

Localização de Falhas em Redes VSC-HVDC por RNA e Coeficientes de Frequência Mel Cepstrais.

Guilherme A. Lopes Neto, Rui Bertho, Jr.
Hermes M. G. Castelo Branco

*Centro de Tecnologia, Universidade Federal do Piauí,
Teresina, Brasil, (e-mail: {guilhermelopes,rui.bertho}@ufpi.edu.br, hermesmanuel@gmail.com).*

Abstract: With the growth of direct current transmission systems, there is a need to propose and analyze efficient methods for fault location. This research aims to obtain and evaluate the performance of a fault location algorithm on a 200 km transmission line. The two terminal VSC-HVDC system was modeled on Simulink and the data was pre-processed with the Mel-Frequency Cepstral Coefficients (MFCC). Then, an Artificial Neural Network (ANN) was used to estimate the fault location. Several scenarios were simulated, varying the resistance and fault location along the line. The low error verified in the distance estimate demonstrates the high reliability of the method in locating the fault.

Resumo: Com o crescimento dos sistemas de transmissão de corrente contínua, é necessário propor e analisar métodos eficientes para localização de faltas. Esta pesquisa tem como objetivo obter e avaliar o desempenho de um algoritmo de localização de faltas em uma linha de transmissão de 200 km. O sistema VSC-HVDC de dois terminais foi modelado no Simulink e os dados foram pré-processados com os Coeficientes de Frequência Mel Cepstrais, do inglês *Mel-Frequency Cepstral Coefficients* (MFCC). Em seguida, uma Rede Neural Artificial (RNA) foi usada para estimar a localização da falta. Vários cenários foram simulados, variando a resistência e a localização da falta ao longo da linha. O baixo erro verificado na estimativa da distância demonstra a alta confiabilidade do método na localização da falta.

Keywords: Fault Location; HVDC; MFCC; Neural Networks; VSC.

Palavras-chaves: Localização de faltas; HVDC; MFCC; Redes Neurais; VSC.

1. INTRODUÇÃO

As linhas de transmissão de corrente contínua de alta tensão, do inglês *High Voltage Direct Current* (HVDC), já são amplamente utilizadas como uma solução eficiente para transmissão de energia em massa a longas distâncias, como o sistema HVDC do Rio Madeira no Brasil, que é um dos maiores do mundo, com uma distância de 2.375 km (ABB Ltd., 2018). Os sistemas HVDC têm várias vantagens sobre os sistemas CA. Por exemplo, a possibilidade de conectar redes assíncronas, como o caso Itaipu no Brasil, onde parte da energia é gerada a 50 Hz em Foz do Iguaçu, e depois retificada novamente e transmitida para Ibiúna, 810 km de distância, para ser convertida novamente em corrente alternada em 60 Hz (ITAIPU, 2015). Outra vantagem é a transmissão em cabos submarinos, situação em que a alta capacitância observada no sistema CA torna impraticável a transmissão em mais de 30 km. Assim, dependendo da distância, a transmissão de corrente contínua torna-se mais vantajosa (Kundur, 1994).

A localização de faltas nos sistemas HVDC ainda não é uma tecnologia estabelecida. O trabalho de Ashouri, Bak and Faria Da Silva (2018), traz uma revisão das metodologias usadas na proteção e localização de faltas para vários sistemas VSC-HVDC, onde os autores mencionam as vantagens e desvantagens de cada método aplicado. Mas, para entender

esses métodos e verificar quais são realmente eficazes, faz-se necessário aprofundar o estudo de como a falta comporta-se em uma linha HVDC. Junior *et al.* (2014) trazem um estudo detalhado sobre esse tópico, a fim de identificar componentes de frequências capazes de auxiliar os sistemas de proteção e/ou classificação de faltas, uma vez que essas frequências específicas sofrem alteração significativas entre a situação pré-falta e pós-falta.

Em Song *et al.* (2011) um algoritmo baseado em frequência natural foi desenvolvido para identificar e localizar faltas nos sistemas VSC-HVDC, demonstrando que esse método é simples e eficaz. Em Daisy, Dashti and Shaker (2017) um novo método de localização de faltas é proposto com base nas componentes DC de corrente e tensão sob o parâmetro de incerteza da linha, sendo que os resultados apontados confirmam que o método proposto também é eficiente. Em Vasanth, Yeap and Ukil (2017) uma Rede Neural Artificial (RNA) é aplicada para estimar a localização de faltas pelo polo, com o auxílio da Transformada Wavelet para extrair as informações dos sinais.

Assim, este artigo tem como objetivo elaborar um algoritmo baseado em Coeficientes de Frequência Mel Cepstrais, do inglês *Mel-Frequency Cepstral Coefficients* (MFCC) e Redes Neurais Artificiais para evidenciar as características do sinal que permitem uma localização com precisão de faltas em

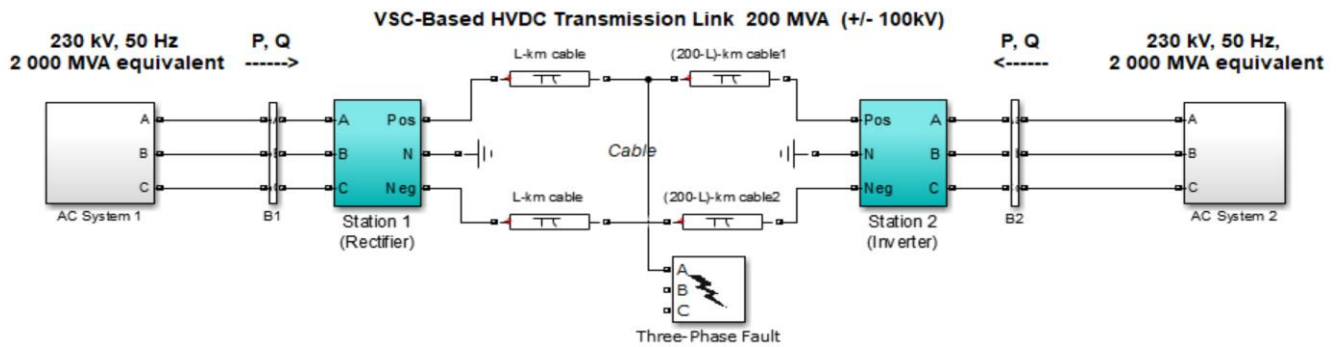


Fig. 1: Sistema HVDC utilizado nos testes.

sistemas VSC-HVDC. O sistema HVDC com dois terminais foi simulado no software Mathworks Simulink® com polo-terra. As oscilografias de falta são extraídas e, assim, calculado os vetores de características, os Coeficientes de Frequência Mel Cepstrais. As análises foram realizadas no software MATLAB.

O documento está organizado como segue-se. A seção 2 apresenta o sistema teste. Os conceitos de MFCC e da RNA foram introduzidos na seção 3 e 4, respectivamente. A metodologia usada e os resultados obtidos do processamento do sinal pela RNA são obtidos na seção 5 e 6. Finalmente, a conclusão é dada pela seção 7.

2. SISTEMA TESTE

Para realizar as simulações, foi utilizado o modelo VSC-HVDC disponível no software Mathworks Simulink®. Este sistema é composto por dois sistemas CA equivalentes com 230 KV, 50 Hz, 2000 MVA. O sistema CA é conectado por uma linha de transmissão HVDC de 20 km através de duas estações conversoras, como mostra a Fig. 1.

O modelo fornecido pelo MATLAB apresenta uma série de oscilações para demonstrar o potencial do sistema de controle. Antes de iniciar as simulações de faltas, é necessário modificar o sistema para eliminar intervenções no controle.

O sistema HVDC é composto por conversores baseados em IGBT de três níveis, operando a +/- 100 KVdc e potência nominal de 200 MVA (Casoria, no date). Os parâmetros da linha de transmissão são mostrados na Tabela 1.

Tabela 1. Parâmetros da linha de transmissão

Parâmetros de linha	Valores
Resistência por unidade de comprimento	$1,39 \cdot 10^{-2} \Omega/\text{km}$
Indutância por unidade de comprimento	$1,59 \cdot 10^{-4} \text{H}/\text{km}$
Capacitância por unidade de comprimento	$2,31 \cdot 10^{-7} \text{F}/\text{km}$
Comprimento da linha de transmissão	200 km
Números de seção Pi	4

3. FREQUÊNCIA MEL CEPSTRAIS

Um dos primeiros passos ao se realizar o processo de predição ou classificação de um determinado sinal, é a extração de características, ou seja, identificar componentes que representem as características do sinal, descartando informações que não são úteis como o ruído presente na maioria dos sinais digitais. Nesse intuito várias ferramentas de processamento de sinais e extração de características vem sendo propostas ao longo dos anos. Neste trabalho os vetores de características de entradas para estimar a distância de falta são Coeficientes de Frequência Mel Cepstrais obtidos dos sinais de corrente após a falta, os Coeficientes de Frequência Mel Cepstrais são amplamente utilizado no processamento de sinais de voz (Furui, 1989). Segundo Nelwamondo and Marwala (2006), os MFCC têm sido amplamente utilizado no campo do reconhecimento de fala por conseguir lidar com suas características dinâmicas à medida que extraem propriedades lineares e não lineares do sinal.

Além da aplicação em sinais de voz, sua utilização prática em outras áreas também é eficiente. Por exemplo, em Nelwamondo and Marwala (2006) foi proposta uma nova abordagem para detectar e classificar tipos de falhas nos rolamentos dos corpos rolantes. A proposta utilizou os Coeficientes de Frequência Mel Cepstrais (MFCC) como auxílio para extrair as informações de vibração do sinal do rolamento, demonstrando que esse método é eficaz. Neste trabalho é proposto, de forma inédita, a utilização de MFCC para localização de faltas em linhas de transmissão HVDC.

O MFCC é uma representação definida como o cepstrum de um sinal definido por uma janela. A diferença do cepstrum real está na utilização de uma escala de frequência não linear, por meio de filtros triangulares, que se aproxima do comportamento do sistema auditivo.

Assim, a ideia básica do MFCC é calcular uma análise de frequência baseada em um banco de filtros triangulares, também chamados de filtros triangulares mel, que possuem um espaçamento não linear, obedecendo a escala mel descrita em (1) (Nelwamondo and Marwala, 2006).

$$mel = 2595 \text{Log}_{10} \left[\left(1 + \frac{f(\text{Hz})}{700} \right) \right] \quad (1)$$

A função desses filtros é calcular o espectro médio em torno de cada frequência central com larguras de banda crescentes,

como ilustrado na Fig. 2. A seguir, apresenta-se o procedimento para extrair os MFCC (Furui, 1989):

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 de Fourier de Tempo Discreto 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 (TDC) sobre o sinal de energia final.




Fig. 2: Filtros triangulares mel.

Importa ressaltar que os coeficientes mais altos representam mudanças rápidas na energia do banco de filtros, trazendo informações relacionadas aos métodos baseados em componentes de alta frequência fundamental. Uma das vantagens da representação MFCC é que as energias de filtro são mais robustas aos erros de estimativa de ruído e espectral (Furui, 1989), o que pode ser útil para a aplicação pretendida neste trabalho. Para a aplicação proposta o espectro de frequências foi dividido em 20 coeficientes calculados sobre uma única janela de 0,0038 segundos, como pode ser verificado na Tabela 3 da seção 6.

4. REDES NEURAIS ARTIFICIAIS

Redes Neurais Artificiais (RNA) são técnicas computacionais que, inspiradas na estrutura neural de organismos inteligentes, podem adquirir conhecimento através da experiência (Braga, Carvalho and Ludermir, 2003). Essa característica faz da RNA uma poderosa ferramenta computacional no reconhecimento de padrões e tomada de decisão.

Assim, o modelo de rede neural usado foi o *Multilayer Perceptron* (MLP), no qual cada neurônio em uma camada está conectado a todos os neurônios na próxima camada (Silva and Spatti, 2010). Uma rede MLP deve ser treinada antes de poder ser aplicada para localizar as faltas. O algoritmo de treinamento utilizado foi a *backpropagation de Levenberg-Marquardt*, que é um algoritmo de *backpropagation* supervisionado, ou seja, o valor do peso na iteração atual será o valor do peso na iteração anterior, corrigido pelo valor proporcional ao gradiente (Leite, 2018).

A Fig. 3 ilustra as 4 camadas da RNA implementadas para prever a distância da falta. A primeira camada é a camada de entrada, contendo 20 entradas, as 2 camadas ocultas (10 neurônios na primeira e 2 neurônios na segunda) e 1 neurônio na saída.




Fig. 3: Estrutura da RNA implementada.

Os parâmetros de treinamento são mostrados na Tabela 2, 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).

Tabela 2. Parâmetros de treinamento.

Parâmetros de treinamento	Valores
Épocas	1000
RMSE	1×10^{-12}
MU inicial	0,001
Fator de diminuição MU	0,1
Fator de aumento MU	9

Destaca-se que durante os testes realizados foram utilizadas diferentes topologias, modificando-se a quantidade de coeficientes utilizados na entrada, números de camadas e de neurônios em cada camada. A topologia apresentada foi a que obteve melhores resultados.

5. METODOLOGIA E SIMULAÇÕES

Após modelar o sistema de teste VSC-HVDC, a falta foi aplicada ao polo positivo da linha de transmissão, entre fase e terra e os valores de corrente CC foram coletados no polo positivo do retificador. A Fig. 4 exemplifica o sinal de corrente medido para uma falta de 70 Ohm a 60 quilômetros do terminal do retificador.

Para criar o conjunto de dados da simulação, várias faltas do polo positivo para terra foram aplicadas. A resistência de falta foi simulada entre 50 a 150 Ohm, em incrementos de 5 Ohm, e a localização da falta de 5 a 195 km, em incrementos de 5 km, totalizando 819 casos de falta. Para cada simulação de falta, uma única janela de 0,0038 segundo com 515 amostras, ou seja, uma frequência de 135 kHz, que inclui o momento da falta, foi extraída, como exemplificado na Fig. 4.

Observe que, após o cálculo dos valores que correspondem aos MFCCs usando como retorno 20 coeficientes Cepstrais, todos os dados são normalizados. A normalização foi realizada para que os valores estejam compreendidos entre 0 e 1.

A metodologia proposta nesta pesquisa consiste no uso dos Coeficientes de Frequência Mel Cepstrais como entrada na Rede Neural Artificial, como pode ser visualizado pelo fluxograma de funcionamento na Fig. 5. O algoritmo foi desenvolvido no software MATLAB. Assim, espera-se que

com auxílio do MFCC, a características que identificam a distância da falta podem ser mais facilmente identificadas pela RNA.

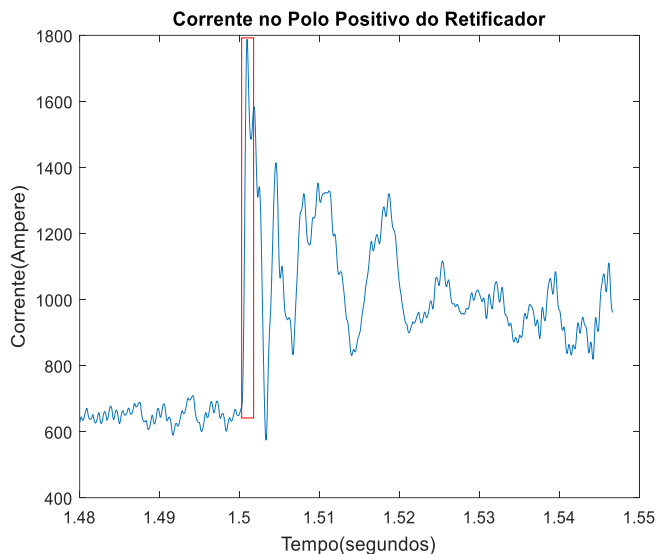


Fig. 4: Sinal de corrente para uma falta de 70 Ohm a 60 km do terminal do retificador.

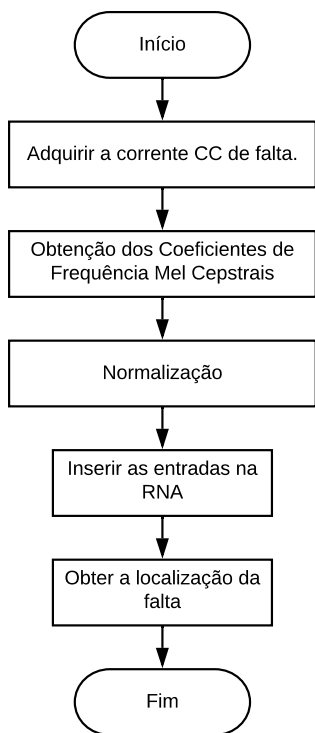


Fig. 5: Fluxograma de execução para estimar a localização.

A RNA usa 80% das simulações de faltas para treinamento. Nesta etapa, os pesos da Rede Neural são ajustados automaticamente em busca de um padrão para a associação correta entre os dados de entrada e a distância da falta. Após a fase de treinamento, 20% dos dados restantes são usados como dados de teste. Portanto, a diferença entre a distância simulada e a prevista é calculada para avaliar o desempenho do método proposto.

6. RESULTADOS E DISCUSSÃO

A RNA foi treinada fornecendo dados dos MFCCs para estimar a localização da falta na linha de transmissão de 200 km do sistema de teste. Os testes foram realizados com quantidades diferentes de números Cepstrais para verificar a melhor configuração. Posteriormente, a qualidade da Rede Neural foi avaliada usando a raiz quadrada do erro médio, do inglês *root-mean-square error* (RMSE), o desvio padrão dos dados de teste, como em (2) e (3). Note-se que os dados de testes não foram apresentados à RNA durante o treinamento.

$$RMSE = \sqrt{\sum_{i=1}^n \frac{(x'_i - x_i)^2}{n}} \quad (2)$$

$$DP = \sqrt{\frac{\sum (x'_i - x_i)^2}{n}} \quad (3)$$

Na qual x'_i é a distância prevista, x_i a distância simulada, e n o número de amostras. A Tabela 3 resume os parâmetros de teste estatístico para algumas configurações de Cepstrais diferentes.

Tabela 3. Erro da RNA para diferentes números Cepstrais.

Número de MFCCs	5	10	15	20
RMSE	3,5145 km	1,5384 km	0,5561 km	0,2161 km
Desvio Padrão	2,7690 km	1,1483 km	0,4914 km	0,1852 km

Verificou-se que quanto mais Cepstrais utilizados melhores resultados. A Fig. 6 mostra uma comparação dos valores previstos dos dados de teste em relação aos valores esperados, em quilômetros, utilizando 20 Cepstrais com o eixo x sendo o número do caso.

A Tabela 4 mostra o erro máximo e mínimo, bem como o RMSE, para algumas faixas de resistência dos dados de teste e de treinamento. Na Tabela 5 é possível verificar o erro de estimativa de acordo com a distância da falta

Tabela 4. Erro de estimativa devido à resistência a falta.

	Erro de estimativa		
	Mínimo	Máximo	Médio
50 Ω	0,0011 km	1,6901 km	0,1549 km
80 Ω	0,0016 km	0,2673 km	0,0613 km
120 Ω	4,35*10 ⁻⁴ km	0,2312 km	0,0607 km
150 Ω	0,0011 km	0,2055 km	0,0687 km

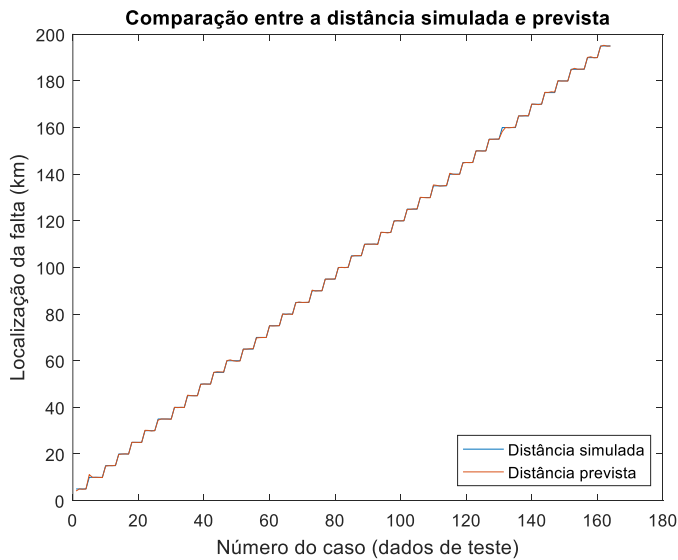


Fig. 6: Comparação entre a distância simulada e prevista da RNA.

Tabela 5. Erro de estimativa devido à localização a falta.

	Erro de estimativa		
	Mínimo	Máximo	Médio
5 km	0,0046 km	0,8673 km	0,0803 km
80 km	0,0045 km	0,1501 km	0,0647 km
150 km	$6,86 \cdot 10^{-4}$ km	0,1271 km	0,0448 km
195 km	0,0013 km	0,2837 km	0,0548 km

Na Tabela 6 apresenta-se uma comparação com o Erro Médio Relativo (EMR) e o Erro Máximo (EMáx) obtidos por outras metodologias presentes na literatura para faltas fase-terra. Cabe destacar que cada metodologia apresenta uma extração de característica e um método para localização. O erro médio relativo é obtido por meio de (4).

$$EMR = \frac{x'_i - x_i}{L} * 100\% \quad (4)$$

Na qual L é o tamanho da linha de transmissão utilizada na simulação, no caso 200 km.

Observa-se que, a resposta da RNA é consistente em toda linha de transmissão e não apenas em faixas específicas. Como também, pela Tabela 6 percebe-se que esta metodologia é válida e apresenta resultados um erro relativo menor em relação a outras metodologias adotadas na literatura.

7. CONCLUSÕES

Neste trabalho, os Coeficientes de Frequência Mel Cepstrais da corrente de falta foram extraídos e utilizados como entradas em uma RNA. Com isto, foi possível evidenciar características relevantes para a localização da falta, garantindo sua correta estimação pela RNA.

Tabela 6. Comparação dos resultados com outras metodologias.

Metodologia	Extração de Carac.	Método	EMR (%)	EMáx (%)
(Vasanth, Yeap and Ukil, 2017) ¹	TWD	RNA	2,27	- ²
(Daisy, Dashti and Shaker, 2017)	FFT	Transiente Derivativos	- ²	0,12
(Yang <i>et al.</i> , 2017)	FFT	Análise do espectro de frequência	0,31	0,62
Modelo Proposto	MFCC	RNA	0,11	0,85

¹O artigo apresenta somente dados de faltas fase-fase.

²O artigo não apresenta essa informação.

Observou-se que a metodologia de localização de faltas por Rede Neural Artificial com auxílio dos MFCCs apresentou resultados bastantes satisfatórios, como pode ser visto pelo baixo erro dos dados de treinamento e teste. Também é digno de nota que o estudo possa ser expandido para redes multiterminais, nas quais a influência de outros terminais tende a dificultar a localização da falta.

AGRADECIMENTOS

Os autores gostariam de agradecer o apoio financeiro recebido do Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) e da Universidade Federal do Piauí (UFPI). Bem como à Liga Acadêmica de Sistemas Inteligentes (LASI) pelo apoio teórico.

REFERÊNCIAS

- ABB Ltd. (2018) *References / ABB*. Available at: <https://new.abb.com/systems/hvdc/references/rio-madeira> (Accessed: 15 February 2020).
- Ashouri, M., Bak, C. L. and Faria Da Silva, F. (2018) 'A review of the protection algorithms for multi-terminal VCD-HVDC grids', *Proceedings of the IEEE International Conference on Industrial Technology*, 2018-Febru(February), pp. 1673–1678. doi: 10.1109/ICIT.2018.8352433.
- Braga, A., Carvalho, A. and Ludermir, T. (2003) *Redes neurais artificiais, Sistemas Inteligentes: Fundamentos e Aplicações*. Available at: <https://sites.icmc.usp.br/andre/research/neural/> (Accessed: 4 May 2020).
- Casoria, S. (no date) *VSC-Based HVDC Transmission System (Detailed Model) - MATLAB & Simulink*. Available at: <https://www.mathworks.com/help/physmod/sps/example/s/vsc-based-hvdc-transmission-system-detailed->

model.html (Accessed: 16 February 2020).

- Daisy, M., Dashti, R. and Shaker, H. R. (2017) 'A new fault-location method for HVDC transmission-line based on DC components of voltage and current under line parameter uncertainty', *Electrical Engineering*. Springer Berlin Heidelberg, 99(2), pp. 573–582. doi: 10.1007/s00202-016-0384-3.
- Furui, S. (1989) *Digital Speech Processing: Synthesis, and Recognition*. Edited by M. Dekker.
- ITAIPU (2015) *Integração ao sistema brasileiro | ITAIPU BINACIONAL*. Available at: <https://www.itaipu.gov.br/energia/integracao-ao-sistema-brasileiro> (Accessed: 15 February 2020).
- Junior, R. B. *et al.* (2014) 'Análise espectral das tensões e correntes durante a ocorrência de faltas em uma linha HVDC', *XX Congresso Brasileiro de Automática*, pp. 684–691.
- Kundur, P. (1994) *Power System Stability And Control*. 7th edn.
- Leite, T. M. (2018) *Redes Neurais, Perceptron Multicamadas e o Algoritmo Backpropagation*. Available at: <https://medium.com/ensina-ai/redes-neurais-perceptron-multicamadas-e-o-algoritmo-backpropagation-eaf89778f5b8> (Accessed: 4 May 2020).
- Nelwamondo, F. V. and Marwala, T. (2006) 'Faults detection using Gaussian mixture models, mel-frequency cepstral coefficients and kurtosis', *Conference Proceedings - IEEE International Conference on Systems, Man and Cybernetics*, 1(April 2015), pp. 290–295. doi: 10.1109/ICSMC.2006.384397.
- Silva, I. N. da and Spatti, D. H. (2010) *Redes Neurais Artificiais curso pratico*. 1st edn. Artliber.
- Song, G. B. *et al.* (2011) 'Natural frequency based protection and fault location for VSC-HVDC transmission lines', *APAP 2011 - Proceedings: 2011 International Conference on Advanced Power System Automation and Protection*, 1, pp. 177–182. doi: 10.1109/APAP.2011.6180405.
- Vasanth, S., Yeap, Y. M. and Ukil, A. (2017) 'Fault location estimation for VSC-HVDC system using Artificial Neural Network', *IEEE Region 10 Annual International Conference, Proceedings/TENCON*, (November), pp. 501–504. doi: 10.1109/TENCON.2016.7848050.
- Yang, Q. *et al.* (2017) 'A Novel Fault Detection and Fault Location Method for VSC-HVDC Links Based on Gap Frequency Spectrum Analysis', *Energy Procedia*. Elsevier B.V., 142, pp. 2243–2249. doi: 10.1016/j.egypro.2017.12.625.