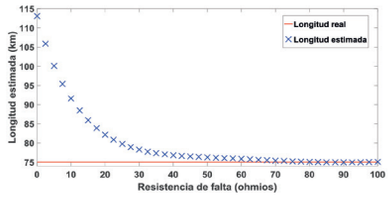
Localización de faltas en enlaces de tipo VSC-HVDC usando redes neuronales



Fault location in a VSC-HVDC link using neural networks

Paula Páramo-Balsa, Juan-Manuel Roldán-Fernández, Francisco González-Longatt, Manuel Burgos-Payán y Jesús Riquelme-Santos
Universidad de Sevilla. Departamento de ingeniería eléctrica. Camino de los Descubrimientos, s/n - 41092 Sevilla (España).

DOI: http://dx.doi.org/10.6036/9637 | Recibido: 14/01/2020 • Inicio Evaluación: 16/01/2020 • Aceptado: 07/04/2020

ABSTRACT

- High-voltage direct current (HVDC) using voltage source converter (VSC) in transmission systems applications are currently a competitive alternative to the traditional AC transmission systems, especially for offshore wind power applications. The increases of rated power and distance to the shore have made VSC-HVDC transmission systems economically more efficient than the conventional solution based on AC lines. Locating a fault in a submarine DC line must be fast and accurate because of the high cost of the submarine repairs as well as the operation cost (not-supplied energy). This paper proposed a fault location methodology based on artificial neural networks (ANN) for VSC-HVDC transmission system. The methodology only uses instantaneous values of electrical quantities (voltage and current) at one of the VSC terminal eliminating the problem of synchronisation. The proposed methodology has been tested and demonstrated using a typical VSC-HVDC test network, and simulation results show the appropriate performance of the methodology.
- **Keywords:** Artificial Neural Networks, Fault Location, HVDC Transmission, VSC-HVDC.

RESUMEN

Actualmente, las aplicaciones en los sistemas de corriente continua en alta tensión (HVDC) con convertidores en fuente de tensión (VSC) es una buena alternativa a los sistemas de CA tradicionales, especialmente en aplicaciones de energía eólica marina. Los sistemas de transmisión VSC-HVDC resultan más eficientes económicamente que la solución convencional basada en líneas de CA debido a los aumentos de potencia nominal y distancia hasta la costa. La localización de una falta en una línea submarina DC debe ser rápida y precisa debido al elevado coste de las reparaciones, así como el coste de operación (energía no suministrada). Este documento propone una metodología basada en la localización de faltas usando redes neuronales artificiales para el sistema VSC-HVDC. La metodología emplea los valores instantáneos de las magnitudes eléctricas (tensión e intensidad) en uno de los terminales VSC, eliminando así el problema de sincronización. La metodología ha sido probada y demostrada usando un sistema de prueba VSC-HVDC, y los buenos resultados obtenidos demuestran la eficacia de la metodología desarrollada.

Palabras clave: Redes neuronales artificiales, Localización de faltas, Transmisión HVDC, VSC-HVDC.

1. INTRODUCCIÓN

Actualmente, la tecnología HVDC (*High Voltage Direct Current*) se encuentra en pleno desarrollo [1]. Ésta representa la forma más adecuada de transportar energía en líneas de elevada longitud, puesto que la potencia transmitida es independiente de la distancia en este tipo de líneas [2], a diferencia de los HVAC cuya capacidad de transporte de la línea disminuye conforme se incrementa la distancia. Además, en los sistemas HVAC la inductancia de la línea genera desfases entre los extremos de ésta, lo que provoca inestabilidad en el sistema. Esto último no se produce en los sistemas HVDC. Otra de las ventajas en comparación con los sistemas HVAC es que los sistemas en DC permiten conectar áreas que trabajan a distinta frecuencia [3]. En términos económicos, un sistema HVDC presenta menor coste de inversión y mayor eficiencia para líneas de elevada longitud [4]. Además, gracias a los avances tecnológicos en electrónica de potencia, esta tecnología es idónea para la sincronización de plantas renovables con la red [5], incluyendo los sistemas eólicos offshore. Los sistemas HVDC se pueden clasificar en función de, principalmente, dos tipos de tecnologías: LCC (*Line Commutated Converter*), basada en tiristores, y VSC (*Voltage Source Converter*), basada en IGBTs. Ésta última es la más usada actualmente debido a su versatilidad, menor tasa de distorsión armónica y a que permite un control de la potencia activa y reactiva [6], a diferencia del LCC que únicamente controla activa [7]. Además, con la mejora de la tecnología de los VSC multinivel modulares, la ventaja en términos de eficiencia que hace un tiempo proporcionaban los LCC ya no es relevante. Sin embargo, la tecnología VSC-HVDC posee desventajas tales como la complejidad de los sistemas de protección y su vulnerabilidad ante una falta, debido a la incapacidad de controlar la corriente de cortocircuito en caso de falta en DC. Los diodos en antiparalelo permiten el paso de la corriente aun abriendo los IGBTs mientras que, en el caso de un tiristor, se puede cortar la sobrecorriente actuando sobre el ángulo de disparo [8]. Por otra parte, en los cables submarinos DC de elevada longitud resulta complicado establecer con precisión la localización de una falta para su reparación, y posterior restablecimiento del servicio. Por ello, la operación de estos sistemas VSC-HVDC requiere de métodos de localización fiables, rápidos y precisos para mantener la estabilidad del sistema [9]. De entre todos los métodos de localización de faltas, cabe destacar (i) *método de ondas viajeras* y (ii) *método de análisis de fallos*. El primer método [10-11] es complejo ya que exige mucha información sobre la dinámica de la corriente durante la falta, además de sensores de tensión preparados para altas frecuencias.

El segundo método se basa en parámetros del sistema y en las magnitudes eléctricas durante la falta. Éste presenta el problema de la incertidumbre de los parámetros eléctricos del sistema [12] y la falta de sincronización entre las dos medidas en el extremo del sistema.

Este artículo propone una metodología para estimar la localización de una falta aplicada a un sistema VSC-HVDC bipolar de tipo punto a punto. La metodología se basa en las Redes Neuronales Artificiales (RN en adelante), que son alimentadas con las magnitudes de tensión e intensidad durante el transitorio de la falta. Esta técnica se ha usado en muchas investigaciones con resultados muy satisfactorios. Sin embargo, una de las grandes problemáticas de este tipo de redes es la complejidad en su creación ya que no existe un guía sobre cómo construir una RN con todos sus parámetros y qué factores se deben tener en cuenta para su obtención [13-17]. La inteligencia artificial, y en concreto, las redes neuronales, están demostrando su eficacia en numerosas ramas de la ingeniería eléctrica, a pesar de estar en sus primeras fases de desarrollo en el sector. Por ello, este artículo tiene dos objetivos, en primer lugar, estimar la localización de una falta en un sistema VSC-HVDC y, en segundo lugar, la construcción paso a paso de la RN, donde se desarrolla la obtención de todos sus parámetros, de forma que se facilite a los investigadores el diseño de estos algoritmos y se fomente su penetración en el sector eléctrico.

2. MATERIAL Y MÉTODOS

Las RN son idóneas en la localización de faltas en sistemas VSC-HVDC ya que pueden modelar sistemas complejos altamente no lineales y que no poseen una ecuación única. Se entrenan para aprender una respuesta en base a unos datos de entrada y salida deseados. Las RN más usadas son las Multi-Layer Perceptron (MLP). Los perceptrones en una capa de la MLP están totalmente conectados a la siguiente y existe un peso (w_i) asociado a cada conexión. Durante el aprendizaje, la RN es alimentada con un vector de entradas (p) y otro con las salidas deseadas (a). El aprendizaje se produce al modificar los pesos de las conexiones en función del error en la salida de la RN con respecto a la salida deseada. En la MLP, para obtener dichos errores se usa el algoritmo de propagación hacia atrás (*Backpropagation*). Una vez que la RN se entrena, se puede introducir una nueva entrada y obtener así la estimación de la salida. La metodología propuesta se basa en la obtención de los datos de entrenamiento, creación de la RN y desarrollo del entrenamiento de la RN.

2.1. DATOS DE ENTRENAMIENTO

Este subapartado tiene por objetivo determinar el vector de entrada de la RN, (p), y el vector de salida deseada (a).

Para ello, se miden las magnitudes de tensión e intensidad durante una falta en la estación convertidora VSC-HVDC resultando: $V= [v_1, v_2, \dots v_{ns}]^T$ (1), $I= [i_1, i_2, \dots i_{ns}]^T$ (2), donde *ns* representa el número de puntos dentro del intervalo de tiempo δt a la frecuencia de muestreo, f_s. Es importante recordar que las magnitudes de tensión e intensidad van a variar en función de la posición de la falta, x_i, y de la resistencia de falta, R_f, para los distintos casos de entrenamiento.

Ambos vectores (1) y (2) constituyen el vector de entradas, $p^x_{Rf}=[V^x_{Rf}\ I^x_{Rf}]^T$ (3), donde el superíndice x representa las posiciones de faltas consideradas, $x = [x_1\ x_2, \dots x_n]^T$ (4), y donde R_f representa la resistencia de falta, $R_f= [R_{f1}, R_{f2}, \dots R_{fn}]^T$ (5). El vector de salida deseado (a), representa la posición de la falta, es decir, $a = x = [x_1\ x_2, \dots x_n]^T$ (6).

2.2. CREACIÓN DE UNA RN

Las RN se definen en función del número de neuronas distribuidas por las capas, las conexiones y los pesos. Los datos se introducen en la *capa de entrada*, pasan a través de la *capa oculta* y, por último, el producto sale por la *capa de salida*. Las RN se pueden clasificar en: (i) *Redes de propagación hacia adelante (feed-forward, FF en adelante) y* (ii) *Redes de propagación hacia atrás (feed-back, FB en adelante).* En las redes FF ninguna salida neuronal es entrada de unidades de la misma capa o capas precedentes. La información circula únicamente de las neuronas de entrada hacia las de salida. En las redes FB las salidas de las neuronas pueden servir de entradas a unidades del mismo nivel o niveles previos.

Para este artículo se utilizan las redes FF. Éstas se clasifican en: *Feed-forward net* (FFN en adelante) y *Cascade-forward net* (CFN en adelante).

- En FFN la entrada está conectada a un grupo de capas ocultas que usan como función de transferencia la *sigmoide*, unidas a una capa de salida que usa una función lineal. Cada neurona tiene un peso definido por el vector **w**; $\mathbf{w} = [w_{1,1}, w_{1,2}, \dots w_{1,R}]^T$ (7), **b** representa el sesgo y $\mathbf{n = w \cdot p + b}$ (8) la entrada neta.
- CFN es similar a FFN salvo por una conexión adicional que va desde la entrada a la capa salida, sin pasar por las capas ocultas.

Por otra parte, se ha demostrado que cualquier arquitectura con características similares a MLP requiere un máximo de dos capas ocultas. Además, dado que para obtener resultados óptimos es suficiente con una capa oculta [18], se decide usar una.

Las entradas que reciben las neuronas llevan asociadas un peso que va cambiando en el proceso de aprendizaje. Dichos pesos se obtienen iterativamente de forma que se minimice el error. Sin embargo, en la fase anterior puede ocurrir un fenómeno indeseado denominado sobreaprendizaje *(overfitting)* que provoca que la RN memorice los datos de entrenamiento. Esto provocaría la pérdida de generalización de la RN y con ello la capacidad de aprender nuevos casos. Para evitarlo, los datos de entrada se dividen en: (i) *Grupo de entrenamiento*, (ii) *Grupo de validación* y (iii) *Grupo de test*. El primero se usa para entrenar la RN y permite que los pesos varíen en función de sus características y valores. El segundo se usa para ajustar ciertos parámetros asociados al entrenamiento. El tercero sirve para comprobar la fiabilidad de la RN ante estímulos previamente no usados.

2.3. PROCESO DE ENTRENAMIENTO DE LA RN

El algoritmo de entrenamiento escogido es *Levenberg-Marquardt* por ser potente y obtener muy buenos resultados [19]. Además, cabe destacar el uso del algoritmo *Backpropagation* (BP en adelante) por su eficacia en la resolución de problemas complejos cuya base se centra en el método del gradiente descendente. Este algoritmo consta de dos etapas: (i) *Aprendizaje hacia adelante* y (ii) *Aprendizaje hacia atrás.* En la primera etapa, los patrones de entrada se sitúan en la primera capa de la RN, que propaga los valores a través de todas las capas posteriores hasta la salida. En la segunda etapa, se compara la salida obtenida con la deseada, generándose así un valor de error para cada neurona de la última capa. Estos errores se transmiten de la capa de salida hacia cada una de las neuronas de la capa intermedia. Este proceso se repite

capa a capa hasta completar todas las neuronas. A partir de ese error, se reajustan los pesos de cada neurona minimizándose el error. La función del error a minimizar se puede expresar de diversas formas, destacando: (i) *Error cuadrático medio* (*MSE* en adelante), (ii) *Raíz del error cuadrático medio* (*RMSE* en adelante) y (iii) *Error medio absoluto* (MAE en adelante):

$$MSE = \frac{1}{2}\sum_{i=1}^{P}\sum_{j=1}^{M}\left(y_{ij} - t_{ij}\right)^2 \quad (9)$$

$$RMSE = \sqrt{MSE} \quad (10)$$

$$MAE = \frac{1}{2}\sum_{i=1}^{P}\sum_{j=1}^{M}\left|y_{ij} - t_{ij}\right| \quad (11)$$

donde M representa el número de variables y P representa el número de patrones. Además, y_{ij} es la componente j-ésima de la salida deseada para el patrón i-ésimo, y t_{ij} la componente j-ésima de la salida para el patrón i-ésimo.

El método de entrenamiento usado es el denominado *Con validación cruzada*, debido a los buenos resultados prácticos [20]. Éste consiste en entrenar la red k =10 veces, calculando los errores en cada uno de los casos y, posteriormente, obteniendo el error global. De esta forma, se evita la aparición del sobreaprendizaje y con ello la pérdida de generalización.

3. SIMULACIÓN Y ENTRENAMIENTO DE LA RN

El sistema de prueba consiste en un sistema HVDC compuesto por dos estaciones convertidoras de tipo VSC bi-polar (± 640 kV), identificados por el extremo emisor y receptor, unidos por un cable submarino por polo de 100 km.

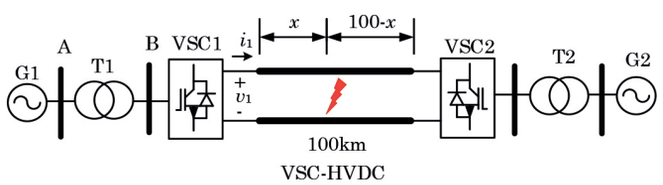


Fig. 1: Sistema de prueba

El sistema posee los siguientes parámetros: potencia en DC de 1000 MW, tensión AC (línea a línea) de 133 kV, tensión DC (línea a línea) de 640 kV, resistencia del cable de DC de 0.0186 Ω/km, inductancia del cable de DC de 7.87641e^{-04} H/km, capacidad del cable de DC de 0.21 μF/km y la frecuencia en el lado de AC de 50 Hz. El sistema se ha desarrollado con el programa PSCAD donde se han llevado a cabo las simulaciones tipo EMT de una falta tipo fase-tierra.

El vector de entrada, $\mathbf{p}^{\mathbf{x}}_{\mathbf{Rf}} = [\mathbf{V}^{\mathbf{x}}_{\mathbf{Rf}}\ \mathbf{I}^{\mathbf{x}}_{\mathbf{Rf}}]^T$ (12), es una ventana de datos de 1.0 ms y una frecuencia de muestreo de 20 kHz usando medidas de tensión (**V**) e intensidad (**I**) desde un terminal. El vector de entrada se puede interpretar como un conjunto de sub-vectores $\mathbf{p}^{\mathbf{x}}_{\mathbf{Rf}}$ donde **x** representa la localización exacta de la falta y $\mathbf{R_f}$ la resistencia de falta. Los valores de R_f usados son $\mathbf{R_f}$ = [0.0, 5.0 y 10.0] ^{T} Ω (13). Para líneas submarinas, los valores R_f son bajos (hierro o agua salada entre conductor y pantalla) [21-23].

La longitud del vector de entrada para cada R_f y posición de la falta, x, es de 2nx1 = 40x1 muestras. Se simulan faltas cada 1km a lo largo de toda la línea, por lo que existen 99 vectores para cada R_f, es decir, 297 vectores.

El vector de salida deseado contiene las distancias medidas en por unidad a las que se produce la falta en función de R_f; **a** = [x_1/ℓ x_2/ℓ, ... x_n/ℓ]^T (15). Los primeros 99 elementos para R_f = 0 Ω, del 100 al 198 para R_f = 5 Ω y los restantes para R_f = 10 Ω.

Una vez creado el vector de entrada y salida deseada a partir de las simulaciones de PSCAD, para el desarrollo de la RN se utiliza *Neural Network Toolbox* de Matlab.

La división de los datos del vector de entrada es de 237 vectores para el entrenamiento, 30 para validación y 30 para test, evitándose así el sobreaprendizaje de la RN.

Al no existir una guía sobre cómo calcular determinados parámetros de la RN, se decide realizar una serie de estudios para obtener el número de capas ocultas, los límites del criterio de entrenamiento (LCE en adelante) y el número de neuronas por capa.

3.1. CÁLCULO DE LOS LÍMITES DEL CRITERIO DE ENTRENAMIENTO

Éstos se van a determinar a partir del *índice de correlación, R,* que establece la proximidad entre la salida obtenida y deseada. Para el cálculo de las neuronas en la capa oculta se utiliza las reglas *ad hoc* que, aunque no son matemáticamente justificables, han demostrado un buen comportamiento [18]. La *Regla de la pirámide geométrica* establece el número de neuronas para una única capa oculta como: $N_c = \sqrt{N * M}$ (16), con M el número de neuronas de salida y N el número de variables de entrada. Para este caso, N = 40 y M = 1, resulta N_c = 6.32. Al no ser un valor exacto, se escogen los valores enteros, por defecto y por exceso, es decir, 5, 6 y 7 neuronas. A partir de éstas, se realizan una serie de pruebas para calcular los LCE.

Para ello, se generan los siguientes pasos partiendo de la RN con estructura CFN y N_c=6:

- Fijar los LCE a los valores por defecto que establece Matlab
- Entrenar la RN diez veces
- Observar el primero de los diez entrenamientos realizados, y determinar por cuál de los cinco LCE se ha detenido
- Aumentar el valor del LCE que ha ocasionado la parada
- Volver al segundo paso

$$\begin{matrix} \overbrace{\quad R_f = 0\Omega \quad} & & & \overbrace{\quad R_f = 5\Omega \quad} & & & \overbrace{\quad R_f = 10\Omega \quad} & & \\ \left[\begin{matrix} V_1^{L=1km} & \cdots & V_1^{L=99km} \\ \vdots & & \vdots \\ V_n^{L=1km} & \cdots & V_n^{L=99km} \\ I_1^{L=1km} & \cdots & I_1^{L=99km} \\ \vdots & & \vdots \\ I_n^{L=1km} & \cdots & I_n^{L=99km} \end{matrix}\right. & & \left.\begin{matrix} V_1^{L=1km} & \cdots & V_1^{L=99km} \\ \vdots & & \vdots \\ V_n^{L=1km} & \cdots & V_n^{L=99km} \\ I_1^{L=1km} & \cdots & I_1^{L=99km} \\ \vdots & & \vdots \\ I_n^{L=1km} & \cdots & I_n^{L=99km} \end{matrix}\right. & & \left.\begin{matrix} V_1^{L=1km} & \cdots & V_1^{L=99km} \\ \vdots & & \vdots \\ V_n^{L=1km} & \cdots & V_n^{L=99km} \\ I_1^{L=1km} & \cdots & I_1^{L=99km} \\ \vdots & & \vdots \\ I_n^{L=1km} & \cdots & I_n^{L=99km} \end{matrix}\right]_{2n\,x\,297} \end{matrix} \quad (14)$$

El criterio para finalizar el bucle es un número máximo de iteraciones, doce. El motivo es que, a partir de éstas, el tiempo que necesita la RN para ser entrenada es muy elevado. Una vez que se han realizado todos los pasos, se repite para N_c={5, 7} y, de igual forma, para FFN.

A partir de los resultados, se observa que la RN proporciona prácticamente la misma salida en cada entrenamiento independientemente de los LCE. Se escogen los LCE: *Iteraciones=1000*, *Rendimiento=0*, *Gradiente=1.00x10^{-6}* y *Número de comprobaciones=1000,* por ser los que tienen un menor tiempo de simulación. A continuación, se analiza según la estructura de la RN dónde se han obtenido los coeficientes de correlación más cercanos a la unidad y para qué número de N_c se produce. Así, los mejores resultados se dan para FFN, N_c = 5 y CFN, N_c = 6.

3.2. CÁLCULO DEL NÚMERO DE NEURONAS DE LA CAPA OCULTA

El objetivo de esta subsección es comprobar que el valor de N_c establecido en la anterior subsección es correcto, ya que los índices *R* en algunos casos son similares. Para ello, se calculan los errores *MAE*, *MSE* y *RMSE*.

	FFN			CFN		
N_c	5	6	7	5	6	7
MAE	**6.47x10^{-4}**	7.07x10^{-4}	0.004	0.0256	**0.0021**	0.0043
MSE	**3.00x10^{-5}**	4.28x10^{-5}	0.0012	0.0016	**1.86x10^{-4}**	5.86x10^{-4}
RMSE	**0.0055**	0.065	0.0346	0.0400	**0.0136**	0.0242

Tabla 1. Errores MAE, MSE y RMSE según estructura y neuronas ocultas

Errores				Índice correlación
Estructura	*MSE (pu)*	*RMSE (pu)*	*MAE (pu)*	*R*
FFN	5.453x10^{-4}	0.0234	0.0058	0.9965
CFN	0.0906	0.3009	0.0333	0.8730

Tabla 2: Errores e índice de correlación según estructura

Errores				Índice correlación
Estructura	*MSE (pu)*	*RMSE (pu)*	*MAE (pu)*	*R*
FFN	0.0305	0.1746	0.0289	0.9551
CFN	7.7335	2.7809	0.3050	0.7081

Tabla 3: Errores e índice de correlación tras señal perturbada según estructura

Los errores más bajos coinciden con las estructuras y N_c obtenidas, por ello se fijan los valores en FFN, N_c = 5 y CFN, N_c = 6.

3.3. RESULTADOS DEL ENTRENAMIENTO DE LA RN

Una vez que se han determinado todos los parámetros de la RN, se procede al entrenamiento con el método *Con validación cruzada*.

A continuación, se muestran las rectas de regresión para cada estructura en función de R_f.

Estas rectas establecen la relación entre la longitud estimada y la longitud real. En la Fig. 2 se observa que, independientemente de R_f, las estimaciones son muy próximas a los valores reales. Con lo cual, queda vigente la potencia de la RN creada para cada estructura.

Para comprobar la robustez de la RN, se calculan los errores e índices de correlación.

Con la Tabla 2 queda vigente que la estructura FFN es la que proporciona mejores estimaciones en la localización de una falta debido a sus menores errores y mayor índice de correlación.

3.3.1. Adición de ruido a una señal a la RN entrenada

Los entrenamientos de la sección anterior utilizan "señales limpias", es decir, sin tener en cuenta los errores propios de los equipos de medida (ruido de la señal). Aunque éste puede ser filtrado, su eliminación completa no es posible. En esta subsección se estudia el comportamiento de la RN al introducirle una serie de perturbaciones en forma de ruido a la entrada. Esto permite analizar la robustez y potencia de la RN de cada una de las estructuras seleccionadas. Al vector de entrada (**p**) se le agrega un vector de ruido $\boldsymbol{\Theta}(\mu,\sigma)$ generado de forma aleatoria con una distribución gaussiana de media (μ) cero y desviación típica del σ= ±1%. La nueva señal ruidosa ($\mathbf{p}^{\boldsymbol{\Theta}}$) es usada en los entrenamientos para cada estructura y método.

Tras añadir dicho ruido, se calculan en ambas estructuras los errores e índices de correlación.

Tal y como era de esperar, el ruido ha provocado un aumento en los errores de ambas estructuras. Para CFN se aprecia un elevado incremento de los errores frente a los de la Tabla 2, por lo que no proporciona buenas estimaciones tras añadir perturbaciones a la señal. Esto también se aprecia en el índice de correlación, que se aleja de la unidad. Sin embargo, para FFN, los incrementos en los errores han sido reducidos y su índice de correlación sigue siendo cercano a la unidad, por lo que proporciona estimaciones muy cercanas a los valores reales. De esta forma, queda vigente la potencia de la RN creada con FFN que, a pesar de haberse modificado su entrada, continúa proporcionando muy buenas estimaciones.

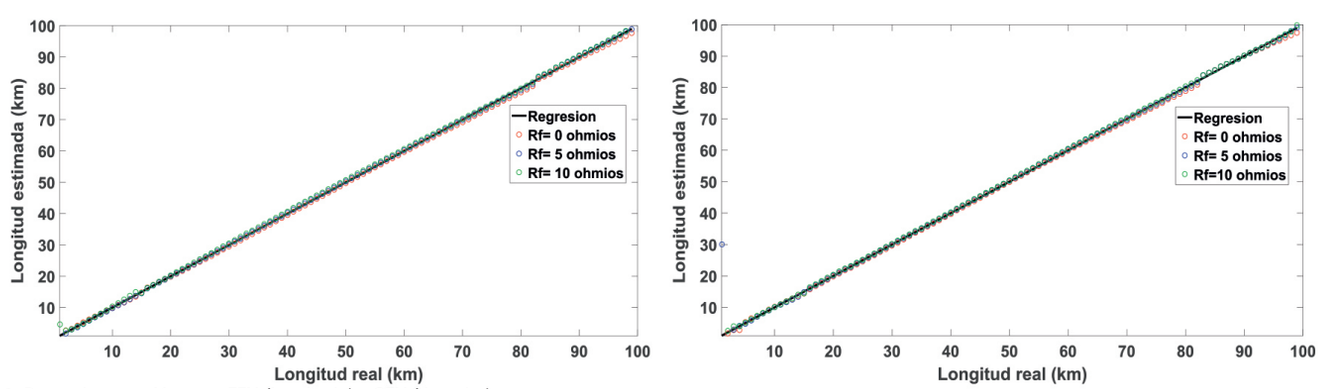


Fig. 2. Recta de regresión para FFN (izquierda) y CFN (derecha)

3.3.2. Adición de nuevas entradas a la RN entrenada

El objetivo de esta subsección es determinar la respuesta de la RN, previamente entrenada con R_f = [0, 5, 10] Ω, cuando se introducen nuevas entradas. Para ello, se analizan dos situaciones:

- Nueva entrada con R_f cercanas a los valores usados durante los entrenamientos
- Nueva entrada con R_f alejadas de los valores usados durante los entrenamientos

3.3.2.1. Nueva entrada con R_f bajas

La Tabla 4 muestra, en porcentaje, el error relativo obtenido de la estimación de la localización de la falta según R_f. Se han seleccionado cinco localizaciones (*x*) y seis valores de R_f.

Los resultados muestran que incrementos en R_f producen mayores errores. Sin embargo, estos errores no son muy elevados por lo que la RN continúa obteniendo buenas estimaciones. Es importante resaltar que, para valores de R_f superiores a 15 Ω, los errores van a ir aumentando progresivamente ya que los entrenamientos

Localización de la falta, x (km)	R_f (Ω)					
	0	2.5	5	7.5	10	15
5	4.724	3.050	2.565	2.444	2.840	8.519
25	0.138	0.012	0.082	0.230	0.334	0.622
50	0.008	0.026	0.035	0.037	0.035	0.029
75	0.093	0.053	0.044	0.063	0.107	0.266
100	0.235	0.076	9.7e-5	0.019	0.034	0.373

Tabla 4: Resultados del % del error relativo en la localización de la falta

han sido realizados con R_f = [0, 5, 10] Ω. Al tratarse de una línea submarina, los valores de R_f son bajos, por lo que la RN para FFN proporciona buenas estimaciones ante nuevas entradas con R_f bajas.

Aun así, se decide analizar la respuesta de la RN a entradas con R_f elevadas. Para ello, se introducen nuevas entradas con variaciones de R_f = 0 Ω hasta R_f = 100 Ω con incrementos de 2.5 Ω en 2.5 Ω para cada simulación. De esta forma, se determina cómo se ve afectada la estimación de la RN conforme aumenta R_f y se aleja de los valores de R_f usados durante el entrenamiento. En la Fig. 3, se observan las estimaciones de la RN según R_f para una longitud real de la falta de 75 km.

En la Fig. 3 se observa que, para valores de R_f cercanos a los usados durante los entrenamientos, las estimaciones son muy cercanas a la longitud real.

Como se esperaba, las estimaciones en torno a los valores de R_f usados durante los entrenamientos son muy cercanas al valor real.

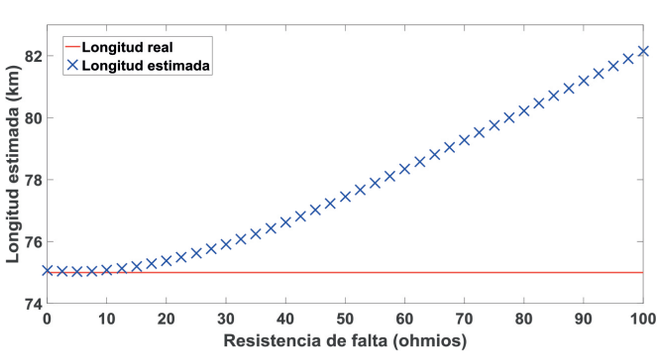


Fig. 3: Longitudes estimadas por la RN original según el valor de R_f

3.3.2.2. Nuevas entradas con R_f altas

En la Fig. 3 se aprecia que, conforme aumenta el valor de R_f de la nueva entrada, las longitudes estimadas divergen paulatinamente de la longitud real. Sin embargo, éstas no presentan unos errores relativos excesivamente elevados. Por ejemplo, para R_f = 50 Ω la longitud estimada es de 77.5 km, es decir, un error relativo del 3.3 %. Para el caso de R_f = 100 Ω, la longitud estimada es de 82.15 km, es decir, un error relativo del 9.5 %. Analizando dichos errores relativos, queda constancia de la potencia de la RN entrenada en este artículo, ya que es capaz de obtener errores inferiores al 10 %, incluso cuando se le añaden nuevas entradas con valores de R_f muy alejados de los usados durante el entrenamiento de la red.

Por otro lado, se decide realizar un último estudio para demostrar que, en función de cómo sean los datos con los que se entrene la RN, las estimaciones que se obtienen a partir de nuevas entradas van a ser diferentes. Para ello, se decide crear y entrenar una nueva RN en este subapartado. Las diferencias respecto a la RN utilizada a lo largo de toda esta investigación son los valores de R_f con los que se entrena. En esta nueva RN se utiliza como vector de entrada los valores de tensión e intensidad para cada localización, x, con R_f = [75, 85, 100] Ω. Una vez que se entrena,

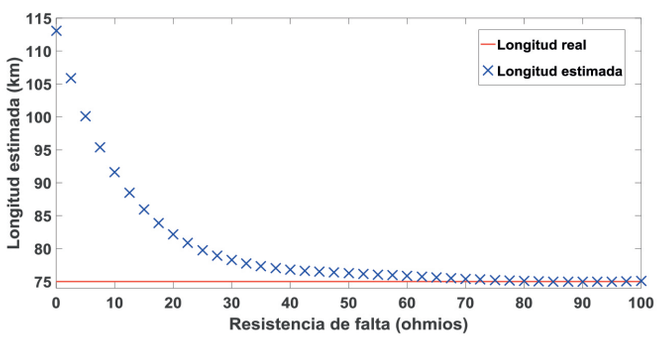


Fig. 4: Longitudes estimadas por la nueva RN según el valor de R_f

se analiza cómo son las estimaciones tras añadir nuevas entradas con variaciones de R_f = 0 Ω hasta R_f = 100 Ω con incrementos de 2.5 Ω en 2.5 Ω para cada simulación. En la Fig. 4, se observan las estimaciones de la nueva RN según R_f para una longitud real de 75 km.

En la Fig. 4 se observa que, para entradas con valores de R_f cercanos a los usados durante el entrenamiento, las estimaciones son muy precisas.

4. CONCLUSIONES

Este artículo establece una metodología para estimar la localización de una falta en un sistema VSC-HVDC. Para ello, se simulan una serie de faltas a lo largo de la línea con PSCAD y se obtienen las magnitudes de tensión e intensidad. A partir de dichas magnitudes, se obtiene el vector de entradas y salida deseado. A continuación, se construye la RN con ayuda de *Neural Network* de Matlab. Para ello, se desarrolla paso por paso el cálculo y elección de todos sus parámetros. El método de entrenamiento escogido es *Con validación cruzada*, con k=10 iteraciones, ya que de esta forma se evita el sobreaprendizaje de la red. Además, se ha añadido un apartado donde se observa la influencia en la RN del ruido en las medidas y cómo afecta a las rectas de regresión y a la estimación. En ausencia de ruido, tanto la estructura FFN como CFN presenta estimaciones muy buenas siendo mejor en FFN. Al perturbar con ruido, CFN no obtiene tan buenas estimaciones, a diferencia de FFN que sigue proporcionando muy buenos resultados, demos-

trando así la potencia de la RN con FFN. Por otra parte, se ha demostrado la potencia de la RN obteniendo buenas estimaciones para entradas distintas a las usadas durante los entrenamientos. Esto se ha comprobado para valores de $R_f = 0\ \Omega$ hasta $R_f = 15\ \Omega$ ya que, para líneas submarinas, las R_f se encuentran en dicho rango.

Por último, se analiza un último caso que tiene como objetivo resaltar la importancia en la elección de los datos de entrenamiento según las nuevas entradas que se quieran estimar. Queda demostrado que los errores relativos aumentan cuando las entradas difieren mucho de los datos usados durante el entrenamiento. Aun así, éstos se mantienen inferiores al 10 % lo que refleja la robustez de la RN creada.

REFERENCIAS

[1] S. N. Martínez Lizana. "Análisis de Sistemas de Transmisión VSC-HVDC en Condición de Contingencia DC". Enrique López Parra, tut., Trabajo Fin de Máster para optar al grado de Máster en Ciencias de la ingeniería. Universidad de Concepción, Departamento de Ingeniería Eléctrica, Chile, 2019.

[2] L. F. Cayetano Cortés. "Estudio de planeación para sistemas de potencia, incluyendo enlaces de Corriente Directa en alta tensión, basado en pérdidas de potencia activa". Daniel Guillén Aparicio, tut., Trabajo Fin de Máster para optar al grado académico de Maestro en Ciencias. Tecnológico de Monterrey, Departamento de Ingeniería Eléctrica, Monterrey, 2019

[3] W. Aguirre Zambrano, L. A. Escobar Quishpe. "Estudio de las ventajas y desventajas de usar HVDC sobre sistemas de generación eólica". Diego Carrión, tut., Trabajo Fin de Carrera para optar al título de ingeniero eléctrico. Universidad Politécnica Salesiana, Quito, 2013

[4] J. Arrillaga, Y.H. Liu, N. R. Watson, "Flexible Power Transmission: The HVDC Options". John Wiley & Sons, Ltd. 2007.

[5] X. Zhang, N. Tai, X. Zheng, and W. Huang, "Wavelet-based EMTR method for fault location of VSC-HVDC transmission lines," J. Eng., vol. 2019, no. 16, pp. 961–966, 2019.

[6] M. Larruskain, I. Zamora, O. Abarrategui, A. Iturregi. "VSC-HVDC configurations for converting AC distribution lines into DC lines". International Journal of Electrical Power & Energy Systems. 54: 589 -597. 2014

[7] J. Yang, J.E. Fletcher, and J. O'reilly. "Short-circuit and ground fault analyses and location in VSC-based DC network cables". IEEE Transactions on Industrial Electronics, 59(10), pp. 3827-3837, 2012.

[8] O. E. Oni, I. E. Davidson, and K. N. I. Mbangula, "A review of LCC-HVDC and VSC-HVDC technologies and applications," EEEIC 2016 - Int. Conf. Environ. Electr. Eng., pp. 1–7, 2016.

[9] T. C. Peng, D. Tzelepis, A. Dysko, and I. Glesk, "Assessment of fault location techniques in voltage source converter based HVDC systems," 2017 IEEE Texas Power Energy Conf. TPEC 2017, 2017.

[10] M. N. Hashim, M. K. Osman, M. N. Ibrahim, A. F. Abidin, and M. N. Mahmud, "Single-ended fault location for transmission lines using traveling wave and multilayer perceptron network," Proc. - 6th IEEE Int. Conf. Control Syst. Comput. Eng. ICCSCE 2016, no. November, pp. 522–527, 2017.

[11] K. Hosseini, S. A. Tayyebi, and M. B. Ahmadian, "Double circuit transmission lines short circuit fault location using wavelet transform and MLP," 2017 25th Iran. Conf. Electr. Eng. ICEE 2017, pp. 1336–1342, 2017.

[12] Y. Liang, G. Wang, and H. Li, "Time-Domain Fault-Location Method on HVDC Transmission Lines Under Unsynchronized Two-End Measurement and Uncertain Line Parameters," IEEE Transactions on Power Delivery, vol. 30, pp. 1031-1038, 2015.

[13] A. Capar and A. B. Arsoy, "ANN fault location algorithms with high speed training," 2017 10th Int. Conf. Electr. Electron. Eng. ELECO 2017, vol. 2018-January, pp. 1360–1363, 2018.

[14] M. Dashtdar, R. Dashti, and H. R. Shaker, "Distribution network fault section identification and fault location using artificial neural network," 2018 5th Int. Conf. Electr. Electron. Eng. ICEEE 2018, pp. 273–278, 2018.

[15] N. Saravanan, and A. Rathinam "A comparitive study on ANN based fault location and classification technique for double circuit transmission line", Proceedings - 4th International Conference on Computational Intelligence and Communication Networks, CICN 2012 2012, pp. 824-830, 2012.

[16] S. K. Padhy, B. K. Panigrahi, P. K. Ray, A. K. Satpathy, R. P. Nanda, and A. Nayak, "Classification of Faults in a Transmission Line using Artificial Neural Network," Proc. - 2018 Int. Conf. Inf. Technol. ICIT 2018, pp. 239–243, 2018.

[17] Mohd Anuar Shafi'i; Noraliza Hamzah. "Internal fault classification using Artificial Neural Network", 4th International Power Engineering and Optimization Conference, PEOCO 2010, pp. 352-357, 2010.

[18] R. Flores, and J.M. Fernandez. "Las redes neuronales artificiales: fundamentos teóricos y aplicaciones prácticas". Oleiros, La Coruña: Netbiblo. 9788497452465, 2008.

[19] J. Gracia, A. J. Mazón and I.Zamora. "Best ANN Structures for Fault Location in Single and Double-Circuit Transmission Lines". Power Delivery, IEEE Transactions on, vol. 20, no. 4, pp. 2389-2395, 2005.

[20] Mohd Anuar Shafi'i; Noraliza Hamzah. "Internal fault classification using Artificial Neural Network", 4th International Power Engineering and Optimization Conference, PEOCO2010, pp. 352-357, 2010.

[21] K. De Kerf, K. Srivastava, M. Reza, D. Bekaert, S. Cole, D. Van Hertem, et al., "Wavelet-based protection strategy for DC faults in multi-terminal VSC HVDC systems," Generation, Transmission & Distribution, IET, vol. 5, pp. 496-503, 2011.

[22] A. K. Khaimar and P. J. Shah, "Study of various types of faults in HVDC transmission system," Proc. - Int. Conf. Glob. Trends Signal Process. Inf. Comput. Commun. ICGTSPICC 2016, no. Lcc, pp. 480–484, 2017.

[23] T. Worzyk. "Submarine power cables: Design, installation, repair environmental aspects". Berlin: Springer-Verlag. 9783642012693, 2009.

AGRADECIMIENTOS

Este trabajo ha sido financiado parcialmente por el Ministerio de Economía y Competitividad del Gobierno de España, y cofinanciado por la Comisión Europea (FEDER, Fondo Europeo de Desarrollo Regional), bajo el proyecto ENE2016-77650-R, así como por la Comisión Europea bajo el proyecto SI-1778/12/2018. Este trabajo también ha sido financiado parcialmente mediante los proyectos US-1265887, Red CYTED 718RT0564 y CER-20191019.