

# Detecção e Classificação de Falhas de Alta Impedância usando Estatística de Ordem Superior e Rede Neural MLP

José G. S. Carvalho\* Aryfrance R. Almeida\* José V. S. B. Sousa\*  
Danilo O. Sobreira\* Danton D. Ferreira\*\*

\* Departamento de Engenharia Elétrica, Universidade Federal do Piauí, PI, (e-mails: eng.genilson@hotmail.com, aryfrance@ufpi.edu.br, sekefink@gmail.com, danillosobreira@hotmail.com).

\*\* Departamento de Engenharia, Universidade Federal de Lavras, MG, (e-mail: danton@deg.ufla.br)

**Abstract:** In this work, a method of detecting and classifying high impedance faults (HIFs) is developed in energy distribution networks using Higher Order Statistics (HOS) in conjunction with the Artificial Neural Network (RNA) Multilayer Perceptron (MLP). Signals of two types of faults for two cases were obtained from the simulation and modeling in the *software* ATPDraw. HOS was used to extract the characteristics of the signals and Fisher Discriminant Ratio (FDR) to select the best characteristics generating a reduced set of data that may indicate the separability between the types of fault. At the end, a space was formed for the selection of characteristics for each case, where the distinction of the type of fault is clear, and these data were treated provided to RNA, where satisfactory results were obtained in the classification of the type of fault, proving the efficiency of the proposed method.

**Resumo:** Neste trabalho é desenvolvido um método de detecção e classificação de falhas de alta impedância (FAIs) em redes de distribuição de energia usando Estatística de Ordem Superior (EOS) em conjunto com uma rede neural artificial (RNA) do tipo Multilayer Perceptron (MLP). Sinais de dois tipos de falhas para dois casos foram obtidos a partir da simulação e modelagem no *software* ATPDraw. A EOS foi utilizada para extrair as características dos sinais e o Discriminante Linear de Fisher (DLF) para selecionar as melhores características gerando um conjunto reduzido de dados que possa indicar a separabilidade entre os tipos de falta. Ao final foi formado um espaço de seleção de características para cada caso, onde a distinção do tipo de falta é nítida, sendo estes dados tratados fornecidos a RNA, onde se obteve resultados satisfatórios na classificação do tipo de falta, comprovando a eficiência do método proposto.

**Keywords:** Distribution Networks; High impedance fault; High order statistics; Fisher Discriminant Ratio; Multilayer Perceptron.

**Palavras-chaves:** Redes de distribuição; Falta de alta impedância; Estatística de ordem superior; Discriminante linear de Fisher; Perceptron multicamadas.

## 1. INTRODUÇÃO

O fornecimento de energia elétrica tornou-se cada vez mais importante para a manutenção e desenvolvimento da sociedade, devido a característica de eficiência dos processos de produção das atividades estar relacionada ao constante uso da energia. Neste sentido, os sistemas elétricos de potência tornam-se gradualmente essenciais, precisando assim aprimorar suas características de confiabilidade, de modo a fornecer energia ininterruptamente, atendendo as regras da ANEEL (2018), agência reguladora de energia no Brasil. Segundo ABRADDEE (2019), o setor de distribuição é um dos mais regulados e fiscalizados do setor elétrico. Atualmente a apuração dos indicadores de qualidade é cada vez mais rigorosa.

Dentre os vários tipos de falta que o sistema de distribuição é susceptível, a falta de alta impedância (FAI) merece aten-

ção, pois não é detectada pelas proteções convencionais de sobrecorrente, podendo gerar danos físicos e materiais.

A detecção de falhas de alta impedância é um grande desafio para todas as concessionárias de distribuição de energia, sendo necessário desenvolvimento de dispositivos de proteção inteligentes para solucionar tais problemas. A tabela 1 ilustra que os acidentes gerados por cabo energizado ao solo são expressivos, ocupando ao longo dos anos a 2ª posição no cenário de acidentes fatais em redes elétricas.

A proposta deste trabalho está direcionada a detecção e classificação de FAIs em redes de distribuição, baseada na extração de características por meio de EOS, que resulte em um conjunto de dados reduzido capaz de separar classes, que facilite a tarefa do classificador baseado em RNA, exigindo menor esforço computacional, porém com resultados satisfatórios e eficazes.

Tabela 1. Acidentes fatais nas redes elétricas por motivo (ABRADEE, 2019).

motivo/ano	2013	2014	2015	2016	2017	2018
1	98	64	75	80	73	89
<b>2</b>	<b>29</b>	<b>53</b>	<b>43</b>	<b>29</b>	<b>27</b>	<b>20</b>
3	22	21	15	11	21	15
4	40	24	21	20	21	12
5	15	13	9	13	15	11
6	12	7	6	5	5	9
7	13	23	15	8	7	7

- <sup>1</sup> Construção ou manutenção predial.  
<sup>2</sup> **Cabo energizado ao solo.**  
<sup>3</sup> Operação de máquina agrícola.  
<sup>4</sup> Ligação clandestina.  
<sup>5</sup> Poda de árvore  
<sup>6</sup> Pipa/papagaio  
<sup>7</sup> Instalação de repetidora/antena TV

## 2. ABORDAGEM TEÓRICA

### 2.1 Falhas de Alta Impedância e suas Características

As FAIs tem características específicas que distingue-as dos demais tipos de faltas, sendo necessário o conhecimento de tais peculiaridades.

Segundo Theron et al. (2018), as FAIs geram baixos valores de corrente devido à superfície de contato apresentar alto valor de impedância, tal que as proteções convencionais (instantânea e temporizada) baseadas na elevação de corrente não conseguem identificar, sendo que de 5 a 20% das faltas nas redes de distribuição são consideradas faltas de alta impedância.

As faltas de alta impedância (FAIs) ocorrem quando um condutor elétrico aéreo energizado entra em contato com uma superfície que apresenta um alto valor de impedância, sendo essa predominantemente resistiva, tais como: solo, areia, calçamento, brita, etc. O contato do cabo energizado com uma árvore também se caracteriza como uma FAI Costa et al. (2015). Segundo Jeerings and Linders (1989), o valor da resistência de falta é desconhecido e depende das características do solo a qual o condutor energizado entra em contato.

Vários trabalhos foram desenvolvidos no intuito de caracterizar FAIs. Em Jeerings and Linders (1989) foi realizada análise detalhada do contato do condutor com o solo. Verificou-se que a resistência de contato com o solo é não linear originando componentes harmônicos na corrente de falta.

Em Emanuel et al. (1990) foram realizados testes experimentais em um alimentador em operação, cuja corrente foi monitorada por uma semana. Chegou-se a conclusão que a 3ª harmônica da corrente de linha e 2ª harmônica da corrente de neutro são bons indicativos da presença de FAIs, já que estes apresentam valores diferentes para os demais tipos de falta.

O trabalho reportado em Nam et al. (2001) realizou experimentos em um alimentador de distribuição e obteve as seguintes características das FAIs: (*Buildup*) a corrente de falta atinge o valor máximo após algumas dezenas de ciclos; (*Shoulder*) em alguns ciclos, o processo de elevação do valor da corrente de falta é interrompido ou atenuado,

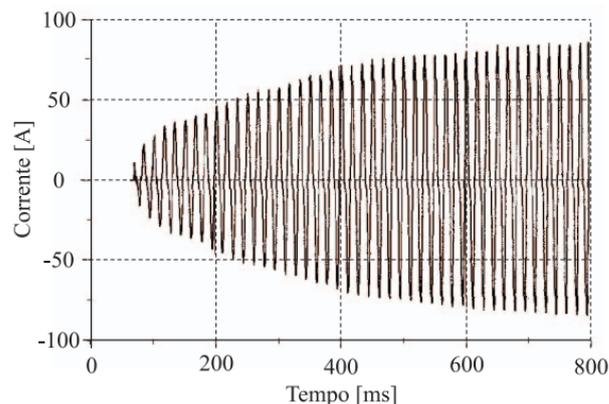


Figura 1. Corrente de FAI experimental obtida em Nam et al. (2001).

se mantendo praticamente constante; a curva  $V \times I$  do arco da corrente de falta é não linear; Os semi-ciclos positivo e negativos da corrente de falta são assimétricos. A Fig. 1 mostra a corrente experimental da FAI obtida.

Alguns modelos foram desenvolvidos para representar o comportamento das FAIs. Os modelos de resistência não-linear e circuito elétrico vistos na Fig. 2 são os mais comuns.

O modelo de Resistência de Falta não linear foi desenvolvido em Nam et al. (2001), onde as características da FAI são geradas como base em duas resistências não lineares modeladas no software ATP. O valor das resistências é controlado pela ferramenta TACS, com R1 representando os efeitos de não-linearidade e assimetria da FAI e R2 os fenômenos de (*Buildup*) e (*Shoulder*).

No modelo de Circuito Elétrico desenvolvido por Emanuel et al. (1990) temos dois diodos conectados em anti-paralelo por meio de duas fontes contínuas. De tal maneira que durante o semi-ciclo positivo a corrente de falta circula através de  $V_p$  e durante o semi-ciclo negativo através de  $V_n$ .

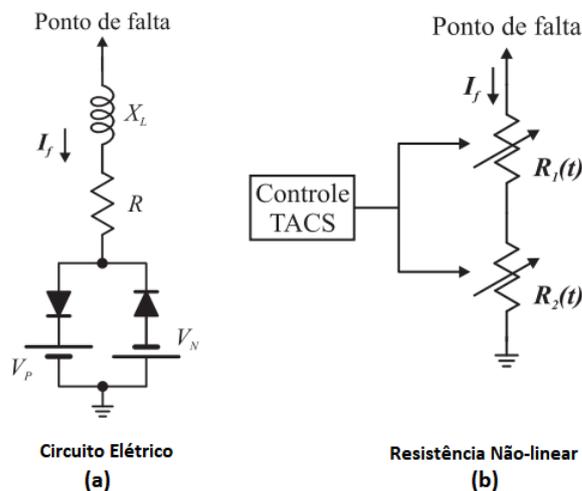


Figura 2. Modelos de FAI obtidos em: (a) Emanuel et al. (1990) e (b) Nam et al. (2001).

## 2.2 Estatística de Ordem Superior

Segundo Mendel (1991), a estatística de ordem superior (EOS) pode ser definida em termos de momentos e cumulantes, sendo adequados para análise de sinais determinísticos (periódicos e transientes) e sinais estocásticos (aleatórios, como ruídos).

Os cumulantes de segunda, terceira e quarta ordens de um sinal discreto  $x[n]$  que contém  $N$  amostras de um evento, com média nula, são definidas por Barbosa et al. (2016), tal que:

$$C_{2x}(i) = \frac{1}{N} \sum_{n=0}^{N-1} x(n)x(\text{mod}(n+i, N)) \quad (1)$$

$$C_{3x}(i) = \frac{1}{N} \sum_{n=0}^{N-1} x(n)x^2(\text{mod}(n+i, N)) \quad (2)$$

$$C_{4x}(i) = \frac{1}{N} \sum_{n=0}^{N-1} x(n)x^3(\text{mod}(n+i, N)) - \frac{3}{N^2} \sum_{n=0}^{N-1} x(n)x(\text{mod}(n+i, N)) \sum_{n=0}^{N-1} x^2(n) \quad (3)$$

onde  $i = 0, 1, 2, \dots, N-1$  e a função  $\text{mod}(a, b)$  é a função que retorna o resto inteiro da divisão de  $a$  por  $b$ .

## 2.3 Discriminante Linear de Fisher - DLF

O DLF seleciona as melhores características que fornecem uma boa separabilidade das classes dentro de um conjunto de dados, reduzindo as dimensões e conseqüentemente o esforço computacional do classificador. A função de custo do DLF é expressa por:

$$J_C = (m1 - m2)^2 \Theta \frac{1}{(D1^2 + D2^2)} \quad (4)$$

onde o vetor  $J_C = [J_1 \dots J_L]^T$ , sendo  $L$  o número total de características. As variáveis  $m1, m2$  e  $D1, D2$  representam as médias e variâncias das duas classes. O símbolo  $\Theta$  representa o produto de Hadamard.

## 2.4 Rede Neural Artificial - RNA

Para os propósitos deste trabalho, a rede neural utilizada para a classificação das faltas foi a Perceptron de Múltiplas Camadas (Multilayer Perceptron ou MLP em inglês).

O algoritmo de treinamento utilizado foi o de Levenberg-Marquardt. Este algoritmo converge mais rápido que o algoritmo Backpropagation (gradiente descendente). Uma breve descrição do seu funcionamento é dada a seguir:

Segundo Yu and Wilamowski (2010), a soma dos erros quadráticos da rede é definida por:

$$E(x, w) = \frac{1}{2} \sum_{p=1}^P \sum_{m=1}^M e_{p,m}^2 \quad (5)$$

Onde:

$\mathbf{x}$  é o vetor de entradas;

$\mathbf{w}$  é o vetor de pesos.

$e_{p,m}$  é o erro de treinamento no neurônio de saída  $m$  quando aplicado a instância  $p$ , e é definido por:

$$e_{p,m} = d_{p,m} - o_{p,m} \quad (6)$$

Sendo:

$\mathbf{d}$  é a saída desejada;

$\mathbf{o}$  é a saída produzida pela rede.

O vetor  $e$  é definido como:

$$e = [e_{1,1} e_{1,2} \dots e_{1,M} \dots e_{p,1} e_{p,2} \dots e_{p,M}]^T \quad (7)$$

A regra de atualização dos pesos é dada por:

$$w_{k+1} = w_{k+1} - (J_k^T J_k + uI)^{-1} J_k^T e_k \quad (8)$$

Onde  $J$  é a matriz Jacobiana,  $k$  indica a época atual e  $u$  é chamado de coeficiente de combinação (sempre positivo). Este coeficiente força a existência de uma inversa para a matriz  $J_k^T J_k + uI$ .

O processo de atualização é repetido até que o critério de parada escolhido seja atingido.

## 3. MÉTODO PROPOSTO

O método Proposto é resumido nos blocos da Fig. 3. De início, o sistema de distribuição da Fig. 4 é modelado no software ATPDraw, onde são simulados os dois tipos de falta e coletados os sinais. Estes formam duas classes de sinais, sendo então fornecidos a ferramenta de extração de características baseada em EOS, onde são calculados os cumulantes de 2ª, 3ª e 4ª ordens para cada classe, gerando um conjunto de características. Em seguida o Discriminante Linear de Fisher é aplicado ao conjunto selecionando os melhores cumulantes capazes de distinguir as duas classes. Ao final, os melhores cumulantes de cada classe, são aplicados a entrada de uma RNA do tipo MLP com três entradas, sendo assim reconhecidos os padrões de cada tipo de falta, possibilitando a correta classificação.

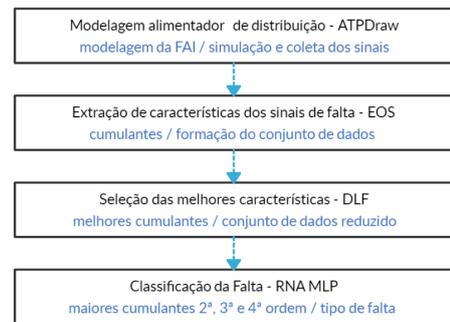


Figura 3. Fluxograma do método proposto.

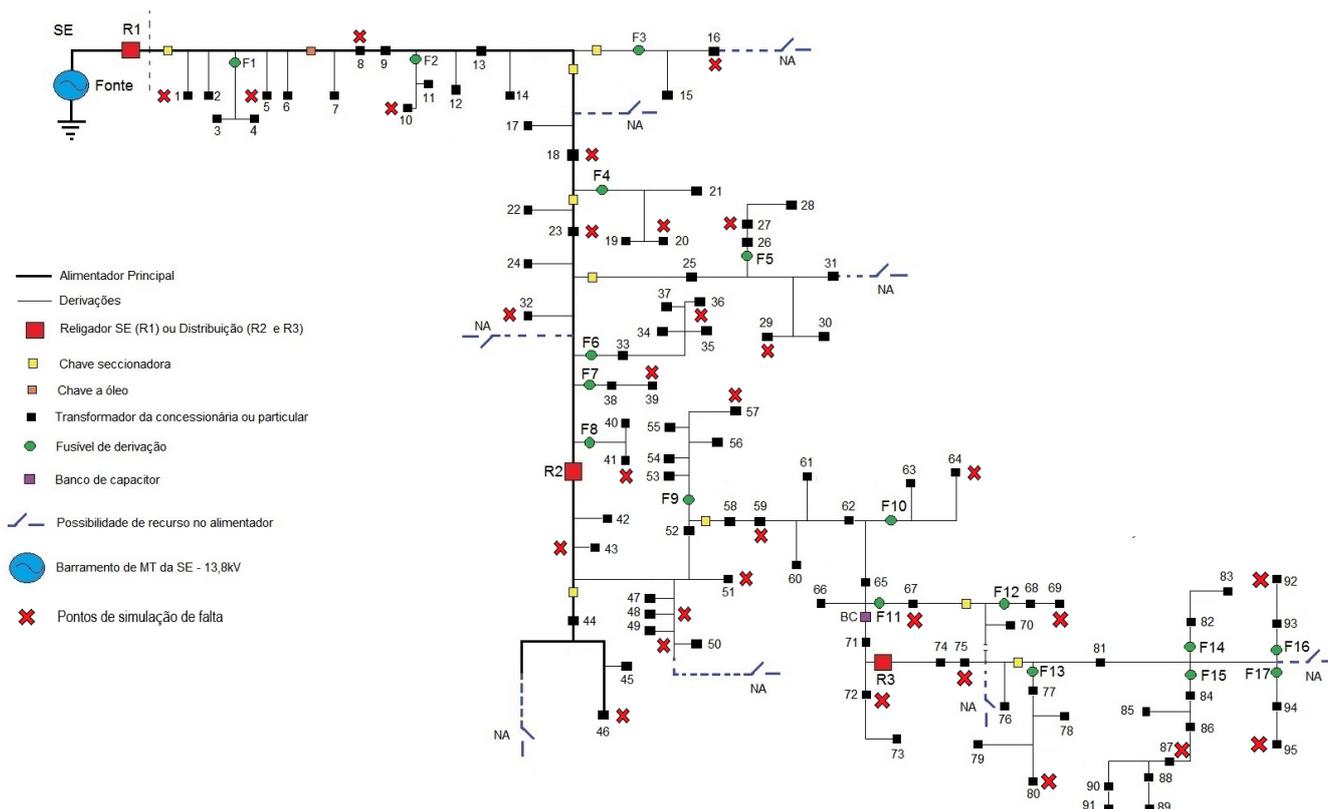


Figura 4. Representação simplificada do alimentador.

### 3.1 Modelagem Computacional

O alimentador de distribuição está localizado na área urbana da cidade de Teresina - PI. O mesmo tem extensão de aproximadamente 16,98 km, com cabos de alumínio CAA, CA e CAP, sob tensão de 13,8 kV e frequência 60Hz, alimentando uma carga composta por 95 transformadores. A Fig. 4 ilustra o seu diagrama simplificado, com destaque para os pontos de falta.

### 3.2 Modelagem da Falta de Alta Impedância

Neste Trabalho usou-se o modelo proposto por Emanuel et al. (1990) com uma modificação. Foi usada uma resistência não linear  $R(t)$  ao invés de uma resistência fixa ( $R$ ), no intuito de representar os fenômenos de *Buildup* e *Shoulder*. Na Fig. 5 temos o circuito de FAI simulado no software ATPDraw.

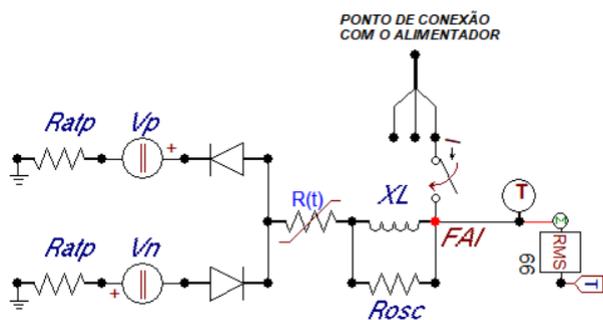


Figura 5. Circuito de FAI simulado no ATPDraw.

Na literatura, existem diversas metodologias para detectar e classificar as FAIs, com resultados satisfatórios. A tabela 2 resume os principais autores de referência para o desenvolvimento deste trabalho em comparação ao método proposto.

Tabela 2. Metodologias para detecção e classificação de FAIs.

Referência	Modelo de FAI	Deteção	Classificador
Cui et al. (2019)	1	algoritmo MDL	2
Moloi et al. (2019)	experimental (laboratório)	wavelet	SVM
Sahoo et al. (2014)	Mayr Arc model	wavelet	SVM
Nikoo et al. (2013)	experimental (campo)	TT transformada	ARTs
método proposto	1	EOS/DLF	RNA MLP

<sup>1</sup> modelo FAI de Emanuel et al. (1990) modificado;

<sup>2</sup> Bayes, SVM, k-nn, Decision tree, Random Forest e ANN.

## 4. RESULTADOS E DISCUSSÕES

No intuito de verificar o potencial conjunto da EOS com o DLF, inicialmente o método foi aplicado para distinguir duas classes de faltas conforme tabela 3. No caso 01 foram simulados dois tipos de faltas em 5 pontos diferentes. Já caso 02, são simulados eventos com FAI (modelo proposto em 3.2) e sem a presença de FAI (curto AT com  $R_f$  fixa) em 30 pontos do alimentador, onde após aplicação da EOS e DLF, os dados tratados são fornecidos a uma rede neural para classificação automática do tipo de falta.

Tabela 3. Características dos casos analisados.

Caso	Classes	Rf	Pontos na Fig. 4
01	AT	20 ohms	1, 9, 15, 35, 47
	AB	0 ohms	
02	AT	20 ohms	em destaque na Fig.4
	FAI	$R(t)^*$	

\* vide 3.2

#### 4.1 caso 01

Para o caso 01 foram simulados dois tipos de falta, sendo eles: Falta AT (monofásico-terra) com resistência de falta de 20 ohms e Falta AB (bifásica) sem aplicação de resistência, ou seja curto franco. Para cada tipo de falta foram gerados 5 eventos (5 sinais formando uma mesma classe), correspondentes a faltas nos pontos P1, P9, P15, P35 e P47.

Todas as faltas descritas na tabela 3 foram geradas no instante de 0,02s, onde se tem o início do fenômeno. Após aquisição dos sinais de falta do software ATPDraw, os mesmos são tratados no software Matlab nas etapas subsequentes de extração e classificação.

Em seguida foram calculados os cumulantes de 2<sup>a</sup>, 3<sup>a</sup> e 4<sup>a</sup> ordens para os 10 eventos, sendo os 5 primeiros eventos correspondentes as falta AT (classe 1) e os 5 demais correspondendo as faltas AB (classe 2).

Aplicando a função de custo do DLF à duas classes de sinais C1 e C2 de cada cumulante, obtêm-se um novo conjunto de dados formando o vetor J (Eq.4). Na Fig. 6 é possível visualizar graficamente o DLF gerado para cada cumulante.

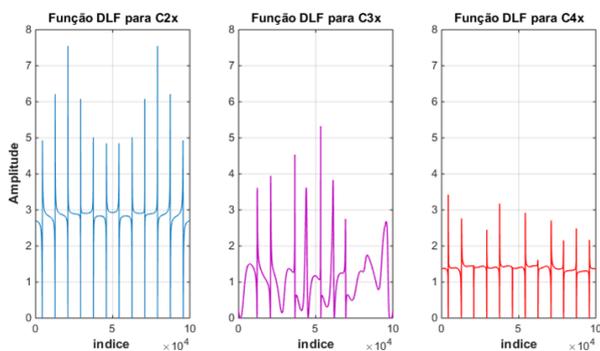


Figura 6. DLF para os cumulantes de 2<sup>a</sup>, 3<sup>a</sup> e 4<sup>a</sup> ordem - caso 01.

No próximo passo foi gerado um espaço de seleção de características a partir dos melhores cumulantes, ou seja aqueles indicados pelo maior valor de  $J$ . O espaço formado da Fig. 7 é composto por duas coordenadas (maiores cumulantes de 2<sup>a</sup> e 3<sup>a</sup> ordem), onde cada classe é representada por 05 pontos. A distribuição de tais pontos e distância intra-classe está relacionada ao fenômeno simulado.

#### 4.2 caso 02

Conforme tabela 3, o caso 02 é formado por duas classes, sendo falta AT com notável elevação de corrente e FAI, onde temos mínima elevação de magnitude, sendo essa a principal característica da FAI. A Fig. 8 ilustra a corrente medida na subestação para os dois casos.

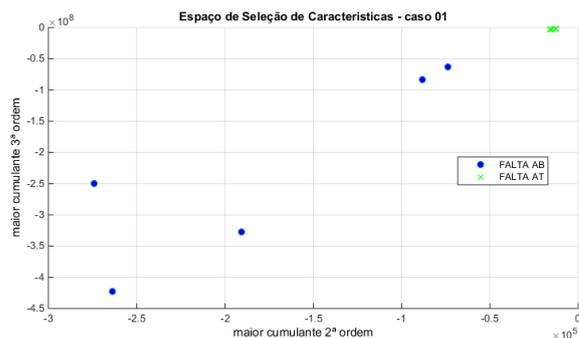


Figura 7. Espaço de seleção de características para distinção dos sinais de falta AT e AB - caso 01.

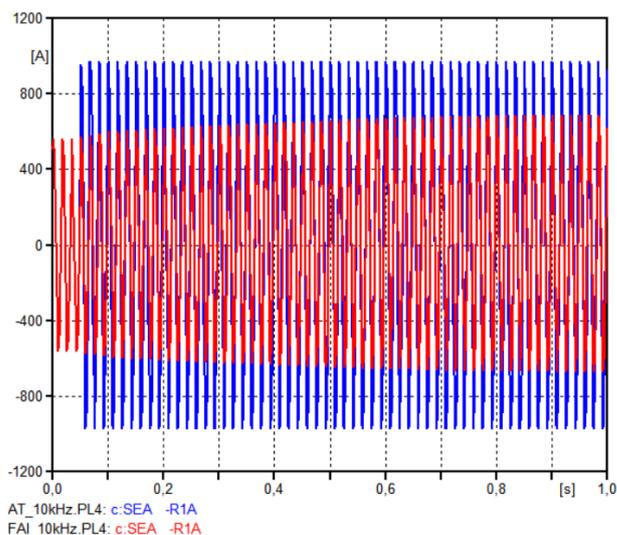


Figura 8. Correntes medidas na subestação para faltas AT e FAI aplicadas ao ponto P1 - caso 02.

Na Fig. 9 temos detalhe do sinal corrente de falta de alta impedância no ponto P1, sendo que o mesmo apresenta aspecto similar ao sinal experimental obtido em Nam et al. (2001) visto na Fig.1.

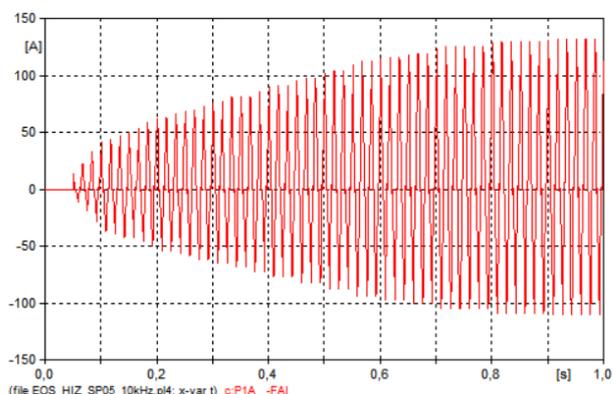


Figura 9. Corrente de FAI à terra medida ponto P1.

Haja visto o bom resultado obtido no caso 01, onde a separabilidade das classes de sinais é evidente, aplicou-se EOS e em seguida DLF para todos os 30 sinais, conforme a tabela 3. Neste caso usou-se os valores de

maiores cumulantes de 2ª, 3ª e 4ª ordens para a entrada da Rede Neural descrita no tópico 2.4. Na Fig. 10 é possível visualizar o espaço de seleção de características tridimensional. A nítida separação de sinais obtida permite que o classificador atinga o máximo de desempenho.

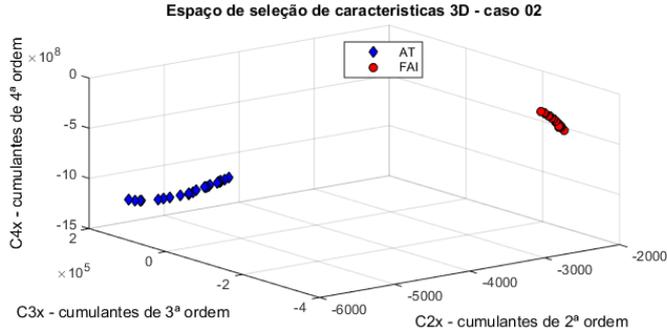


Figura 10. Espaço de seleção de características para distinção dos sinais de falta (AT) e com a presença de FAI (FAI) - caso 02.

Após o pré-processamento dos dados, os cumulantes mais relevantes de cada ordem (2ª, 3ª e 4ª) são extraídos dos sinais do banco de dados, e fornecidos a RNA MLP, que possui três entradas correspondentes. O banco foi dividido em 2 partes. Uma parte destinada ao treino da rede e outra destinada ao teste da rede (generalização).

Como entrada da RNA, utiliza-se um vetor com os cumulantes mais relevantes de 2ª, 3ª e 4ª ordem, normalizados segundo a seguinte regra para cada cumulante:

$$x_j^{norm} = \frac{x_j - x_j^{min}}{x_j^{max} - x_j^{min}} \quad (9)$$

Todas as funções de ativação utilizadas na rede foram do tipo sigmoide:  $f(x) = 1/(1 + e^{-x})$ .

A saída da rede é um número que quando arredondado, se aproxima de 0 (sinal com FAI) ou de 1 (sinal sem FAI, ou seja falta AT de elevada corrente). Na tabela 3 são listadas as características da rede MLP usada para classificar faltas no caso 02.

Tabela 4. Características rede MLP - caso 02

Característica	descrição
nº entradas	03 (C2x, C3x, C4x)
nº saídas	01 (tipo de falta)
nº neurônios camada escondida	03
algoritmo	Levenbert-Marquardt
percentual de treino	20% (12 sinais)
percentual generalização	80% (48 sinais)
percentual acertos	100%
percentual erros	0%

## 5. CONCLUSÕES

O trabalho aplicou com êxito as técnicas baseadas em estatística de ordem superior (EOS) e no discriminante linear de fisher (DLF) para distinguir dois tipos de faltas nos dois casos da tabela 3. A técnica proposta gerou resultados satisfatórios nos casos 01 e 02, distinguindo as duas classes de sinais, sendo que no caso 02 foi possível classificar corretamente o tipo de falta com o uso de RNA.

De forma a primorar a técnica proposta e consolidar a robustez dos resultados, o método desenvolvido nesse trabalho pode ser aplicado a outros tipos de falta, de modo a distinguir sinais com um banco de dados amplo contemplando várias situações de distúrbio na rede de distribuição.

Para o modelo de FAI proposto, é necessária análise ampla da variabilidade dos parâmetros para que seja possível definir vários tipos superfície de alta impedância. Também é necessário aplicar outras técnicas de classificação

## REFERÊNCIAS

- ABRADEE (2019). *Campanha Nacional de Segurança com Energia Elétrica 2019*. Associação Brasileira De Distribuidores de Energia Elétrica. URL <https://www.abradee.org.br/xiii-semana-nacional-de-seguranca-com-energia>.
- ANEEL (2018). *Procedimentos de Distribuição de Energia Elétrica no Sistema Elétrico Nacional – PRODIST Módulo 8 – Qualidade da Energia Elétrica*. Agência Nacional de Energia Elétrica. URL <https://www.aneel.gov.br/modulo-8>.
- Barbosa, T.S., Ferreira, D.D., and Pereira, D.A. (2016). Fault detection and classification in cantilever beams through vibration signal analysis and higher-order statistics. *J Control Autom Electr Systm*, 27, 535–541.
- Costa, F.B., Souza, B., Brito, N., Silva, J., and Santos, W. (2015). Real-time detection of transients induced by high-impedance faults based on the boundary wavelet transform. *IEEE Transactions on Industry Applications*, 51(6), 5312–5323.
- Cui, Q., El-Arroudi, K., and Weng, Y. (2019). A feature selection method for high impedance fault detection. *IEEE Transactions on Power Delivery*, 34(3).
- Emanuel, A.E., Gulachenski, E.M., Cyganski, D., Orr, J.A., and Shiler, S. (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*, 5, 676–686.
- Jeerings, D.I. and Linders, J.R. (1989). Ground resistance-revisited. *IEEE Transactions on Power Delivery*, 4.
- Mendel, J.M. (1991). Tutorial on higher-order statistics (spectra) in signal processing and system theory: Theoretical results and some applications. *IEEE*, 79(3).
- Moloi, K., Jordaan, J.A., and Hamam, Y. (2019). A hybrid method for high impedance fault classification and detection. *IEEE*, 3.
- Nam, S., Park, J.K., Kang, Y., and Kim, T. (2001). A modeling method of a high impedance fault in a distribution system using two series time-varying resistances in emp. *Power Engineering Society Summer Meeting. Conference Proceedings*.
- Nikoofekr, I., Sarlak, M., and Shahrtash, S. (2013). Detection and classification of high impedance faults in power distribution networks using art neural networks. *IEEE*.
- Theron, J.J., Pal, A., and Varghese, A. (2018). Tutorial on high impedance fault detection. *Annual Conference for Protective Relay Engineers (CPRE)*.
- Yu, H. and Wilamowski, B.M. (2010). *Intelligent Systems*, chapter Levenberg–Marquardt Training, 1–15. Auburn University, <http://www.eng.auburn.edu>.