

A Proteção de uma Linha de Transmissão com Compensação Série utilizando Redes Neurais Artificiais

Matheus do V. Oliveira * Leonardo da S. Lessa * Mário Oleskovicz *

* *Escola de Engenharia de São Carlos, Universidade de São Paulo, SP,
(e-mail: matheusdoval@usp.br, leonardolessa@usp.br, olesk@sc.usp.br)*

Abstract: Series compensators regulate and keep acceptable voltage levels in power transmission lines that will reflect positive power quality indexes. However, depending on the kind of compensator to be used, it can add complex parameters to the line modelling due to its non-linear operation and, consequently, in the responses of the current methods utilized for fault location in transmission lines. In this context, this work aims to present an efficient way to determine which section of the two terminals compensated transmission line a single phase to ground fault occurred. The methodology used consists of obtaining voltage and current signals of transmission line terminals. Considering the signs, applying the Discrete S Transform for a pre-processing and, by the calculated coefficients, feeding an Artificial Neural Network so that the determination of in what section the fault occurred, in the left or the right side of the compensator. The obtained results were promising and presented the potentiality of the utilized methodology.

Resumo: Compensadores em série regulam e mantém os níveis aceitáveis da tensão em Linhas de Transmissão (LTs) de energia, os quais refletirão em índices positivos na qualidade da energia elétrica. Entretanto, dependendo do tipo do compensador a ser empregado, o mesmo pode adicionar parâmetros complexos para a modelagem da linha, devido à sua não linearidade na operação e, conseqüentemente, nas respostas dos métodos usualmente empregados para a localização de faltas nas LTs. O objetivo deste trabalho é apresentar um método para determinar em qual trecho da LT de dois terminais com compensação série, ocorreu uma falta monofásica. A metodologia consiste em se obter os sinais das tensões e correntes trifásicas dos terminais da LT, aplicar a Transformada S Discreta (TSD) para um pré-processamento dos sinais e, por meio dos coeficientes obtidos, alimentar uma Rede Neural Artificial (RNA) que determinará em qual trecho ocorreu a falta monofásica, ou à esquerda, ou à direita do compensador série. Os resultados obtidos foram promissores e apontam para a potencialidade da metodologia empregada.

Keywords: Artificial Neural Networks; Discrete S Transform; TCSC; Fault Classification; Transmission Lines.

Palavras-chaves: Redes Neurais Artificiais; Transformada Discreta S; TCSC; Classificação de Faltas; Linhas de Transmissão.

1. INTRODUÇÃO

As Linhas de Transmissão (LTs) de energia elétrica são os elementos dos Sistemas Elétricos de Potência (SEPs) que têm maior extensão e, conseqüentemente, estão sujeitas a inúmeras adversidades que o próprio ambiente lhes proporciona. Além disso, as LTs fazem a conexão entre diversos elementos que constituem os SEPs, de modo que falhas (curtos-circuitos) nas linhas podem acarretar danos aos demais elementos do sistema. Portanto, vê-se necessário um esquema completo de proteção, compreendendo a detecção, a classificação e a localização da falta, pois o isolamento de uma linha em falta poderá garantir uma adequada e esperada operação dos demais elementos conectados à linha.

* Auxílio financeiro (bolsa de IC) recebido por parte do CNPq (Conselho Nacional de Desenvolvimento Científico e Tecnológico).

Associado à operação dos SEPs, destaca-se que o fluxo de potência nas LTs depende primariamente da reatância série da linha (Hingorani and Gyugyi, 2000). Caso necessário, será de interesse amenizar o efeito indutivo, favorecendo a transferência de potência, por exemplo, pela compensação série capacitiva. Em tal situação, pode-se dispor de dispositivos FACTS (do inglês, *Flexible AC Transmission Systems*), sendo neste estudo empregado o TCSC (*Thyristor Controlled Series Capacitor*), que vem sendo constantemente estudado e aplicado em sistemas reais a fim de resolver o problema anteriormente comentado.

De fato, a compensação capacitiva série viabilizada pelos dispositivos FACTS permitem uma melhora da estabilidade da tensão e do amortecimento das oscilações de potência, bem como, das oscilações subsíncronas (Hingorani and Gyugyi, 2000). Especificamente sobre o TCSC, a ser apresentado na Seção 2, Jamhoria and Srivastava (2014)

apresentam a sua aplicação no controle ótimo do fluxo de potência e na minimização de perdas. Já em (Ahmed et al., 2022), a melhora na estabilidade da tensão e a melhora da estabilidade transitória são demonstrados. Além disso, o TCSC tem sido estudado para melhorar a qualidade da energia (Khederzadeh, 2007), para amortecer oscilações inter-áreas (Liu et al., 2015) e, mais recentemente, para amortecer oscilações torcionais (Gandhi and Darji, 2022).

Ainda que se empregue o TCSC para a obtenção de tais benefícios, deve-se destacar que o mesmo acrescenta problemas para os sistemas de proteção usualmente empregados. Kang et al. (2020) apresentam que o sistema de chaveamento dos tiristores e o sistema de proteção do TCSC, geralmente composto por um MOV (*Metal Oxide Varistor*) em paralelo com o TCSC, faz com que os relés de distância usualmente empregados não consigam localizar as faltas adequadamente. Além disso, Zand et al. (2020) destacam o fato da própria reatância capacitiva do TCSC alterar a reatância da LT vista pelo relé no momento da falta.

Para resolver os problemas acima descritos, Kang et al. (2020) e Zand et al. (2020) utilizam-se de métodos numéricos para estimarem a queda de tensão no TCSC e aplicarem os métodos convencionais de localização de faltas em LTs. Por sua vez, Mirzaei et al. (2018) fizeram uso de *Deep Learning* para localizar faltas em uma linha compensada por TCSC, enquanto que Biswas et al. (2020) e Prasad and Biswal (2020) utilizaram Modos de Decomposição Empírica, tendo o primeiro utilizado também Árvores de Decisão para a detecção e a classificação das faltas, e o segundo um operador no domínio do tempo não linear (TEO - *Teager Energy Operator*) para a detecção das faltas. Kothari et al. (2020) faz uso de Máquinas de Vetores de Suporte para classificar as faltas e identificar a seção na qual a mesma ocorreu.

Este trabalho tem por objetivo o desenvolvimento de um método de identificação da seção faltosa para faltas monofásicas em LTs de dois terminais compensadas em série por TCSC protegido por MOV e *Spark Gap*, conforme utilizado por Conceição (2015), utilizando Redes Neurais Artificiais (RNAs). A Transformada S Discreta (TSD) será empregada em uma fase de pré-processamento dos sinais de faltas. Neste contexto, as RNAs serão utilizadas em um problema de reconhecimento de padrões. Já a TSD, permitirá evidenciar as características dos sinais em análise, servindo como um método alternativo às transformadas usualmente aplicadas ao problema, como é o caso da STFT (*Short Time Fourier Transform*) e da Transformada Discreta Wavelet (TDW). Assim, espera-se que o método desenvolvido consiga localizar precisamente o trecho em falta de uma LT com compensação série.

2. ANÁLISE TEÓRICA

A fim de prover o embasamento teórico necessário para a completa compreensão do presente trabalho, esta seção apresenta as informações relativas ao TCSC, à Transformada Discreta S e às Redes Neurais Artificiais.

2.1 TCSC

O TCSC consiste de um capacitor em paralelo com um reator controlado a tiristores (TCR - *Thyristor Controlled Reactor*), como mostrado na Figura 1.

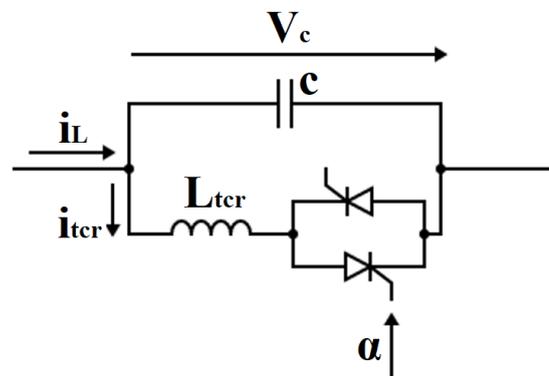


Figura 1. Representação do TCSC por meio de elementos de circuitos eletrônicos (adaptado de Jovcic and Pillai (2005)).

A Figura 1 ainda mostra alguns parâmetros associados à operação do TCSC, sendo estes: a corrente da LT (i_L); a tensão sobre o capacitor (v_c); a corrente pelo reator (i_{tcr}); a capacitância (c); a indutância do reator (l_{tcr}); e o ângulo de disparo dos tiristores (α). Tais variáveis são utilizadas para a implementação do controle do sistema conforme encontrado em Jovcic and Pillai (2005).

Destaca-se que o TCSC, conforme Hingorani and Gyugyi (2000), opera como uma reatância variável, podendo operar com aspecto indutivo ou capacitivo conforme o ângulo α , dependendo das necessidades do sistema. A Figura 2 mostra que abaixo de um ângulo α_r de ressonância, para o qual o TCSC anula a reatância série da LT, o TCSC adquire aspecto indutivo, enquanto que acima de α_r , o TCSC adquire aspecto capacitivo.

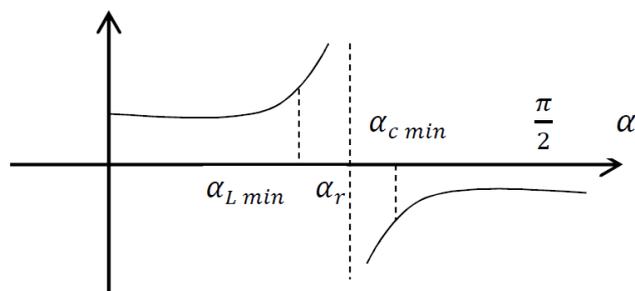


Figura 2. Reatância variável em função do ângulo de disparo do TCSC (Zand et al., 2020).

2.2 Transformada de Stockwell

Conforme proposto por Stockwell et al. (1996), a Transformada de Stockwell ou Transformada S Contínua (TSC) consiste da Transformada *Wavelet* Contínua (TWC) com uma correção de fase. De fato, a TWC, $W(\tau, d)$, de uma função $h(t)$ é definida por:

$$W(\tau, d) = \int_{-\infty}^{\infty} h(t)\omega(t - \tau, d)dt, \quad (1)$$

sendo $\omega(\tau, d)$ a réplica escalonada da *wavelet* mãe e d a dilatação que determina a largura da *wavelet* e, portanto, sua resolução. Um ponto destacado pelos autores é que $\omega(\tau, d)$ deve ter média 0 (zero).

Desta forma, a TSC, $S(\tau, f)$, de um sinal $h(t)$ pode ser vista como a TWC deste mesmo sinal, mas com um fator de correção de fase dado por:

$$S(\tau, f) = e^{i2\pi f\tau} W(\tau, d), \quad (2)$$

sendo a *wavelet* mãe definida por

$$\omega(t, f) = \frac{|f|}{\sqrt{2\pi}} e^{-\frac{t^2 f^2}{2}} e^{-i2\pi ft}, \quad (3)$$

e a frequência (f) o inverso de d .

A TSC é dada, portanto, por:

$$S(\tau, f) = \int_{-\infty}^{\infty} h(t) \frac{|f|}{\sqrt{2\pi}} e^{-\frac{(\tau-t)^2 f^2}{2}} e^{-i2\pi ft} dt \quad (4)$$

Pela Equação 4, fica evidente a utilidade da TSC, pois dado que $S(\tau, f)$ é uma função tanto do tempo (τ), quanto da frequência (f), então, para cada instante de tempo escolhido, é possível observar quais as intensidades das frequências presentes.

Entretanto, o que será implementada é a TSD, também fornecida e dada por Stockwell et al. (1996) como:

$$S\left[jT, \frac{n}{NT}\right] = \sum_{m=0}^{N-1} H\left[\frac{m+n}{NT}\right] e^{-\frac{2\pi^2 m^2}{n^2}} e^{i\frac{2\pi m j}{N}}, n \neq 0, \quad (5)$$

considerando $f \rightarrow \frac{n}{NT}$, $\tau \rightarrow jT$, que $H\left[\frac{n}{NT}\right] = \frac{1}{N} \sum_{k=0}^{N-1} h[kT] e^{-i\frac{2\pi nk}{N}}$, para a série temporal discreta $h[kT]$ obtida do sinal $h(t)$, e que para $n = 0$, $S[jT, 0] = \frac{1}{N} \sum_{m=0}^{N-1} h\left(\frac{m}{NT}\right)$.

Observa-se, então, que a TSD resulta em uma matriz cujas linhas representam as frequências e as colunas os intervalos de tempo.

2.3 Redes Neurais Artificiais

As RNAs fazem parte de um conjunto de ferramentas computacionais baseadas na forma com a qual o cérebro humano obtém e armazena o conhecimento. Segundo Silva et al. (2016), as mesmas têm a capacidade de adquirir e dar manutenção ao conhecimento, podendo ser definidas como a constituição de unidades de processamento menores, denominadas neurônios artificiais, e que são interligadas por um grande número de interconexões (sinapses artificiais), cuja representação pode ser realizada por meio de matrizes de pesos sinápticos.

Nesta pesquisa, será considerada uma Rede Perceptron de Múltiplas Camadas (PMCs), cujo modelo é ilustrado na Figura 3. Como ilustrado e, posteriormente justificado,

a topologia escolhida para a PMC deste trabalho é a mesma da Figura 3, com 13 neurônios na primeira camada escondida, 3 na segunda camada escondida e somente um neurônio na camada de saída.

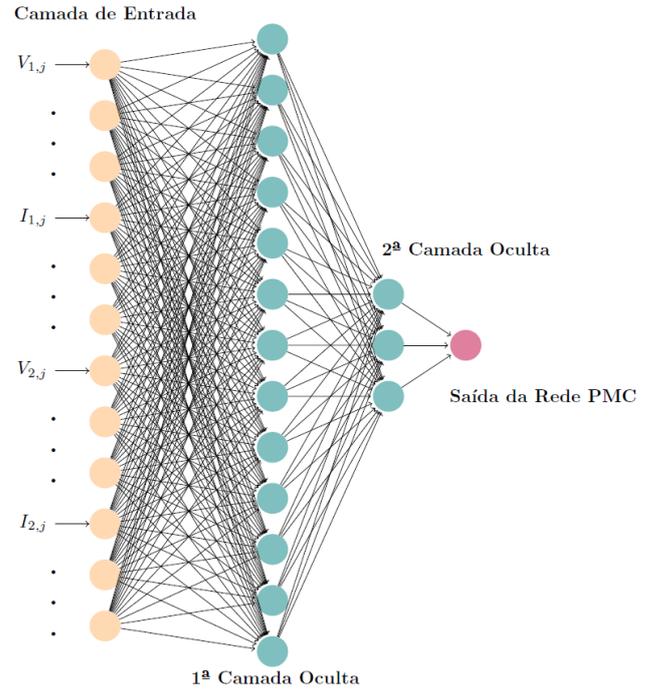


Figura 3. Representação esquemática de redes PMC (adaptada de Silva et al. (2016)).

As RNAs PMCs contêm pelo menos uma camada neural intermediária (escondida), como mostra a Figura 3. Na Figura 3, os nós intermediários representados por n_i dizem respeito a cada neurônio artificial. Tais redes pertencem à arquitetura *feedforward* de camadas múltiplas e devem ser treinadas por meio de um algoritmo de treinamento supervisionado (Silva et al., 2016).

Deve-se observar que neste tipo de rede a informação flui do sentido da camada de entrada em direção à camada de saída (*feedforward*), sendo que não se observa qualquer realimentação entre as camadas.

3. METODOLOGIA

Com base nas informações apresentadas na Seção 2, tem-se na sequência as principais etapas da metodologia considerada.

3.1 Geração dos sinais de falta

O sistema elétrico analisado, a ser detalhado na Seção 4, foi modelado via o *software* ATP (*Alternative Transients Program*), dispondo da interface gráfica do *software* ATP-Draw. A Figura 4 ilustra o sistema modelado. Pode-se observar na mesma um ramo com uma chave em série com um resistor conectado à terra, ramo pelo qual as faltas monofásicas envolvendo a fase A com conexão ao terra (A-T) foram geradas. Em ambos os trechos, à esquerda e à direita do TCSC, colocado no meio da linha, tais faltas foram geradas.

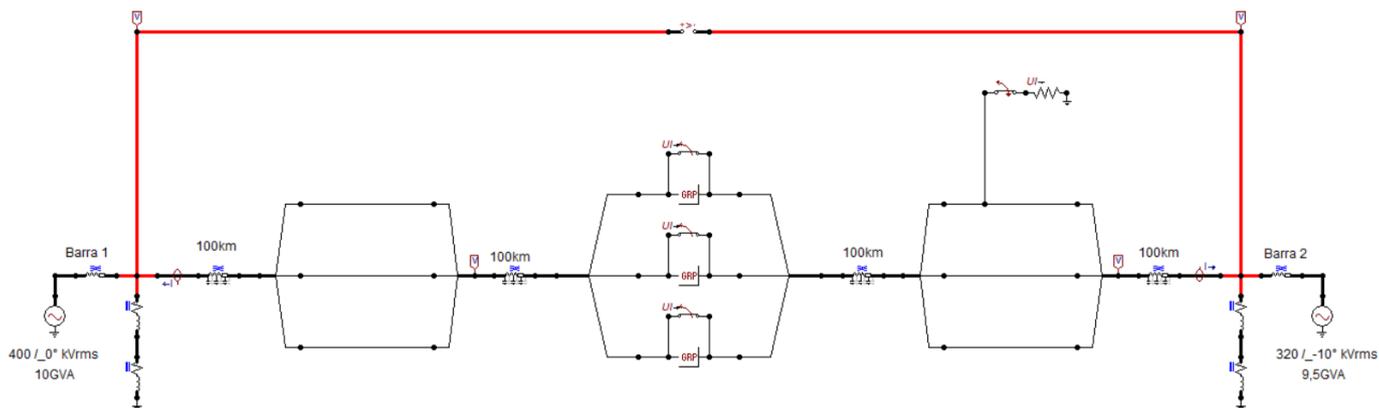


Figura 4. Sistema elétrico modelado via o software ATPdraw.

Foi gerado um conjunto de dados representativo das situações de faltas monofásicas, sendo que para cada situação, foram medidas a tensão na Barra 1 e a corrente entrando na mesma, e a tensão na Barra 2 e a corrente entrando na mesma, isto é, para cada situação de falta, foram obtidas quatro séries temporais.

É importante salientar que os dados gerados representam somente faltas monofásicas. Então, após a detecção da situação de falta, função esta que não foi implementada neste trabalho, foi utilizado somente o segundo ciclo pós-falta, conforme será apresentado na sequência. Logo, para às funções associadas diretamente a localização de falta, não foram considerados os dados de pré-falta.

3.2 Aplicação da TSD nos sinais obtidos

Os dados obtidos via o software ATPdraw foram manipulados via o MATLAB a fim de selecionar somente o segundo ciclo pós-falta de cada série temporal e aplicar a TSD sobre cada uma delas. O algoritmo da TSD utilizado é como o encontrado em Dash (2022). Utilizando o conceito de Frequência Dominante (FD) apresentado em Souza (2015), foram escolhidos três valores máximos de cada sinal de tensão e corrente transformado pela TSD conforme (6).

$$\max |S[jT, \frac{n}{NT}]^T| \quad (6)$$

Exemplo de utilização: Como exemplo de aplicação, tem-se na Figura 5, o segundo ciclo pós-falta do sinal de corrente na Barra 2 para uma situação de falta A-T, em 15 % do segundo trecho da linha, para uma resistência de falta de 0,001 Ω e ângulo de incidência de falta de 90°.

Com base no conceito de FD, no mesmo sinal foi feita a aplicação da Equação (6), e o resultado obtido é o mostrado na Figura 6. Foram destacados os três picos que serão utilizados na RNA a ser projetada. A fim de se automatizar o processo, foi utilizada a função *findpeaks* do MATLAB, e para sinais onde não houve a localização de três picos pela função, foi adotado o valor 0 para esta informação.

A Figura 6, bem como todos os resultados que serão apresentados neste trabalho, foram simulados com uma frequência de amostragem de 30,72 kHz, correspondendo a

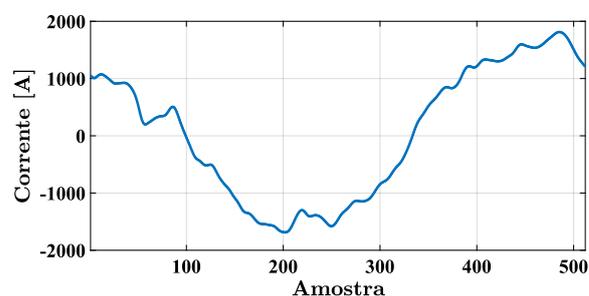


Figura 5. Forma de onda da corrente da fase A - Barra 2.

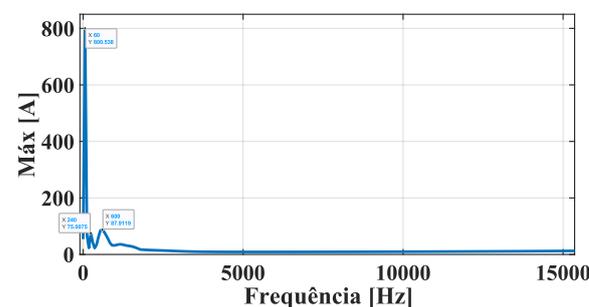


Figura 6. Aplicação do conceito de FD no sinal da Figura 5.

512 amostras por ciclo da componente fundamental (neste caso, de 60 Hz).

3.3 Aplicação de RNAs

Como foram medidas as tensões e correntes monofásicas de cada barra, tem-se um conjunto de quatro sinais para cada situação de falta gerada. Considerando os três valores máximos de cada sinal, foram então extraídos 12 valores no total que representaram cada situação de falta. De posse de tais valores, uma RNA com arquitetura *Feed Forward* foi escolhida.

Com base na metodologia apresentada, um conjunto de 2.048 amostras para cada sinal de falta aplicado (512 amostras do segundo ciclo de onda pós-falta para o sinal de tensão e 512 para o de corrente, das Barras 1 e 2) pôde ser reduzido para 12 valores, a partir da consideração das FDs. Vale frisar que não houve uma normalização dos valores a serem utilizados como entrada pela RNA.

Como saída da rede neural, escolheu-se 0 (zero) para as situações de faltas aplicadas no trecho 1, entre a Barra 1 e o TCSC, e 1 (um) para as situações consideradas no trecho 2, entre o TCSC e a Barra 2. Sendo assim, para cada situação de falta, foi necessário, tanto para a fase de treinamento, quanto para a fase de teste, apresentar 13 valores para a RNA implementada via o MATLAB, 12 associados à aplicação da TSD no sinal, e um associado à saída esperada.

Uma vez que a função de ativação escolhida para a camada de saída foi a logística sigmoideal, com valor de saída entre 0 e 1, adotou-se o critério de que se a saída fosse menor do que 0,1, a mesma seria considerada 0 (zero), e se fosse maior do que 0,9, igual a 1 (um).

Conforme será posteriormente apresentado na seção de resultados, foi gerado um conjunto de dados representativo contendo 162 situações de faltas envolvendo a fase A com o terra. Destas situações, 80 % foram tomadas de forma aleatória para compor o conjunto de treinamento, e os 20 % restantes para o conjunto de validação. O algoritmo de treinamento da RNA escolhida foi o de *Levenberg-Marquardt*.

Vale também adiantar que conforme será apresentado, um novo e distinto conjunto de situações de faltas foi gerado para compor o conjunto de teste. Este conjunto é composto por 84 novos casos.

4. SISTEMA ANALISADO

O sistema de transmissão teste modelado é de uma LT de dois terminais, e com um compensador série disposto exatamente na metade do comprimento da linha. Além disso, o sistema conta com a presença de compensadores em derivação nos terminais da linha, e de reatores de neutro. A Figura 7 ilustra o esquemático do sistema em questão, enquanto que a Figura 4 apresentada na Seção 3 mostra o sistema modelado no ATPdraw.

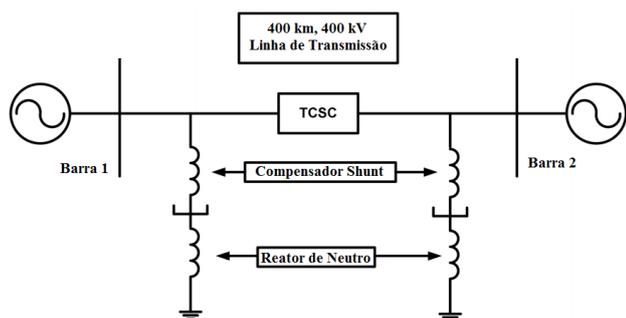


Figura 7. Sistema elétrico em análise (adaptada de (Sahoo and Samantaray, 2017)).

Tendo em vista os elementos destacados na Figura 7, a Tabela 1, contém os dados de tensão em valor eficaz, ângulo de fase e impedâncias de sequência equivalentes, cujos parâmetros indexados com 1 dizem respeito aos elementos de sequência positiva, e com 0, aos de sequência zero. Já a Tabela 2, apresenta os parâmetros dos reatores *shunt*, a Tabela 3, apresenta os parâmetros dos reatores de neutro, e a Tabela 4, contém os valores dos parâmetros da LT por parâmetros distribuídos e considerando a linha transposta.

Tabela 1. Dados dos terminais equivalentes do sistema de transmissão (Tavares et al., 2003).

Terminal	1	2
Tensão (kV)	400	320
Fase (°)	0	-10
Potência Aparente (GVA)	10	9,5
R_1 (Ω /m)	1,40	0,95
L_1 (mH/m)	42,44	28,59
R_0 (Ω /m)	6,19	4,17
L_0 (mH/m)	187,17	126,09

Tabela 2. Parâmetros por fase do compensador *shunt* (Sahoo and Samantaray, 2017).

Parâmetros	Valores
Resistência (Ω)	89,30
Indutância (mH)	11,37

Tabela 3. Parâmetros por fase do reator de neutro (Sahoo and Samantaray, 2017).

Parâmetros	Valores
Resistência (Ω)	20,83
Indutância (mH)	2652,57

Tabela 4. Valores dos parâmetros do sistema de transmissão (Sahoo and Samantaray, 2017).

Sequência	R (m Ω /km)	L (mH/km)	C (nF/km)
Positiva/Negativa	12,74	0,93	12,40
Zero	386,40	4,42	7,75

5. RESULTADOS

A Tabela 5 contém os parâmetros considerados para gerar as situações de faltas para o treinamento e validação da RNA. Já a Tabela 6 contém os parâmetros para gerar situações distintas para a fase de teste da RNA em análise. Nas mesmas, são variadas as percentagens das localizações da falta nos dois trechos, bem como a resistência e o ângulo de incidência de falta (AIF).

Tabela 5. Situações de faltas geradas para o treinamento e a validação da RNA proposta.

Parâmetros	Valores
Trecho 1 (%)	5, 15, 25, 50, 75, 80, 85, 90, 95
Trecho 2 (%)	5, 10, 15, 20, 25, 50, 75, 85, 95
Resistência de falta (Ω)	0,001, 50, 100
AIF (°)	0, 45, 90

Tabela 6. Situações de faltas geradas para o teste da RNA proposta.

Parâmetros	Valores
Trecho 1 (%)	35, 44, 60, 65, 78, 88, 93
Trecho 2 (%)	7, 12, 22, 35, 40, 56, 65
Resistência de falta (Ω)	1, 50, 75
AIF (°)	30, 60

Da combinação entre os parâmetros da Tabela 5, vê-se que foram gerados 162 casos (80 % destes, foram escolhidos de forma aleatória para o treinamento, e os 20 % restante para a validação cruzada), enquanto que da Tabela 6, 84 casos, utilizados exclusivamente para a fase de teste da RNA. Conforme discutido, a rede treinada deve ser capaz de distinguir entre uma falta entre a Barra 1 e o compensador (trecho 1), e entre o compensador e a Barra 2 (trecho 2).

O treinamento da rede foi realizado tomando por base uma camada de entrada, duas camadas escondidas e a camada de saída.

A camada de entrada consiste dos 12 valores obtidos pela aplicação da TSD e das FDs nos quatro sinais medidos e citados na Seção 3. Matematicamente, o vetor de entradas pode ser representado por:

$$[V_{1,1} \ V_{1,2} \ V_{1,3} \ I_{1,1} \ I_{1,2} \ I_{1,3} \ V_{2,1} \ V_{2,2} \ V_{2,3} \ I_{2,1} \ I_{2,2} \ I_{2,3}]^T, \quad (7)$$

sendo $V_{i,j}$ o representante do pico da tensão relativa à j -ésima FD da i -ésima Barra e $I_{i,j}$ o representante do pico da corrente relativa à j -ésima FD da i -ésima Barra, com $i = \{1, 2\}$ e $j = \{1, 2, 3\}$.

Para a primeira camada escondida, empiricamente, 13 neurônios foram adotados, sendo a função de ativação utilizada a tangente sigmoidal, cuja expressão é dada por $\text{tansig}(x) = \frac{2}{1 + e^{-2x}} - 1$, cuja saída permanece no intervalo $[-1, 1]$. Para a segunda camada escondida foram necessários três neurônios, cuja função de ativação também é a tangente sigmoidal. Já para o único elemento na camada de saída, a função logística sigmoidal foi a escolhida, cuja expressão é dada por $\text{logsig}(x) = \frac{1}{1 + e^{-x}}$, garantindo então que o resultado fique entre 0 e 1. A Figura 3 anteriormente apresentada ilustra de forma exata a topologia final da rede escolhida para esta pesquisa.

Em relação aos critérios de desempenho adotados no processo de treinamento, foi estabelecido um critério de 50.000 épocas máximas de treinamento, levando em consideração um erro de 10^{-5} . Além disso, a taxa de aprendizado escolhida foi de 0,01.

Pode-se ver na Figura 8 o Erro Quadrático Médio (EQM) do processo de treinamento para cada época. Neste caso específico, que resultou em um erro de 0,060413, foram necessárias as 50.000 épocas de treinamento. Este caso ilustra o que mais ocorreu durante a fase de treinamento, isto é, o EQM manteve-se na faixa de 0,01 a 0,1. A minoria dos casos referiu-se à convergência tomando por base o critério de erro adotado. O erro médio, adotando 5 simulações de treinamentos ao acaso, foi de 0,0451.

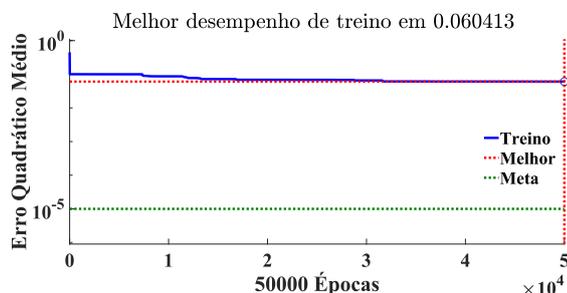


Figura 8. Performance do melhor caso durante o treinamento da RNA proposta.

Adotando o critério de acerto proposto na Seção 3 para os casos em que se alcançou o erro da ordem de 10^{-5} , observou-se um acerto de 100 % dos casos de testes. Ou seja, todas as 42 situações de faltas consideradas, e que re-

caíram no trecho 1, foram corretamente reconhecidas pela RNA, como de fato neste trecho 1. O mesmo acontecendo com todas as 42 situações de faltas consideradas sobre o trecho 2.

A Figura 9 ilustra as respostas obtidas por parte da RNA para os 42 primeiros casos, onde estas situações de faltas foram aplicadas no trecho 1 da LT. Na mesma figura, as outras 42 respostas que vêm na sequência ilustram a resposta da RNA para as situações de faltas que recairão no trecho 2. Vale destacar nesta figura os dois limiares de 0,1 e 0,9 que foram adotados para considerar as respostas da RNA iguais à zero ou a um, respectivamente. Dado que os resultados relativos ao trecho 1 ficaram muito próximos de 0 e os relativos ao trecho 2, muito próximos de 1, optou-se por destacar um ponto de cada caso para ilustrar a ordem de grandeza dos resultados obtidos.

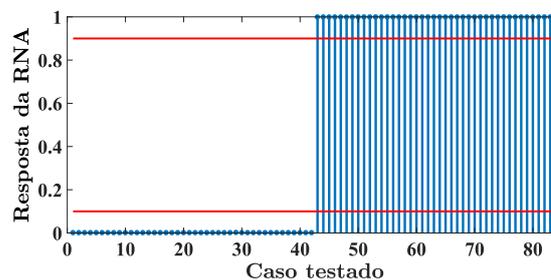


Figura 9. Respostas obtidas por parte da RNA para o problema formulado.

6. CONCLUSÃO

Levando em consideração a metodologia proposta, pode-se considerar que a mesma respondeu satisfatoriamente e que os resultados obtidos são promissores, pois pelo conjunto de testes até então considerado, foi possível observar 100 % de acerto em todas as situações testadas. De fato, a associação do pré-processamento dos dados na presença da falta pela TSD e pelas FDs às RNAs permitiu que a situação de falta aplicada fosse corretamente associada a um trecho da LT com compensação série.

Entretanto, o presente trabalho permite que diversas análises surjam e que diversas melhorias sejam propostas para trabalhos futuros. Neste contexto, as próximas etapas da presente pesquisa são:

- 1) Aumentar o conjunto de dados de treinamento considerando todos os tipos de faltas: monofásicas, bifásicas e bifásicas-terra, e trifásicas e trifásicas-terra;
- 2) Projetar uma nova RNA que localize em qual dos dois trechos da LT a falta do item (1) tenha ocorrido;
- 3) Projetar uma segunda RNA para atuar diretamente na classificação do tipo de falta; e
- 4) Finalmente, com a falta classificada, implementar mais um método inteligente que, com base no trecho da LT em que ocorreu a falta (item 2) e na classificação da mesma (item 3), consiga realizar de fato a localização física da ocorrência.

De fato, ainda que pareça que a quantidade de RNAs propostas seja alta, espera-se que as mesmas tenham uma

topologia simples (poucas camadas intermediárias com um número reduzido de neurônios), uma vez que se espera funções mais simples e que apresentem padrões ainda mais representativos para as redes PMC a serem treinadas. Ressalta-se que o pré-processamento para todas as RNAs propostas será realizado com base na aplicação da TSD, tendo-se, então, um sistema de proteção completo para LTs baseado somente em sistemas inteligentes.

AGRADECIMENTOS

Os autores gostariam de agradecer ao Laboratório de Sistemas de Energia Elétrica (LSEE), da Escola de Engenharia de São Carlos (EESC - USP) pela infraestrutura proporcionada, assim como ao CNPq (Conselho Nacional de Desenvolvimento Científico e Tecnológico) pelo suporte financeiro disponibilizado.

REFERÊNCIAS

- Ahmed, N., Zhongdong, Y., Mumtaz, T., Ather, T., Rudy, K., and S.Murtaza (2022). Comprehensive comparative analysis of tcsc on power flow regulation in hvac system. In *2022 International Conference on Power Energy Systems and Applications (ICoPESA)*, 326–330. doi:10.1109/ICoPESA54515.2022.9754443.
- Biswas, S., Nayak, P., and Pradhan, G. (2020). An emd-dt assisted intelligent protection scheme for tcsc compensated transmission lines. In *2020 IEEE Power Energy Society General Meeting (PESGM)*, 1–5. doi:10.1109/PESGM41954.2020.9281397.
- Conceição, J. (2015). Análise de transitórios em linhas de transmissão com compensação série. Trabalho de conclusão de curso (Bacharelado em Engenharia Elétrica), Universidade de Brasília, Brasília.
- Dash, B. (2022). Stockwell transform (s-transform). URL <https://www.mathworks.com/matlabcentral/fileexchange/45848-stockwell-transform-s-transform>.
- Gandhi, P. and Darji, P. (2022). Performance evaluation of tcsc and gcsc for damping of torsional oscillations. In *2022 IEEE International Conference on Power Electronics, Smart Grid, and Renewable Energy (PESGRE)*, 1–6. doi:10.1109/PESGRE52268.2022.9715945.
- Hingorani, N. and Gyugyi, L. (2000). *Understanding FACTS: Concepts and Technology of Flexible AC Transmission Systems*. IEEE Press, Piscataway.
- Jamhoria, S. and Srivastava, L. (2014). Applications of thyristor controlled series compensator in power system: An overview. In *2014 International Conference on Power Signals Control and Computations (EPSCICON)*, 1–6. doi:10.1109/EPSCICON.2014.6887516.
- Jovcic, D. and Pillai, G. (2005). Analytical modeling of tcsc dynamics. *IEEE Transactions on Power Delivery*, 20, 1097–1104.
- Kang, S., Hong, H., and Son, Y. (2020). A fault location algorithm using estimated voltage drop across tcsc bank in a series compensated transmission line. In *15th International Conference on Developments in Power System Protection (DPSP 2020)*, 1–6. doi:10.1049/cp.2020.0101.
- Khederzadeh, M. (2007). Application of tcsc to enhance power quality. In *2007 42nd International Universities Power Engineering Conference*, 607–612. doi:10.1109/UPEC.2007.4469017.
- Kothari, N., Tripathi, P., Bhalja, B., and Pandya, V. (2020). Support vector machine based fault classification and faulty section identification scheme in thyristor controlled series compensated transmission lines. In *2020 IEEE-HYDICON*, 1–5. doi:10.1109/HYDICON48903.2020.9242719.
- Liu, J., Ding, L., Cai, D., and Song, Z. (2015). The application of tcsc for damping inter-area oscillations. In *2015 IEEE PES Asia-Pacific Power and Energy Engineering Conference (APPEEC)*, 1–4. doi:10.1109/APPEEC.2015.7381060.
- Mirzaei, M., Vahidi, B., and Hosseinian, S. (2018). Fault location on a series-compensated three-terminal transmission line using deep neural networks. *IET Science, Measurement & Technology*, 12, 746–754(8).
- Prasad, C. and Biswal, M. (2020). Time-domain current information based faulty phase detection in thyristor controlled series compensated transmission system. In *2020 International Conference on Power, Instrumentation, Control and Computing (PICC)*, 1–5. doi:10.1109/PICC51425.2020.9362498.
- Sahoo, B. and Samantaray, S. (2017). An enhanced traveling wave-based fault detection and location estimation technique for series compensated transmission network. In *2017 7th International Conference on Power Systems (ICPS)*, 61–68. College of Engineering Pune, IEEE, Pune.
- Silva, I., Spatti, D., and Flauzino, R. (2016). *Redes Neurais Artificiais para Engenharia e Ciências Aplicadas*. Artliber, São Paulo.
- Souza, S. (2015). *Uso de redes neurais artificiais e transformada de Stockwell na localização de faltas em linhas de transmissão*. Mestrado em engenharia elétrica, Departamento de Engenharia Elétrica, Universidade Federal do Ceará, Fortaleza.
- Stockwell, R., Mansinha, L., and Lowe, R. (1996). Localization of the complex spectrum: the s transform. *IEEE Transactions on Signal Processing*, 44(4), 998–1001. doi:10.1109/78.492555.
- Tavares, M., Campos, P., and Prado, P. (2003). *Guia Resumido do ATP - Alternative Transient Program*. URL <http://www.dsce.fee.unicamp.br/~crisina/pos%20graduacao/GUIA.ATP.pdf>.
- Zand, M., Neghabi, O., Nasab, M., Eskandari, M., and Abedini, M. (2020). A hybrid scheme for fault locating in transmission lines compensated by the tcsc. In *2020 15th International Conference on Protection and Automation of Power Systems (IPAPS)*, 130–135. doi:10.1109/IPAPS52181.2020.9375626.