

Support Vector Machines no suporte à detecção de faltas de alta impedância. Caso base: LT 500 kV Xingu / Tucuruí

Vittorio T. Missaglia^{1,2}. Thiago A. do Brasil¹.
Rodrigo A. das Neves². João A. Moor¹.

1 – Centro Federal de Educação Tecnológica Celso Suckow da Fonseca
Rio de Janeiro, Brasil (e-mail: vitt.torres@gmail.com).
2 – Operador Nacional do Sistema Elétrico, Rio de Janeiro, Brasil.

Abstract: The equipments of an electrical system is subject to several types of failures, especially those present in the transmission that are built in an unsheltered way, thus being exposed to bad weather, which invariably results in wear and, therefore, equipment failure. Of these, transmission lines (LT) are the most susceptible to failure, due to their large extensions. From this feature in particular, the construction of LT in dense tropical forest regions has led to the occurrence of high impedance faults (FAI), which are difficult to identify by current protection systems. In this sense, identifying this phenomenon quickly before it evolves to more severe short circuits are essential, protecting equipment, reducing operation and maintenance costs, protecting the environment from possible fires and reducing the energy consequences of transmission outages. Therefore, getting the LT 500 kV Xingu / Tucuruí as an example, this work aims to analyze and propose a strategy for identifying FAI based on the use of supervised learning classifiers of the Support Vector Machines type.

Resumo: Os equipamentos de um sistema elétrico estão sujeitos a toda sorte de falhas, especialmente aqueles presentes na transmissão que são dispostos de forma desabrigada, sendo assim expostos a múltiplos tipos de intempéries que invariavelmente resultam em desgastes e, portanto, falhas nos equipamentos. Destes, as linhas de transmissão (LT) são as mais suscetíveis às falhas, devido às suas grandes extensões. Desta característica em particular, a construção de LT em regiões de densa floresta tropical tem levado a ocorrência de faltas de alta impedância (FAI) que são de difícil identificação pelos atuais sistemas de proteção. Neste sentido, identificar este fenômeno rapidamente antes que evoluam a curtos-circuitos mais severos é primordial, protegendo equipamentos, reduzindo custos de operação e manutenção, protegendo o meio ambiente de possíveis incêndios e reduzindo as consequências energéticas de indisponibilidades na transmissão. Portanto, tomando a LT 500 kV Xingu / Tucuruí como exemplo, este trabalho tem como objetivo analisar e propor uma estratégia de identificação de FAI a partir do uso de classificadores por aprendizado supervisionado do tipo Support Vector Machines.

Keywords: high impedance fault; FAI; identification; costs; LT; supervised learning.

Palavras-chaves: falta de alta impedância; FAI; identificação; custos; LT; aprendizado supervisionado.

1. INTRODUÇÃO

A crescente demanda energética obriga a expansão do Sistema Interligado Nacional – SIN na direção de áreas de densa floresta tropical e grande diversidade ambiental. Esta interação da fauna e flora com as linhas de transmissão (LT), em especial a flora, leva a ocorrência de contato elétrico entre os condutores energizados e a vegetação, o que aumenta significativamente as probabilidades de faltas de alta impedância (Isolani and David, 2011; JUNIOR, 2016). Este tipo de falta é geralmente de difícil identificação, podendo evoluir para curtos-circuitos mais severos (Coelho and Oliveira, 2017). Infelizmente, as proteções convencionais, tais como relés de distância, de sobrecorrente residual e diferencial não são sensibilizados na maior parte das vezes (Louis, 2015). Associado a isso, a característica desbalanceada de algumas linhas, que também possuem compensações série e paralelo, torna a coordenação das proteções ainda mais complexa.

Sabe-se que a falta de alta impedância (FAI) ocorre pela formação de um caminho à terra, por intermédio de um material cuja resistência elétrica é elevada, tal como galhos de árvores. Esta condição impõe correntes que são comumente associadas ao desbalanço natural do sistema, não sensibilizando, deste modo, as proteções convencionais. Em outro aspecto, dada a natureza intrínseca das faltas de alta impedância, um arco voltaico inicia sua ignição quando a tensão imposta na superfície de contato é superior à sua tensão de ruptura, revelando assim, assinaturas características na forma de onda, principalmente na corrente residual. Segundo (Louis, 2015), a taxa de incidência das FAI é incerta embora, pela percepção de profissionais de campo do setor, eventos de FAI aparentam ser fenômenos mais habituais do que o imaginado. Geralmente, avarias perceptíveis visualmente nas peças dos equipamentos sem histórico de atuações de proteções podem indicar a ocorrência de uma FAI. Deste modo, estas peculiaridades fazem com que a análise espectral

da corrente medida seja uma ferramenta adequada na tentativa de detecção destes eventos.

A partir do uso de técnicas de extração de características de sinal, as componentes harmônicas de corrente e tensão de fase foram propostas para detecção de FAI (Jeerings and Linders, 1990, 1991). A comparação do conteúdo de terceiro harmônico com a soma dos harmônicos pares e ímpares foi proposta por (Torres *et al.*, 2014). Outra alternativa, apresentada por (Louis, 2015), foi a partir do uso de uma combinação de Transformada Rápida de Fourier e Transformada Wavelet na componente de sequência zero das correntes de fase medidas. Considerando que em sua maioria as FAI são monofásicas, (Sarwagya, De and Nayak, 2018) adotaram dois critérios para a detecção dessas faltas, utilizando a tensão residual no barramento da subestação e as correntes de sequência negativa que fluem através das fases sãs. (Michalik *et al.*, 2006), propôs o uso da Transformada Wavelet para extração de características e de redes neurais no processo de classificação. No mesmo caminho, trabalhos utilizando-se do algoritmo de aprendizado supervisionado *Support Vector Machine* (SVM) foram propostos para classificação e posterior detecção de FAI em sistemas de distribuição (Ghaderi *et al.*, 2015; Brasil, Gois and Moor, 2021).

Os SVMs têm se mostrado mais atraentes do que outros classificadores, como os baseados em árvores de decisão (Samantaray, Tripathy and Dash, 2009), em conhecimento prévio (Don Russell, 1990), em regras (Abdoos, Khorshidian Mianaei and Rayatpanah Ghadikolaei, 2016), classificadores bayesianos (Sedighi *et al.*, 2005), ou algoritmo genético (Sedighi, Haghifam and Malik, 2005). Geralmente, os SVMs não sofrem de problemas relacionados a *overfitting*, apresentando capacidade de generalização adequada quando uma indicação clara de separação entre classes é alcançada. Sua generalização fornece a possibilidade para o classificador agir corretamente, garantindo adaptabilidade para o sistema de detecção, o que é essencial para uso no campo.

Um fato importante a ser observado diz respeito a origem da ocorrência de uma FAI nos sistemas de distribuição e transmissão. No primeiro, a grande capilaridade dos sistemas em regiões urbanas e característica de carga altamente desbalanceada fazem com que as FAI tenham como possíveis origens: contato com vegetação, com animais silvestres, queda de condutor ao solo e o próprio desgaste dos equipamentos. Já no segundo, a queda de condutor não apresenta razoabilidade técnica pois, apesar de haver um grau de desbalanceamento na transmissão, a ausência de uma fase pode sensibilizar proteções diferenciais ou de neutro. Dessa forma, as assinaturas atribuídas às FAI na distribuição e na transmissão podem ter características comuns, mas causas distintas. Paralelamente, observando a quase totalidade dos trabalhos apresentados na literatura, pode-se notar que, em sua maioria, dedicam-se a análise e identificação de FAI em sistemas de distribuição (Michalik *et al.*, 2006; (Louis, 2015). É neste sentido, portanto, que este trabalho se propõe a analisar FAI em LT, haja vista que conhecer as particularidades do fenômeno se faz necessário para uma abordagem adequada do problema.

Neste trabalho, um classificador baseado em Support Vector Machines é obtido via treinamento supervisionado, visando suporte na identificação de eventos de FAI em um sistema de transmissão. Para tal, foi elencado e simulado um conjunto de manobras de equipamentos próximos ao ponto de interesse, de maneira que o classificador possa ser capaz de discernir corretamente um evento de FAI de um transitório normal de manobra. Sendo assim, a contribuição original deste trabalho é fornecer uma solução de classificação de FAI a partir do uso do modelo de faltas proposto por (Wei *et al.*, 2020) durante a etapa de treinamento do classificador SVM. Para produzir a generalização do algoritmo SVM no que tange a correta capacidade na classificação de faltas de alta impedância, trezentos eventos transitórios foram realizados ao longo de diversas simulações em um sistema de transmissão de 500 kV, especificamente na linha transmissão em 500 kV que interliga as subestações de Xingu e Tucuruí no Estado do Pará, em que aproximadamente metade deles consistia em FAI, os quais ocasionalmente apresentaram variações aleatórias e intermitência. Um esquema de detecção de FAI usando *Short-Time Fourier Transform* (STFT) para extração de características, tendo o SVM como o classificador do sistema foi desenvolvido. Um esquema de consistência temporal é proposto, visando melhor distinguir FAI de outros eventos transitórios convencionais, aumentando a segurança e confiabilidade do sistema como um todo.

2. MODELO DE FAI

De forma a estabelecer um modelo adequado de classificação de FAI, é de extrema importância compreender adequadamente o comportamento dinâmico do defeito. Como já explicitado anteriormente, as correntes provenientes de uma FAI possuem baixa amplitude, sendo geralmente compatíveis com os valores das correntes de carga (Louis, 2015). Pelo fato de não haver um caminho sólido à terra, na medida que a tensão varia, a rigidez dielétrica do material em contato com o condutor pode sofrer ruptura, gerando, consequentemente, o arco elétrico. Este fenômeno apresenta característica randômica elevada sendo importante a sua consideração no modelo matemático utilizado (Louis, 2015). Adicionalmente, as FAI são caracterizadas por: aspecto não estacionário (Ghaderi *et al.*, 2015), não linearidade (Wang, Geng and Dong, 2018), intermitência do arco voltaico (Hamel, Gaudreau and Côté, 2004), componentes de alta frequência na corrente medida (Emanuel *et al.*, 1990; Ghaderi, Ginn and Mohammadpour, 2017).

Portanto, de forma a prover um modelo de falta que contemple todas estas características com precisão satisfatória, foi adicionado um coeficiente aleatório (RC) para o modelo de arco voltaico convencional de Mayr (Zhu *et al.*, 2020), tal qual em (Brasil, Gois and Moor, 2021) e (Wei *et al.*, 2020):

$$\frac{1}{g_{arc}} \left(\frac{dg_{arc}}{dt} \right) = \frac{1}{\tau_0} \left(\frac{u_f i_f}{P_{loss0} RC} - 1 \right), \quad (1)$$

onde g_{arc} representa a condutância equivalente do arco [S], u_f e i_f representam a tensão do arco [kV] e a corrente [kA] respectivamente, τ_0 e P_{los} representam constante de tempo [s] e potência dissipada estável [MW]. Assim, de acordo com (Wei *et al.*, 2020), o coeficiente aleatório RC é descrito como:

$$\begin{cases} RC = RC_{ign}, & \text{se } RC_{sel} = 0, \\ RC = RC_{ext}, & \text{se } RC_{sel} = 1, \end{cases} \quad (2)$$

onde RC_{sel} , RC_{ign} e RC_{ext} são três variáveis aleatórias, sendo RC_{sel} a variável de escolha entre 0 ou 1, com probabilidades complementares q_0 e q_1 a cada xT segundos ($x \in [1,5; 2,5]$), onde $T = 0,016$ s, considerando a frequência da rede como 60 Hz. RC_{ign} e RC_{ext} representam os coeficientes de potência dissipada de ignição e extinção do arco voltaico, respectivamente, e são usados para implementar variações limitadas na potência dissipada, anteriormente constante $P_{loss}(P_{loss} = P_{loss0}RC)$. Eles podem ser calculados como (Wei *et al.*, 2020):

$$\begin{cases} RC_{ign} \in \left(k_1, \frac{k_2 P_{lossb}}{P_{loss0}} \right) \\ RC_{ext} \in \left(\frac{k_3 P_{lossb}}{P_{loss0}}, \frac{k_4 P_{lossb}}{P_{loss0}} \right) \end{cases} \quad (3)$$

Observa-se que P_{lossb} denota a potência dissipada limite, que representa o coeficiente de potência dissipada a partir do qual o arco é extinto e cujo valor precisa ser determinado por meio de simulação. Em outras palavras, o arco simulado sofre ignição sempre que $P_{loss} < P_{lossb}$ e é extinto a partir do momento que $P_{loss} > P_{lossb}$. A aleatoriedade geral e a probabilidade de intermitência podem ser alcançadas por meio da seleção dos parâmetros k_1 , k_2 , k_3 e k_4 . A representação do modelo de arco convencional modificado é apresentada na Fig. 1.

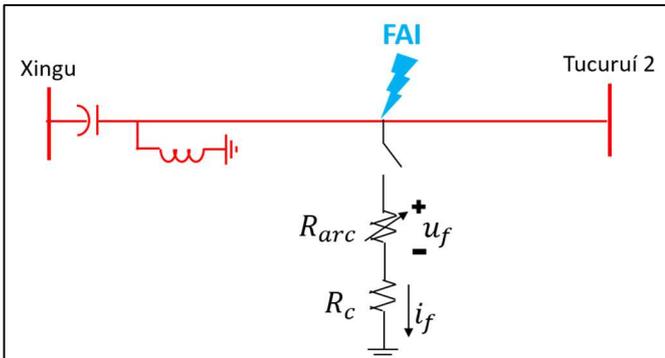


Fig. 1 Destaque da LT 500 kV Xingu / Tucuruí 2 com modelo de FAI.

R_{arc} representa a resistência do arco ($1/g_{arc}$) que é responsável por seu comportamento dinâmico. R_c representa a resistência de contato entre o condutor e a terra via objeto em contato (e. g. galhos de árvores) (Nam *et al.*, 2001).

Finalmente, as FAI costumam se dividir em dois intervalos distintos (Wei *et al.*, 2020). Primeiramente, a corrente de falta pode apresentar comportamento com maior nível de não-linearidade e certa aleatoriedade. Após dado momento, o arco se comporta de maneira mais estável. O instante a partir do qual ocorre a estabilização do arco, bem como sua duração, presença, ausência de intermitência, aleatoriedade e amplitude geral da falha são variáveis inerentes ao modelo de arco aprimorado que podem ser calculadas a cada chamada do modelo, de forma a simular tantos comportamentos de corrente

de falta distintos quanto possível, como pode ser visualizado na Fig. 2.

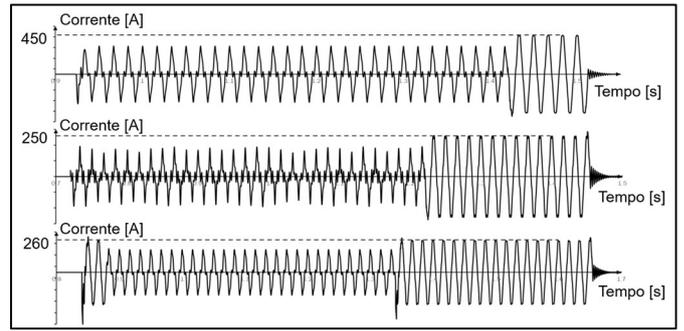


Fig. 2 3 exemplos de FAI a partir da modelagem proposta com valores de parâmetros distintos.

3. CASO E SISTEMA SIMULADO

Sobre o exposto da condição de maior incidência de FAI nas LTs em regiões de grande interação do meio ambiente local com estes equipamentos, o caso em estudo foi dedicado a analisar FAI na LT 500 kV Xingu / Tucuruí 2 (XNG / TUC2). Esta LT está localizada na região amazônica, Estado do Pará, e interliga as subestações de Xingu e Tucuruí, sendo ilustrado na Figura 3 a localização da LT. Possui um desbalanço natural em razão de particularidades construtivas como a transposição das fases e a construção sobre as copas das árvores. Possui 265 km de extensão, compensações série e paralelo e forte acoplamento eletromagnético com o circuito em paralelo. Em razão do exposto, segundo relato de profissionais da área de proteção do Operador Nacional do Sistema Elétrico – ONS ouvidos para elaboração deste trabalho, faltas com impedâncias próximas a 800Ω já foram verificadas nas LTs da região, com correntes de valores inferiores aos de carga, tendo como estratégia para identificação e extinção o uso de relés de distância do tipo quadrilateral, prolongando a componente resistiva. Contudo, apesar da solução ter sido capaz de identificar alguns casos de FAI, também foi responsável pela sensibilização desnecessária de proteções na LT. Na presença de faltas eletricamente distantes do trecho em questão, houve perda de seletividade da proteção de distância.

Neste sentido, a simulação buscou reproduzir o sistema real no qual a LT XNG / TUC2 está construída e inserida. Trata-se de um sistema com especificação dos equipamentos utilizados nos eventos teste para treino do classificador. A Figura 4 apresenta o sistema simplificado simulado em ambiente PSCAD/EMTDC.

Os eventos simulados para os equipamentos abordados consistiram em manobras de energização e desenergização dos mesmos, de forma aleatória e não sequencial, de modo que o classificador não fosse modelado de forma parcial, perdendo assim, sua capacidade de generalização. Ao final, os eventos foram caracterizados de forma binária: 1 para ocorrência de FAI e 0 para as demais circunstâncias.

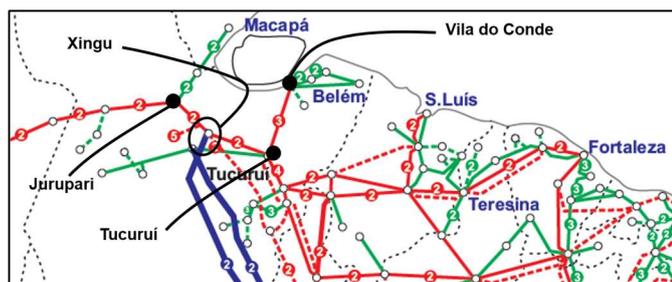


Fig. 3 Localização geográfica da LT 500 kV XNG / TUC2. Fonte: ONS.

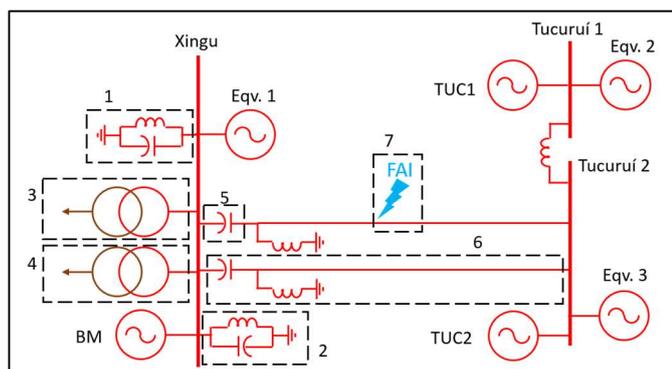


Fig. 4 Diagrama simplificado do sistema simulado.

Os equipamentos que serviram de teste ao classificador foram: um filtro harmônico de sintonias no 3°, 11° e 50° harmônicos; um filtro harmônico de sintonias no 13°, 24° e 36° harmônicos; dois transformadores conversores, referentes ao Elo CC localizado na subestação Xingu, considerando no *software* PSCAD/EMTDC os aspectos de saturação do núcleo (curva de histerese) conforme características construtivas; um banco de capacitor série na LT, e seu circuito paralelo. Todos esses equipamentos estão representados na Figura 4 e identificados na Tabela 1.

A saber, na Figura 4, BM representa a usina de Belo Monte, TUC1 e TUC2 as partes da usina de Tucuruí separadas na subestação pelo reator limitador de curto-circuito, e Eqv. 1, Eqv.2 e Eqv. 3 representam os equivalentes do sistema nas barras de Xingu, Tucuruí 1 e Tucuruí 2, respectivamente.

Tab. 1 Dados dos equipamentos manobráveis

Nº	EQUIP. /EVENTO	DADOS
1	Filtro A	220 MVar, 3°/11°/50°
2	Filtro B	180 MVar, 13°/24°/36°
3	TR-1	500 / 335,7 kV, Y-Y
4	TR-2	530 / 336,7 kV, Y-Y
5	Capacitor série	802 MVar
6	LT XNG / TUC2 circuito 2	500 kV
7	Modelo de FAI	Tab. 2

Tab. 2 Dados do modelo de FAI.

	P_{loss0}	P_{lossb}	k_1	k_2	k_3	k_4	RC [Ω]
FAI	0,8 MW	32 MW	[0,50 - 0,95]	[0,75 - 1,50]	[0 - 1,00]	[0 - 1,05]	800

4. TREINAMENTO DO CLASSIFICADOR

Devido às FAI possuírem elevada aleatoriedade, principalmente devido a variedade dos materiais que podem entrar em contato com o condutor energizado, a forma de onda da corrente agrega considerável conteúdo harmônico (Wei *et al.*, 2020). Este conteúdo harmônico pode ser utilizado como as características consideradas pelo classificador para diferir, nos dados que receber, um evento de FAI de outro. Portanto, neste trabalho, a STFT foi escolhida como a ferramenta matemática utilizada para a extração das componentes harmônicas responsáveis pela etapa de classificação.

A STFT efetua a Transformada de Fourier de um sinal através do particionamento do sinal em múltiplas janelas e, posteriormente, para cada janela aplica-se a Transformada (Zhu *et al.*, 2020). Em (4) segue a equação geral da STFT:

$$\mathcal{F}\{s(t)\}(\tau; \omega) = \int_{-\infty}^{+\infty} [s(t) \cdot w(t - \tau)] e^{-j\omega t} dt, \quad (4)$$

onde $s(t)$ é a função que representa o sinal no domínio do tempo a ser transformado, τ é o passo para janelamento, ω representa a frequência e w é a função de janelamento.

Devido à existência de vários processos estocásticos não correlacionados gerados pelas características aleatórias das FAI, torna-se impossível assumir algum tipo de tendência ou comportamento anterior sem uma análise mais aprofundada do conteúdo espectral destas faltas. Desse modo, a STFT apresenta-se como a melhor ferramenta para extração de informação relevante. Sendo assim, a seleção de características foi realizada de modo análogo ao exposto por (Brasil, Gois and Moor, 2021), sendo o espectro harmônico utilizado na etapa de extração de 0 Hz (componente CC) até o 14° harmônico (840 Hz).

5. APRENDIZADO SUPERVISIONADO E SVM

O aprendizado de máquina (*machine learning* em inglês) consiste em um conjunto de métodos onde um programa tem a capacidade de aprender a distinguir/classificar diferentes estados com os dados que recebe sem ser explicitamente programado para isso. Inicialmente treinado de forma que se oriente o que é cada dado de entrada, posteriormente o programa pode ser capaz de retroalimentar-se com os dados que receber e aprimorar seu processo de classificação, desde que apontados os erros cometidos. Neste sentido, o modelo que efetua a distinção dos dados através de suas características denomina-se classificador.

O classificador de aprendizado supervisionado usado neste trabalho foi o *Support Vector Machines (SVM)*. Para seu treinamento, iniciou-se o processo a partir de um conjunto inicial de dados característicos marcados e orientados como sendo de uma classe ou outra, observando as características destes dados de forma a construir um modelo de identificação, a partir de reconhecimento de padrões. Assim, o classificador é capaz de prever a qual classe cada novo dado recebido pertence, tomando por base o banco de dados que teve acesso na execução de seu treinamento.

Pensando em um conjunto de dados plotados em um plano cartesiano, o SVM se atém a separar cada classe através de um hiperplano. Dentro do escopo deste trabalho, os dados a serem separados são os de FAI ou não FAI e as características que o método têm a sua disposição são as componentes harmônicas obtidas via *STFT*. Estas características determinam a dimensão do hiperplano, tendo esse tantas dimensões quantas características forem fornecidas. Traçado o hiperplano, o SVM delimita uma margem entre a características de cada classe, sendo estas os vetores de suporte (*Support Vector*), os quais dão nome ao método. A Fig. 5 ilustra a separação das classes pelo hiperplano.

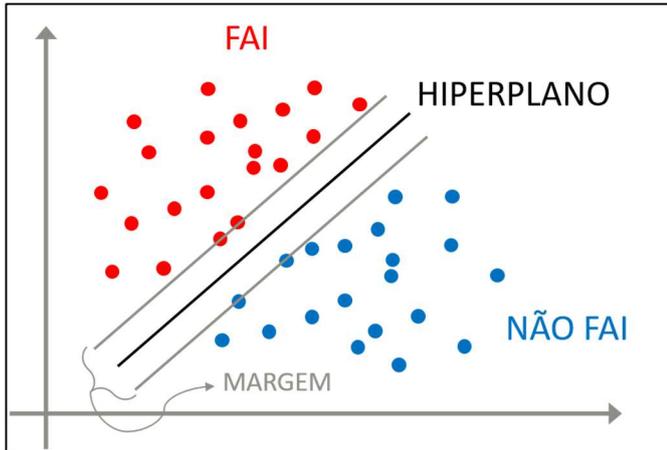


Fig. 5 Ilustração da separação de classes pelo SVM.

De acordo com (Abdoos, Khorshidian Mianaei and Rayatpanah Ghadikolaei, 2016), o subespaço vetorial de amostras que determina o hiperplano é dado por (5), onde x_i corresponde aos vetores de entrada e y_i indica a diferenciação das classes entre os lados do hiperplano:

$$T = \{(x_i, y_i) \mid x_i \in \mathbb{R}^n, y_i \in \{+1, -1\}\}_{i=1}^m. \quad (5)$$

5.1 Obtendo dados e extraindo características

Os dados obtidos para treinamento do classificador são oriundos de simulações no *software* PSCAD/EMTDC e correspondem a medição da corrente residual da linha em estudo (via TCs localizados na barra de Xingu). Estes dados, como já explicitado, tiveram suas características extraídas e separadas para que o classificador pudesse realizar a identificação de padrões e separação das classes como FAI ou não FAI. Portanto, a partir do *software* MATLAB, determinou-se a *STFT* para cada simulação obtida do PSCAD e, posteriormente, agrupados os dados em um arquivo único (matriz de vetores), o qual foi inserido no aplicativo *Classification Learner* (próprio do MATLAB), de maneira a iniciar o treinamento do SVM.

Para tal, foram realizadas diversas simulações, cada uma com duração de dois segundos, executando os eventos descritos na Tab. 1 de modo aleatório, um a um, totalizando trezentos fenômenos distintos, sendo que praticamente metade deles consistiu de ocorrências de FAI, respeitando os limites estabelecidos na Tab. 2. Todos os eventos tiveram tanto a duração quanto a localidade de ocorrência da falta na LT

randomizadas. A Fig. 6 ilustra o fluxograma com as etapas cumpridas até o treino do classificador.

Considerando o tempo para cada simulação de 2 segundos, o passo de integração de 20 microssegundos e a frequência fundamental em 60 Hz, cada ciclo completo do sinal possui, aproximadamente, 833 pontos. Neste sentido, para a aplicação da *STFT*, foram considerados 2500 pontos em cada janela da transformada (3 ciclos), resultando em 40 janelas por simulação. Assim, o conjunto das 300 simulações resultou no total de 12000 janelas. Portanto, considerando que foram estratificadas 14 componentes harmônicas, além da caracterização do evento em si (FAI ou manobra normal), a matriz de vetores obtida para o treinamento do classificador consta de 15 linhas e 12000 colunas. A Fig. 7 ilustra o exposto.

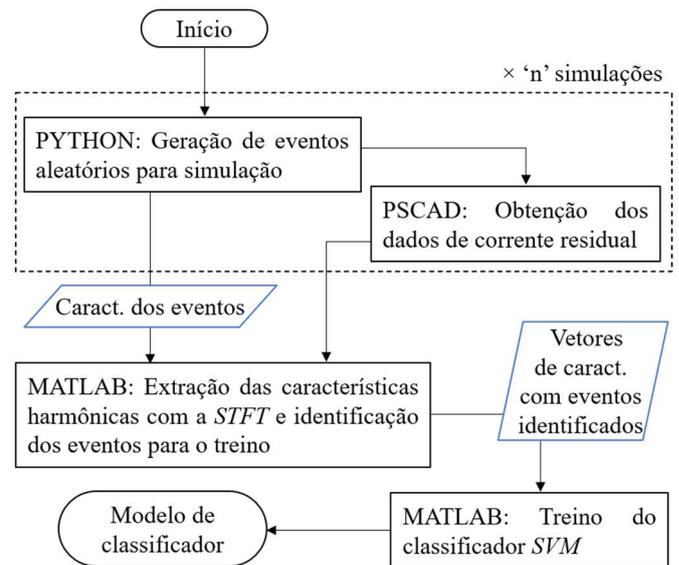


Fig. 6 Fluxograma para o treino do classificador.

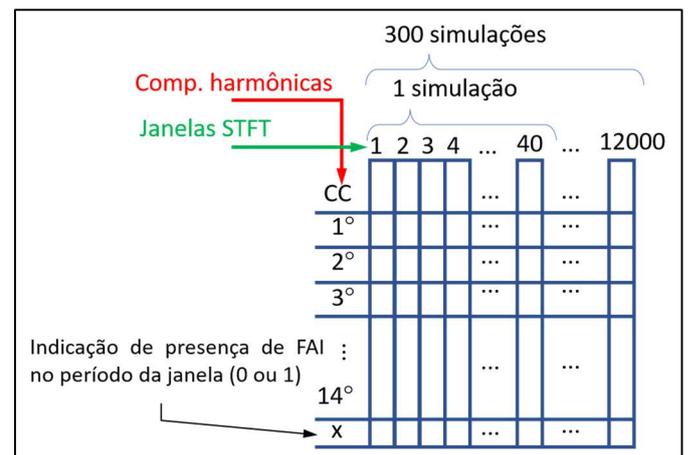


Fig. 7 Matriz de vetores para treino do classificador.

6. RESULTADOS DA CLASSIFICAÇÃO

A partir da biblioteca de algoritmos para aprendizado supervisionado do MATLAB, realizou-se o teste com todos os tipos de SVM presentes no *Classification Learner*, considerando um k_{fold} de 10 na etapa de validação cruzada, a saber: Linear, Quadratic, Cubic, Fine Gaussian, Medium Gaussian e Coarse Gaussian. Foram observados os resultados

de acurácia (AC), sensibilidade (SB), seletividade (ST) e tempo de execução do treinamento. As equações (6)-(8) apresentam a formulação para cálculo de cada um dos indicativos de performance do algoritmo supracitados como proposto por (Lever, Krzywinski and Altman, 2016):

$$AC = \frac{TP + TN}{P + N}, \quad (6)$$

$$SB = \frac{TP}{P}, \quad (7)$$

$$ST = \frac{TN}{N}, \quad (8)$$

onde TP corresponde a todas as amostras corretamente classificadas como FAI (*true positive*), P corresponde a todas as amostras que de fato são FAI, TN corresponde a todas as amostras corretamente classificadas como não-FAI (*true negative*) e N corresponde a todas as amostras que não são FAI.

Os dados de acurácia denotam, de forma global, a capacidade do classificador em acertar a predição de dados, ou seja, realizar a separação correta dos mesmos. Por outro lado, a sensibilidade e a seletividade demonstram, respectivamente, a capacidade de o classificador apontar uma FAI como tal e de não apontar como FAI aquilo que não for FAI; de forma análoga aos conceitos utilizados para as proteções convencionais.

Pelos dados apresentados na Tab. 3, pode-se observar que todos os tipos de algoritmos treinados obtiveram desempenho satisfatório. Portanto, o critério de desempate levou em consideração a relação custo-benefício entre tempo de execução do treinamento e a acurácia de cada um dos algoritmos, sendo o SVM Linear o que demonstrou melhor desempenho neste quesito.

Tab. 3 Resultado do desempenho dos classificadores após treinamento.

TIPO	ACUR.	SENSIB.	SELET.	TEMPO	TEMPO/ ACUR
Linear	98,1%	98,0%	98,1%	22,34s	0,23
Quadratic	98,6%	99,7%	98,4%	50,25s	0,51
Cubic	98,5%	99,3%	98,4%	104,9s	1,06
Fine G.	97,5%	99,3%	97,2%	65,04s	0,67
Medium G.	98,6%	99,4%	98,4%	77,01s	0,78
Coarse G.	98,3%	99,1%	98,2%	88,06s	0,9

7. RESULTADOS DA DETECÇÃO

Após obtenção do modelo de previsão baseado no treinamento proposto na seção anterior, foi desenvolvido um sistema de detecção considerando uma estimativa da probabilidade de ocorrência de uma FAI. Em linhas gerais, a corrente residual é adquirida e suas características espectrais são extraídas por meio de uma janela de comprimento $N = 2500$ pontos, tal qual realizado no processo de treinamento do classificador. Assim, o estado de classificação de cada janela pode ser 0 (não-FAI) ou 1 (FAI). Para otimizar o processo de detecção, utilizou-se uma estratégia de janela deslizante, onde cada janela analisada apresenta uma sobreposição de 15% em

relação à anterior. Dessa forma, uma estimativa da ocorrência de um evento FAI pode ser calculada como:

$$Estim. = \sum_{k=1}^{k_{window}} \frac{c(k)}{k_{window}} \quad (9)$$

onde $c(k)$ é o k -ésimo estado de classificação da janela sobreposta k_{window} , que é 30% maior do que a janela principal N da $STFT$, considerando a sobreposição selecionada de 15%. Para evitar alarmes espúrios devido à presença de transitórios de curta duração cujas características harmônicas podem ser semelhantes às presentes nas FAIs, foi verificada a consistência temporal de cada evento detectado. Ou seja, a variável ESTADO DE ALARME, que indica o alarme de detecção, apenas muda seu estado lógico se a consistência temporal for maior que $2N$. A Fig. 8 mostra o fluxograma do algoritmo proposto para detecção de HIF.

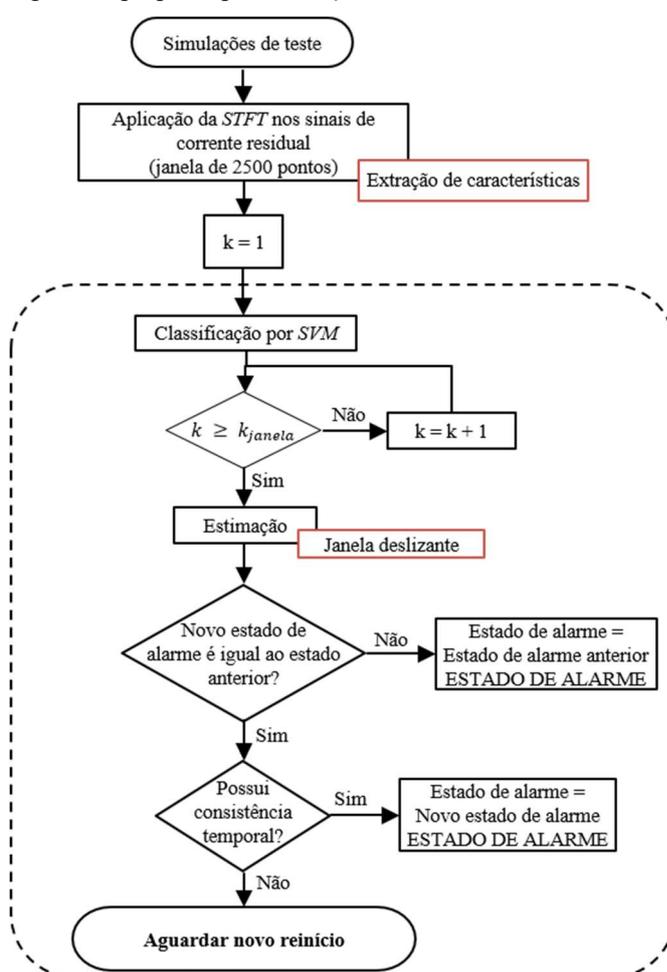


Fig. 8 Fluxograma do algoritmo de detecção.

Como forma de aferir o desempenho da etapa de detecção, foi executado um segundo conjunto de 60 simulações, nos moldes do proposto na subseção anterior, considerando agora, também, outras manobras não previstas no treinamento realizado anteriormente, dentre elas: energização e desenergização do capacitor série do circuito paralelo a LT em questão, energização e desenergização do reator da LT em questão, energização e desenergização da LT 500 kV Tucuruí 2 / Vila do Conde circuito 3 (Eqv. 3), e curto-circuito

monofásico na barra de 500 kV da SE Jurupari (eletricamente vizinha a SE Xingu – Eqv. 1), conforme pode ser observado na Fig. 3. Os resultados do teste são apresentados na Tab. 4, que apresenta a matriz de confusão da etapa de detecção por validação cruzada. A Fig. 9 demonstra um caso de correta detecção de evento de FAI. Em azul, destaca-se a consistência temporal, a partir da qual apenas após um intervalo de tempo superior a 2N com a estimação acima do limiar utilizado (0,25), o sinal de alarme apresenta mudança em seu estado lógico.

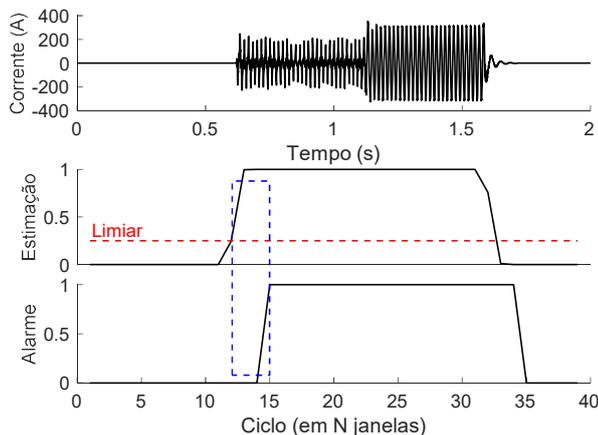


Fig. 9 Correta previsão de uma FAI a partir do esquema de detecção proposto.

Tab. 4 Matriz de confusão da etapa de detecção.

	Predição não FAI	Predição FAI
Simul. sem FAI	36	0
Simul. com FAI	0	24

8. DISCUSSÃO DOS RESULTADOS

A solução proposta apresenta potencial para o problema de FAI podendo trazer ganhos à economicidade do sistema, dados os resultados que foram obtidos. Observa-se que para a realização deste estudo, foram necessários obter os dados por intermédio de simulações no PSCAD, extrair as características dos dados via STFT no MATLAB e, por fim, treinar o classificador, também em ambiente MATLAB. Todo este processo demandou, computacionalmente, cerca de 13 horas e 22 minutos. Para a execução do algoritmo de detecção, cada arquivo de dados com 2 segundos de simulação demandou aproximadamente um minuto. Neste sentido, o esforço computacional é uma questão a ser observada para uma potencial aplicação da solução que se propõe.

Por outro aspecto, conforme apresentado na Tabela 3, aumentar o conjunto de eventos, assim como o período de simulação se faz necessário para obtenção de bons resultados do classificador, já que a ocorrência de tipos de evento que não compuseram o treinamento podem comprometer a acurácia do classificador. Quanto a ferramenta e estratégia para extração de características, ajustes no janelamento da STFT, assim como considerar o uso de outras ferramentas, tal qual a Transformada Wavelet, devem ser consideradas. Do ponto de vista físico e real, os dados de corrente residual são obtidos por intermédio de transformadores de corrente, os quais podem atenuar certas componentes de alta frequência, o que poderia

também comprometer a acurácia deste tipo de classificador. Para estes casos, a utilização de bobinas de Rogowski (Homrich, Ruppert Filho and De Freitas, 2003) para medição da corrente residual pode ser uma alternativa viável.

9. CONCLUSÃO

Não obstante algumas considerações ainda necessárias em razão de aspectos práticos para a implementação da proposta, bem como para aferir o desempenho e capacidade de generalização do classificador obtido, dos resultados obtidos, verifica-se que a proposta apresentada demonstrou ser capaz de identificar e detectar uma FAI, tomando por base as características harmônicas inerentes a corrente de falta e utilizando-se de aprendizado supervisionado. Dessa forma, como perspectivas para trabalhos futuros, um adensamento da atual proposta faz-se ímpar para consolidação da mesma como solução para o problema das faltas de alta impedância nas linhas de transmissão.

REFERÊNCIAS

- (Louis), H. W. (2015) ‘Study of High Impedance Fault Characteristics and Detection Methods’, *Master thesis. School of Electrical Engineering and Telecommunications The University of New South Wales Sydney, Australia*, p. 150.
- Abdoos, A. A., Khorshidian Mianaei, P. and Rayatpanah Ghadikolaei, M. (2016) ‘Combined VMD-SVM based feature selection method for classification of power quality events’, *Applied Soft Computing Journal*, 38, pp. 637–646. doi: 10.1016/j.asoc.2015.10.038.
- Brasil, T. A., Gois, J. N. and Moor, J. A. (2021) ‘Detection of High Impedance Faults in Primary Distribution Grid using Support Vector Machines Classification’, *IEEE/IAS International Conference on Industry Applications*, p. 8.
- Coelho, A. F. and Oliveira, C. da S. (2017) ‘Limites de Sensibilidade das Funções de Distância, Sobrecorrente Direcional e Diferencial de Linha para Faltas de Alta Impedância’, *XXIV SNPTEE SEMINÁRIO NACIONAL DE PRODUÇÃO E TRANSMISSÃO DE ENERGIA ELÉTRICA*, p. 9.
- Don Russell, B. (1990) ‘Computer relaying and expert systems: New tools for detecting high impedance faults’, *Electric Power Systems Research*, 20(1), pp. 31–37. doi: 10.1016/0378-7796(90)90023-V.
- Emanuel, A. E. *et al.* (1990) ‘High impedance fault arcing on sandy soil in 15kV distribution feeders: Contributions to the evaluation of the low frequency spectrum’, *IEEE Transactions on Power Delivery*, 5(2), pp. 676–686. doi: 10.1109/61.53070.
- Ghaderi, A. *et al.* (2015) ‘High-impedance fault detection in the distribution network using the time-frequency-based algorithm’, *IEEE Transactions on Power Delivery*, 30(3), pp. 1260–1268. doi: 10.1109/TPWRD.2014.2361207.
- Ghaderi, A., Ginn, H. L. and Mohammadpour, H. A. (2017) ‘High impedance fault detection: A review’, *Electric Power Systems Research*, 143, pp. 376–388. doi:

10.1016/j.epr.2016.10.021.

Hamel, A., Gaudreau, A. and Côté, M. (2004) 'Intermittent arcing fault on underground low-voltage cables', *IEEE Transactions on Power Delivery*, 19(4), pp. 1862–1868. doi: 10.1109/TPWRD.2003.822979.

Homrich, R. P., Ruppert Filho, E. and De Freitas, R. C. (2003) 'Transdutor de corrente do tipo Bobina de Rogowski', *Ciencia y Engenharia/ Science and Engineering Journal*, 12(3), pp. 101–105.

Isolani, B. G. and David, W. R. J. (2011) 'FERRAMENTA DE PRÉ-ANÁLISE AUTOMÁTICA DE PERTUBAÇÕES', *XXI SNTPEE SEMINÁRIO NACIONAL DE PRODUÇÃO E TRANSMISSÃO DE ENERGIA ELÉTRICA*, p. 8.

Jeerings, D. I. and Linders, J. R. (1990) 'Unique aspects of distribution system harmonics due to high impedance ground faults', *IEEE Transactions on Power Delivery*, 5(2), pp. 1086–1094. doi: 10.1109/61.53126.

Jeerings, D. I. and Linders, J. R. (1991) 'A Practical Protective Relay for Down-Conductor Faults', *IEEE Transactions on Power Delivery*, 6(2), pp. 565–574. doi: 10.1109/61.131113.

JUNIOR, J. A. P. (2016) 'Localizador De Faltas Por Ondas Viajantes Em Linhas De Transmissão', *Faculdade de Engenharia do Campus de Guaratinguetá, Universidade Estadual Paulista*, p. 50.

Lever, J., Krzywinski, M. and Altman, N. (2016) 'Classification evaluation', *Nature Publishing Group*, 13(8), pp. 603–604. doi: 10.1038/nmeth.3945.

Michalik, M. *et al.* (2006) 'High-impedance fault detection in distribution networks with use of wavelet-based algorithm', *IEEE Transactions on Power Delivery*, 21(4), pp. 1793–1802. doi: 10.1109/TPWRD.2006.874581.

Nam, S. R. *et al.* (2001) 'A modeling method of a high impedance fault in a distribution system using two series time-varying resistances in EMTP', *Proceedings of the IEEE Power Engineering Society Transmission and Distribution Conference*, 2(SUMMER), pp. 1175–1180. doi: 10.1109/pess.2001.970231.

Samantaray, S. R., Tripathy, L. N. and Dash, P. K. (2009) 'Combined EKF and SVM based high impedance fault detection in power distribution feeders', *2009 International Conference on Power Systems, ICPS '09*, (30), pp. 25–30. doi: 10.1109/ICPWS.2009.5442697.

Sarwagya, K., De, S. and Nayak, P. K. (2018) 'High-impedance fault detection in electrical power distribution systems using moving sum approach', *IET Science, Measurement and Technology*, 12(1), pp. 1–8. doi: 10.1049/iet-smt.2017.0231.

Sedighi, A. R. *et al.* (2005) 'High impedance fault detection based on wavelet transform and statistical pattern recognition', *IEEE Transactions on Power Delivery*, 20(4), pp. 2414–2421. doi: 10.1109/TPWRD.2005.852367.

Sedighi, A. R., Haghifam, M. R. and Malik, O. P. (2005) 'Soft computing applications in high impedance fault

detection in distribution systems', *Electric Power Systems Research*, 76(1–3), pp. 136–144. doi: 10.1016/j.epr.2005.05.004.

Torres, V. *et al.* (2014) 'Modeling and detection of high impedance faults', *International Journal of Electrical Power and Energy Systems*, 61, pp. 163–172. doi: 10.1016/j.ijepes.2014.03.046.

Wang, B., Geng, J. and Dong, X. (2018) 'High-Impedance Fault Detection Based on Nonlinear Voltage-Current Characteristic Profile Identification', *IEEE Transactions on Smart Grid*, 9(4), pp. 3783–3791. doi: 10.1109/TSG.2016.2642988.

Wei, M. *et al.* (2020) 'High Impedance Arc Fault Detection Based on the Harmonic Randomness and Waveform Distortion in the Distribution System', *IEEE Transactions on Power Delivery*, 35(2), pp. 837–850. doi: 10.1109/TPWRD.2019.2929329.

Zhu, W. *et al.* (2020) 'An STFT-LSTM System for P-Wave Identification', *IEEE Geoscience and Remote Sensing Letters*, 17(3), pp. 519–523. doi: 10.1109/LGRS.2019.2922536.