

Detecção e Classificação de Falhas de Energia Usando a Transformada Wavelet e Métodos de Inferência

Almir Laranjeira Neri Júnior
Petrobras
Salvador, Brasil
almir.neri@petrobras.com.br

Fernando Augusto Moreira
UFBA
Salvador, Brasil
moreiraf@ufba.br

Benemar Alencar de Souza
UFCEG
Campina Grande, Brasil
benemar@dee.ufcg.edu.br

Resumo – Todo sistema elétrico está vulnerável à ocorrência de falhas de energia. Situações transitórias podem ser eliminadas por uma detecção de falta eficaz e um sistema de religamento. No caso de falhas permanentes, equipes de manutenção devem corrigir o defeito na rede antes de restabelecer o fornecimento. Neste trabalho pretende-se apresentar uma técnica alternativa para detectar e classificar eventos de falta de energia utilizando a Transformada Wavelet e um método de inferência baseado em limiares para cada um dos diferentes tipos de curto-circuito, auxiliando na velocidade de retorno em operação da rede elétrica.

Palavras-Chave – Transformada Wavelet, Detecção de Falhas de Energia, Classificação de Falhas de Energia

I. INTRODUÇÃO

A detecção e classificação de falhas de energia é um problema que acompanha todos os envolvidos na operação e manutenção de um sistema elétrico. Um sistema de proteção eficiente precisa detectar os eventos nocivos à continuidade operacional do sistema ao mesmo tempo em que permite que as condições normais de operação e variação de cargas não seja questionado ou acarrete desligamentos indesejados.

Ademais, a correta classificação do tipo da falta leva a uma maior agilidade no tratamento do evento indesejado, permitindo um restabelecimento mais rápido. Este trabalho apresentará a ferramenta matemática Transformada Wavelet [1]-[5] para processar dados de simulações realizadas no software ATP na sua seção II. Em seguida, de forma sucinta, alguns artigos de detecção e classificação de falta de energia são comentados nas seções III e IV.

Dois algoritmos implementados no software Scilab irão prover a detecção e classificação das falhas de energia simuladas, e estes algoritmos são detalhados na seção V. Estes algoritmos são robustos a distorções harmônicas e outros eventos transitórios como mudanças normais de carga. Os resultados são descritos e analisados na seção VI, concluindo o artigo na seção VII.

II. TRANSFORMADA WAVELET

A Transformada Wavelet possui muitas aplicações práticas, mas em sistemas de potência o foco recai nas propriedades de identificação conjunta de tempo e frequência. Ela opera de modo similar à transformada de Fourier,

indicando as frequências presentes num certo sinal, mas com a vantagem de identificar os momentos em que cada frequência aparece. Existem muitos tipos de wavelet, contínuas, discretas, redundantes, pacotes de 1 e assim por diante, mas neste trabalho iremos detalhar e operar apenas com a transformada discreta. Melhores explicações podem ser encontradas nas referências [1]-[5].

A. Transformada Wavelet Discreta

DWT é a sigla em inglês para a Transformada Wavelet Discreta. Ela pode ser usada matematicamente de duas formas, de modo ortonormal ou por quadros (*frames*). O método por quadros é a implementação computacional da Transformada Wavelet contínua, resultando na decomposição de frequência e tempo de ondas sobrepostas [3].

Algumas condições precisam ser alcançadas para que a wavelet seja considerada ortonormal [1], mas para fins deste trabalho ortonormal significa, na prática, componentes não redundantes.

A formulação diádica da DWT é

$$WT_{n,m} = 2^{-\frac{m}{2}} \cdot \int_{-\infty}^{\infty} f(t) \cdot \psi^* \left(\frac{t - n \cdot 2^m}{2^m} \right) dt = C_{\psi_{m,n}} \quad (1)$$

onde t é o tempo, m é a variável inteira relacionada à frequência, n é a variável inteira relacionada ao tempo, $f(t)$ é o sinal que está sendo analisado, ψ é uma função oscilatória do tipo janela, também chamada de wavelet Mãe, e $C_{\psi_{m,n}}$ é o coeficiente vinculado a cada par tempo e frequência.

DWT tem muitas propriedades interessantes [1]-[3] e aplicações [4]. Uma maneira muito comum de aplicar a DWT é a Análise Multiresolucional (MRA, na sigla em inglês).

B. Análise Multiresolucional

MRA é a maneira mais comum de implementar a Transformada Wavelet. Um exemplo simples se encontra na Fig. 1. Da compressão de imagens à supressão de ruídos em todo tipo de sinal [2], a análise multiresolucional pode ser facilmente implementada em computadores.

A MRA tem boas propriedades de reconstrução, de modo que com base nos coeficientes de um determinado sinal, é

possível recuperar o sinal original. Uma descrição simples é que a MRA funciona como um par de filtros recursivamente aplicados ao sinal. Uma função associada com a wavelet mãe, denominada função escalar, opera como filtro passa-baixas, gerando um sinal médio (*Average*), enquanto o filtro passa-alta é a derivada da própria wavelet mãe, e gera um sinal de detalhamento (*Detail*).




Figura 1 – Estrutura da MRA

A cada novo nível do processamento multiresolucional wavelet, os dados digitais têm seu número de amostras dividido pela metade de modo a manter inalterada a quantidade total de amostras do sinal. Este *downsample* é realizado até que o sinal permita, já que as wavelets alteram seu espectro e momento através da dilatação e translação da wavelet mãe, gerando diversos níveis de detalhe, e um coeficiente médio final.

III. DETECÇÃO DE FALTAS DE ENERGIA

Estas aplicações da Transformada Wavelet tem o propósito de adicionar informação qualificada aos sistemas de proteção elétrico. Um outro fator importante é a correta identificação de faltas de alta impedância, já que os componentes de frequências harmônicas têm participação significativa neste tipo de curto, e valores da frequência fundamental em geral se encontram na faixa de correntes nominais, não sendo detectados pela proteção normal.

A maioria dos artigos consultados usa o método de inferência baseado em limiar para definir o momento em que o curto acontece [6]-[11]. Essencialmente o sinal é filtrado pela estrutura wavelet e um dos coeficientes é escolhido para operar como detector, passando por algum tipo de referência fixa ou calculável que decide se o evento é classificado como curto circuito ou operação normal. Esta opção clássica foi seguida neste artigo.

Também é possível aplicar inteligência artificial ou outros métodos lógicos para aumentar a precisão e evitar falsos positivos [12], mas não parece ser tão necessário a não ser para filtrar certos tipos de faltas de alta impedância.

IV. CLASSIFICAÇÃO DE FALTAS DE ENERGIA

Classificação de faltas de energia é uma extensão da detecção de falta. Identificar qual das fases está em falta, e se

é fase-terra, dupla-fase (envolvendo a terra ou não) ou trifásico produz diferentes resultados para a atuação da proteção, bem como para a resposta das equipes de manutenção.

A maioria dos artigos de classificação de faltas também usa o método de inferência baseado em limiares para efetuar a classificação da falta, mas essas técnicas em geral são mais complexas. Muitos autores usam técnicas de limiar com diferentes formatos [16]-[23], mesmo em trabalhos bem recentes [24]. Em geral a formulação clássica da técnica de inferência é semelhante à de detecção, com uma referência calibrada que serve de comparação para um determinado conjunto de coeficientes extraídos pelas wavelets. Outros autores aplicam algum tipo de inteligência artificial [25]-[32], em que podemos notar o uso de redes neurais, máquinas de vetores de suporte e mesmo lógica *fuzzy*. Estas técnicas funcionam inclusive em redes hexafásicas [33].

A proposta deste trabalho é apresentar um novo método de inferência simples e intuitivo para detectar e classificar a ocorrência da falta.

V. O SISTEMA DE PROCESSAMENTO

O algoritmo opera em módulos. O primeiro módulo carrega o arquivo de correntes e tensões gerado pelo ATP dentro do ambiente do Scilab. Os dados são processados e transformados em vetores de corrente e tensão, medidos sempre na origem do circuito simulado.

O segundo módulo estabelece uma janela de observação das variáveis, de modo a limitar o processamento dos sinais num tamanho fixo e permitir liberdade nas características da simulação. Com isso, diferentes tipos de simulação e de intervalos temporais podem ser processados.

Considerando que o sinal original é amostrado/computado em 1 MHz, foram testadas janelas de 2^{10} (1024) a 2^{14} (16384) pontos, mas para as análises efetuadas, uma janela com 2^{12} (4096) pontos, significando aproximadamente 4,1 ms ou $\frac{1}{4}$ do ciclo de 60 Hz foi a mais adequada. Com isso, as wavelets vão da faixa de 500 kHz (detalhe d1) até 7,8 kHz (detalhe d7), já que a wavelet mãe utilizada, Daub4, possui 25 pontos.

O terceiro módulo é o processamento wavelet, em que basicamente é efetuada a rotina da análise multiresolucional até o nível do detalhe d7, gerando, portanto, para cada corrente de fase e a corrente de terra a média A7 e os detalhes d1 a d7.

O módulo de detecção de falta em seguida analisa os valores do detalhe d3 (63 kHz – 125 kHz) de cada corrente e compara com um valor de limiar previamente definido de modo a segregar eventos de curto-circuito de eventos de mudança de carga ou distorção harmônica.

Se o limiar é ultrapassado, este módulo interrompe seu processamento e passa para a próxima rotina, a classificação de falta. Se o limiar jamais é alcançado durante o intervalo da simulação, o programa sinaliza que não aconteceram eventos de falta. A detecção neste método possui uma imprecisão específica máxima de 4,1 ms, haja vista que a janela de análise possui esta largura e o instante do curto é sempre definido como o início da janela. O algoritmo de classificação de falta

usa a energia da média A7 da janela em que o curto circuito foi detectado. Essa energia é computada integrando o quadrado de cada uma das variáveis A7 no espaço da janela em questão.

VI. O CIRCUITO ANALISADO

O circuito teórico aqui analisado (vide Fig. 2) possui 5 barras e opera com 24,5 kV fase-fase. Existe apenas um ponto de medição, colocado na origem da rede, no alimentador da subestação (CT1 da Fig. 2).




Figura 2 – Rede de distribuição simulada

Esta rede elétrica é modelada no ATP com a configuração apresentada na Fig. 3. Os dados das linhas de transmissão modeladas pela rotina LCC (o próprio bloco da linha de transmissão possui o código LCC na figura 3), interna ao programa ATP, estão na Tabela I.




Figura 3 – Representação no ATP do circuito simulado

O bloco RLC em série com o gerador senoidal é a impedância interna da fonte, e funciona também como o ponto de medição. Como o circuito simulado é teórico, a fonte é praticamente uma barra infinita, com impedância série de 0,1 mΩ. Os três blocos RLC aterrados são as cargas do circuito,

cada uma delas com 300 kW de demanda, ou 2000 Ω, e o bloco RLC, com uma chave controlada pelo tempo, faz parte do sistema que simula os diferentes tipos de curto circuito.

TABELA I: DADOS DAS LINHAS DE DISTRIBUIÇÃO MODELADAS NO ATP

Fase	$r_{int}(cm)$	$r_{ext}(cm)$	$R(\Omega/km)$	$L(m)$	$V_{Torre}(m)$	$V_{Rede}(m)$
1	0.2925	0.7925	0.1	-0.65	10	7
2	0.2925	0.7925	0.1	0	10.8	7.8
3	0.2925	0.7925	0.1	0.65	10	7

VII. SIMULAÇÕES E RESULTADOS

O circuito ATP da Fig. 3 é transcrito em formato texto, e posteriormente é modificado por uma rotina Scilab que gera em cada nó (1 a 5) cada tipo de falta (AG, BG, CG, AB, BC, AC, ABG, ACG, BCG, ABC) com 4 ângulos de incidência (0, 90, 180 e 270 graus) e 3 diferentes impedâncias (0.001 Ω, 10 Ω e 1000 Ω), totalizando 600 casos. Isto significa que cada nó teve 120 casos distintos de teste de curto-circuito.

Além das 600 simulações em diferentes condições de falta, foram efetuados mais 34 testes sem falta. 10 destes testes foram a injeção de sinais harmônicos em cada uma das barras (2 tipos diferentes X 5 barras). Os tipos de harmônicos foram sempre fontes de corrente injetadas em cada um dos nós. Um dos tipos foi o acréscimo durante um intervalo de 5 ms de um sinal do tipo dente de serra de 10 A repetido por 4 vezes, gerando um sinal de interferência apresentado na Fig. 4.

O outro foi um sinal constante composto por uma soma de diversos harmônicos de 60 Hz, com coeficientes variáveis (3°, 5°, 9° e 17°), chegando a um valor de pico aproximado de 20 A, conforme Fig. 5.




Figura 4 – Corrente dente-de-serra injetada no sistema




Figura 5 – Corrente harmônica injetada no sistema

Os outros 24 testes de verificação foram feitos nas barras com carga, barras 3, 4 e 5. Em cada barra com carga foram testados nos 4 ângulos (0, 90, 180 e 270 graus), 2 variações de carga, dobrando a carga original do nó de 300 kW para 600 kW, e em outros casos reduzindo à metade, para 150 kW. Testes de incrementos de carga mais significativos, como a entrada em operação de cargas maiores que 500 kW foram testados de forma não sistemática, e, portanto, não merecem ser apresentados aqui, caracterizando-se como uma limitação do sistema apresentado. É importante perceber que um curto de 1000 Ω em 24,5 kV é uma potência de 600 kVA, relativamente pequena.

A. Simulações de curto-circuito – 1 exemplo de 600 casos

Para exemplificar a sequência do processamento proposto, iremos usar como exemplo um curto-circuito BCG com impedância de 1 m Ω e ângulo zero simulado na barra 3. Todas as 600 ocorrências de curto-circuito sofrem o mesmo tipo de processamento, com as variações peculiares aos seus sinais.

O curto simulado no ATP possui o gráfico apresentado na Fig. 6.




Figura 6 – Correntes trifásicas para um curto franco BCG na barra 3

Essas correntes e tensões são processadas pelo primeiro módulo do algoritmo de forma a se obterem os coeficientes wavelet. Esses coeficientes por fim são observados através de uma janela fixa, conforme descrito na seção IV, e os valores dos detalhes d3 e da média A7 são computados.

Na Fig. 7 pode-se ver diversas janelas do detalhe d3 sobrepostas, caracterizando a aplicação do módulo de detecção. Em operação normal, o valor do detalhe d3 é praticamente nulo, e no momento em que o curto-circuito se inicia ele tem um pico facilmente detectável através de um limiar neste detalhe. O eixo das abscissas é o número de amostras do detalhe d3 (no caso, $4096/2^3$, 512 amostras), como as janelas estão sobrepostas não é possível perceber a correlação linear com o tempo. O eixo das ordenadas é o coeficiente wavelet do detalhe.

Assim que um curto circuito é detectado com base no detalhe d3, passa a operar o módulo de classificação da falta, baseado na energia do valor médio A7.




Figura 7 – Detalhe d3 das correntes em janelas sobrepostas, mostrando o momento de um curto franco BCG na barra 3

Na Fig. 8 pode-se perceber que a energia do valor médio A7 nunca é nula, fica flutuando com as oscilações senoidais da fase, já que a janela de 4,1 ms, como dito, $\frac{1}{4}$ do sinal de 60 Hz, gera sinais repetitivos em condições normais. No momento do curto, no entanto, pode-se perceber que as fases com falta têm um crescimento significativamente perceptível. O eixo das abscissas representa o número de janelas processadas, portanto tem correlação com o tempo do sinal que está sendo avaliado. De fato, cada ponto representa 4,1 ms, ou seja, o curto acontece no instante $27 \times 4,1 \text{ ms} = 110,7 \text{ ms}$, corroborando com a Fig. 6. O eixo das ordenadas é a energia, numa correlação com o quadrado da corrente.




Figura 8 – Energia da média A7 das 3 fases para um curto franco BCG na barra 3

No caso da Fig. 8, as fases B e C têm crescimento acima da média, e a energia da corrente de terra sai do valor praticamente nulo anterior. A energia da fase A se mantém no mesmo comportamento anterior.

Neste módulo, a regra de inferência baseada em limiares é relativa, ou seja, proporcional aos valores calculados antes da

falta. Apenas quando um salto significativo é detectado, a fase é considerada em falta.

B. Simulações de conferência – 2 exemplos de 34 casos

Estes sinais geram alterações perceptíveis na forma de onda da tensão, como se pode ver nas Figs. 9 e 10.




Figura 9 – Tensão resultante da injeção da corrente dente-de-serra, barra 3




Figura 10 – Tensão resultante da injeção da corrente senoidal, barra 3

Ainda assim, estes sinais não chegam a ultrapassar os limiares definidos no algoritmo, e os valores de corrente de interferências de qualidade de energia não são significativos a ponto de serem confundidos com curto-circuito.

C. Resultados

O sistema proposto, portanto, detectou corretamente as 600 condições de falta e não detectou nenhuma das 34 condições sem falta. Adicionalmente classificou corretamente 599 dos casos, ou seja, 99,83% de acerto. Apenas uma falta do tipo BT com impedância de 1000 ohms no ângulo de 270 graus na barra 5 não foi classificada com precisão, mas o algoritmo definiu como uma falta do tipo XG, indicando claramente que o evento foi um curto fase-terra. Esta falha demonstra que o sistema ainda tem pontos de melhoria a serem verificados.

VIII. CONCLUSÕES

O sistema proposto neste trabalho se mostrou bastante eficiente para detectar e classificar faltas de energia em

sistemas radiais, considerando medição num único ponto da rede elétrica. A detecção é realizada utilizando um limiar fixo atuando sobre o detalhe d3 das correntes, e a classificação é efetuada com um limiar relativo (proporcional) sobre a média A7 das transformadas Wavelets.

Ambos os resultados são úteis em si mesmo, proporcionando detecção de faltas de energia de modo preciso e confiável, bem como agregando informações confiáveis no caso de falhas permanentes, informações que irão ajudar a um restabelecimento mais rápido por parte das equipes de manutenção. Ademais, este processo se mostrou robusto a variações de carga ou à presença de harmônicos.

Pontos frágeis do sistema são a incapacidade de detectar falhas cuja impedância se aproxime do limiar da impedância de carga, já que o método de inferência empregado usa um limite rígido de detecção. Estes casos não foram tratados de forma sistemática, mas com base em dados preliminares esta limitação se apresenta. Para a maior parte das faltas práticas em sistemas de distribuição, todavia, o sistema é amplamente válido, já que a intensidade do curto é significativamente maior que as variações normais de carga.

Trabalhos futuros, no entanto, deverão ampliar a aplicação deste sistema, desenvolvendo um sistema amplo de detecção, classificação e localização de faltas de energia. Para esta última finalidade, no entanto, sistemas de inteligência artificial deverão ser agregados ao conjunto de análise.

REFERÊNCIAS

- [1] I. Daubechies, Ten Lectures on Wavelets, SIAM, 1992
- [2] J. S. Walker, A Primer on Wavelets and their Scientific Applications, CRC Press, 1999
- [3] C. Gargour, M. Gabrea, V. Ramchandran, J.-M. Lina, "A Short introduction to wavelets and their applications", IEEE Circuits and Systems Magazine 2009; 9(2): 57-68
- [4] A. W. Galli, G. T. Heydt, P. F. Ribeiro, "Exploring the power of wavelet analysis", IEEE Computer Application in Power Systems 1996; 9(4): 37-41
- [5] R. M. de C. Fernandez, H. N. D. Rojas, "An Overview of wavelet transforms application in power systems", 14th Power System Computation Conference – PSCC 2002
- [6] O. Chaari, M. Meunier, F. Brouaye, "Wavelets: a new tool for the resonant grounded power distribution systems relaying", IEEE Transactions on Power Delivery 1996; 11(3): 1301-8
- [7] A. Ukil, R. Zivanovic, "Abrupt change detection in power system fault analysis using wavelet transform", International conference on Power Systems Transients – IPST 2005, paper 202
- [8] A. Ukil, R. Zivanovic, "Adjusted Haar wavelet for application in the power system disturbances analysis", Digital Signal Processing 2008; 18(2): 103-115
- [9] T. NengLing, C. JiaJia, "Wavelet-based approach for high impedance fault detection of high voltage transmission line", European Transactions on Electrical

- Power 2008; 18:79–92
- [10] Y. Huang M. Chen J. Zhai, “High impedance fault identification method of the distribution network based on discrete wavelet transform”, International Conference on Electrical and Control Engineering - ICECE 2011: 2262-5
 - [11] V. Torres, H. Ruiz, “High impedance fault detection using discrete wavelet transform”, Electronics, Robotics and Automotive Mechanics Conference 2011: 325-9
 - [12] I. Baqui, I. Zamora, J. Mazón, G. Buigues, “High impedance fault detection methodology using wavelet transform and artificial neural networks”, Electric Power Systems Research 2011; 81: 1325-33
 - [13] T. M. Lai, L. A. Snider, E. Lo, “Wavelet transform based relay algorithm for the detection of stochastic high impedance faults”, Electric Power Systems Research 2006; 76: 626-33
 - [14] A. Lazkano, J. Ruiz, E. Aramendi, L. A. Leturiondo, “Evaluation of a new proposal for an arcing fault detection method based on wavelet packet analysis”, European Transactions on Electrical Power 2004; 14:161–74
 - [15] R. H. Salim, K. R. C. Oliveira, A. S. Bretãs, “Fault detection in primary distribution systems using wavelets”, International conference on Power Systems Transients - IPST 2007, paper 125
 - [16] J. Liang, S. Elangovan, J. B. X. Devotta, “A wavelet multiresolution analysis approach to fault detection and classification in transmission lines”, Electric Power Systems Research 1998; 20 (5): 327-32
 - [17] C. Hong, S. Elangovan, “A B-spline wavelet based fault classification scheme for high speed protection relaying”, Electric Machines & Power Systems 2000; 28(4): 313-24
 - [18] O. A. S. Youssef, “Fault classification based on wavelet transforms”, Proceedings of 2001 IEEE/PES Transmission and Distribution Conference and Exposition, 2001
 - [19] O. A. S. Youssef, “A Modified wavelet-based fault classification technique”, Electric Power Systems Research 2003; 64: 165-72
 - [20] D. Chanda, N. K. Kishore, A. K. Sinha, “Identification and classification of faults on transmission lines using wavelet multiresolution analysis”, Electric Power Components and Systems 2004; 32(4): 391-405
 - [21] K. M. Silva, K. M. C. Dantas, B. A. Souza, N. S. D. Brito, F. B. Costa, J. A. C. B. Silva, “Haar wavelet-based method for fast fault classification in transmission lines”, Transmission & Distribution Conference and Exposition – TDC, 2006: 1-5
 - [22] S. P. Valsan, K. S. Swarup, “Fault detection and classification logic for transmission lines using multi-resolution wavelet analysis”, Electric Power Components and Systems 2008; 36(4): 321-44
 - [23] S. Safty, A. El-Zonkoly, “Applying wavelet entropy principle in fault classification”, International Journal of Electrical Power and Energy Systems 2009; 31: 604-7
 - [24] Y. Allipilli, G. Narashima Rao, “Detection and classification of faults in transmission lines based on wavelets”, International Conference on Electrical, Electronics, Signal, Communication and Optimization – EESCO, 2015
 - [25] O. A. S. Youssef, “Combined fuzzy-logic wavelet-based fault classification technique for power system relaying”, IEEE Transactions on Power Delivery 2004; 19(2): 582-9
 - [26] O. Dag, C. Ucak, “Fault classification for power distribution systems via a combined wavelet-neural approach”, International Conference on Power Systems Technology – POWERCON 2004; 2: 1309-14
 - [27] K. M. Silva, B. A. Souza, N. S. D. Brito, “Fault detection and classification in transmission lines based on wavelet transform and ANN”, IEEE Transactions on Power Delivery 2006; 21(4): 2058-63
 - [28] R. N. Mahanty, P. B. Dutta Gupta, “Comparison of fault classification methods based on wavelet analysis and ANN”, Electric Power Components and Systems 2006; 34(1): 47-60
 - [29] G. Sudha, T. Basavaraju, “A Comparison between different approaches for fault classification in transmission lines”, International Conference on Information and Communication Technology in Electrical Sciences – ICTES 2007: 398-403
 - [30] B. Bhalja, R. P. Maheshwari, “Wavelet-based fault classification scheme for a transmission line using a support vector machine”, Electric Power Components and Systems 2008; 36(10): 1017-30
 - [31] Upendar, J., Gupta, C. P., Singh, G. K., Ramakrishna, G., “PSO and ANN-based fault classification for protective relaying”, IET Generation, Transmission & Distribution 2010; 4 (10): 1197-1212
 - [32] J. Upendar, C. P. Gupta, C. K. Singh, “Statistical decision-tree based fault classification scheme for protection of power transmission lines”, International Journal of Electrical Power and Energy Systems 2012; 36: 1 – 12
 - [33] R. Kumar, E. Koley, A. Yadav, A. S. Thoke, “Fault classification of phase to phase fault in six phase transmission line using Haar wavelet and ANN”, 2014 International Conference on Signal Processing and Integrated Networks (SPIN), 2014