

PROPOSTA DE ALGORITMOS INTELIGENTES PARA PROTEÇÃO DE SISTEMAS HVDC-MULTITERMINAIS

JULIO ARITA TORRES, RICARDO CANELOI DOS SANTOS, EDMARCIO ANTONIO BELATI E PATRÍCIA TEIXEIRA LEITE*

* *Centro de Engenharia, Modelagem e Ciências Sociais Aplicadas
Universidade Federal do ABC
Santo André, São Paulo, Brasil*

Email: julio.arita@ufabc.edu.br, ricardo.santos@ufabc.edu.br,
patricia.leite@ufabc.edu.br, edmarcio.belati@ufabc.edu.br

Abstract— This work presents a protection scheme based on Artificial Neural Networks (ANNs) for fault detection and location in Multi Terminal Direct Current (MTDC) systems. To perform these tasks only local signals are used and communication links are not required. Two different schemes based on ANN are evaluated (DC current samples and DC current wavelet coefficients), allowing a comparison between the advantages and disadvantages of each one. The proposed method has been tested for different fault locations and fault resistances in a four terminal MTDC system with three DC lines. The adopted MTDC system was modeled in ATP-Draw, while the proposed algorithm was developed in Matlab. The results show that the proposed scheme is able to properly detect and locate a fault within a few milliseconds.

Keywords— HVDC systems, MTDC protection, Artificial Neural Networks, Discrete Wavelet Transform, Digital relay.

Resumo— Este trabalho apresenta um esquema de proteção baseado em Redes Neurais Artificiais (RNAs) para detecção e localização de faltas em sistemas de transmissão de corrente contínua multiterminais (MTDC). Para executar essas tarefas apenas sinais locais são utilizados e não são necessários links de comunicação. Dois esquemas diferentes baseados em RNAs são avaliados (amostras da corrente DC e coeficientes de wavelet da corrente DC), permitindo uma comparação entre as vantagens e desvantagens de cada um. O método proposto foi testado para diferentes locais de falta e diferentes resistências de falta num sistema MTDC de quatro terminais e três linhas DC. O sistema MTDC adotado foi modelado no ATP-Draw, enquanto o algoritmo proposto foi desenvolvido no Matlab. Os resultados mostram que o esquema proposto é capaz de detectar e localizar corretamente uma falta dentro de alguns milissegundos.

Palavras-chave— Sistemas HVDC, Proteção MTDC, Redes Neurais Artificiais, Transformada Discreta de Wavelet, Relé Digital.

1 Introdução

Normalmente, os melhores lugares para a exploração de fontes de energia estão localizados fora dos grandes centros. Nesse sentido, a transmissão DC é atrativa para a exploração destas fontes de energia, pois especialmente nos casos onde a energia precisa ser transportada através de longas distâncias, os sistemas HVDC (*High Voltage Direct Current*) apresentam muitas vantagens sobre os sistemas HVAC (*High Voltage Alternating Current*). A integração de fontes renováveis também considera o uso de sistemas HVDC, por exemplo, para a conexão na rede elétrica de fazendas eólicas e sistemas solares. Atualmente, a integração de vários sistemas de geração é possível mediante a utilização dos sistemas multiterminais HVDC (MTDC), baseados em conversores VSC (*Voltage Source Converter*). O desenvolvimento das redes MTDC baseadas em conversores VSC é comprometido pela falta de experiência operacional, falta de dispositivos de proteção apropriados, além da falta de técnicas apropriadas de análises de faltas. Os sistemas VSC-HVDC são vulneráveis à faltas entre polos e entre polo e terra, provocando altas correntes em virtude da descarga do capacitor

presente no elo DC (Kontos et al., 2015a; Pfeiffer et al., 2013; Rafferty et al., 2014). Um dos grandes desafios dos sistemas HVDC é o elevado valor que as correntes de falta podem atingir, chegando a ordem de 24 pu (Kontos et al., 2015b). Dessa forma, muitos estudos têm sido conduzidos para o desenvolvimento de esquemas de proteção mais eficientes para os sistemas MTDC (Li et al., 2016; Johannesson and Norrga, 2016; Abu-Elanien et al., 2016; Ikhida and Tennakoon, 2015).

A Transformada Discreta de Wavelet (TDW) tem demonstrado ser uma ferramenta poderosa para a análise de transitórios nos sistemas AC (*Alternating Current*) (Lima et al., 2012; Mahela et al., 2015; Sharma et al., 2016; Kamble, 2014), com resultados significativos na área de proteção de sistemas elétricos de potência (Silva et al., 2006; Oliveira and Bretas, 2009; Rajeswari and Kamaraj, 2007). No entanto, este não é o caso dos sistemas HVDC, que ainda requerem estudos para a consolidação de técnicas de proteção. As ferramentas baseadas em inteligência artificial têm demonstrado robustez frente à problemas de proteção nos sistemas HVAC e HVDC. Nessa linha, Ramesh (2012) faz uma revisão geral das aplicações de inteligência artificial na detecção de fal-

tas em sistemas HVDC. Nesse trabalho, os autores ressaltam as características das RNAs para reconhecer padrões e regiões complexas, além de discutirem sistemas Neuro-Fuzzy que tem características melhoradas, como o fato de não precisarem de dados exatos para seu preciso funcionamento. Em Bawane (2003), os autores utilizam RNAs para a detecção de faltas em um sistema HVDC, utilizando como parâmetro o comportamento dos dispositivos de chaveamento dos conversores. Finalmente, em Santos (2016) e Santos (2018) os autores desenvolvem algoritmos baseados em RNAs para a proteção completa de sistemas HVDC. Nesses trabalhos, somente os dados da subestação retificadora são utilizados, sendo os sistemas de proteção capazes de cobrir defeitos nos lados AC e DC dos sistemas HVDC.

A grande dificuldade na implementação dos sistemas MTDC ainda reside na limitação dos dispositivos seccionadores, visto que neste caso a corrente de falta sobe abruptamente e não tem passagem por zero. Assim, torna-se difícil isolar somente a porção faltosa do sistema (Pfeiffer et al., 2013; Mokhberdorran et al., 2016).

Na tentativa de contribuir para um esquema de proteção rápido e preciso, este trabalho apresenta e compara dois diferentes algoritmos baseados em RNAs para detecção e localização de faltas em sistemas MTDC. O primeiro esquema faz uso somente das amostras das correntes DC para alimentar duas RNAs, sendo uma para a detecção da falta e outra para a sua localização. Já o segundo esquema, realiza um pré-processamento (TDW - Transformada Discreta Wavelet) dessa corrente DC, alimentando as RNAs para detecção e localização de falta com os coeficientes de aproximação e detalhe de wavelet.

2 Sistema Elétrico Adotado

Os sistemas MTDC de grande porte, caracterizados por varias subestações conversoras, não são comuns (Yang et al., 2012; Le Blond et al., 2016). Para este trabalho o sistema elétrico adotado para o estudo é composto por um sistema de transmissão de quatro terminais (4 fontes) e três linhas. As linhas são modeladas com o modelo JMarti (parâmetros dependentes da frequência), sendo linhas de transmissão monopolares com retorno pela terra. As fontes têm níveis de tensão de 500kV. O sistema adotado é representado na Figura 1, onde *A*, *B*, *C*, *D*, *E* e *F* representam os disjuntores DC. O primeiro trecho de linha possui 650km, o segundo trecho possui 530km e o terceiro trecho possui 370km. Todos os demais parâmetros do modelo adotado podem ser encontrados em Le Blond (2014).

Neste trabalho é admitido que, na ocorrência de uma falta, todos os terminais (inversores ou retificadores) se comportam como alimenta-

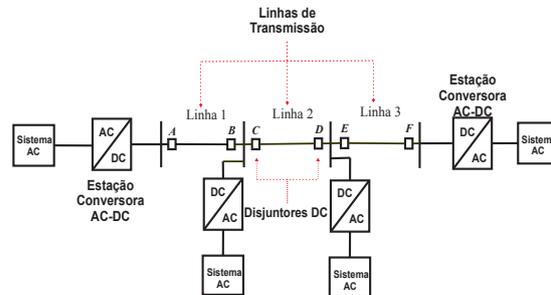


Figura 1: Sistema Elétrico Adotado.

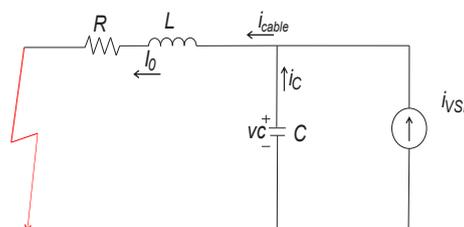


Figura 2: Circuito equivalente de uma subestação VSC sob falta.

dores da corrente de falta, uma vez que os diodos ligados em antiparalelo nos IGBTs (*Insulated Gate Bipolar Transistor*) conduzem e o sistema de controle não atua nos IGBTs (Abu-Elanien et al., 2016; Ikhida and Tennakoon, 2015; Yang et al., 2012; Le Blond and Burgin, 2014; Le Blond et al., 2016). A Figura 2 mostra o circuito equivalente de uma subestação VSC durante a ocorrência de uma falta na linha DC. Onde R , L e C representam os parâmetros de resistência, indutância e capacitância da linha de transmissão, respectivamente. A corrente i_{VSI} representa a contribuição da corrente de falta fornecida pelo sistema AC, a corrente i_C representa a contribuição da corrente de falta fornecida pela descarga do capacitor e a corrente I_0 representa o valor total da corrente de falta no cabo (Le Blond et al., 2016).

O sistema da Figura 1 foi modelado no ATP (*Alternative Transients Program*), sendo as situações de falta caracterizadas por curtos circuitos em diferentes pontos de todas as linhas DC e com diferentes valores de resistência de falta. Para o desenvolvimento do algoritmo proposto foi utilizado o *software* Matlab e os *toolboxes* de RNAs e processamento de sinais

3 Algoritmo Proposto

A parte principal do algoritmo proposto é composta pelas RNAs para detecção e localização de faltas. O trabalho propõe duas versões distintas do algoritmo, permitindo decidir sobre o esquema mais adequado para proteger o sistema MTDC adotado. Assim, a estrutura interna principal do algoritmo será igual, apenas mudando o pré-processamento dos dados de entrada, ou

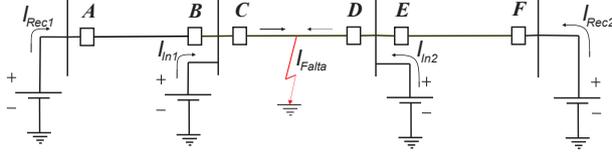


Figura 3: Circuito equivalente do sistema adotado com falha na linha 2.

seja, ora se usa como entrada das RNAs as amostras da corrente DC e ora se usa como entrada das RNAs os coeficientes de wavelet da corrente DC. O algoritmo proposto se baseia na capacidade de classificação e reconhecimento de padrões das RNAs para realizar as tarefas mencionadas anteriormente. Outro ponto importante sobre este algoritmo é a sua capacidade de aprender por exemplos, dispensando a definição de valores de referência, normalmente necessários, para as tarefas de proteção.

3.1 Estrutura do Algoritmo

Neste trabalho são considerados três relés baseados em RNAs, sendo cada um responsável por um trecho de linha DC. Tais relés estão posicionados no início de cada linha, ou seja, existe um relé associado ao disjuntor A, um ao disjuntor C e outro ao disjuntor E.

No momento da ocorrência de uma falha em qualquer das linhas DC, todos os relés percebem a mudança no valor de corrente, mas somente o relé do trecho da ocorrência da falha trocará de estado ($0 \rightarrow 1$) e enviará o sinal de *trip* ao disjuntor DC correspondente ao trecho faltoso. Uma vez que a falha é detectada pela RNA de detecção de faltas (tarefa *online*), é ativada a RNA para a localização da falha (tarefa *offline*) no trecho faltoso.

A Figura 3 apresenta o sistema adotado com uma falha na linha 2, onde I_{Rec1} e I_{Rec2} representam as contribuições das subestações retificadoras para a corrente de falha, I_{In1} e I_{In2} representam as contribuições das subestações inversoras para a corrente de falha e I_{Falta} representa a corrente de falha total. Já a Figura 4, mostra a corrente no ponto de falha, ressaltando-se que o valor de base adotado foi o maior valor observado nas simulações de curto circuito. Conforme já discutido (Figura 2), durante um curto período de tempo as subestações podem ser representadas como fontes de tensão DC alimentando à falha (Yang et al., 2012). No momento da falha a mudança da corrente é percebida pelos três relés, mas somente o relé da linha 2 atuará, detectando a falha e enviando um sinal de *trip* para os disjuntores C e D, isolando a linha faltosa e deixando o resto do sistema em operação normal, incrementando a disponibilidade do mesmo.

O algoritmo baseado em RNAs para detecção e localização de faltas pode ser dividido em duas

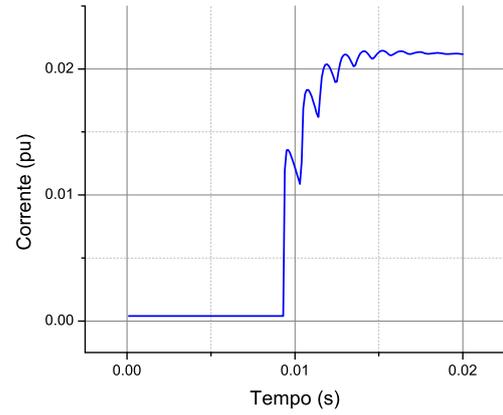


Figura 4: Corrente de falha na linha 2 do sistema adotado.

etapas, listadas a seguir:

- **Etapa Online:** Nesta etapa do algoritmo são realizados, em tempo real, as medições das correntes no sistema DC, a montagem dos vetores de entrada das RNAs e a aplicação desses vetores às RNAs. As três RNAs para detecção da falha recebem os seus respectivos vetores de entrada, possuem o mesmo número de neurônios e o mesmo número de camadas. Entretanto, cada uma delas é responsável pela detecção das faltas em um trecho específico do sistema.
- **Etapa Offline:** Esta etapa também é composta por três RNAs, sendo responsável pela localização das faltas. As RNAs possuem arquiteturas diferentes das usadas na etapa *online*, porém todas possuem a mesma arquitetura entre elas e recebem os seus respectivos vetores de entrada. Dessa forma, cada uma delas é responsável pela localização da falha em um trecho específico do sistema.

3.2 Algoritmo Baseado em Amostras da Corrente DC e RNAs

Nesta primeira versão do algoritmo, este é implementado considerando-se apenas amostras da corrente DC, normalizadas e agrupadas para formar os padrões de entrada das RNAs. Utiliza-se uma frequência de amostragem de $2kHz$, o que representa um espaçamento de $500\mu s$ entre cada amostra. Uma janela deslizante de 8 amostras ($4ms$) é utilizada para gerar os vetores de treinamento. A Figura 5 ilustra como a janela de dados desloca-se para amostrar os valores de corrente DC e formar os vetores de entrada das RNAs.

É importante destacar que durante a fase de desenvolvimento do algoritmo, foram avaliadas diferentes topologias de RNAs e tamanhos de janela de dados. Após uma exaustiva bateria de testes,

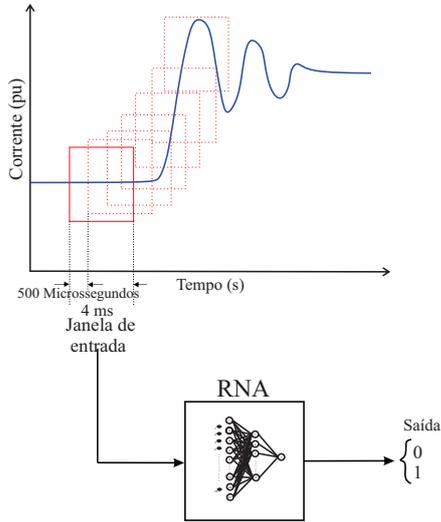


Figura 5: Janela deslizante de 4ms utilizada na primeira proposta.

Tabela 1: Valores para gerar o conjunto de treinamento.

Dados para Treinamento das RNAs	
Resistência de Falta (Ω)	0, 1, 5, 10, 20, 50 e 100
Distância da Falta (km)	10, 20, 50, 80 e 90

observa-se que o melhor desempenho do algoritmo é alcançado para uma janela de dados de 4ms e uma RNA de 16-8-1, ou seja, dezesseis neurônios na camada de entrada, oito neurônios na camada oculta e um neurônio de saída.

Para se obter um melhor desempenho na etapa de treinamento das RNAs, as amostras de corrente provenientes do sistema MTDC são normalizadas com relação ao valor máximo de corrente observado durante o processo de treinamento (1193,9 A). Tal medida foi adotada porque as RNAs utilizam valores de entrada entre -1 e 1. Para gerar um conjunto de treinamento representativo, são realizados diferentes casos de falta ao longo de cada linha DC, sendo considerados somente casos de falta pólo-terra, uma vez que o sistema MTDC adotado é monopolar. A Tabela 1 apresenta os valores de resistência de falta e distância da falta utilizados para gerar os casos de treinamento. Para cada linha são gerados 35 casos de falta, totalizando 105 casos para todo o sistema. Salienta-se que tais valores foram selecionados para possibilitar a elaboração de um conjunto de treinamento que represente os limites do universo de operação do sistema elétrico adotado.

A Tabela 2 apresenta um resumo dos vetores de entrada para o treinamento de cada RNA utilizada para a função de detecção de faltas. Os 2100 vetores pós-falta são formados por 20 janelas (pós-falta) de cada um dos 105 casos de falta. Somente uma janela pré-falta é considerada para cada caso.

Para gerar os casos de treinamento para as RNAs, responsáveis pela função de localização de faltas, novos casos de falta foram gerados. Tais

Tabela 2: Treinamento para a função de detecção.

Resumo dos Dados de Treinamento			
Casos de Treinamento	Vetores Pré-Falta	Vetores Pós-Falta	Tamanho de Janela (Amostras)
105	105	2100	8

casos consideram diferentes valores de resistência e distância da falta, totalizando 36 casos para cada trecho de linha. Diferentemente do treinamento das RNAs para a detecção da falta, onde cada RNA foi treinada com casos de falta em todos os trechos de linha, para o treinamento das RNAs de localização da falta, cada RNA foi treinada apenas com os casos de falta de seu próprio trecho de linha.

Para formar o conjunto de treinamento das RNAs para a localização da falta é utilizada uma taxa de amostragem de 10kHz (100μs entre amostras) e uma janela de dados de 100 amostras (10ms). Uma vez detectada a falta (pela RNA de detecção), em um determinado trecho de linha, o sistema de localização solicita a oscilografia do relé e utiliza os últimos 10ms de dados armazenados (amostras da corrente DC) como entrada da RNA responsável por esta função. De maneira análoga ao realizado para função de detecção da falta, a definição do tamanho da janela de dados (10ms) e a topologia das RNAs (100-50-1) foram definidas após a observação de um grande número de simulações.

3.3 Algoritmo Baseado nos Coeficientes de Aproximação e Detalhe.

Nesta segunda versão do algoritmo, este é implementado considerando-se os coeficientes wavelet de aproximação e detalhe de quinto nível como entrada das RNAs. Dessa forma, diferentemente da proposta anterior, existe um pré-processamento da corrente de falta DC por meio da Transformada Discreta de Wavelet.

Na fase de treinamento do algoritmo são utilizados os coeficientes de aproximação e detalhe do sinal de corrente DC para fazer a detecção da falta. Uma taxa de amostragem de 10kHz (100μs) é utilizada para amostrar o sinal de corrente, enquanto uma janela deslizante de 16 amostras (1,6ms) é utilizada para gerar os padrões de entrada das RNAs. Cada padrão de entrada é decomposto por meio de uma TDW e os coeficientes de quinto nível são extraídos, conforme a Figura 6. Tal critério foi adotado após a observação de um grande número de simulações e testes. Dessa forma, as RNAs de detecção recebem padrões de entrada com dezesseis valores relativos aos coeficientes de aproximação e detalhe do sinal de falta. A Figura 7 apresenta o esquema de processamento do sinal para formar os padrões de treinamento das RNAs.

Considerando o mesmo procedimento adotado

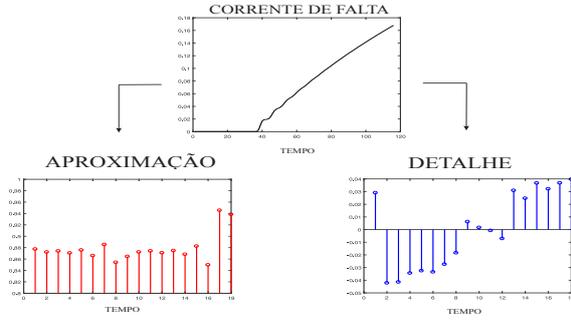


Figura 6: Coeficientes de aproximação e detalhe de um sinal de corrente de falta.

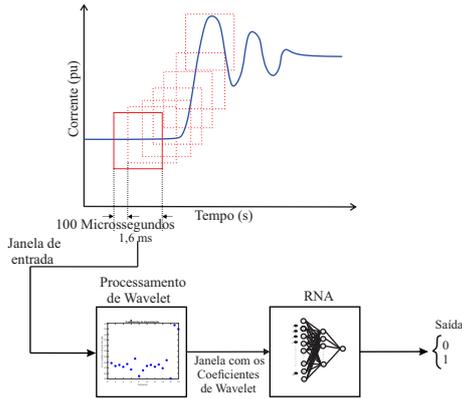


Figura 7: Janela deslizante de 1,6ms utilizada na segunda proposta

na proposta anterior, para o treinamento das RNAs responsáveis pela detecção de faltas são utilizados os 105 casos gerados nas três linhas da Figura 1, conforme apresentado na Tabela 2.

Em se tratando da função de localização de faltas, para gerar os casos de treinamento das RNAs, responsáveis por esta função, foi utilizada uma taxa de amostragem de $10kHz$ (100μ entre amostras) e uma janela de dados de 50 amostras ($5ms$). Uma vez amostrada a corrente DC, esse sinal é processado por meio da Transformada Discreta de Wavelet a qual extrai os coeficientes de aproximação e detalhe de quinto nível. Utilizando o mesmo conceito da Figura 6 e diferentemente do caso de treinamento para a função de detecção da falta, para o treinamento da RNA de localização da falta apenas os 18 coeficientes de aproximação mais representativos são utilizados. Após muitas simulações e observações, verificou-se que somente 18 coeficientes de aproximação variam consideravelmente durante a falta, sendo portanto suficientes para executar a função de interesse.

Dessa forma, de maneira resumida, para a tarefa de detecção de faltas as RNAs recebem dezesseis valores relativos aos coeficientes de aproximação e detalhe de quinto nível da corrente DC. Já para a tarefa de localização de faltas, as RNAs recebem dezoito valores relativos aos coeficientes de aproximação de quinto nível da corrente DC.

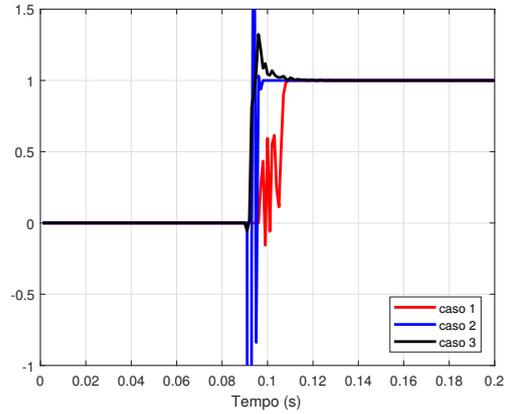


Figura 8: Resposta do algoritmo diante dos seguintes casos: 1) 0Ω e 9% da linha 1. 2) 7Ω e 27% da linha 2. 3) 70Ω e 65% da linha 3.

Igualmente ao procedimento utilizado na primeira proposta, foram gerados um total de 36 casos de falta para cada linha DC, visando treinar as RNAs responsáveis pela tarefa de localização de faltas.

4 Resultados e Análises

4.1 Resultados do Algoritmo Baseado em Amostragem de Corrente DC e RNAs.

Para testar as RNAs para detecção de faltas foram utilizados 60 casos diferentes dos casos de treinamento. Na Figura 8 pode-se observar as respostas de três casos de falta distintos nos diferentes trechos de linha do sistema, com diferentes localizações e resistências de falta. Ressalta-se que todos os casos testados foram detectados com sucesso, porém houve variações de tempo a medida que a falta se aproxima do extremo oposto da linha DC, uma vez que nessa situação a saída da RNA não é totalmente estável. Dessa forma, para faltas acima de 90% da linha DC e com alta resistência, alguma imprecisão é observada.

Os resultados da função de localização de faltas são apresentados na Tabela 3. Os testes foram realizados com casos diferentes daqueles utilizados no processo de treinamento, ou seja, diferentes localizações e resistências de falta foram consideradas.

Como pode ser observado nos testes de detecção e localização de faltas nas linhas DC do sistema MTDC adotado, o algoritmo baseado em amostras do sinal de corrente DC e RNAs é bastante promissor. Apesar dos bons resultados observados com relação à função de localização de faltas, independentemente do trecho considerado, cabe ressaltar que a função de detecção de faltas se mostrou um pouco instável com relação ao trecho de linha 2, quando comparada aos demais trechos (ver caso 2 da Figura 8). O erro de localização foi calculado segundo (1).

Tabela 3: Resultados da Função de Localização - Amostras da Corrente DC e RNAs.

Testes					
Caso	Linha	Distância da Falta (%)	Resistência de Falta (Ω)	Resposta RNA (%)	Erro (%)
1	I	10	100	11,03	1,028
2	I	25	83	25,59	0,587
3	I	75	100	74,98	0,019
4	II	20	59	20,00	0
5	II	70	17	69,95	0,053
6	II	75	100	73,50	1,500
7	III	10	15	13,95	3,951
8	III	40	0	40,12	0,116
9	III	75	50	73,17	1,82
Erro médio(%)					1,008

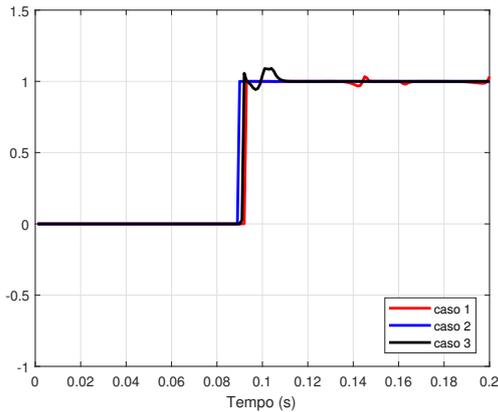


Figura 9: Resposta do algoritmo diante dos seguintes casos: 1) 0 Ω e 9% da linha 1. 2) 7 Ω e 27% da linha 2. 3) 70 Ω e 65% da linha 3.

$$Erro(\%) = \frac{|L_{real} - L_{estimado}|}{L_{total}} \cdot 100 \quad (1)$$

Onde:

L_{real} = distância onde a falta ocorreu;

$L_{estimado}$ = distância estimada pelo algoritmo;

L_{total} = comprimento de cada trecho de linha.

4.2 Resultados do Algoritmo Baseado nos Coeficientes de Aproximação e Detalhe e RNAs

Para testar a RNA para detecção de faltas foram utilizados 60 casos diferentes dos casos de treinamento. Na Figura 9 pode-se observar a resposta do algoritmo para três diferentes casos de falta nas linhas do sistema MTDC adotado, considerando diferentes localizações e resistências de falta. Os resultados do algoritmo com relação à função de localização de faltas são apresentados na Tabela 4. Novamente, destaca-se que os testes foram realizados com casos diferentes daqueles usados na etapa de treinamento.

A exemplo das respostas observadas para a primeira proposta de algoritmo, os resultados observados utilizando-se os coeficientes wavelet de aproximação e detalhe como entrada das RNAs

Tabela 4: Resultados da Função de Localização - Coeficientes de Aproximação e RNAs.

Testes					
Caso	Linha	Distância da Falta (%)	Resistência de Falta (Ω)	Resposta RNA (%)	Erro (%)
1	I	10	100	9,97	0,0459
2	I	25	83	23,93	1,0679
3	I	75	100	71,53	3,4699
4	II	20	59	20,00	0
5	II	70	17	69,84	0,1557
6	II	75	100	79,24	0,2447
7	III	10	15	10,00	0,0037
8	III	40	0	40,00	0,0013
9	III	75	50	76,02	1,0234
Erro médio(%)					0,668

também revelam o bom desempenho do algoritmo em termos de localização de faltas. Da mesma maneira, é possível observar que a resposta foi precisa em termos de detecção de falta, porém neste caso (Fig. 9) os sinais oscilam menos do que no caso anterior (Fig. 8) para atingir o valor final. É importante destacar que as duas propostas de algoritmo foram avaliadas diante dos mesmos casos de falta, permitindo uma comparação direta entre os seus desempenhos. Nitidamente, verifica-se que apesar dos acertos nas duas situações, a saída da função de detecção é mais estável para a segunda proposta de algoritmo. Da mesma forma, a função de localização da segunda proposta também apresentou desempenho superior ao verificado para a primeira proposta diante de todos os casos considerados.

5 Conclusões

Este trabalho evidenciou que a aplicação de RNAs nas tarefas de detecção e localização de faltas em sistemas MTDC é bastante promissora. Dezenas de casos foram utilizados para avaliar o desempenho das propostas apresentadas, sendo constatado que, apesar de ambas oferecerem bons resultados, a segunda proposta, baseada nos coeficientes wavelet de aproximação e detalhe da corrente DC e RNAs, é mais precisa. Cabe ressaltar que apesar de apresentar um desempenho um pouco inferior, a primeira proposta é mais simples e não necessita de nenhum tipo de pré-processamento antes do estágio das RNAs.

Também é importante ressaltar que todas as RNAs para uma mesma função possuem a mesma arquitetura, o que torna significativamente mais simples a implementação prática do algoritmo. Independentemente, da versão do algoritmo analisada, ambas foram bastante seletivas para a detecção de faltas até 90% da sua própria linha. Além disso, os erros médios de localização da primeira e segunda proposta foram 1,008% e 0,6680%, respectivamente.

Agradecimentos

Este trabalho está relacionado ao Projeto Universal do CNPq - Processo 432423/2016-8 e ao suporte financeiro CAPES/OEA -Processo 1622737.

Referências

- Abu-Elanien, A. E., Elserougi, A. A. and Abdel-Khalik, Ayman S e Massoud, A. M. e. A. S. (2016). A differential protection technique for multi-terminal hvdc, *Electric Power Systems Research* **130**: 78–88.
- Bawane, Narendra e Kothari, A. (2003). Artificial neural network based fault identification of hvdc converter, *Diagnostics for Electric Machines, Power Electronics and Drives, 2003. SDEMPED 2003. 4th IEEE International Symposium on*, IEEE, pp. 152–157.
- Ikhide, M. and Tennakoon, Sarath e Griffiths, A. e. S. S. e. H. H. (2015). Fault detection in multi-terminal modular multilevel converter (mmc) based high voltage dc (hvdc) transmission system, *Power Engineering Conference (UPEC), 2015 50th International Universities*, IEEE, pp. 1–6.
- Johannesson, N. and Norrga, Staffan e Wikström, C. (2016). Selective wave-front based protection algorithm for mt-dc systems.
- Kamble, Saurabh e Dupare, I. (2014). Detection of power quality disturbances using wavelet transform and artificial neural network, *Emerging Research Areas: Magnetics, Machines and Drives (AICERA/iCMMD), 2014 Annual International Conference on*, IEEE, pp. 1–5.
- Kontos, E., Pinto, R. T., Rodrigues, S. and Bauer, P. (2015a). Impact of hvdc transmission system topology on multiterminal dc network faults, *2015 IEEE Power Energy Society General Meeting*, pp. 1–1.
- Kontos, E., Pinto, R. T., Rodrigues, S. and Bauer, P. (2015b). Impact of hvdc transmission system topology on multiterminal dc network faults, *IEEE Transactions on Power Delivery* **30**(2): 844–852.
- Le Blond, S., Bertho Jr, R., Coury, D. and Vieira, J. (2016). Design of protection schemes for multi-terminal hvdc systems, *Renewable and Sustainable Energy Reviews* **56**: 965–974.
- Le Blond, S. Q. D. and Burgin, M. (2014). High frequency protection scheme for multi-terminal hvdc overhead lines, *12th IET International Conference on Developments in Power System Protection (DPSP 2014)*, pp. 1–5.
- Li, R., Fletcher, J. E., Yao, L. and Williams, B. W. (2016). Dc fault protection structures at a dc-link node in a radial multi-terminal high-voltage direct current system, *IET Renewable Power Generation* **10**(6): 744–751.
- Lima, M. A., Cerqueira, A. S., Coury, D. V. and Duque, C. A. (2012). A novel method for power quality multiple disturbance decomposition based on independent component analysis, *International Journal of Electrical Power & Energy Systems* **42**(1): 593–604.
- Mahela, O. P., Shaik, A. G. and Gupta, N. (2015). A critical review of detection and classification of power quality events, *Renewable and Sustainable Energy Reviews* **41**: 495–505.
- Mokhberdorani, A., Silva, N., Leite, H. and Carvalho, A. (2016). A directional protection strategy for multi-terminal vsc-hvdc grids, *Environment and Electrical Engineering (EE-EIC), 2016 IEEE 16th International Conference on*, IEEE, pp. 1–6.
- Oliveira, M. O. and Bretas, A. S. (2009). Application of discrete wavelet transform for differential protection of power transformers, *Power-Tech, 2009 IEEE Bucharest*, IEEE, pp. 1–8.
- Pfeiffer, M., Bucher, M. and Franck, C. M. (2013). The effect of grid topology on transient fault currents in multi-terminal vsc-hvdc offshore networks, *Proc. International Conference on Power Systems Transients (IPST), Vancouver, Canada*, Citeseer.
- Rafferty, J., Xu, L. and Morrow, J. (2014). Analysis of voltage source converter-based high-voltage direct current under dc line-to-earth fault, *IET Power Electronics* **8**(3): 428–438.
- Rajeswari, R. and Kamaraj, N. (2007). Diagnosis of inter turn fault in the stator of synchronous generator using wavelet based anfis, *World Academy of Science, Engineering and Technology* **36**: 203–209.
- Ramesh, M. and Laxmi, A. J. (2012). Fault identification in hvdc using artificial intelligence - recent trends and perspective, *Power, Signals, Controls and Computation (EPS-CICON), 2012 International Conference on*, IEEE, pp. 1–6.
- Santos, R. C., Le Blond, S., Coury, D. V. and Aggarwal, R. K. (2016). A novel and comprehensive single terminal ann based decision support for relaying of vsc based hvdc links, *Electric Power Systems Research* **141**: 333–343.

- Santos, R. C., Le Blond, S., Coury, D. V. and Aggarwal, R. K. (2018). An intelligent backup scheme for current source converter-high voltage direct current systems based on artificial neural networks, *Electric Power Components and Systems* pp. 1–13.
- Sharma, A. K., Mahela, O. P. and Ola, S. R. (2016). Detection of power quality disturbances using discrete wavelet transform, *Electrical Power and Energy Systems (ICEPES), International Conference on*, IEEE, pp. 450–455.
- Silva, K., Souza, B. A. and Brito, N. S. (2006). Fault detection and classification in transmission lines based on wavelet transform and ann, *IEEE Transactions on Power Delivery* **21**(4): 2058–2063.
- Yang, J., Fletcher, J. E. and O'Reilly, J. (2012). Short-circuit and ground fault analyses and location in vsc-based dc network cables, *IEEE transactions on Industrial Electronics* **59**(10): 3827–3837.