013)	<i>Wavelet, S e Fuzzy</i>	—	98%

Fonte: Autor Próprio

que as wavelets são sensíveis a influência do ruído, além do sistema Fuzzy exigir uma grande quantidade de regras lógicas para um determinado tipo de conjunto de dados.

Numa análise final, as funções bases da ACI podem se relacionar com outras transformadas no contexto da extração de características, dentre elas, a Transformada Wavelet. Como apresentado, a ACI extrai as componentes independentes dos dados, utilizando estatísticas de ordem superior à segunda, obtendo um sistema de eixos não ortogonal (sistema de separação) com boa resolução no tempo e na frequência de acordo com as suas funções bases. As wavelets constituem funções bases de Wavelet mãe, que usam o conceito de análise de acordo com a escala, com boa resolução no tempo e na frequência. A semelhança entre as funções bases de ACI e as funções bases das Wavelets, constituíram também uma das motivações para a realização desta pesquisa, visto que a Transformada Wavelet é a técnica mais popular e empregada na literatura para soluções de problemas de transitórios de faltas em sistemas de energia elétrica. A Tabela 15 apresenta um comparativo entre ACI e Wavelets.

Tabela 15 – Relação entre a ACI e Wavelet.

Técnica	Propriedades
ACI	<ul style="list-style-type: none"> - Análise de acordo com as funções base; - Máxima a independência estatística dos dados; - Boa resolução no tempo e frequência; - Utiliza estatística de ordem superior a segunda; - Não é ortogonal (não minimiza o erro quadrático); - Insensibilidade a ruídos;
Wavelet	<ul style="list-style-type: none"> - Análise de acordo com a escala ; - Boa resolução no tempo e na frequência; - Os coeficientes obtidos têm distribuição esparsa; - Sensibilidade a ruídos;

Fonte: Autor próprio

5.4 Considerações Finais

Por fim, analisando os resultados verificou-se que a combinação da ACI com a TOV e ACI com MVS-MDS forneceram resultados relevantes, quanto à minimização do erro considerando a presença de ruído. Isto foi possível devido as funções bases terem usado o conceito de **codificação eficiente** apresentando uma minimização da redundância dos dados com uma melhor simplificação no processo de localização e classificação da falta. Por conseguinte, melhorando a velocidade do processamento, geram uma maior precisão na localização e classificação de faltas quando comparada às principais técnicas tradicionais tais como as Wavelets e RNAs.

6 CONCLUSÃO

Nesta pesquisa, apresentou-se a análise de componentes independentes (ACI) para a extração de características dos sinais transitórios de falta combinadas com a teoria das ondas viajantes (TOV) para detecção e localização de faltas. A ACI também foi combinada com a máquina de vetores de suporte (MVS) e a teoria do escalonamento multidimensional (MDS) para a classificação de falta com e sem a presença de ruídos. A aplicação foi desenvolvida sobre um modelo real de linha de transmissão, utilizando dados de um terminal para o monitoramento de registros oscilográficos de tensão de falta e um banco de dados de sinais de falta obtido pelo software ATP. Um novo algoritmo de detecção de transitórios foi proposto. Este algoritmo usa a teoria de ACI como extrator de características dos sinais transitórios de falta, para sinais que são corrompidos por ruídos, em uma linha de transmissão de alta tensão de 500 kV, que interliga a subestação de Presidente Dutra - MA a subestação de Boa Esperança - PI.

Da revisão bibliográfica, percebe-se que os dispositivos para a localização de faltas não são capazes de detectar, localizar e classificar faltas com e sem a presença de ruídos nos registros de oscilografia. A origem destes tipos de faltas podem não ser detectadas no SEP e podem levar a má interpretação da sua oscilografia pela equipe de operação, fato este motivador dessa pesquisa.

Em um primeiro momento, foi apresentada a fundamentação teórica da ACI com o conceito de separação cega de fontes, com propriedades estatísticas de alta ordem. No segundo momento, foi apresentado a implementação da ACI com o algoritmo *FastICA*, que nesta pesquisa foi usado para a extração de características dos sinais transitórios de faltas através de suas funções bases da ACI.

O algoritmo proposto para a detecção de transitórios é baseado na ACI. O método realiza a identificação dos instantes de chegada das ondas viajantes no terminal de monitoramento da subestação de Presidente Dutra - MA, usando as funções bases de ACI para extração de características do transitório de falta para sinais de tensão combinadas com a TOV para a localização de faltas.

Inicialmente, a técnica proposta para a detecção de transitórios de faltas foi aplicada, considerando registros oscilográficos reais e depois foi usado o ATP para a geração de um banco de dados de sinais mais representativo de faltas simuladas em um modelo de linha de transmissão real de 500 kV.

As funções base da ACI foram usadas no conceito da **codificação eficiente**, redu-

zindo o tamanho do banco de dados de faltas, assim como a redundância destes dados para obter uma boa estimativa de representação em componentes independentes sobre a localização e a classificação das faltas com um menor tempo de processamento dos dados.

Como contribuição adicional, apresentou-se no Capítulo 5 uma análise comparativa entre o método de localização de falta baseado no espectro de energia das Wavelets e a ACI. Através desta análise, confirmaram-se as vantagens da ACI no que diz respeito à robustez a fontes de erros típicas na localização de falta tais como: influência do ângulo de incidência de falta, distância de falta, resistência de falta e, principalmente, a diferentes valores de ruídos adicionados ao sinal de falta.

Desta forma, a ACI apresentou melhores resultados de precisão quanto ao erro na localização de faltas em relação às principais técnicas convencionais apresentados na Tabela 14 como: Wavelets, Redes Neurais e outras técnicas de processamento digital de sinais.

Como segunda contribuição adicional, realizou-se uma análise sobre as funções bases da ACI em comparação com as Wavelets, abordando suas diferenças e semelhanças no tratamento do sinal na extração de características, abordado na Tabela 15, visto que as Wavelets são as técnicas mais bem difundidas e exploradas na literatura. Em contrapartida a ACI ainda é pouco explorada em problemas de distúrbios em sistemas elétricos de energia e bastante usadas nas áreas de Engenharia Biomédica, separação de sinais e telecomunicações.

Além destas contribuições adicionais, apresentou-se no Capítulo 5, também, os resultados e discussões das combinações das funções bases da ACI com técnicas de classificação de padrões como a MVS através da biblioteca da LibSVM e MDS, abordando seus fundamentos de implementação e interpretação gráfica dos banco de sinais de faltas com e sem ruído, servindo como ferramenta de classificação de padrões de faltas sob diferentes ruídos, cujos resultados foram comparados as principais técnicas de classificação como as Redes Neurais e lógica Fuzzy, entre outras técnicas, sendo apresentada na Tabela 14.

Observou-se, que a ACI apresentou resultados de localização de faltas com erros abaixo de 1% e com taxas de classificação de faltas com 100% de acerto para alguns níveis de ruído a partir de 50 dB. Este desempenho indica que a ACI pode ser usada como extrator de características dos sinais transitórios de faltas e com resultados superiores aos algoritmos até atualmente desenvolvido. As funções base da ACI podem ser aplicadas na localização da falta combinando as seguintes técnicas ACI + TOV e para a classificação da falta, as técnicas (ACI + MVS combinadas com MDS).

6.1 Prospecção de Novas Aplicações

Como continuação dos estudos realizados nesta pesquisa, pretende-se:

Usar análise de componentes independentes (ACI), combinada com as principais técnicas de inteligência computacional (Redes Neurais Artificiais) e processamento digital de sinais (Transformada Wavelet) para localização e classificação de faltas com dados simulados em tempo real, procurando verificar seu desempenho e a influência de outras fontes de ruído (falhas em isoladores, queimadas sob as linhas de transmissão). Também pode ser motivo de estudo a sua aplicação à separação e classificação destas fontes de ruído, presentes em linhas de transmissão, devido ao fato de que a maioria dos sinais e ruídos são não-gaussianos e que podem ser resolvidos com técnicas de separação de sinal com métricas de estatísticas de ordem superior.

Ainda como continuidade, pode-se desenvolver protótipos em hardware de localizadores de faltas baseados na teoria das ondas viajantes que utilizem a análise de componentes independentes (ACI) como extração de características dos sinais transitórios de faltas na detecção, localização e classificação de faltas, usando o conceito de *Smart Grids* (Redes Inteligentes) no contexto de separação de sinais para o desenvolvimento e configuração auto-adaptativa dos sistemas de proteção, controle automático e diagnóstico de transitórios e de fontes geradoras de ruídos em sistemas elétricos.

REFERÊNCIAS

- ABUR, A.; MAGNAGO, F. Use of time delays between modal components in wavelet based fault location. **International Journal of Electrical Power and Energy Systems**, v. 22, n. 6, p. 397 – 403, 2000. ISSN 0142-0615. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0142061500000107>>.
- AJAEI, F. B.; SANAYE-PASAND, M. Minimizing the impact of transients of capacitive voltage transformers on distance relay. In: **2008 Joint International Conference on Power System Technology and IEEE Power India Conference**. [S.l.: s.n.], 2008. p. 1–6.
- BEWLEY, L. V. Traveling waves on transmission systems. **Transactions of the American Institute of Electrical Engineers**, v. 50, n. 2, p. 532–550, June 1931. ISSN 0096-3860.
- BIRLASEKARAN, S.; LI, H. J. Detection of faulty insulators on power transmission line. In: **2000 IEEE Power Engineering Society Winter Meeting. Conference Proceedings (Cat. No.00CH37077)**. [S.l.: s.n.], 2000. v. 4, p. 2817–2821 vol.4.
- BORG, I.; GROENEN, P. J. F. **Modern Multidimensional Scaling: Theory and Application**. [S.l.]: Springer, 2005.
- CHANG, C.-C.; LIN, C.-J. **A library for support vector machines**. Springer Berlin Heidelberg, 2001. (Engineering online library). Disponível em: <<https://www.csie.ntu.edu.tw/~cjlin/libsvm>>.
- CHEN, Z.; MAUN, J. C. Artificial neural network approach to single-ended fault locator for transmission lines. **IEEE Transactions on Power Systems**, v. 15, n. 1, p. 370–375, Feb 2000. ISSN 0885-8950.
- CHOI, J. Y.; BAE, S. H.; QIU, X.; FOX, G. High performance dimension reduction and visualization for large high-dimensional data analysis. In: **2010 10th IEEE/ACM International Conference on Cluster, Cloud and Grid Computing**. [S.l.: s.n.], 2010. p. 331–340.
- CICHOCKI, A.; AMARI, S. **Adaptative Blind Signal and Image Processing**. [S.l.]: John Wiley Sons, LTD, 2003.
- CLARKE, E. **Circuit analysis A-C power systems**. [S.l.]: John Wiley, 1993.
- COSTA, F. B. Transformada wavelet discreta aplicada ao diagnóstico de distúrbios. **Simpósio Brasileiro de Sistemas Elétricos**, Maio 2010.
- COSTA, F. B. Fault-induced transient detection based on real-time analysis of the wavelet coefficient energy. **IEEE Transactions on Power Delivery**, v. 29, n. 1, p. 140–153, Feb 2014. ISSN 0885-8977.
- COSTA, F. B.; SOUZA, B. A.; BRITO, N. S. D. A wavelet-based algorithm to analyze oscillographic data with single and multiple disturbances. In: **2008 IEEE Power and Energy Society General Meeting - Conversion and Delivery of Electrical Energy in the 21st Century**. [S.l.: s.n.], 2008. p. 1–8. ISSN 1932-5517.
- COURY, D. V.; OLESKOVICZ, M.; GIOVANNI, R. **Proteção Digital de Sistemas Elétricos de Potência: dos Relés Eletromecânicos aos Microprocessados Inteligentes**. São Carlos, São Paulo: Edgard USP, 2007.

DALLBELLO, A. C.; SILVEIRA, P. M.; PARENTONI, M. F. C.; ADAMI, J. F. **Análise de Sinais Provocados por Defeitos em Linhas de Transmissão Utilizando Técnicas de Telecomunicação e Processamento de Sinais**. Araxá, Minas Gerais: IV Congresso de Inovação Tecnológica em Engenharia Elétrica - CITENEL, 2007.

DAVOUDI, M. G.; SADEH, J.; KAMYAB, K. Time domain fault location on transmission lines using genetic algorithm. In: **2012 11th International Conference on Environment and Electrical Engineering**. [S.l.: s.n.], 2012. p. 1087–1092.

DAWIDOWSKI, P.; IZYKOWSKI, J. Accurate location of phase-to-earth and phase-to-phase faults on power transmission lines using two-end synchronized measurements. In: **2011 10th International Conference on Environment and Electrical Engineering**. [S.l.: s.n.], 2011. p. 1–4.

DOMMEL, H. W. **Electromagnetic Transients Program Reference Manual: EMTP Theory Book**. Portland, BPA: [s.n.], 1996.

EKICI, S. Support vector machines for classification and locating faults on transmission lines. **Applied Soft Computing**, v. 12, n. 6, p. 1650 – 1658, 2012. ISSN 1568-4946. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S1568494612000713>>.

EKICI, S.; YILDIRIM, S.; POYRAZ, M. Energy and entropy-based feature extraction for locating fault on transmission lines by using neural network and wavelet packet decomposition. **Expert Systems with Applications**, v. 34, n. 4, p. 2937 – 2944, 2008. ISSN 0957-4174. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0957417407001881>>.

EL-NAGGAR, K. M. A genetic based fault location algorithm for transmission lines. In: **16th International Conference and Exhibition on Electricity Distribution, 2001. Part 1: Contributions. CIRED. (IEE Conf. Publ No. 482)**. [S.l.: s.n.], 2001. v. 3, p. 5 pp. vol.3–. ISSN 0537-9989.

FAYBISOVICH, V.; FEIGINOV, M.; KHOROSHEV, M. I. Investigation of frequency domain traveling wave fault location methods. In: **IEEE PES T D 2010**. [S.l.: s.n.], 2010. p. 1–9. ISSN 2160-8555.

FENG, Z.; JUN, L.; LI, Z.; ZHIHAO, Y. A new fault location method avoiding wave speed and based on traveling waves for ehv transmission line. In: **2008 Third International Conference on Electric Utility Deregulation and Restructuring and Power Technologies**. [S.l.: s.n.], 2008. p. 1753–1757.

FERREIRA, V.; ZANGHI, R.; FORTES, M.; SOTELO, G.; SILVA, R.; SOUZA, J.; GUIMARÃES, C.; JR., S. G. A survey on intelligent system application to fault diagnosis in electric power system transmission lines. **Electric Power Systems Research**, v. 136, p. 135 – 153, 2016. ISSN 0378-7796. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0378779616300086>>.

FUKUYAMA, Y.; UEKI, Y. Fault analysis system using neural networks and artificial intelligence. In: **[1993] Proceedings of the Second International Forum on Applications of Neural Networks to Power Systems**. [S.l.: s.n.], 1993. p. 20–25.

GALE, P. F.; CROSSLEY, P. A.; BINGYIN, X.; YAOZHONG, G.; CORY, B. J.; BARKER, J. R. G. Fault location based on travelling waves. In: **1993 Fifth International Conference on Developments in Power System Protection**. [S.l.: s.n.], 1993. p. 54–59.

GILANY, M.; IBRAHIM, D. k.; ELDIN, E. S. T. Traveling-wave-based fault-location scheme for multiend-aged underground cable system. **IEEE Transactions on Power Delivery**, v. 22, n. 1, p. 82–89, Jan 2007. ISSN 0885-8977.

GIRGIS, A. A.; HART, D. G.; PETERSON, W. L. A new fault location technique for two- and three-terminal lines. **IEEE Transactions on Power Delivery**, v. 7, n. 1, p. 98–107, Jan 1992. ISSN 0885-8977.

GLOBO. **Apagão foi causado por queimada no Piauí, diz ministro**. São Paulo, SP: GLOBO, 2013. Disponível em: <<http://g1.globo.com/economia/noticia/2013/08/apagao-foi-causado-por-queimada-no-piaui-diz-lobao.html>>. Acesso em: 28 aug. 2013.

GLOBO. **Falha provoca falta de energia ao menos 11 estados do Brasil**. São Paulo, SP: GLOBO, 2014. Disponível em: <<http://g1.globo.com/economia/noticia/2014/02/ons-confirma-falha-desligamento-de-energia.html>>. Acesso em: 04 fev. 2014.

GLOVER, J. D.; SARMA, M. S.; OVERBYE, T. J. **Power System Analysis and Design**. 4ed. ed. [S.l.]: CL - Engineering, 2009.

GUO, Y.; KEZUNOVIC, M.; CHEN, D. Simplified algorithms for removal of the effect of exponentially decaying dc-offset on the fourier algorithm. **IEEE Transactions on Power Delivery**, v. 18, n. 3, p. 711–717, July 2003. ISSN 0885-8977.

HART, D. G.; NOVOSEL, D. S.; SMITH, R. **Modified Cosine Filters**. N: U.S Patent 6154687, 2000.

HASHEMINEJAD, S.; SEIFOSSADAT, S. G.; RAZAZ, M.; JOORABIAN, M. Ultra-high-speed protection of transmission lines using traveling wave theory. **Electric Power Systems Research**, v. 132, p. 94 – 103, 2016. ISSN 0378-7796. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0378779615003478>>.

HE, Z. Y.; MAI, R. K.; HE, W.; QIAN, Q. Q. Phasor-measurement-unit-based transmission line fault location estimator under dynamic conditions. **IET Generation, Transmission Distribution**, v. 5, n. 11, p. 1183–1191, Nov 2011. ISSN 1751-8687.

HYVARINEM, A.; KARHUNEM, j.; OJA, E. **Independent Component Analysis**. [S.l.]: Wiley Interscience, 2001.

IURINIC, L. Accurate fault location technique for power transmission lines. **International Conference on Power Systems Transients**, July 2013.

IZYKOWSKI, J.; ROSOŁOWSKI, E.; BALCEREK, P.; FULCZYK, M.; SAHA, M. M. Accurate noniterative fault location algorithm utilizing two-end unsynchronized measurements. **IEEE Transactions on Power Delivery**, v. 25, n. 1, p. 72–80, Jan 2010. ISSN 0885-8977.

IZYKOWSKI, J.; ROSOŁOWSKI, E.; BALCEREK, P.; FULCZYK, M.; SAHA, M. M. Accurate noniterative fault-location algorithm utilizing two-end unsynchronized measurements. **IEEE Transactions on Power Delivery**, v. 26, n. 2, p. 547–555, April 2011. ISSN 0885-8977.

JAMALI, S.; GHEZELJEH, A. Fault location on transmission line using high frequency travelling waves. In: **2004 Eighth IEE International Conference on Developments in Power System Protection**. [S.l.: s.n.], 2004. v. 1, p. 220–223 Vol.1. ISSN 0537-9989.

- JAMIL, M.; KALAM, A.; ANSARI, A.; RIZWAN, M. Generalized neural network and wavelet transform based approach for fault location estimation of a transmission line. **Applied Soft Computing**, v. 19, p. 322 – 332, 2014. ISSN 1568-4946. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S1568494614000908>>.
- JIAN, Q.; XIANGXUN, C.; JIANCHAO, Z. Travelling wave fault location of transmission line using wavelet transform. In: **Power System Technology, 1998. Proceedings. POWERCON '98. 1998 International Conference on**. [S.l.: s.n.], 1998. v. 1, p. 533–537 vol.1.
- JOHNS, A. T.; JAMALI, S. Accurate fault location technique for power transmission lines. **IEE Proceedings C - Generation, Transmission and Distribution**, v. 137, n. 6, p. 395–402, Nov 1990. ISSN 0143-7046.
- JOHNS, A. T.; SALMAN, S. K. **Digital Protection for Power Systems**. [S.l.]: Peter Peregrinus Ltd, 1995.
- JOLLIFFE, T. J. **Principal Component Analysis**. [S.l.]: Springer, 2002.
- KEZUNOVIC, M.; RIKALO, I. Detect and classify faults using neural nets. **IEEE Computer Applications in Power**, v. 9, n. 4, p. 42–47, Oct 1996. ISSN 0895-0156.
- L, P. B.; HOIDALEN, H. K. **User Manual Preliminary Release - AtpDraw**. [S.l.: s.n.], 2000.
- LEE, D.-G.; KANG, S.-H.; NAM, S.-R. New modified fourier algorithm to eliminate the effect of the dc offset on phasor estimation using dft. In: **2008 IEEE/PES Transmission and Distribution Conference and Exposition**. [S.l.: s.n.], 2008. p. 1–6. ISSN 2160-8555.
- LIANG, F.; JEYASURYA, B. Transmission line distance protection using wavelet transform algorithm. **IEEE Transactions on Power Delivery**, v. 19, n. 2, p. 545–553, April 2004. ISSN 0885-8977.
- LIN, D.; JUN, P.; WENXIA, S.; JUN, T.; JUN, Z. Fault location for transmission line based on traveling waves using correlation analysis method. In: **2008 International Conference on High Voltage Engineering and Application**. [S.l.: s.n.], 2008. p. 681–684.
- LOPES, F. V. **Localização de Falhas em Linhas de Transmissão Baseada em Ondas Viajantes**. Dissertação (Mestrado) — Universidade Federal de Campina Grande, Paraíba, Brasil, Março 2011.
- LOPES, F. V.; FERNANDES, D.; NEVES, W. L. A. Transients detection in ehv transmission lines using park's transformation. In: **PES T D 2012**. [S.l.: s.n.], 2012. p. 1–6. ISSN 2160-8555.
- LOPES, F. V.; FERNANDES, D.; NEVES, W. L. A. A traveling-wave detection method based on park's transformation for fault locators. **IEEE Transactions on Power Delivery**, v. 28, n. 3, p. 1626–1634, July 2013. ISSN 0885-8977.
- LOPES, F. V.; SANTOS, W. C.; FERNANDES, D.; NEVES, W. L. A.; SOUZA, B. A. An adaptive fault location method for smart distribution and transmission grids. In: **2011 IEEE PES CONFERENCE ON INNOVATIVE SMART GRID TECHNOLOGIES LATIN AMERICA (ISGT LA)**. [S.l.: s.n.], 2011. p. 1–7.

MALATHI, V.; MARIMUTHU, N.; BASKAR, S. Intelligent approaches using support vector machine and extreme learning machine for transmission line protection. **Neurocomputing**, v. 73, n. 10?12, p. 2160 – 2167, 2010. ISSN 0925-2312. Subspace Learning / Selected papers from the European Symposium on Time Series Prediction. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0925231210000822>>.

MANN, B. J.; MORRISON, I. F. Digital calculation of impedance for transmission line protection. **IEEE Transactions on Power Apparatus and Systems**, PAS-90, n. 1, p. 270–279, Jan 1971. ISSN 0018-9510.

MARTI, J. R. Accurate modelling of frequency-dependent transmission lines in electromagnetic transient simulations. **IEEE Transactions on Power Apparatus and Systems**, PAS-101, n. 1, p. 147–157, Jan 1982. ISSN 0018-9510.

MATSOPOULOS, G. K. **Self Organizng Maps**. [S.l.]: INTECH, 2010.

NAIDU, S. R. **Transitórios Eletromagnéticos em Sistemas Elétricos**. [S.l.]: Grafset, 1985.

NGU, E.; RAMAR, K. A combined impedance and traveling wave based fault location method for multi-terminal transmission lines. **International Journal of Electrical Power and Energy Systems**, v. 33, n. 10, p. 1767 – 1775, 2011. ISSN 0142-0615. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0142061511002018>>.

ONS. **Mapas do Sin**. www.ons.org.br, 2014. Disponível em: <http://www.ons.org.br/download/mapas_rede_operacao/n_ne/DU-CT.NNE.01_r139.pdf>. Acesso em: 04 may. 2017.

ONS. **Extensão de Linhas de Transmissão**. www.ons.org.br, 2015. Disponível em: <http://www.ons.org.br/download/biblioteca_virtual/publicacoes/DADOS_2015/html/7-2.html>. Acesso em: 04 may. 2017.

ONS. **Indicadores de Confiabilidade da Rede Básica**. www.ons.org.br, 2017. Disponível em: <http://www.ons.org.br/indicadores_desempenho/qualidade_operacao.aspx>. Acesso em: 04 may. 2017.

PERCIVAL, D. B.; WALDEN, A. T. **Wavelet Methods for Time Series Analysis**. New York - USA: Cambridge Uiversity Press, 2000.

PHADKE, A. G.; THORP, J. S. **Computer Relaying for Power Systems**. New York, USA: John Wiley and Sons Inc, 2009.

PRESTON, G.; RADOJEVIC, Z. M.; KIM, C. H.; TERZIJA, V. New settings-free fault location algorithm based on synchronised sampling. **IET Generation, Transmission Distribution**, v. 5, n. 3, p. 376–383, March 2011. ISSN 1751-8687.

PRESTON, G.; RADOJEVIC, Z. M.; KIM, C. H.; TERZIJA, V. New settings-free fault location algorithm based on synchronised sampling. **IET Generation, Transmission Distribution**, v. 5, n. 3, p. 376–383, March 2011. ISSN 1751-8687.

REDDY, M. J. B.; MOHANTA, D. K. Performance evaluation of an adaptive-network-based fuzzy inference system approach for location of faults on transmission lines using monte carlo simulation. **IEEE Transactions on Fuzzy Systems**, v. 16, n. 4, p. 909–919, Aug 2008. ISSN 1063-6706.

- SACHDEV, M. S.; BARIBEAU, M. A. A new algorithm for digital impedance relays. **IEEE Transactions on Power Apparatus and Systems**, PAS-98, n. 6, p. 2232–2240, Nov 1979. ISSN 0018-9510.
- SADINEZHAD, I.; AGELIDIS, V. G. An adaptive precise one-end power transmission line fault locating algorithm based on multilayer complex adaptive artificial neural networks. In: **2009 IEEE International Conference on Industrial Technology**. [S.l.: s.n.], 2009. p. 1–6.
- SAHA, M. M.; IZYKOWSKI, J.; ROSOŁOWSKI, E. **Fault Location on Power Networks**. London: Ed. Springer, 2010. ISBN 9781848828858.
- SAHA, M. M.; ROSOŁOWSKI, E.; IZYKOWSKI, J. A fault location algorithm for series compensated transmission lines incorporated in current differential protective relays. In: **2011 International Conference on Advanced Power System Automation and Protection**. [S.l.: s.n.], 2011. v. 1, p. 706–711.
- SALIM, R. H.; SALIM, K. C. O.; BRETAS, A. S. Further improvements on impedance-based fault location for power distribution systems. **IET Generation, Transmission Distribution**, v. 5, n. 4, p. 467–478, April 2011. ISSN 1751-8687.
- SAMANTARAY, S. A systematic fuzzy rule based approach for fault classification in transmission lines. **Applied Soft Computing**, v. 13, n. 2, p. 928 – 938, 2013. ISSN 1568-4946. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S1568494612004309>>.
- SHI, Q.; TROELTZSCH, U.; KANOUN, O. Detection and localization of cable faults by time and frequency domain measurements. In: **2010 7th International Multi- Conference on Systems, Signals and Devices**. [S.l.: s.n.], 2010. p. 1–6.
- SIDHU, T. S.; ZHANG, X.; ALBASRI, F.; SACHDEV, M. S. Discrete-fourier-transform-based technique for removal of decaying dc offset from phasor estimates. **IEE Proceedings - Generation, Transmission and Distribution**, v. 150, n. 6, p. 745–752, Nov 2003. ISSN 1350-2360.
- SILVA, M. da; COURY, D. V.; OLESKOVICZ, M.; SEGATTO, E. C. An alternative fault location algorithm based on wavelet transforms for three-terminal lines. In: **2008 IEEE Power and Energy Society General Meeting - Conversion and Delivery of Electrical Energy in the 21st Century**. [S.l.: s.n.], 2008. p. 1–7. ISSN 1932-5517.
- SOUZA, B. **Implantação de Técnicas de Inteligência Artificial para Identificação e Análise de Ocorrência no Sistema Elétrico**. Campina Grande: [s.n.], 2004.
- TAKAGI, T.; YAMAKOSHI, Y.; YAMAURA, M.; KONDOW, R.; MATSUSHIMA, T. Development of a new type fault locator using the one-terminal voltage and current data. **IEEE Power Engineering Review**, PER-2, n. 8, p. 59–60, Aug 1982. ISSN 0272-1724.
- TZIOUVARAS, D. A.; ROBERTS, J. B.; BENMOUYAL, G. New multi-ended fault location design for two- or three-terminal lines. In: **2001 Seventh International Conference on Developments in Power System Protection (IEE)**. [S.l.: s.n.], 2001. p. 395–398. ISSN 0537-9989.
- VAPNIK, V. **The support vector method of function estimation**. [S.l.]: Kluwer Academic Publishers, 1998.

YU, C. S. An unsynchronized measurements correction method for two-terminal fault-location problems. **IEEE Transactions on Power Delivery**, v. 25, n. 3, p. 1325–1333, July 2010. ISSN 0885-8977.

YUSUFF, A.; JIMOH, A.; MUNDA, J. Fault location in transmission lines based on stationary wavelet transform, determinant function feature and support vector regression. **Electric Power Systems Research**, v. 110, p. 73 – 83, 2014. ISSN 0378-7796. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0378779614000066>>.

ZANETTA, J. **Transitórios Eletromagnéticos em Sistemas de Potência**. São Paulo, SP-Brasil: Edusp - Editora da Universidade de São Paulo, 2003.

ZHANG, G.; SHU, H.; LIAO, Y. Automated double-ended traveling wave record correlation for transmission line disturbance analysis. **Electric Power Systems Research**, v. 136, p. 242 – 250, 2016. ISSN 0378-7796. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0378779616300384>>.

ZIMATH, S. L.; RAMOS, M. A. F.; FILHO, J. E. S. Comparison of impedance and travelling wave fault location using real faults. In: **IEEE PES T D 2010**. [S.l.: s.n.], 2010. p. 1–5. ISSN 2160-8555.