

Detecção de Falhas de Alta Impedância Utilizando os Vetores de Energia dos Centroides das Sub-bandas Espectrais

Reginaldo B. G. Grimaldi*, Fernando Augusto Moreira*, Tarso Vilela Ferreira**, Jugurta Montalvão**, Wellinsilvio C. dos Santos***

* Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal de Bahia – PPGEE/UFBA Rua Aristides Novis, n.02, 4º andar, Sala 23 Federação - CEP: 40210-630. Salvador - Bahia, Brasil. E-mails: reginaldogrimaldi@gmail.com, moreiraf@ufba.br

** Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal de Sergipe – PROEE/UFS Av. Marechal Rondon, s/n, Jd. Rosa Elze, São Cristóvão/SE - Brasil, CEP: 49100-000. E-mails: tarso@ufs.br, jugurta.montalvao@gmail.com

*** Centro de Tecnologia da Universidade Federal de Alagoas Grande – CTEC/UFAL Campus A.C. Simões - BR 101 Norte - Km. 14 - Tabuleiro do Martins - Maceió/AL - Brasil CEP: 57.072-970. E-mails: wellinsilvio.santos@ctec.ufal.br

Abstract: In many situations, conductor rupture in distribution systems or even their contact with structures external to the systems (such as trees) does not sensitize protection systems. This type of occurrence and its variations are typically called high impedance faults, considered to be of high severity by the concessionaires. The present work aims to present a method for detecting high impedance faults based on the Energy Vectors of the Centroids of the Spectral Sub-bands. Regarding the validation of the method, a database was created through simulations performed in the Alternative Transients Program, based on a real distribution system. In addition to high impedance faults, load energization and capacitor bank switching situations were also simulated to test the robustness of the method against probable false positives. A database containing real oscillography of high impedance faults was also used. An Artificial Neural Network was trained in order to classify the disturbances using the proposed method. From the satisfactory results obtained, the viability of the developed method can be seen.

Resumo: Em muitas situações, o rompimento de condutores nos sistemas de distribuição, ou mesmo seu contato com superfícies de alta impedância (como árvores), não sensibiliza o sistema de proteção. Este tipo de ocorrência e suas variações são tipicamente chamados de falhas de alta impedância, considerada de alta gravidade pelas concessionárias. O presente trabalho tem por objetivo apresentar um método de detecção de falhas de alta impedância baseadas nos Vetores de Energia dos Centroides das Sub-bandas Espectrais. Com relação à validação do método, foi criado um banco de dados por meio de simulações realizadas no programa *Alternative Transients Program*, com base em um sistema de distribuição real. Além das falhas de alta impedância, também foram simuladas situações de energização de carga e comutação de banco de capacitores para testar a robustez do método contra prováveis falsos positivos. Um banco de dados contendo oscilografias reais de falhas de alta impedância também foi utilizado. Uma Rede Neural Artificial foi treinada a fim de classificar os distúrbios por meio do método proposto. A partir dos resultados obtidos, satisfatórios, percebe-se a viabilidade do método desenvolvido, que obteve uma taxa de sucesso de 98,23%.

Keywords: High Impedance Faults, Spectral Sub-band Centroid Energy Vectors, Artificial Neural Network, Capacitor Bank Switching, Load Energization.

Palavras-chaves: Falta de Alta Impedância, Vetores de Energia dos Centroides das Sub-bandas Espectrais, Redes Neurais Artificiais, Comutação de Banco de Capacitores, Energização de Cargas.

1. INTRODUÇÃO

Os sistemas de distribuição de energia elétrica (SDEE) estão expostos a várias perturbações e anomalias que afetam a operação de redes elétricas. Entre inúmeras perturbações, as falhas de alta impedância (FAI) são algumas das principais preocupações e podem ocorrer quando um cabo energizado, rompido ou não, entra em contato com uma superfície de alta impedância, como por exemplo um galho de árvore. Na ocorrência de uma FAI, a corrente de falta apresenta baixa

amplitude, tendo a mesma ordem de grandeza que outros fenômenos típicos de um SDEE, como energização de carga (EC) ou comutação de banco de capacitores (CBC). De acordo com García et al. (2014), essas falhas não podem ser detectadas pelos dispositivos de proteção usuais ativados por sobrecorrente.

De acordo com Ghaderia et al. (2017), a frequência de ocorrência de uma FAI é um tópico que envolve bastante discussão, pois a maioria das ocorrências não é registrada pelas equipes de campo. As melhores estimativas são que

entre 5% e 10% de todos os eventos de falha do sistema de distribuição são condutores inoperantes, ou seja, ocorrências de Falhas.

Em relação à ocorrência de episódios de FAI, além de comprometer a qualidade do serviço, as empresas de distribuição de energia podem sofrer sanções estipuladas pelos órgãos reguladores, que avaliam e regulam - em vários aspectos - o fornecimento de energia elétrica. O não atendimento aos limites impostos pela ANEEL, no módulo 8 do PRODIST, podem acarretar multas e compensação aos consumidores (Zamboni, 2011). Adicionalmente, um mal desempenho dos indicadores de continuidade de fornecimento tendem a desvalorizar a imagem da concessionária frente à opinião pública.

No entanto, as perdas financeiras e os danos intangíveis associados à imagem das empresas de energia não são as consequências mais preocupantes da FAI. Acidentes, riscos à saúde de animais e pessoas, eventualmente levando à morte, são de fato as consequências mais trágicas. Ante o exposto, o estudo desse fenômeno tem despertado o interesse tanto da academia quanto das empresas, principalmente, no desenvolvimento de métodos de diagnóstico, haja vista as dificuldades de sua identificação por meio dos sistemas de proteção convencionais baseados em sobrecorrente. Muitos trabalhos foram publicados propondo a análise de sinais de FAI no domínio do tempo e no domínio da frequência. Muitos trabalhos foram publicados envolvendo Transformada Wavelet Discreta (TWD) (Hafidz, 2017; Moloji, 2019), Morfologia Matemática (Sarлак et al., 2013; Gautam et al., 2013), Transformada S (Samantaray et al., 2008; Routray et al., 2015) e Análise de Conteúdo Harmônico (Lima et al., 2018; Grimaldi et al., 2021).

Embora pesquisas significativas tenham sido realizadas para a detecção de FAI em sistemas de distribuição, há uma forte necessidade de desenvolvimento de novos métodos que possam detectar a FAI de forma eficiente e confiável, uma vez que nenhum dos métodos apresentados até agora foi consolidado na prática. Assim, considerando o problema causado pelo FAI, o presente trabalho tem como objetivo principal desenvolver um método de detecção de faltas de alta impedância baseadas no comportamento do sinal de corrente, a partir dos Vetores de Energia dos Centroides das Sub-bandas Espectrais (VECSE). O método desenvolvido é menos sensível a variação, o que pode ser vantajoso em alguns casos, já que nos sistemas elétricos ocorrem muitas variações no sinal de corrente e muitos fenômenos de curta duração como o CBC e EC.

2. FALTAS DE ALTA IMPEDÂNCIA

A principal característica de uma FAI é a baixa amplitude das correntes da falta, as quais são causadas principalmente pelo rompimento ou não do condutor energizado e do seu contato com uma superfície de alta impedância, como areia, asfalto, cascalho, grama e calçamento (Santos, 2016). Durante o fenômeno, antes do cabo entrar em contato com o solo, pode ocorrer um arco elétrico, pois, quando o cabo energizado se aproxima do solo, a diferença de potencial aumenta e o campo elétrico torna-se mais intenso, diminuindo a

resistência do ar, o que facilita o processo de condução do ar (Nakagomi, 2006).

A ocorrência do arco elétrico na FAI dá origem a algumas características nas formas de onda dos sinais de corrente de uma FAI, que são:

- **Intermitência:** processo relacionado à formação e extinção do arco elétrico durante a FAI. A penetração do arco na superfície de alta impedância diminui a umidade da região de contato, forçando a extinção do mesmo. Todavia, a umidade de outra área próxima ao condutor pode difundir-se, reiniciando a formação do arco, processo conhecido como intermitência (Nakagomi, 2006).
- **Assimetria:** magnitude do semiciclo positivo maior que a do semiciclo negativo. Essa característica é atribuída à porosidade e umidade da superfície de contato (Emanuel, 1990).
- **Não linearidade:** resultante de diferentes resistividades das diversas camadas do solo (Lima, 2018).
- **Build-up e Shoulder:** a presença do arco elétrico provoca ainda o crescimento da envoltória da corrente de falta, fenômeno conhecido como *build-up*, pois o cabo demora certo tempo para assentar-se completamente no solo. Durante o *build-up*, a amplitude pode permanecer constante antes de voltar a crescer, dando origem ao fenômeno denominado de *shoulder* (Nakagomi, 2006).

Todas essas características são apresentadas na Fig. 1.




Fig. 1 Detalhamento do comportamento da corrente de uma FAI.

Com relação à análise do sinal no domínio da frequência, as características dos sinais de corrente geradas pela FAI produzem um comportamento harmônico, que pode ser usado para detectar as FAI. Segundo Nakagomi (2006), as correntes de FAI produzem os seguintes componentes espectrais:

- A distorção na forma de onda, decorrente da não-linearidade da resistência do arco, propicia o

aparecimento de harmônicas de baixa ordem na corrente (3° ao 10° harmônicos, aproximadamente).

- A assimetria entre os semiciclos é responsável pela presença dos harmônicos de ordem par.
- A intermitência da corrente durante a formação e a extinção do arco leva ao surgimento de um espectro de harmônicos de alta frequência.
- Os fenômenos de *build-up* e *shoulder* provocam variação da amplitude da corrente ao longo do tempo, produzindo inter-harmônicos resultantes do comportamento dinâmico da resistência de contato do defeito.

3. VETORES DE ENERGIA DOS CENTROIDES DAS SUB-BANDAS ESPECTRAIS

Dado que as FAI têm comportamentos característicos explicitados no domínio da frequência, percebeu-se a necessidade, neste trabalho, de uma técnica que permitisse agrupar estas características e compactar a informação relevante. Desta forma, resolveu-se analisar a influência da FAI nos centroides de sub-bandas espectrais, utilizando o método dos Vetores de Energia dos Centroides de Sub-bandas Espectrais (VECSE).

De acordo com Ferreira (2011), o comportamento dos centroides espectrais de um sinal no domínio da frequência pode ser utilizado como um dos parâmetros para detecção da FAI. O centroide espectral indica o “centro de massa” (baricentro) de um espectro de frequências ou sub-banda espectral. Ele é calculado como uma média ponderada das frequências presentes no sinal, em que as amplitudes das frequências são os pesos. Outro parâmetro que pode ser utilizado é a energia espectral, que é a energia contida no espectro de frequência.

Segundo Ferreira (2011), os passos para obtenção do VECSE, encontram-se descritos abaixo:

1. Aplicação da transformada rápida de Fourier (TRF) do sinal para estimar o espectro de potência;
2. Divisão do espectro em um número de sub-bandas de frequências sobrepostas, obtido pela aplicação de superposição dos filtros.
3. Localização dos centroides espectrais de cada sub-banda no espectro aplicando (14):

$$C_H = \frac{\sum_{k=0}^{N-1} W_m(k) \cdot P(k)}{\sum_{k=0}^{N-1} P(k)} \quad (1)$$

em que, $P(k)$ é a potência na k -ésima frequência da parcela do espectro estimado que foi limitado pelo filtro (sub-banda); $W_m(k)$ é o vetor de frequências; e N é o número de amostras disponíveis na sub-banda. Deve-se destacar que tanto $P(k)$ quanto $W_m(k)$ são números reais positivos.

4. Cálculo da energia média associada a cada centroide aplicando (15):

$$E_C = \sum_{k=\sigma_1}^{\sigma_2} P(k) \quad (2)$$

$\sigma_1 = C_H - \delta \cdot N$ e $\sigma_2 = C_H + \delta \cdot N$, sendo σ_1 e σ_2 números inteiros, aproximados a partir dos cálculos de σ_1 e σ_2 ; C_H é a localização do centroide da sub-banda em questão; e δ é o parâmetro que definirá a largura da faixa em torno do centroide que será utilizada para o cálculo da energia média.

4. REDES NEURAIS ARTIFICIAIS

As RNA possuem propriedades particulares tais como a habilidade de adaptar-se e aprender, generalizar, agrupar ou organizar dados. As operações são baseadas em processamento paralelo. Esse tipo de ferramenta computacional é particularmente apropriado em tarefas de reconhecimento de padrões, classificação, otimização, quantização vetorial e agrupamento de informações (Haykin, 2001).

Em diversos problemas, as RNA são empregadas para classificar padrões. Cada classe C contém n elementos (padrões) que a representam, e a união das classes compõe a base de dados. A base de dados tem seus padrões aleatoriamente dispostos, e em geral dividida em três subconjuntos: treinamento, validação e teste (Ferreira, 2011):

- Treinamento: responsável por passar efetivamente o conhecimento sobre a aplicação em questão. Durante a etapa de treinamento todos os padrões de treinamento são apresentados sucessivas vezes à RNA, em iterações chamadas “épocas”.
- Validação: o conjunto de validação é utilizado para supervisionar o desenvolvimento da capacidade de generalização da rede durante a fase de aprendizagem. Ao fim de cada época o conjunto de dados de validação é apresentado à RNA, permitindo-se verificar se a rede consegue tomar decisões corretas a partir de dados que não compõem o conjunto de treinamento.
- Teste: o conjunto de teste só é aplicado ao final da etapa de aprendizagem, para verificar a qualidade do aprendizado da rede.

Existem diversos tipos de Redes Neurais, entre elas as mais conhecidas são a *Adaline*, *Perceptron* de Camada Única e *Perceptron* Multicamada, ou redes MLP (*Multilayer Perceptron*) (Oliveira, 2005). Uma rede MLP consiste em uma camada de entrada constituída de unidades sensoriais, uma ou mais camadas ocultas e uma camada de saída, todas conectadas (FERREIRA, 2011).

As redes MLP possuem um processo de aprendizagem supervisionado, baseado no subconjunto de treinamento de onde a rede irá extrair o conhecimento da aplicação. Durante o treinamento, cada resultado apresentado na camada de saída de RNA é confrontado com o resultado esperado (Ferreira, 2011). Além da arquitetura, pode-se dizer que uma vantagem é que a rede MLP permite a aplicação da Regra de Aprendizado Delta Generalizada ou Regra *Backpropagation* ou, ainda, Regra de Retropropagação do Erro, uma das mais

poderosas regras de aprendizado das RNA (Abdi et al., 1999).

5. METODOLOGIA

No desenvolvimento do trabalho foi realizado inicialmente a construção da base de dados e depois a proposição e avaliação do algoritmo de detecção.

5.1 Construção da Base de Dados

As bases de dados contendo oscilografias dos fenômenos tratados foram construídas em duas frentes de atuação: uma relativa às FAI e outra relativa a fenômenos que guardam semelhança com as FAI (energização de cargas e bancos de capacitores), no sentido de avaliar a ocorrência de falsos positivos. A base de dados foi construída com 775 simulações (oscilografias), sendo 214 simulações de FAI, 313 simulações de CBC e 248 simulações de EC. Nos três fenômenos simulados (FAI, CBC e EC), as condições de carregamento das cargas variaram entre 25 e 100% em passos de 25% da capacidade instalada. Nas FAI o ângulo de incidência da falta variou de 0 a 180° em passos de 30°. Além disso, nas simulações de FAI, CBC e EC foram realizadas em diferentes locais do sistema-teste desde a barra 1 até a barra 90.

A segunda base de dados composta por sinais reais de FAI foi composta de 27 sinais. A Tabela 1 sumariza a base de dados utilizada em todo o trabalho.

Tabela 1. Base de dados.

Fenômenos		Número de Registros
Simulados	FAI	214
	CBC	313
	EC	248
Real	FAI	27
Total		802

Após a construção da base de dados, todos os sinais foram reamostrados na taxa de 15.360 Hz, que é a frequência de amostragem típica adotada pelos registradores digitais de perturbação (RDP). Em aplicações reais os sinais de tensão e corrente registrados estão sujeitos à presença de ruído. Assim, foi necessário realizar a modelagem do ruído nos sinais simulados, para que os mesmos estivessem mais próximo de situações reais. Neste trabalho foi utilizado um ruído gaussiano branco de 60 dB.

As simulações de FAI foram geradas a partir de um modelo proposto por Santos (2016) que foi capaz de reproduzir as principais características de uma FAI, ou seja: não-linearidade, assimetria, intermitência, *build-up* e *shoulder*. Para construção do modelo, Santos (2016) utilizou registros oscilográficos resultantes de ensaios de campo, considerando seis tipos de solos (secos e molhados): areia, asfalto, calçamento, grama, brita e terra local. O modelo de Santos (2016) é apresentado na Fig. 2.

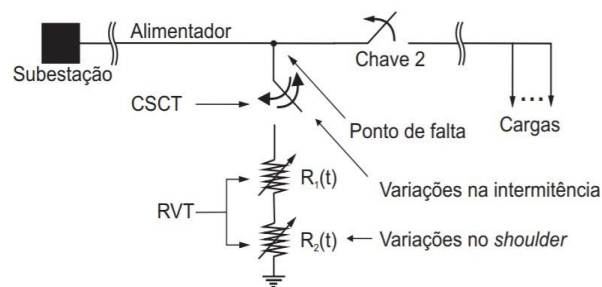


Fig. 2 Modelo utilizado para simular a FAI. (Santos, 2016).

O modelo proposto fez o uso de duas resistências variantes no tempo, em série e controladas por *Transient Analysis of Control Systems* (TACS) no ATP, além de uma chave simples controlada por TACS, que foi acrescida de forma a dar início à falta e simular a descontinuidade da corrente de falta. Uma chave comum foi ligada a jusante do ponto de falta para simular o rompimento do condutor (Santos, 2016).

Vale ressaltar que apenas as FAI geradas com o rompimento do condutor foram simuladas. Para simular as FAI, além do modelo proposto, foi realizada no ATP uma modelagem de um sistema teste (um sistema de distribuição real de 13,8 kV de uma concessionária de energia elétrica brasileira) cujo diagrama é apresentado na Fig. 3. Foram geradas simulações de FAI nas 90 barras do sistema-teste.




Fig. 3 Diagrama unifilar do modelo do alimentador escolhido. Adaptado de (Santos, 2016).

O sistema-teste foi modelado considerando as seguintes características (Santos, 2016):

- Linhas trifásicas não transpostas a parâmetros distribuídos e constantes com a frequência.
- Trechos compostos por um único tipo de cabo: cabo 4 AWG.
- Cargas de pontos próximos ao longo do alimentador, agrupadas em uma única barra, resultando em um alimentador com 90 barras.

- Fator *skin* para os cabos de 0,33.
- Resistividade da terra de 350 Ω /m.
- Modelo de impedância constante para as cargas, considerando circuitos (RL) paralelos, conectados entre cada fase de cada barra e a terra.
- Fator de potência médio de 0,955.

Todos os dados georreferenciados do alimentador, assim como as cargas distribuídas ao longo dos transformadores foram modeladas. Apenas faltas entre uma fase e terra foram simuladas porque as FAI são consideradas monofásicas (Santos, 2016).

Visando avaliar a capacidade de seletividade do método de detecção de FAI proposto neste trabalho, foram simulados dois tipos de distúrbios usuais nos SDEE: chaveamento de bancos de capacitores (CBC) e energização de cargas (EC). Os eventos foram simulados no mesmo sistema-teste.

A energização de cargas foi simulada adicionando uma chave em determinada barra do sistema teste. Os transitórios devem ocorrer por alguns ciclos após o chaveamento seguido de um aumento das correntes à montante do ponto de conexão. O chaveamento de bancos de capacitores foi simulado considerando um banco de 1,8 Mvar, valor usual em sistemas de distribuição. Os transitórios devem ocorrer a partir do momento do fechamento de uma chave alocada junto ao banco de capacitores, em determinada barra, e por alguns ciclos seguintes.

5.2 Proposição e Avaliação do Algoritmo de Detecção

A corrente de fase observada na subestação do sistema teste (religador no barramento 1) foi usada como o único sinal de entrada para o processo de classificação. Inicialmente todos os sinais de corrente obtidos nas simulações (FAI e fenômenos) passaram por um processo de janelamento com uma largura de janela de 5 ciclos, com um passo de um ciclo por vez. Cada parcela do sinal de corrente obtida a partir do janelamento foi separada e identificada como FAI, EC, CBC e situação sem distúrbio. Uma vez identificadas cada parcela do sinal, foi realizado o processamento para a estimação dos VECSE, conforme apresentado na seção 4.

Após o processo de janelamento, obteve-se uma base de dados com 10.912 parcelas janeladas de sinais, sendo que cada evento possui 2.728 janelas (FAI, CBC, EC e situação sem distúrbio). Esta base de dados foi utilizada no treinamento, validação e teste da RNA. Cada janela foi processada pelo algoritmo dos VECSE e a saída deste processamento serviu de entrada à RNA. A base de dados possui, portanto, 10.912 amostras dispostas em 4 classes, e durante os processos de treinamento, validação e teste estas amostras foram apresentadas à RNA de forma aleatória.

Os percentuais da base de dados destinados ao treinamento, validação e teste da RNA, foram arbitrados da seguinte forma:

- Treinamento - 70% (7638 padrões).

- Validação - 15% (1637 padrões).
- Teste - 15% (1637 padrões).

A arquitetura do sistema neural utilizado foi constituída de uma rede do tipo *multilayer feedforward network*, mais particularmente uma *multilayer perceptron* (MLP) de três camadas (duas camadas ocultas) e implementada no software MATLAB®. Neste trabalho, foi empregada nas camadas ocultas e na camada de saída a função de ativação não-linear do tipo sigmoial (logsig), que assume um intervalo contínuo de valores entre 0 e 1.

Para o treinamento, foi utilizado o algoritmo de *Levenberg Marquardt* (LM), sendo as redes projetadas para calcular os pesos sinápticos do MLP empregando aprendizagem por retropropagação do erro. O desempenho da rede é avaliado pelo erro quadrático médio (MSE – *mean squared error*) que é a média do somatório dos quadrados dos erros de cada caso, tanto do conjunto de treinamento, quanto do conjunto de testes.

Como o método dos VECSE possui parâmetros que podem ser variados de aplicação para aplicação, uma análise de sensibilidade foi realizada a fim de determinarem-se valores que permitiam o melhor desempenho do algoritmo proposto. Tais parâmetros são: número de filtros, percentual de sobreposição dos filtros e o δ .

Depois dos ajustes dos parâmetros do VECSE, foram realizados testes com diferentes topologias de RNA (todas MLP) com o intuito de identificar qual a configuração que apresenta o melhor desempenho no processo de classificação. As variações de parâmetros de VECSE e de topologias de RNA foram testadas em diversas combinações, e a combinação com maior taxa de sucesso será apresentada na seção de resultados.

O diagrama de blocos apresentado na Fig. 4 sumariza a metodologia de ajuste do método de detecção e classificação da FAI baseado no VECSE.

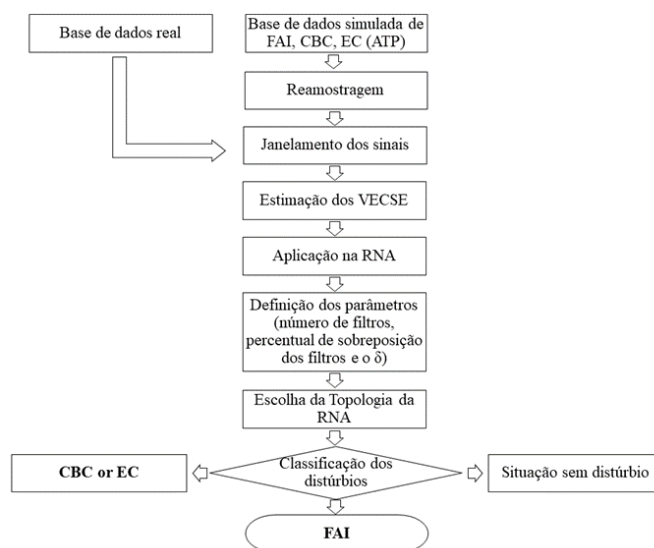


Fig. 4 Diagrama de blocos representando metodologia baseada no VECSE.

Após definidos os parâmetros do VECSE e a topologia da rede, testes foram realizados com o intuito de verificar a quantidade de ciclos necessários para a correta classificação de cada fenômeno, o que permite quantificar o tempo de classificação. Para isso, 36 oscilografias de FAI (equivalente a 15% das oscilografias de FAI), 36 oscilografias de CBC e 36 oscilografias de EC, foram separadas aleatoriamente, para que os teste referentes a quantidade de ciclos necessários para classificação de cada fenômeno fosse realizado. O restante da base de dados foi utilizada para treinamento da RNA. Após o treinamento, a RNA foi salva e os teste foram realizados. Os resultados serão apresentados na seção de resultados.

6. RESULTADOS

Uma RNA foi treinada neste trabalho, a fim de classificar os distúrbios por meio de VECSE. O comportamento das magnitudes e frequências dos centroides espectrais, partes constituintes dos vetores, foi utilizado para classificar os eventos.

Relativamente à FAI, na medida em que aumenta o número de amostras de sinal com presença da falta dentro da janela amostral, tanto a energia associada a cada centroide quanto a localização dos centroides espectrais de cada sub-banda, variam. Na Fig. 5 é apresentado o comportamento dos vetores à medida que aumentavam o número de amostras dentro da FAI, ocorrida no barramento 10 em uma superfície de brita com condições de carga em 25%, utilizando 20 filtros, porcentagem de sobreposição de 90% e $\delta = 0,1$.

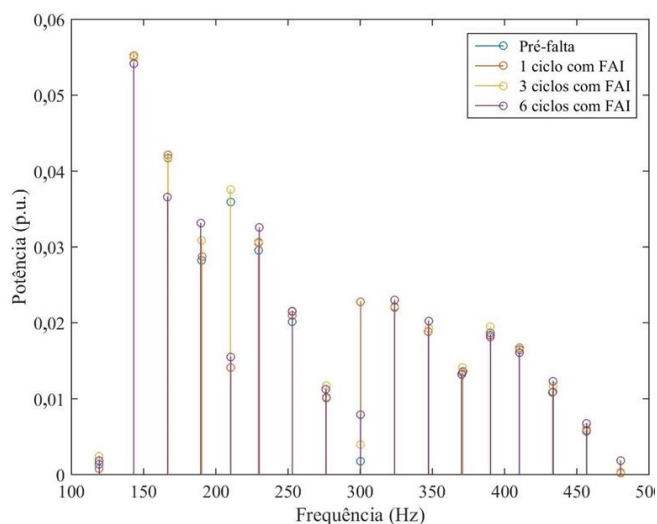


Fig. 5 Resultado do Processamento de uma FAI ocorrida na brita, no barramento 10.

Na Fig. 5 cada cor indica uma quantidade de amostras do sinal dentro da janela amostral: as colunas azuis representam a situação pré-falta; as colunas laranja representam os VECSE quando a janela amostral está enquadrando 1 ciclo (256 amostras) da FAI; as colunas amarelas, 3 ciclos (768 amostras); e as colunas roxas, 6 ciclos (1536 amostras), respectivamente.

Após o período de *build-up* e *shoulder* o comportamento do VECSE é bastante diferente. Na Fig. 6 são apresentados os

VECSE de uma mesma oscilografia, sendo as colunas azuis a representação da situação pré-falta e as colunas laranjas a representação após o período de *build-up* e *shoulder*, utilizando novamente 20 filtros, porcentagem de sobreposição de 90% e $\delta = 0,1$.

É possível perceber a variação de todos os vetores após o período de *build-up* e *shoulder*. As variações mais notáveis aconteceram nos vetores 3, 4, 5 e 9 (neste caso, variações percentuais da energia espectral de 22,31%, 12,63%, 58,94% e 79,99%, respectivamente). A RNA deverá realizar a classificação dos fenômenos com base nestas variações das intensidades de energia e localização dos centroides na frequência, uma vez que a FAI possui um comportamento diferenciado no domínio da frequência.




Fig. 6 Resultado do Processamento de uma FAI ocorrida na brita, no barramento 10.

De posse da base de dados construída, o número de filtros, o percentual de sobreposição dos filtros e o δ foram ajustados para facilitar a detecção e validação. Em cada janelamento tanto a energia associada a cada vetor como a frequência de cada vetor foram utilizados como entrada na RNA. Destaca-se que vários padrões foram simulados para definir o melhor número de filtros, percentual de sobreposição dos filtros e δ . Esses padrões foram executados 10 vezes para cada combinação dos parâmetros citados. A Tabela 2 apresenta a média dos resultados da análise de sensibilidade baseada na variação dos parâmetros do VECSE.

Tabela 2. Taxa de Acerto da variação dos parâmetros do VECSE.

Número de filtros	Sobreposição dos filtros (%)	δ	Taxa de Acerto (%)
10	0,5	0,1	85,93
		0,2	85,24
		0,3	85,79
	0,7	0,1	90,61
		0,2	85,36
		0,3	90,55
	0,9	0,1	89,23
		0,2	87,17

		0,3	86,03
15	0,5	0,1	91,32
		0,2	91,69
		0,3	93,24
		0,1	92,16
	0,7	0,2	90,65
		0,3	89,53
		0,1	89,98
	0,9	0,2	89,21
		0,3	85,30
0,1		85,89	
20	0,5	0,2	90,82
		0,3	87,79
		0,1	86,46
	0,7	0,2	85,75
		0,3	85,54
		0,1	98,23
	0,9	0,2	88,92
		0,3	91,57

Analisando a Tabela 2, considerando a melhor combinação encontrada de todos os parâmetros, adotou-se a topologia com 20 filtros, 90% de sobreposição dos filtros e um δ de 0,1 para uma análise mais profunda dos resultados (topologia com taxa de sucesso de 98,23%). Comparando o custo computacional para as diferentes quantidades de filtros, observou-se durante as simulações que o tempo de processamento foi o mesmo.

Conforme descrito na seção que trata da metodologia, a base de dados gerada possui 4 classes distintas (FAI, CBC, EC e situação pré-distúrbio). O número de entradas da RNA depende dos parâmetros definidos (número de filtros, percentual de sobreposição e δ). A combinação de 20 filtros, com 0,9 de sobreposição dos filtros e um δ de 0,1 gerou 23 sub-bandas, e cada sub-banda possui informação de energia e frequência que tendem a ter valores distintos em função da classe a que o VECSE pertence.

Desta forma, a RNA gerada possui 46 neurônios (23 elementos de frequência e 23 elementos de energia) na camada de entrada (número correspondente à quantidade de parâmetros extraído de cada janelamento), 4 neurônios na camada de saída (número correspondente a cada tipo de fenômeno) e 10 neurônios em cada uma das duas camadas ocultas (quantidade de camadas ocultas definida por análise de sensibilidade).

Uma vez definida a RNA juntamente com os parâmetros do VECSE, 36 oscilografias de cada fenômeno foram separadas aleatoriamente, conforme descrito na seção da metodologia. O restante da base de dados foi utilizada para treinamento da RNA. Depois de treinada, a rede foi salva e essa base de dados separada anteriormente foi apresentada à RNA, mas com disposição dos padrões em forma sequencial, emulando um funcionamento em situação real de monitoramento. Essa abordagem foi executada 10 vezes. Nesta situação, o janelamento de cada oscilografia resulta em uma sequência de algumas amostras em condição pré-fenômeno, seguidas de amostras em condição de transição (de pré-fenômeno para

fenômeno) e que, por fim, são seguidas de amostras em condição típica do fenômeno, até que este se extinga.

Com esta abordagem, além de avaliar-se o comportamento da RNA em uma situação mais próxima da realidade, também pode-se avaliar a quantidade de ciclos necessários para a correta classificação de cada fenômeno, o que permite quantificar o tempo de classificação.

Relativamente à FAI, em todos os testes, toda a base de dados utilizada nesta etapa conseguiu obter a exata classificação. No entanto, em alguns casos foram necessários mais ciclos da FAI dentro da janela amostral para que a rede conseguisse classificar o fenômeno corretamente. A Fig. 7 apresenta a média dos resultados, mostrando a quantidade de ciclos necessária para a classificação da FAI.

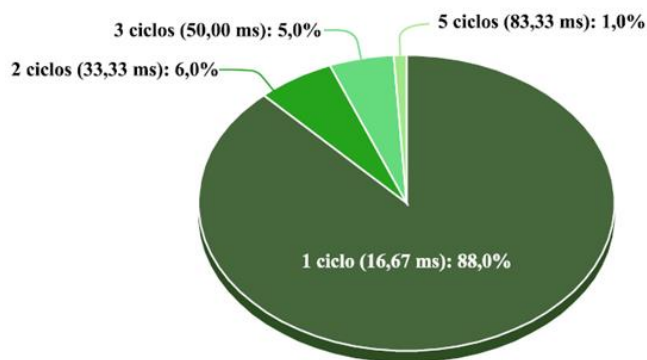


Fig. 7 Quantidades de ciclos para a detecção da FAI.

Foi possível detectar a FAI em 100% dos casos da base de dados, sendo que em 88% dos casos foi possível detectar a FAI com apenas 1 ciclo do fenômeno dentro da janela amostral (16,67 ms); em 6% dos casos foi possível detectar a FAI com 2 ciclos do fenômeno dentro da janela amostral (33,33 ms); em 5% dos casos foi possível detectar a FAI com 3 ciclos do fenômeno dentro da janela amostral (50 ms); e em 1% dos casos só foi possível detectar a FAI com 5 ciclos do fenômeno dentro da janela amostral (83,33 ms).

Para o fenômeno de CBC foi obtido a taxa máxima de sucesso, com classificação do fenômeno no primeiro ciclo dentro da janela amostral. Já a EC, em 89% dos casos ocorreu a exata classificação do fenômeno, sendo que em 11% dos casos o fenômeno foi confundido com a situação pré-distúrbio. Ainda assim, nenhum falso positivo com relação a FAI foi detectado, o que se constata que o método de detecção FAI baseado no VECSE teve desempenho satisfatório em todos os casos.

7. CONCLUSÕES

Este trabalho propõe o uso de uma técnica para detecção de FAI em sistemas elétricos. A técnica em questão utiliza os Vetores de Energia dos Centroides das Sub-bandas Espectrais para detecção da FAI. A energia espectral e frequência de cada centroide foi utilizada como entrada em uma RNA para classificação da FAI. Como método de detecção, alguns parâmetros que não são definidos, como número de filtros, percentual de sobreposição dos filtros e o δ foram ajustados

para facilitar a detecção e validação do método. Foi verificado também o comportamento dos vetores gerados, tanto nos sinais de FAI quanto nos outros fenômenos (energização de carga e chaveamento de banco de capacitores). Quanto à detecção da FAI, foi obtida uma taxa máxima de sucesso (em 100% dos casos da base de dados utilizada), com um tempo necessário de apenas 5 ciclos (83,33 milissegundos), sendo que na maioria dos casos foi possível detectar a FAI no primeiro ciclo do fenômeno (16,67 milissegundos).

O método desenvolvido foi menos sensível a variação, o que pode ser vantajoso em alguns casos, já que nos sistemas elétricos ocorrem muitas variações no sinal de corrente e muitos fenômenos de curta duração como o CBC e EC. No entanto, o método necessitou de procedimentos *offline* (treinamento da RNA). Pelos resultados apresentados, satisfatórios, percebe-se a viabilidade do método desenvolvido. No entanto, ainda é necessário avaliar o método quanto à presença de fenômenos como correntes de *inrush* ou cargas não lineares. Adicionalmente, deve-se avaliar o impacto da geração distribuída no desempenho do algoritmo, bem como sua aplicabilidade em outros sistemas (por exemplo, o barramento IEEE 14) e regimes neutros.

AGRADECIMENTOS

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001.

REFERÊNCIAS

- Abdi, H.; Valentin, D.; Edelman, B., (1999). Neural Networks. *Sage University Papers Series on Quantitative Applications in the Social Sciences*, 07-124. Thousands Oaks, CA.
- Balser, S. J., Clements, K. A. e Lawrence, D. J. A. (1986) microprocessor-Based technique for detection of high impedance faults, *IEEE Transactions on Power Delivery*, v. 1, n. 3.
- Braga, A. P.; Carvalho A. C.; Ludermir T. B. (2003). *Redes Neurais Artificiais, In Rezende, Sistemas Inteligentes: Fundamentos e Aplicações*. p. 141-168. Editora Manole, Barueri, SP, 525.
- Emanuel, A. E., Cyganski, D., Orr, J. A., Shiller, S. e Gulachenski, E. M., (1990). High impedance fault arcing on sandy soil in 15 kV distribution feeders: contributions to the evaluation of the low frequency spectrum. *IEEE Transactions on Power Delivery*. p. 676–686.
- Ferreira, T. V. (2011). Estimação Inteligente da Poluição de Isolamentos Elétricos Baseada nos VECSE do Ruído Ultrassônico, Tese de Doutorado, Universidade Federal de Campina Grande - UFCG.
- García, J.C., García, V. V. E kagan, N., (2014) Detection of high impedance faults in overhead multi grounded networks, *11th IEEE/IAS International Conference on Industry Applications*, pp. 1-6, Juiz de Fora.
- Ghaderia, A.; Ginn, H. L.; Mohammadpourb, H. A. (2017). High impedance fault detection: A review, in *Electric Power Systems Research*, vol. 143, Pages 376-388.
- Grimaldi, R. B. G., Chagas, T. S. A., Montalvão, J., Brito, N. S. D., Santos, W. C., Ferreira, T. V., (2021). High impedance fault detection based on linear prediction, in *Electric Power Systems Research*, vol. 190, pp 106846.
- Hafidz, I., Nofi, P. E., Anggriawan, D. O., Priyadi, A. e Pumomo, M. H. (2017). Neuro wavelet algortihm for detecting high impedance faults in extra high voltage transmission systems, *2nd International Conference Sustainable and Renewable Energy Engineering (ICSREE)*, Hiroshima, pp. 97-100.
- Haykin, S. (2001) *Redes neurais, princípios e prática*. 2ª Edição. ed. Porto Alegre: Bookman.
- Lima, É. M.; Junqueira C. M. S.; Brito, N. S. D.; Souza, B. A.; Coelho, R. A. e Medeiros, H. G. M. S., (2018). High impedance fault detection method based on the short-time Fourier transform, in *IET Generation, Transmission & Distribution*, vol. 12, no. 11, pp. 2577-2584.
- Moloi, K., Jordaan, J. A. and Hamam, Y., (2019). A hybrid method for high impedance fault classification and detection, Southern African Universities Power Engineering Conference/Robotics and Mechatronics/Pattern Recognition Association of South Africa (SAUPEC/RobMech/PRASA), Bloemfontein, South Africa, pp. 548-552.
- Nakagomi, R. M., (2006). Proposição de um sistema de faltas de alta impedância em redes de distribuição. Dissertação de Mestrado, Universidade de São Paulo -USP, São Paulo.
- Oliveira, A. R., (2005). Redes Neurais Artificiais Aplicadas na Detecção, Classificação e Localização de Defeitos em Linhas de Transmissão, Dissertação de Mestrado, Universidade Federal de Juiz de Fora, Juiz de Fora - MG.
- Routray, P., Mishra, M. and Rout, P. K., (2015). High impedance fault detection in radial distribution system using S-Transform and neural network, *IEEE Power, Communication and Information Technology Conference (PCITC)*, Bhubaneswar, pp. 545-551.
- Santos, W. C., (2006). Identificação de Faltas de Alta Impedância em Sistemas de Distribuição, Tese de Doutorado, Universidade Federal de Campina Grande - UFCG.
- Samantaray, S.R., Panigrahi, B.K., Dash, P.K., (2008). High impedance fault detection in power distribution networks using time–frequency transform and probabilistic neural network, *IET Gen., Transm. Distrib.*, vol. 2, no. 2, pp. 261–270.
- Sarlak, M. and Shahrtash, S. M., (2013). High-Impedance Faulted Branch Identification Using Magnetic-Field Signature Analysis, *IEEE Trans. Power Del.*, vol. 28, no. 1, pp. 67–74.
- Zamboni, L., (2013). Detecção e Localização de Faltas em Sistemas Elétricos de Distribuição Usando Abordagem Inteligente Baseada em Análise Espectral de Sinais, Tese de Doutorado, Universidade de São Paulo, São Carlos.