

Localização de Faltas em Linha de Transmissão Utilizando Coeficientes de Frequência Mel Cepstrais (MFCC) e Redes Neurais Artificiais (RNA)

José de Anchieta A. Marques*. Hermes M. G. Castelo Branco.**

* Centro de Tecnologia, Universidade Federal do Piauí,
Teresina, Brasil (Tel: 86-99981-0325; e-mail: anchietaamtrt22@gmail.com).

** Centro de Tecnologia, Universidade Federal do Piauí,
Teresina, Brasil, (e-mail: hermescb@ufpi.edu.br).

Abstract: The faults in the transmission lines (LT) may cause great loss to the users of the Electric Power Systems (EPS). Thus, it is important to make the process of locating these faults more efficient, since this would allow them to be repaired as quickly as possible. In the present study, the Mel Frequency Cepstral Coefficients (MFCC) were used as a tool for processing voltage signals during faults. Moreover, an Artificial Neural Network (ANN) was responsible for locating the faults. A modeled line based on parameters from a real line was used as well. The proposed method provides results with high precision in locating faults in the simulations performed, with a relative average error of 0.00023%.

Resumo: Faltas nas Linhas de Transmissão (LT) podem causar grandes prejuízos aos usuários de Sistemas Elétricos de Potência (SEP). Dessa forma, é de suma importância tornar o processo de localização de tais faltas cada vez mais eficiente, de forma que estas possam ser reparadas o mais rápido possível. No presente estudo foram utilizados os Coeficientes de Frequência Mel Cepstrais (MFCC) como ferramenta de pré-processamento dos sinais de tensão durante a falta, e uma Rede Neural Artificial (RNA), responsável pela localização das faltas na prática. Utilizou-se uma linha modelada com base em parâmetros de uma linha real. O método proposto forneceu resultados com alta precisão na localização de faltas nas simulações executadas, com erro médio relativo de 0,00023%.

Keywords: *Fault location; Transmission line; MFCC; RNA; SEP.*

Palavras-chaves: *Localização de falta; Linha de transmissão; MFCC; RNA; SEP.*

1. INTRODUÇÃO

Variados são os cenários nos quais os Sistemas Elétricos de Potência (SEP) interrompem o fornecimento de energia de forma programada ou de forma não programada. Dentre as interrupções não programadas, destacam-se as faltas permanentes, que na maioria dos casos necessitam de deslocamento de equipe até o local da falha para o reestabelecimento do sistema. Dessa maneira, busca-se formas cada vez mais eficientes de localizar os pontos de falta em um sistema permitindo se reestabelecer tal fornecimento de forma rápida, a fim de mitigar os decorrentes impactos negativos sobre o consumidor (Silva, Oleskovicz, Coury, 2005). Dentre os vários componentes do SEP, as Linhas de Transmissão (LT) merecem uma atenção especial, visto que sua grande extensão as torna mais vulneráveis a possíveis ocorrências (Almeida et al., 2017). Além disso, também devido à grande extensão das LT, outro motivo que aumenta a importância de se localizar com precisão as faltas em LT, é possibilitar que as equipes de manutenção possam ser direcionadas de forma adequada aos locais de ocorrência de falta, agilizando o reestabelecimento do SEP (Chen, Huang e He, 2016).

Ao longo do tempo foram desenvolvidos vários métodos de se localizar faltas em LT, os quais são costumeiramente baseados ou em componentes de frequência fundamental ou em componentes de alta frequência. Recentemente ferramentas de Inteligência Computacional (IC) dispoem de características tanto de frequência fundamental, quanto de alta frequência (Almeida et al., 2017).

Dentre as propostas baseados em componentes de frequência fundamental têm-se algoritmo que utilizam como ferramentas de extração de característica a Transformada de *Fourier* (Phadke e Thorp, 2009), a teoria dos mínimos quadrados (Ajai e Sanaye-Pasand, 2008), a Transformada de *Wavelet* (Liang e Jeyasurya, 2004; Silva et al., 2008), além de abordagens com filtros (Sidhu et al., 2003; Lee, Kang e Nam, 2008; Guo, Kezunovic e Chen, 2003). Apesar de suas particularidades, todos atuam estimando a impedância da linha entre o ponto de medição e o ponto de falta (Aggarwal, Oleskovicz e Coury, 2003). A estimativa da impedância, por sua vez, se dá através do cálculo dos fasores, com a inspeção das variações de fase e módulo das tensões durante a falta (Almeida et al., 2017). Entretanto, elementos como resistência de falta, carregamento de linha, parâmetros da fonte e

contribuição de corrente do terminal remoto podem prejudicar a acurácia de tais métodos (Silva, Oleskovicz, Coury, 2005).

Já as propostas baseadas em componentes de alta frequência, tem como núcleo a teoria das ondas viajantes (Almeida *et al.*, 2017). Inicialmente, procura-se determinar dois tipos de informação, a saber: 1) a velocidade de propagação da onda de tensão na LT; 2) o intervalo de tempo que essa tensão ou corrente levou para percorrer a distância entre o ponto de falta e o terminal da linha onde está instalado o localizador (Almeida *et al.*, 2017). Dessa maneira, o sistema é capaz de definir com maior precisão a distância da falta na LT (Bo *et al.*, 2000). Salienta-se a necessidade de identificar rigorosamente o instante de incidência das ondas viajantes nos terminais da linha. Da mesma forma, deve-se garantir que as informações obtidas do transitório do distúrbio sejam pertinentes, posto que, com base nestas, serão desenvolvidas expressões matemáticas associadas à distância da falta (Almeida *et al.*, 2017; Silva, Oleskovicz, Coury, 2005). Como consequência de tais especificidades, numerosas pesquisas propuseram maneiras de acelerar o reconhecimento dos transitórios (Silva *et al.*, 2008; Lin *et al.*, 2008; Costa, 2014; Lopes, Fernandes e Neves, 2013; Lopes, 2011). Ademais, a obtenção de informações pertinentes, em diversos trabalhos, dá-se mediante análise espectral dos transitórios no período de falta ou até mesmo logo após seu isolamento (Faybisovich, Feiginoy e Khoroshev, 2010; Shi, Troeltzsch e Kanoun, 2010; Iurinic, 2013; Mamis, Arkan e Keles, 2013; Alves *et al.*, 2015; Souza *et al.*, 2014; Souza *et al.*, 2015; Ngu e Ramar, 2011). Finalmente, vale destacar que um dos maiores obstáculos desse método é a necessidade de se utilizar altas taxas de amostragem (Silva, Oleskovicz e Coury, 2005), o que vem se tornando um problema cada vez menor em face da produção de processadores cada vez mais rápidos (Almeida *et al.*, 2017).

Os métodos firmados sobre Inteligência Computacional têm se destacado recentemente na literatura correlata vista disso, diversas pesquisas foram conduzidas nas últimas décadas, através de algoritmos como a Lógica Fuzzy (Reddy e Mohanta, 2008) e os Algoritmos Genéticos (Davoudi, Sadeh e Kamyab, 2012; El-Naggar, 2001), assim como as Redes Neurais Artificiais (RNAs - *Neural Networks*) (Chen e Maun, 2000; Sadinezhad e Agelidis, 2009), propostas baseadas em regressão de vetores de suporte (SVR) (Yusuff *et al.*, 2011; Yusuff, Jimoh e Munda, 2014; Fei, Qi, e Li, 2018), bem como propostas baseadas em regressão de vetores de suporte de mínimos quadrados (LS-SVR) (Uyar, 2012).

Assim, este artigo apresenta um algoritmo de IC baseado em Redes Neurais Artificiais para localizar, com precisão, faltas em LT. O algoritmo proposto utiliza como sinais de entrada Coeficientes de Frequência Mel Cepstrais (MFCC – *Mel Frequency Cepstral Coefficients*) obtidos dos sinais de tensão dos dois terminais da linha. Utilizou-se uma LT modelada com base em parâmetros de uma linha real. O restante deste documento está organizado nas seguintes seções: A seção 2 apresenta os recursos utilizados, com os conceitos de MFCC e da RNA. Na seção 3 a metodologia e as simulações. Na seção 4 os resultados e discussões e, finalmente, a seção 5 é a conclusão.

2. CONCEITOS BÁSICOS SOBRE AS FERRAMENTAS UTILIZADAS

O intuito dessa seção é abordar os princípios básicos de funcionamento dos algoritmos relacionados ao cálculo dos Coeficientes de Frequência Mel Cepstrais e das Redes Neurais Artificiais.

2.1 Coeficientes de Frequência Mel Cepstrais (MFCC)

Os MFCC – que consistem no *cepstrum* real de um sinal definido por uma janela – são utilizados com frequência nas áreas de reconhecimento de voz ou fala, posto que conseguem obter as propriedades lineares e não lineares do sinal mesmo com as características dinâmicas destes (Nelwamondo e Marwala, 2006). Isso porque o *cepstrum* real utiliza uma escada de frequência não linear, similar ao comportamento do aparelho auditivo (Nelwamondo e Marwala, 2006). Dessa forma, os MFCC obtêm o espectro médio de cada frequência central com larguras de banda cada vez maiores.

Então, a ideia é que os MFCC forneçam uma informação no domínio da frequência baseada em um banco de filtros triangulares, também chamados de filtros triangulares mel, como ilustrado na Fig. 1. Também pode-se obter informações no plano tempo-frequência dispondo do janelamento do sinal, mas esta abordagem não será empregada nesta proposta.




Fig. 1. Filtros triangulares de mel

O espaçamento não linear obedece a escala mel descrita em (1).

$$mel = 2595 \log_{10}\left(1 + \frac{f(Hz)}{700}\right) \quad (1)$$

Os filtros têm a função de calcular o espectro médio em torno de cada frequência central com o aumento da largura de banda. Abaixo o procedimento para extrair os MFCC (Furui, 2000; Peixoto, 2019):

1. Divide-se o sinal em janelas pequenas ou toma-se o sinal inteiro como única janela.
2. Para cada janela, aplica-se a **Transformada Discreta de Fourier (DFT)** para calcular o periodograma do espectro de potência.
3. Aplica-se um banco de filtros em escala mel e soma-se a energia em cada filtro.
4. Aplica-se o logaritmo de todas as energias do banco de filtros.
5. Aplica-se a Transformada Discreta de Cosseno (DCT) sobre o sinal de energia final.

Neste trabalho foram usados 20 MFCC para os sinais de tensão de cada terminal da linha, para cada uma das 3 fases. O uso de outros valores de MFCC serão propostas de simulações futuras. Os sinais foram amostrados a uma taxa de 400 KHz. Destaca-se que os coeficientes mais altos, relativos às maiores frequências, significam mudanças aceleradas nas energias do banco de filtros. Têm como função apresentar informações relacionados a métodos baseados em componentes de alta frequência para localização de falhas. Por outro lado, os coeficientes mais baixos trazem informações associadas aos métodos de frequência fundamental (Peixoto, 2019).

Outra informação relevante acerca das vantagens apresentadas pelos MFCC é que as energias de filtro são mais resistentes a erros de estimativa decorrentes de espectro e ruído (Peixoto, 2019). Tal característica é benéfica aos objetivos da aplicação pretendida neste trabalho.

2.2 Redes Neurais Artificiais (RNA)

As Redes Neurais Artificiais são ferramentas que possuem a característica de absorverem e reterem conhecimento mediante experiência – característica que teve como inspiração a organização neural de organismos inteligentes (Simon, 2001). Isso significa que as RNAs têm notório potencial no que concerne à identificação de padrões e à realização de decisões autônomas.

Um dos modelos de rede neural existentes é o *Multilayer Perceptron* (MLP), cuja maior particularidade consiste em cada neurônio de uma camada estar conectado a todos os neurônios da camada seguinte (Simon, 2001). Assim como outros exemplares de redes neurais, a MLP deve ser treinada antes de ser colocada em operação. Essa tarefa é realizada por algoritmos de regressão apropriados e, para a averiguação em pauta, optou-se neste trabalho pelo *backpropagation* de *Levenberg-Marquardt* (LM) (Levenberg, 1944 e Marquardt, 1963), que é classificado como um algoritmo de *backpropagation* supervisionado. Portanto, o valor do peso na iteração vigente é igual ao valor do peso na iteração anterior, corrigido pelo valor proporcional ao gradiente.

Os parâmetros de treinamento são mostrados na Tabela 1, na qual a constante que atualiza os pesos para impedir que a RNA fique presa no mínimo local é chamada de constante de momento ou parâmetro de momento (MU).

A Fig. 2 ilustra as 3 camadas da RNA implementadas para prever a distância da falta. A primeira camada possui 120 entradas. A segunda camada é a primeira camada neural oculta, com 120 neurônios. A terceira é a camada neural de saída, com um neurônio na saída.




Fig. 2: Estrutura da RNA implementada.

A quantidade de 120 neurônios da camada interna foi definida em testes realizados para diversas configurações, no qual obteve-se melhor resultado utilizando a mesma quantidade de entradas da RNA. Outras propostas serão abordadas e simulações futuras.

Tabela 1. Parâmetros da arquitetura da RNA

Critérios	Valor
Número de entradas	120
Número de neurônios na camada escondida	120
Número de neurônios na camada de saída	1
Função de ativação	Função sigmoide
Função de ativação	Purelin
Algoritmo de rede neural	Levenberg-Marquardt
Critério de parada	Teste de validação (6) ou número de épocas (1000)
Medida de erro adotado	Erro Quadrático Médio (EQM)
MU inicial	0,001
Fator de diminuição MU	0,1
Fator de aumento MU	10
Erros calculados após treino da RNA	EMA(KM), EMR(%) e Desvio Padrão

3. METODOLOGIA E SIMULAÇÕES

Para execução desta pesquisa foi selecionada uma linha de transmissão de cerca de 330 km que interliga as subestações de SOBRAL (CE) a TERESINA (PI). Esta LT faz parte de um sistema de transmissão de alta tensão real de 500 kV (Abreu, 2015) que utiliza torres estaiadas do tipo VX. A Fig. 3 ilustra a estrutura das torres descritas. As referidas torres possuem três fases, com dois cabos guarda e quatro condutores cada, além de uma disposição horizontal nas fases espaçadas de 11 metros e 4 sub-condutores 954 MCMRAIL. O raio externo dos condutores, por sua vez, é de 14,795 mm, enquanto o raio interno é de 3,7 mm. A resistência em corrente contínua é de 0,05995 ohm/km. Os condutores estão a uma altura de 41 m.




Fig. 3. Modelo de linha com torre em V Feixe Expandido Simétrico (VX – Simétrico) de 500 kV.

Foi utilizado o software ATP versão 2010® (*Electromagnetic Transients Program*) para a modelagem da LT apresentada, por meio da interface do ATPDraw. O Sistema da forma como modelado é apresentado na Fig. 4.




Fig. 4. Sistema de Transmissão modelado no software ATPDraw

A base de dados das faltas foram obtidas para diferentes distâncias, variando resistência e ângulo de falta para os seguintes tipos de faltas: Monofásica envolvendo a terra (FT), bifásicas (FF), bifásicas envolvendo a terra (FFT), trifásicas (FFF) e trifásicas envolvendo a terra (FFFT). A taxa de amostragem utilizada para as simulações foi de 400 KHz. Nas simulações também foram variados a resistência e o ângulo de falta ao longo de toda extensão a LT. Na tabela 2 a seguir resume-se as características das faltas simuladas.

Tabela 2. Quantidades de simulações por tipo de falta

Tipo de falta	Resistência (Ohm)	Ângulo (Graus)	Distância (KM)	Quantidade
FT	De 0 a 400	0, 45 e 90	0,9 a 329,1	20.301
FF	De 0 a 400	0, 45 e 90	0,9 a 329,1	20.301
FFT	De 0 a 400	0, 45 e 90	0,9 a 329,1	20.301
FFF	De 0 a 400	0, 45 e 90	0,9 a 329,1	20.301
FFFT	De 0 a 400	0, 45 e 90	0,9 a 329,1	20.301
Total de Faltas Simuladas				101.505

Da base de dados obtidas, 70% foram selecionadas para conjunto de treino da RNA, 15% para conjunto de validação e 15% para conjunto de testes, todas separadas aleatoriamente para treinamento da RNA e usando os parâmetros definidos na Tabela 1.

As entradas para a RNA foram obtidas a partir dos sinais de tensão das 3 fases em cada um dos dois terminais, após a falta, totalizando 6 sinais de tensão. De cada sinal de tensão foram calculados os MFCC. Para o cálculo dos MFCC em cada fase, utilizou-se apenas 1 ciclo do sinal logo após a inserção da falta, com uma única janela. Utilizou-se, ainda, 20 filtros, que forneceram 20 coeficientes MFCC para cada sinal. A topologia de rede que obteve os melhores resultados nos testes realizados utilizou como entrada os 20 MFCC de cada sinal de tensão (3 fases medidas em cada um dos 2 terminais), totalizando 120 padrões de entradas para a RNA proposta. Contudo foram testadas topologias com entradas provenientes de um número menor de coeficientes. A Fig 5 ilustra o processo de

treinamento da RNA proposta. Destaca-se que várias topologias foram testadas, variando-se o número de entradas, neurônios na camada escondida bem como outros parâmetros da rede.




Fig. 5. Fluxograma para Treinamento da RNA proposta.

Após a etapa de treinamento da RNA, esta foi utilizada para estimar a distância de falta do conjunto de teste. A Fig. 6 ilustra as etapas da metodologia proposta com a RNA em operação.




Fig. 6. Fluxograma da metodologia proposta para localização de falta de LT.

4. RESULTADOS E DISCUSSÕES

A partir do método utilizado nessa pesquisa, a qual se deu sobre 15.226 casos do conjunto de teste, descobriu-se um Erro Médio Absoluto (EMA), calculado conforme (2), de 0,00075 km, com desvio padrão de 0,03664. Ao mesmo tempo, obteve-se um Erro Médio Relativo (EMR), calculado de acordo com (3), de 0,00023%, com desvio padrão de 0.01110%.

$$EMA = \frac{1}{N} \sum_{i=1}^N E_i \quad (2)$$

$$EMR = \frac{1}{N} \sum_{i=1}^N \frac{E_i}{L} \times 100 \quad (3)$$

sendo E_i o erro de localização de falta, dado pelo módulo da diferença, entre a distância real e a distância estimada, N a quantidade de faltas, e L o comprimento da linha (330 km).

Os resultados obtidos evidenciam a eficiência do método proposto para localização de faltas em LT. Destaca-se que o método proposto obteve resultados superiores aos melhores resultados apontados na literatura correlata pesquisada até esta data, conforme tabela 7, como será discutido a seguir.

O gráfico de desempenho da Fig. 7 ilustra o Erro Quadrático Médio (EQM) do treino, da validação e do teste de acordo com o algoritmo *Levenberg-Marquardt*.




Fig. 7. Desempenho de treinamento da rede neural.

Observa-se na Tabela 3, registro da influência do tipo de falta na localização, que as faltas FFT apresentaram um maior EMR de 0,00083% e que os menores EMR foram verificados nas faltas FF e FFFT, ambos 0,00002%. Conforme apresentado na Tabela 3 é possível deduzir que a metodologia proposta apresenta resultados aceitáveis para todos os tipos de falta. As piores situações (faltas FFT) apresentam em média erro absoluto de aproximadamente 2,74 m, que é um erro aceitável.

Tabela 3. Influência do tipo de falta

Tipo de falta	EMA (KM)	Desvio Padrão (KM)	EMR (%)	Desvio Padrão (%)
FT	0,00073	0,00214	0,00022	0,00065
FF	0,00008	0,00011	0,00002	0,00003
FFT	0,00274	0,08129	0,00083	0,02463
FFF	0,00008	0,00013	0,00003	0,00004
FFFT	0,00008	0,00013	0,00002	0,00004

Considerando a influência do ângulo de falta nesta proposta, representada na Tabela 4, observou-se que faltas ocorridas com o ângulo 0° apresentaram um maior EMR de 0,00079%, reduzindo-se com o aumento do ângulo até obter o menor valor de EMR para o ângulo de 90° de 0,00011%. Observa-se que o ângulo de 0°, mesmo com o pior resultado de EMA de 1,53m, ainda, é bem preciso.

Tabela 4. Influência do ângulo de falta

Ângulo de falta (°)	EMA (KM)	Desvio Padrão (KM)	EMR (%)	Desvio Padrão (%)
0	0,00153	0,06247	0,00079	0,01893
45	0,00048	0,00716	0,00024	0,00217
90	0,00021	0,00078	0,00011	0,00024

Em seguida, a Tabela 5 apresenta os resultados levando em conta diferentes distâncias de ocorrência de faltas. Optou-se por dividir os dados de 30 km em 30 km. Com isso, foi possível constatar que as distâncias intermediárias (95 km a 270 km) tiveram EMR melhores, variando muito pouco de 0,00008% a 0,00010% e, também, pouca variação e desvio padrão. As distâncias iniciais (0,9 km a 90 km) e finais (275 km a 329,1 km), ou seja, aquelas mais próximas aos terminais, apresentaram EMR um pouco maiores que os valores intermediários. Ademais, verificou-se que a distância de falta também interfere no comportamento do método de localização de falta sugerido, contudo as respostas apresentadas ainda possuem EMR bem pequenos, mesmo nas piores situações, que em termos absolutos foram de aproximadamente 4m para as faltas ocorridas próximo ao segundo terminal da linha.

Tabela 5. Influência da distância de falta

Distância de falta (KM)	EMA (KM)	Desvio Padrão (KM)	EMR (%)	Desvio Padrão (%)
0,9 a 30	0,00104	0,01277	0,00031	0,00387
35 a 60	0,00038	0,00178	0,00011	0,00054
65 a 90	0,00045	0,00290	0,00014	0,00088
95 a 120	0,00032	0,00108	0,00010	0,00033
125 a 150	0,00027	0,00086	0,00008	0,00026
155 a 180	0,00031	0,00104	0,00009	0,00032
185 a 210	0,00034	0,00199	0,00010	0,00060
215 a 240	0,00028	0,00103	0,00009	0,00031
245 a 270	0,00033	0,00145	0,00010	0,00044
275 a 300	0,00057	0,01093	0,00017	0,00331
305 a 329,1	0,00403	0,12258	0,00122	0,03714

Os grupos representados na Tabela 6 a seguir basearam-se no valor da resistência de falta. Optou-se por dividir os dados da seguinte forma: 0 a 50 Ω ; 55 a 250 Ω e de 255 a 500 Ω . Dessa forma, foi possível observar que as resistências maiores que 50 Ω tiveram melhores EMR, de aproximadamente 0,00007%, e poucas variações. Observa-se que os valores de resistência inferiores a 50 Ω são responsáveis por mais de 90% dos erros de regressão. No entanto, mesmo nas faltas de baixa impedância os erros de estimação observados não são tão relevantes, representando em média aproximadamente 5 metros.

Tabela 6. Influência da resistência de falta

Resistência de falta (Ω)	EMA (KM)	Desvio Padrão (KM)	EMR (%)	Desvio Padrão (%)
0 a 50	0,00482	0,11011	0,00146	0,03337
55 a 250	0,00025	0,00042	0,00007	0,00013
255 a 500	0,00024	0,00039	0,00007	0,00012

O gráfico de regressão linear da RNA de acordo com o algoritmo de *Levenberg-Marquardt*, ilustrado na Fig. 8, mostra o ajuste entre o valor real e o estimado, refletindo o que foi discutido sobre os valores apresentados nas Tabelas 3 a 6.




Fig. 8. Regressão linear para o algoritmo de treinamento LM.

Apesar algumas das condições discriminadas nas tabelas 3, 4, 5 e 6 influenciarem positiva ou negativamente na performance do método proposto, percebe-se que tal influência não é relevante. Os resultados alcançados sugerem que este é capaz de identificar a localização de faltas com erros médios absolutos inferiores a 5m para todas as situações. Em termos de erros médios relativos, os erros em cada situação das tabelas de 3 a 6 são, em média, inferiores a 0,0012%. Com objetivo de verificar o desempenho da metodologia proposta frente a outros métodos já apresentados na literatura, apresenta-se a Tabela 7 que resume o desempenho de diversas abordagens. É possível observar que o método proposto foi o que apresentou menor EMR dentre todos os métodos listados na Tabela 7.

Ressalta-se que o método proposto neste trabalho utilizou apenas sinais de tensão, enquanto todos os outros documentados na Tabela 7 utilizaram sinais de tensão e corrente como entradas para seus algoritmos. Por outro lado 4 dos trabalhos apresentados utilizaram uma janela de dados menor (de 0,5 e 0,25 ciclos) que a utilizada nesta proposta (1 ciclo) e, ainda assim, apresentaram resultados bastante satisfatórios. Apesar de o tamanho da janela de dados utilizada (1 ciclo a 60Hz) não ser um parâmetro que possa influenciar no tempo total gasto no reparo da linha, realmente é interessante investigar propostas com janelas menores a fim de

propor estratégias que demandem menor processamento dos algoritmos utilizados para extração de características e de estimação da distância de falta.

Tabela 7. Comparação dos resultados de técnicas que usam inteligência computacional

Metodologia	Extração de Características	Ferramenta IC	EMR (%)	Ciclos
Joorabian, Taleghani and Aggarwal, 2004		RBF	0,05000	1,00
Samantaray, Dash e Panda, 2006	HS-Transformer	RBF	0,89000	2,00
Samantaray, Dash e Panda, 2007	DWT	RBF	0,51000	2,00
Chunju et al., 2007	DWT	Neuro-Fuzzy	0,00100	2,00
Ekici, Yildirim e Poyraz, 2008	WPT	RNA	0,00100	1,00
Yusuff et al., 2011	WPT	SVR	0,00210	0,50
Uyar, 2012	S-Transformer	LS-SVR	0,00170	1,00
Yusuff, Jimoh e Munda, 2014	SWT	SVR	0,00210	0,25
Fei, Qi and Li, 2018	-	SVR	0,00090	0,25
Proposta	MFCC	RNA	0,00023	1,00

5. CONCLUSÕES

Faltas em LT causam grandes prejuízos aos usuários de Sistemas Elétricos de Potência (SEP). Dessa forma, é de suma importância tornar o processo de localização de tais faltas cada vez mais eficiente, de forma que estas possam ser reparadas o mais rápido possível. Este artigo apresentou uma metodologia que utiliza uma RNA, no intuito de determinar a distância da falta. As entradas da RNA foram coeficientes MFCC obtidos dos sinais de tensão das três fases da tensão medidas nos dois terminais da linha.

Os resultados oriundos das simulações com o modelo abordado trazem EMR inferiores a 0,0012%, apontando que a metodologia proposta é uma boa alternativa para localização de faltas em LT. A comparação com resultados da literatura pesquisada até essa data apontou que a metodologia proposta apresenta resultados, conforme tabela 7, com precisão equivalentes ou superiores aos reportados em outros trabalhos que utilizam técnicas de IC para localização de faltas em LT. Acredita-se que os resultados obtidos estão associados à ferramenta de extração de características utilizada. A MFCC é pouco explorada na área de SEP, contudo os resultados encontrados neste trabalho indicam que esta é uma ferramenta que pode ser útil para esta e outras aplicações em SEP.

Como trabalhos futuros pretende-se investigar o emprego dos dados de tensão obtidos em um único terminal para a localização de falta, utilizando as mesmas ferramentas propostas neste trabalho. Pretende-se, também investigar a aplicação de metodologia utilizando as correntes medidas em um e nos dois terminais, associadas ou não com os sinais de

tensão. Pretende-se ainda propor a aplicação de algoritmos com janelas inferiores a 1 ciclo também utilizando RNA e MFCC. Por fim, pretende-se também investigar o desempenho da abordagem proposta em outras linhas de transmissão modeladas no ATP.

AGRADECIMENTOS

Os autores gostariam de agradecer à UFPI pela disponibilização de toda a infraestrutura necessária e a CAPES e CNPQ pelo suporte financeiro que possibilitou a realização desta pesquisa.

REFERÊNCIAS

- Abreu, F.C.M. (2015). Localização de faltas em linhas de transmissão utilizando ondas viajantes e transformada Wavelet sob influência de ruído branco (mestrado) – Universidade Federal do Ceará, Centro de Tecnologia, Departamento de Engenharia Elétrica, Programa de Pós-Graduação em Engenharia Elétrica, Fortaleza.
- Ajaei, F.B. and Sanaye-Pasand, M. (2008). Minimizing the impact of transients of capacitive voltage transformers on distance relay. *Joint International Conference on Power System Technology and IEEE Power India Conference*.
- Almeida, A.R., Almeida, O.M., Junior, B.F.S., Barreto, L.H.S.C. and Barros, A.K. (2017). ICA feature extraction for location and classification of faults in high-voltage transmission lines. *Electric Power System Research*, volume 148, pages 254-263.
- Alves, M.H.S., Almeida, O.M., Almeida, A.R., Carvalho, J. G. S., Junior, B.F.S. e Abreu, F.C.M. (2015). Teoria das ondas viajantes e filtragem adaptativa de sinais para localização de faltas em linhas de transmissão. *Congresso Brasileiro de Inteligência Computacional (CBIC)*, Curitiba - PR.
- Bo, Z.Q., Jiang, Z.C., Chen, Z.X., Dong, Z., Weller, G. and Redfern, M.A. (2000). Transients based Protection for Power Transmission Systems. *IEEE – Power Engineering Society Winter Meeting*, volume 3, pages 1832-1837, January.
- Chen, Z. and Maun, J.C. (2000). Artificial neural network approach to single-ended fault locator for transmission lines. *IEEE Transactions on Power Systems*, volume 15, number 1, pages 370–375.
- Chen, K., Huang, C. and He, J. (2016). Fault detection, classification and location for transmission lines and distribution systems: a review on the methods. *High Volt*, volume 1, issue 1, pages 25–33.
- Chunju, F., Li, K.K., Chan, W.L., Weiyong, Y. and Zhaoning, Z. (2007). Application of wavelet fuzzy neural network in locating single line to ground fault (slg) in distribution lines, *International Journal of Electrical Power & Energy Systems*, volume 29, pages 497–503.
- Costa, F.B. (2014). Fault-induced transient detection based on real-time analysis of the wavelet coefficient energy. *IEEE Transactions on Power Delivery*, volume 29, number 1, pages 140–153. February.
- Davoudi, M.G., Sadeh, J. and Kamyab, K. (2012). Time domain fault location on transmission lines using genetic algorithm. *11th International Conference on Environment and Electrical Engineering*.
- Ekici, S., Yildirim, S. and Poyraz, M. (2008). Energy and entropy-based feature extraction for locating fault on transmission lines by using neural network and wavelet packet decomposition, *Expert Systems with Applications*, volume 34, pages 2937– 2944.
- El-Naggar, K.M. (2001). A genetic based fault location algorithm for transmission lines. *16th International Conference and Exhibition on Electricity Distribution*.
- Faybisovich, V., Feiginov, M., Khoroshev and M.I. (2010). Investigation of frequency domain traveling wave fault location methods. *IEEE PES T D*.
- Fei, C., Qi, G. and Li, C. (2018). Fault location on high voltage transmission line by applying support vector regression with fault signal amplitudes. *Electric Power Systems Research*, volume 160, pages 173-179.
- Furui, S. (2000). Digital speech processing: synthesis, and recognition. *CRC Press*.
- Guo, Y., Kezunovic, M. and Chen, D. (2003). Simplified algorithms for removal of the effect of exponentially decaying dc-offset on the fourier algorithm. *IEEE Transactions on Power Delivery*, volume 18, number 3, pages 711–717.
- Iurinic, L. (2013). Accurate fault location technique for power transmission lines. *International Conference on Power Systems Transients*, July.
- Joorabian, M., Taleghani, S.M.A. and Aggarwal, R.K. (2004). Accurate fault locator for ehv transmission lines based on radial basis function neural networks, *Electric Power Systems Research*, volume 71, pages 195–202.
- Lee, D.G., Kang, S.H. and Nam, S.R. (2008). New modified fourier algorithm to eliminate the effect of the dc offset on phasor estimation using dft. *IEEE/PES Transmission and Distribution Conference and Exposition*.
- Levenberg, K. (1944). A method for the solution of certain problems in least squares, *Quarterly of Applied Mathematics*, volume 5, pages 164–168.
- Liang, F. and Jeyasurya, B. (2004). Transmission line distance protection using wavelet transform algorithm. *IEEE Transactions on Power Delivery*. Volume 19, number 2, pages 545–553.
- Lin, D., Jun, P., Wenxia, S., Jun, T. and Jun, Z. (2008). Fault location for transmission line based on traveling waves using correlation analysis method. *International Conference on High Voltage Engineering and Application*.
- Lopes, F.V. and Santos, W.C., Fernandes, D., Neves, W.L.A. and Souza, B.A. (2011). An adaptive fault location method for smart distribution and transmission grids. *IEEE Pes Conference on Innovative Smart Grid Technologies Latin America (ISGT LA)*.
- Lopes, F.V., Fernandes, D. and Neves, W.L.A. (2013). A traveling-wave detection method based on park's transformation for fault locators. *IEEE Transactions on Power Delivery*, volume 28, number 3, pages 1626–1634, July.
- Mamis, M.S., Arkan, M. and Keles, C. (2013). Transmission lines fault location using transient signal spectrum.

- Electrical Power and Energy Systems*, volume 53, pages 714–718.
- Marquardt, D. (1963). An algorithm for least squares estimation of nonlinear parameters. *J. Soc. Indust. Ap. Math.* volume 11, pages 431–441.
- Nelwamondo, F.V. and Marwala, T. (2006). Faults detection using gaussian mixture models, mel-frequency cepstral coefficients and kurtosis. *IEEE International Conference on Systems, Man and Cybernetics. IEEE.* pages 290–295.
- Ngu, E.E. and Ramar K. (2011). A combined impedance and traveling wave based fault location method for multi-terminal transmission lines”. *Electrical Power and Energy Systems*, volume 33, pages 1767–1775.
- Oleskovicz, M., Coury, D.V. and Aggarwal, R.K. (2003). O emprego de redes neurais artificiais na detecção, classificação e localização de faltas em linhas de transmissão. *Sba Controle & Automação*, volume 14, número 2, páginas 138–150, Campinas.
- Peixoto, J.S.J. (2019). Métodos de extração de atributos para detecção de crises epiléticas: uma abordagem comparativa. Dissertação (Mestrado Acadêmico em Engenharia de Teleinformática) – *Departamento de engenharia de Teleinformática, Universidade Federal do Ceará (UFC)*, Fortaleza.
- Phadke, A.G. and Thorp, J.S. (2009). Computer Relaying for Power Systems. *John Wiley and Sons Inc.* New York, USA.
- Reddy, M.J.B. and Mohanta, D.K. (2008). Performance evaluation of an adaptive-network-based fuzzy inference system approach for location of faults on transmission lines using monte carlo simulation. *IEEE Transactions on Fuzzy Systems*, volume 16, number 4, pages 909–919.
- Sadinezhad, I. and Agelidis, V.G. (2009). An adaptive precise one-end power transmission line fault locating algorithm based on multilayer complex adaptive artificial neural networks. *IEEE International Conference on Industrial Technology*.
- Samantaray, S.R., Dash, P.K. and Panda, G. (2006). Fault classification and location using hs transform and radial basis function neural network, *Electric Power Systems Research*, volume 76, pages 897–905.
- Samantaray, S.R., Dash, P.K. and Panda, G. (2007). Distance relaying for transmission line using support vector machine and radial basis function neural network, *International Journal of Electrical Power & Energy Systems* 29, pages 551–556.
- Shi, Q., Troeltzsch, U. and Kanoun, O. (2010). Detection and localization of cable faults by time and frequency domain measurements. *7th International Multi- Conference on Systems, Signals and Devices*.
- Sidhu, T.S., Zhang, X., Albasri, F. and Sachdev, M.S. (2003). Discrete-fourier-transform-based technique for removal of decaying dc offset from phasor estimates. *IEE Proceedings - Generation, Transmission and Distribution*, volume 150, number 6, pages 745–752.
- Silva, M., Oleskovicz, M. and Coury, D.V. (2005). Uma nova ferramenta baseada na transformada wavelet para localização digital de faltas. *Sba Controle & Automação*, volume 16, número 3, páginas 345–358. Campinas.
- Silva, M., Coury, D.V., Oleskovicz, M. and Segatto, E.C. (2008). An alternative fault location algorithm based on wavelet transforms for three-terminal lines. *IEEE Power and Energy Society General Meeting - Conversion and Delivery of Electrical Energy in the 21st Century*.
- Souza, S.C.A., Almeida, A.R., Braga, A.P.S., Almeida, O.M., Abreu, F.C.M. e Junior, J.S.A. (2014). Localização de faltas em linhas de transmissão usando redes neurais artificiais e ondas viajantes. *Congresso Brasileiro de Automação (CBA)*, Belo Horizonte - MG.
- Souza, S.C.A., Almeida, A.R., Braga, A.P.S., Leão, R.P.S., Almeida, O.M. e Abreu, F.C.M. (2015). Uso de Redes Neurais e Transformada de Stockwell na Localização de faltas em linha de transmissão. *Simpósio Brasileiro De Automação Inteligente - SBAI*, Natal - RN.
- Uyar, M. (2012). ST and LSSVR-based the fault location algorithm for the series compensated power transmission lines. *Energy Educ. Sci. Technol. Part A: Energy Sci. res.*, 30(1), pages 75–88.
- Yusuff, A.A., Fei, C., Jimoh, A.A. and Munda, J.L. (2011). Fault location in a series compensated transmission line based on wavelet packet decomposition and support vector regression. *Electric Power Systems Research*, volume 81, issue 7, pages 1258–1265.
- Yusuff, A.A., Jimoh, A.A. and Munda, J.L. (2014). Fault location in transmission lines based on stationary wavelet transform, determinant function feature and support vector regression. *Electric Power Systems Research*, volume 110, pages 73–83.