

Localização de Falhas em Linhas de Transmissão de Energia Elétrica Utilizando as Redes Neurais Recorrentes LSTM e GRU

Patrick E. M. Karvat¹, Eduardo C. Almeida¹, Leandro A. Ensina¹,
Luiz E. S. Oliveira¹, Signie L. F. Santos², Leandro S. Bernardino³

¹Universidade Federal do Paraná – Curitiba – PR – Brazil

²Instituto de Tecnologia Para o Desenvolvimento – Curitiba – PR – Brazil

³Companhia Paranaense de Energia – Curitiba – PR – Brazil

patrickkarvat.pk@ufpr.br, eduardo.almeida@ufpr.br

Abstract. *Transmission lines demand constant attention from the electric power system's protection mechanisms since the occurrence of faults can lead to the unavailability of the electric energy supply. Therefore, this paper presents a method based on recurrent neural networks (LSTM and GRU) for fault location in transmission lines, using data from two post-fault cycles of current and voltage signals for a single terminal. The results demonstrate the effectiveness of the proposed method, with better performance in LSTM, with an average error of $0.1168 \text{ km} \pm 0.5193 \text{ km}$, equivalent to $0.0282\% \pm 0.1254\%$ of the line's extension.*

Resumo. *As linhas de transmissão demandam de atenção especial dos mecanismos de proteção do sistema elétrico de potência, visto que a ocorrência de faltas pode acarretar na indisponibilidade do fornecimento de energia elétrica. Frente a isso, o presente trabalho apresenta um método baseado em redes neurais recorrentes (LSTM e GRU) para a localização de faltas em linhas de transmissão, utilizando dados de dois ciclos pós-falta dos sinais de corrente e tensão para um único terminal. Os resultados demonstram a efetividade do método proposto, com melhor desempenho para a LSTM, com erro médio de $0,1168 \text{ km} \pm 0,5193 \text{ km}$, equivalente a $0,0282\% \pm 0,1254\%$ da extensão da linha.*

1. Introdução

O Sistema Elétrico de Potência (SEP) é uma estrutura complexa que engloba todo o conjunto de instalações e equipamentos que realizam a geração, a transmissão e a distribuição de energia elétrica [Bichels 2018]. Neste cenário, as linhas de transmissão destacam-se como elementos fundamentais do SEP, realizando a interligação entre a produção de energia e o consumidor final, como indústrias e residências. Entretanto, estes elementos demandam de atenção especial devido a sua constante exposição a situações e agentes externos que podem impactar negativamente em seu funcionamento, como tempestades e contato das linhas com a vegetação [Singh and Vishwakarma 2015].

Essas perturbações ocasionam em faltas, que podem interromper o fornecimento de energia de modo temporário ou permanente. Uma falta pode ser definida como um

fluxo anormal das grandezas elétricas, como tensão e corrente, nos componentes do SEP [Yadav and Dash 2014]. Assim sendo, uma falha pode afetar uma ou mais fases (usualmente identificadas pelas letras A, B e C), envolvendo ou não o aterramento (G).

Devido à presença indispensável da energia elétrica nos centros urbanos, industriais e rurais, surge a necessidade do monitoramento e correção de falhas que ocorram nas linhas de transmissão, de modo a garantir a disponibilidade contínua e com qualidade de energia elétrica para os usuários. Frente a isso, o sistema de proteção presente nas subestações visa garantir a estabilidade da rede e minimizar qualquer dano causado por essas falhas. Uma das principais informações que essa proteção pode fornecer aos operadores corresponde à provável localização desta falta na linha de transmissão, de modo que uma equipe de manutenção possa ser encaminhada para realizar os reparos necessários.

Neste cenário, diversas abordagens são encontradas na literatura especializada para a localização de falhas. Porém, grande parte destes métodos exigem dados, como tensão e corrente, de ambos os terminais da linha simultaneamente [Chen et al. 2018, Zhang et al. 2020, Belagoune et al. 2021], os quais necessitariam ainda de sincronização a partir de alguma outra técnica. Tais aspectos podem inviabilizá-los pois não é garantido que os dados de ambas as extremidades da linha estejam disponíveis.

O presente trabalho apresenta um método para a localização de falhas em linhas de transmissão, utilizando dois ciclos pós-falta para cada uma das três fases dos sinais da corrente e da tensão para um único terminal da linha. Esses dados segmentados e padronizados pela técnica *Z-Score*, foram utilizados como entrada para dois modelos baseados em redes neurais recorrentes, *Long Short-Term Memory* (LSTM) e *Gated Recurrent Unit* (GRU), de modo a determinar a melhor configuração para o método proposto. As principais contribuições deste trabalho são um método para localização de falhas empregando dados de um único terminal e sem a necessidade de uma engenharia de atributos explícita.

2. Base de Dados

A *Fault Analysis Database* (FADb) [Ensina 2021] é uma base pública composta por simulações de faltas em uma rede de alta tensão baseada no sistema elétrico de nove barramentos da IEEE. A linha de transmissão avaliada se assemelha aos parâmetros da linha mais longa da Companhia Paranaense de Energia (Copel), com 414 km de extensão, 500 kV de tensão e frequência de 60 Hz.

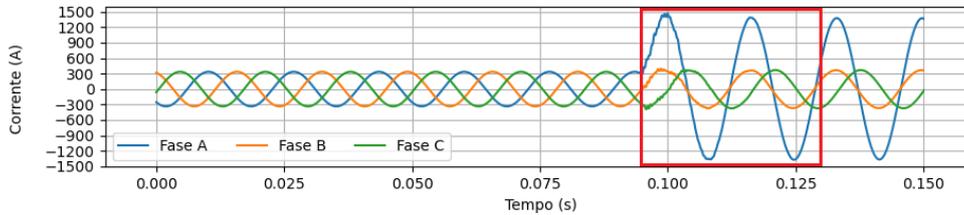
A base é constituída por 168.000 simulações com taxa de amostragem de 10 kHz, armazenando dados (oscilografias) de corrente e tensão para cada uma das três fases para ambos os terminais da linha. Todas as simulações iniciam sem a presença de falta, sendo uma falha inserida em instantes distintos entre as simulações de modo a representar a incerteza do momento em que ela inicia. Os parâmetros de falta considerados foram:

- Tipo: AG, BG, CG, AB, AC, BC, ABG, ACG, BCG, ABC;
- Localização: 1 a 100% da extensão da linha em intervalos de 1%;
- Resistência: 0,01 a 200 Ω , com intervalos de 10 Ω ;
- Início da falha: 0,091 s, 0,093 s, 0,095 s, 0,097 s, 0,099 s, 0,101 s, 0,103 s, 0,105 s.

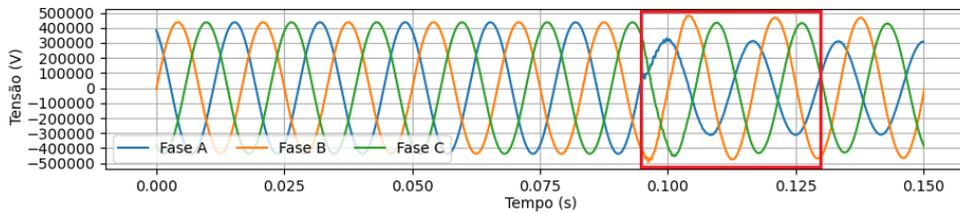
As letras A, B e C representam cada uma das três fases da linha de transmissão, enquanto a letra G corresponde ao terra. Portanto, as iniciais AG indicam uma falta envolvendo a fase A e o terra, enquanto AB representa uma falta entre as fases A e B, sem a ação do aterramento.

3. Método Proposto

A primeira etapa do método corresponde à extração dos dados a serem utilizados das oscilografias da base de dados. Em vista disso, foram extraídos apenas os dois primeiros ciclos pós-falta das formas de onda da corrente e da tensão, conforme destacado na Figura 1.



(a) Sinal da corrente.



(b) Sinal da tensão.

Figura 1: Exemplo de uma falta do tipo AG, na qual estão destacados dois ciclos pós-falta dos sinais de (a) corrente e (b) tensão.

Em seguida, foi aplicada a padronização nestes dados extraídos por meio da técnica *Z-Score*, definida na Equação 1, em que Z_i representa o valor padronizado de X_i no instante i , enquanto \bar{X} e σ representam a média e o desvio padrão, respectivamente, para um conjunto de valores X . Tal procedimento foi realizado separadamente entre os conjuntos de treinamento, validação e teste, conforme será explicado na Seção 4.

$$Z_i = \frac{X_i - \bar{X}}{\sigma} \quad (1)$$

O espaço de entrada consiste de uma matriz de dimensão 6×334 , sendo que cada linha representa os valores individuais para cada fase (A, B e C), iniciando pela corrente e, em seguida, pela tensão, nesta respectiva ordem. Por sua vez, o conteúdo de cada coluna são os valores dos dois ciclos pós-falta (334 valores) após a padronização.

3.1. Experimentos

Para o método proposto, foram desenvolvidos dois modelos baseados em redes neurais recorrentes: LSTM e GRU. Esses algoritmos foram escolhidos devido a sua capacidade de lidar com relações temporais complexas, com dependências sequenciais entre os atributos [Hochreiter and Schmidhuber 1997, Cho et al. 2014], característica inerente aos dados de tensão e corrente. A arquitetura para o modelo LSTM pode ser observada na Tabela 1. Para o modelo GRU, podem ser considerados os mesmos valores para os parâmetros, substituindo (na coluna camada) o algoritmo LSTM por GRU.

Tabela 1: Definição das camadas que compõe o modelo. O valor LSTM na coluna camada é substituído por GRU para obter a rede correspondente.

Camada	Unidades	Retornar sequências	Formato da entrada
LSTM	1000	True	(6, 334)
LSTM	1000	True	-
LSTM	1000	False	-
Dense	1	-	-

Para os treinamentos utilizou-se o otimizador Adam, a métrica *Mean Squared Error* (MSE), a taxa de aprendizagem de 0,001, e para o *batch size* o valor de 1680. É digno de nota que tais valores de parâmetros foram estabelecidos empiricamente, conforme será discutido na Seção 4. A saída do modelo é um valor entre [0, 1], representando a porcentagem da extensão da linha na qual houve a incidência da falta. Esse valor é convertido para a distância em quilômetros (km) pela Equação 2.

$$dist_{km} = LT_{comprimento} * dist_{pred} \quad (2)$$

sendo $dist_{km}$ a localização da falta em km, $LT_{comprimento}$ o comprimento da linha de transmissão (414 km na base FADb - Seção 2), e $dist_{pred}$ a saída predita pelo modelo.

A base de dados FADb foi aleatoriamente dividida em três conjuntos sem interseção entre os exemplos (simulações), utilizados como treinamento, teste e validação. O conjunto de treinamento equivale a 60% dos registros da base original (100.800 simulações), enquanto as bases de validação e teste correspondem a 20% cada (33.600 simulações). Conforme citado previamente, cada conjunto de dados foi tratado separadamente para evitar que as características das bases de validação e teste influenciassem na padronização do conjunto de treinamento [Brownlee 2020].

4. Resultados e Discussão

Os experimentos realizados compreenderam os sinais da corrente e da tensão em conjunto, visto que as avaliações com o uso individualizado destes sinais demonstraram desempenhos inferiores. Portanto, apesar do sinal da corrente prover maior poder de informação sobre faltas [Yadav and Dash 2014], foi necessária a incorporação da forma de onda da tensão para resultados mais precisos. De modo similar ocorreu para a determinação do uso de dois ciclos pós-falta, uma vez que uma menor quantidade de dados repercutiu em um pior desempenho, enquanto o uso de mais dados não revelou melhoria nos resultados.

Ainda, os dados das simulações foram separados em três conjuntos sem interseção – treino, validação e teste – e padronizados utilizando a técnica *Z-Score*, cuja finalidade é garantir que os dados utilizados estejam em uma mesma ordem de grandeza, evitando assim possíveis enviesamentos que possam ser causados pela presença de valores muito discrepantes. É importante ressaltar que a padronização foi realizada após a separação dos dados para evitar o fenômeno conhecido como *Data Leakage*, ou seja, evitar que as características dos dados de teste, por exemplo, influenciem a padronização do conjunto de treinamento e, conseqüentemente, vazem suas informações para o treinamento dos modelos [Brownlee 2020]. Desse modo, garantindo que os exemplos das

bases de validação e teste nunca tenham sido vistos pelo modelo, direta ou indiretamente, durante seu treinamento, aspecto que poderia comprometer os resultados e superestimar os desempenhos dos modelos [Kaufman et al. 2012].

Foram utilizados dados de um único terminal da linha de transmissão para evitar a necessidade de sincronização de dados entre as extremidades da linha. Este é um aspecto crucial pois a disponibilidade de dados de ambos os terminais simultaneamente não é garantida, o que pode comprometer a usabilidade de um método que requer dados de ambas as extremidades [Chen et al. 2018, Zhang et al. 2020, Belagoune et al. 2021]. É digno de nota que esta particularidade é uma das principais contribuições deste trabalho frente aos métodos presentes na literatura.

As arquiteturas dos modelos gerados para este trabalho foram alcançadas por experimentos empíricos sobre a base de validação, a partir de inúmeras combinações de topologias e valores de parâmetros. Inicialmente foram utilizados modelos com um número reduzido de camadas e neurônios que foram incrementados gradualmente, buscando minimizar o erro obtido durante o treinamento. O parâmetro *batch_size* também precisou ser incrementado gradualmente, devido a sua influência na precisão com a qual o modelo realiza as suas predições [Radiuk 2017]. Como resultado destes experimentos, foi obtida a arquitetura descrita na Seção 3.1.

Na Tabela 2 estão dispostos os resultados obtidos pelos modelos considerando o conjunto de teste, os quais foram discretizados em dez partições para cada seção da extensão da linha de transmissão, bem como o desempenho geral. A maior incidência de erros está presente nas seções próximas às extremidades da linha de transmissão. Esse comportamento já foi observado previamente na literatura [Ray and Mishra 2016], porém ainda não foram determinadas justificativas conclusivas a respeito de suas causas.

Tabela 2: Comparativo entre os erros – em quilômetros – resultantes da aplicação da base de testes sobre os modelos desenvolvidos.

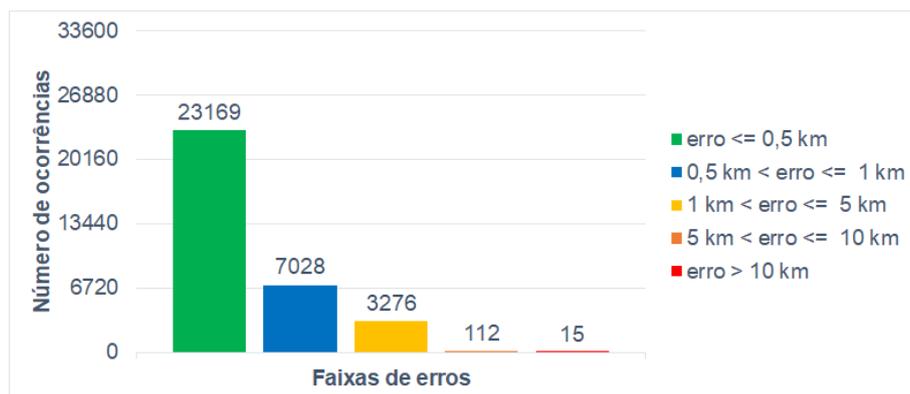
Partições		Erro médio		Erro máximo	
Início	Fim	LSTM	GRU	LSTM	GRU
4,14	41,4	0,2789 ± 1,5628	0,6510 ± 3,1659	58,3243	172,2753
41,4	82,8	0,0813 ± 0,1163	0,3551 ± 0,3334	2,1907	3,9564
82,8	124,2	0,0645 ± 0,0577	0,3095 ± 0,2720	0,7758	3,3565
124,2	165,6	0,0689 ± 0,0712	0,3437 ± 0,3245	2,2535	7,9291
165,6	207,0	0,0648 ± 0,0550	0,3477 ± 0,3065	0,4701	3,3154
207,0	248,4	0,0683 ± 0,0629	0,3438 ± 0,3331	1,1345	4,4586
248,4	289,8	0,0878 ± 0,1313	0,4374 ± 0,7444	4,0310	22,9337
289,8	331,2	0,1084 ± 0,1235	0,4818 ± 0,5448	1,5035	10,6987
331,2	372,6	0,1735 ± 0,2676	0,7195 ± 0,8803	4,1163	10,9601
372,6	414,0	0,1552 ± 0,3029	1,0077 ± 1,2996	5,9568	24,7245
TOTAL		0,1168 ± 0,5193	0,5000 ± 1,1870	58,3243	172,2753

Apesar dos elevados erros máximos dos modelos, eles podem ser considerados *outliers*, visto que os erros superiores a 10 km para a LSTM representam apenas 10 ocorrências, enquanto para a GRU são 15 de um total de 33.600 eventos de falha no conjunto de teste, equivalente a apenas cerca de 0,03% e 0,04%, respectivamente. Essas

análises podem ser observadas nos histogramas da Figura 2. A maioria dos erros é menor ou igual a 0,5 km e correspondem a 97,65% (LSTM) e 68,96% (GRU) de todos os exemplos de teste. Com isso, é possível observar que o modelo LSTM apresenta resultados superiores aos da GRU, de modo que pode ser considerado o modelo mais indicado em nosso método para a localização de faltas.



(a) LSTM.



(b) GRU.

Figura 2: Histograma de erros – em km – utilizando os modelos (a) LSTM e (b) GRU.

5. Conclusão

Este trabalho apresentou um método para localização de faltas em linhas de transmissão, utilizando amostras de sinais de corrente e tensão para uma única extremidade da linha sem a necessidade de uma engenharia de características explícita por um especialista do domínio. O método proposto foi avaliado com falhas para todos os pontos da linha de transmissão considerando os algoritmos LSTM e GRU, determinando melhor desempenho para a LSTM com erro médio de $0,1168 \text{ km} \pm 0,5193 \text{ km}$ ($0,0282\% \pm 0,1254\%$). Assim, os resultados corroboram que o método proposto atende ao nosso objetivo.

Trabalhos futuros incluem (1) o refinamento do método para localizar com precisão as faltas próximas aos terminais, como combinar vários modelos; (2) a avaliação do método utilizando taxas de amostragem inferiores a 10 kHz; e (3) a avaliação com eventos de falhas reais. Pretende-se também (4) avaliar a competência do método para generalização, ou seja, utilizar o modelo para prever a distância da falta para uma linha de transmissão diferente daquela para a qual foi treinado.

Referências

- Belagoune, S., Bali, N., Bakdi, A., Baadji, B., and Atif, K. (2021). Deep learning through lstm classification and regression for transmission line fault detection, diagnosis and location in large-scale multi-machine power systems. *Measurement*, 177:109330.
- Bichels, A. (2018). *Sistemas Eletricos de Potência - Métodos de Análise e Solução*. EDUTFPR.
- Brownlee, J. (2020). *Data Preparation for Machine Learning: Data Cleaning, Feature Selection, and Data Transforms in Python*, pages 25 – 36. Machine Learning Mastery.
- Chen, Y. Q., Fink, O., and Sansavini, G. (2018). Combined fault location and classification for power transmission lines fault diagnosis with integrated feature extraction. *IEEE Transactions on Industrial Electronics*, 65(1):561–569.
- Cho, K., van Merriënboer, B., Bahdanau, D., and Bengio, Y. (2014). On the properties of neural machine translation: Encoder-decoder approaches. *CoRR*, abs/1409.1259.
- Ensina, L. A. (2021). Fault analysis database. <https://1drv.ms/u/s!ArMEeMx4MYDNimHVxiDx3b4CI3iL?e=8GfXg7>. Acessado em 30/12/2021.
- Hochreiter, S. and Schmidhuber, J. (1997). Long short-term memory. *Neural Computation*, 9(8):1735–1780.
- Kaufman, S., Rosset, S., Perlich, C., and Stitelman, O. (2012). Leakage in data mining: Formulation, detection, and avoidance. *ACM Trans. Knowl. Discov. Data*, 6(4).
- Radiuk, P. (2017). Impact of training set batch size on the performance of convolutional neural networks for diverse datasets. *Information Technology and Management Science*, 20:20–24.
- Ray, P. and Mishra, D. P. (2016). Support vector machine based fault classification and location of a long transmission line. *Engineering Science and Technology, an International Journal*, 19(3):1368–1380.
- Singh, S. and Vishwakarma, D. N. (2015). Intelligent techniques for fault diagnosis in transmission lines — an overview. In *International Conference on Recent Developments in Control, Automation and Power Engineering (RDCAPE)*, pages 280–285.
- Yadav, A. and Dash, Y. (2014). An overview of transmission line protection by artificial neural network: Fault detection, fault classification, fault location, and fault direction discrimination. *Advances in Artificial Neural Systems*, 2014:1–20.
- Zhang, F., Liu, Q., Liu, Y., Tong, N., Chen, S., and Zhang, C. (2020). Novel fault location method for power systems based on attention mechanism and double structure gru neural network. *IEEE Access*, 8:75237–75248.