



MODELIZACIÓN DE LA RESISTENCIA DE PUESTA A TIERRA EMPLEANDO REDES NEURONALES¹

CORINA M. FELTAN; ALDO L. CABALLERO

¹Trabajo de Investigación

Resumen

El objetivo de este trabajo es el desarrollo de una metodología para la estimación de la resistencia de puesta a tierra usando técnicas de inteligencia artificial, en particular redes neuronales artificiales –RNA–. Es conocido que el valor de la resistencia de una puesta a tierra depende principalmente de sus características morfológicas, siendo también directamente proporcional al valor de la resistividad del suelo. Por otra parte, este último se modifica de acuerdo con el contenido de humedad, por lo cual el valor de la resistencia de puesta a tierra fluctúa a lo largo del año según el régimen de lluvias. Es importante entonces predecir dichas fluctuaciones.

Mediante este trabajo se pretende principalmente aprovechar las capacidades de las RNA para aprender y reconocer patrones de relación entre diversos parámetros. Aplicando la técnica propuesta se estima la resistencia de puesta a tierra tomando en cuenta mediciones de resistividad del suelo y precipitación acumulada. Las RNA desarrolladas han sido entrenadas y validadas mediante el uso de datos experimentales, con el fin de examinar su capacidad para predecir la resistencia de puesta a tierra. Los resultados obtenidos demuestran la eficacia de la metodología propuesta

Palabras Clave:

Sistemas de puestas a tierra – Redes Neuronales Artificiales – Red de retropropagación – Perceptrón multicapa

Introducción

Las interrupciones del servicio de energía eléctrica no programadas constituyen un indicador del desempeño de los sistemas con implicancias económicas relevantes. Aun cuando la operación se planifique y gestione adecuadamente, la ocurrencia de fallos es inevitable. Pero la problemática asociada a las puestas a tierra no sólo tiene que ver con interrupciones del servicio y sus consecuencias económicas, sino también con la seguridad de las personas y los equipos.

Las estadísticas mundiales indican que el impacto de este tipo de eventos es significativo y que sus causas están relacionadas con el comportamiento de las puestas a tierra. En efecto, es bien conocido que, en la mayoría de los casos, tanto las sobretensiones como las corrientes de falla, así



como la acción de los elementos de protección, están vinculados al comportamiento de las puestas a tierra. Particularmente, en las regiones de niveles cerámicos elevados –tal el caso de la Provincia de Misiones–, las sobretensiones de origen atmosférico implican la necesidad de prestar todavía más atención a la cuestión. Es de destacar que la región comprendida entre el norte argentino, Paraguay y el sur brasileño es una de las cuatro regiones del mundo con mayor densidad anual de tormentas eléctricas [1].

Ya hace tiempo que en todo el mundo se vienen realizando numerosos trabajos referidos a esta temática, no obstante, como esos mismos trabajos lo ponen en evidencia, la influencia de las características del suelo es determinante [2] [3] [4]. Por otra parte, también se sabe que las características de los suelos pueden variar estacionalmente, afectando el comportamiento de las puestas a tierra según el régimen de lluvias [5] [6] [7].

Metodología

Para la modelización de la red neuronal se utilizó el perceptrón multicapa, constituido por tres capas, como se esquematiza en la Figura 1

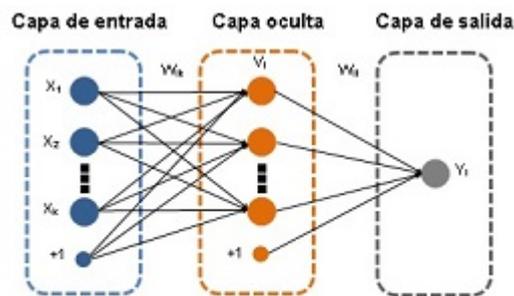


Figura 1: Estructura de la red neuronal

La matriz de entrada X está compuesta por 5 variables: X_1 es la lluvia promedio en mmca caída la semana anterior a la medición de la resistividad, X_2 es la lluvia diaria correspondiente al día que se estima la resistencia de puesta a tierra R_t , X_3 y X_4 constituyen la resistividad aparente del suelo medidas por el método de Wenner [8], con un espaciado entre electros de 1m y 2m, respectivamente. X_5 es la resistencia promedio en W durante la semana precedente. El vector de salida de la RNA es la resistencia de puesta a tierra estimada R_{test} en W .

La puesta a tierra testigo, en la que se mide R_t , consiste en un dispersor tipo jabalina de 1,5m de longitud y 16mm de diámetro.

Para el entrenamiento de la RNA se normalizan los valores de modo que se asegure la



convergencia y se eviten problemas de saturación. A esos efectos se utiliza la siguiente expresión:

$$\hat{X} = a + \frac{b-a}{X_{\max} - X_{\min}} \cdot (X - X_{\min}) \quad (1)$$

Donde \hat{X} es el valor normalizado de la variable X , y X_{\min} y X_{\max} son sus valores mínimo y máximo, a y b son los valores mínimo y máximo del rango en el cual se requiere normalizar X .

Para el entrenamiento de la red se utiliza el algoritmo de retropropagación (*back-propagation*). Este método se seleccionó por su capacidad de aproximador universal de funciones. El problema planteado posee cinco variables a correlacionar y no es factible hallar una solución por los métodos tradicionales, puesto que no se dispone de un modelo matemático que represente la correlación entre todas las variables [9].

La función a minimizar es el error cuadrático medio y el proceso de optimización se lleva a cabo mediante el método del gradiente estocástico. La función de activación empleada es la tangente hiperbólica.

La actualización de los pesos w se realiza al final de cada iteración it según:

$$\Delta \vec{w}(it) = -\eta \cdot \nabla G(\vec{w}(it)) + \alpha \cdot \Delta \vec{w}(it - 1) \quad (2)$$

Donde η es la tasa de aprendizaje, α es el *momentum*

$$G(n) = \frac{1}{2} \sum_{j \in C} (Y_j - O_j)^2 \quad (3)$$

y la ecuación 3 es la suma del error cuadrático medio para la neurona de salida después de la n -ésima iteración. Y es el valor de salida de la red y O es el valor deseado [9].

Se adiciona el *momentum* para mejorar la convergencia de la red atenuando las oscilaciones numéricas, al incorporar cierta inercia al algoritmo al variar sus parámetros [10].

La cantidad de neuronas en la capa oculta N es seis y los parámetros θ y ϕ . Para los parámetros de la función de activación se utilizaron $a_1 = 1.3$ en la capa oculta y $a_2 = 0.2$ para la capa de salida [11][12].



Resultados y Discusión

El método propuesto se programó en Matlab y se aplicó para la estimación del valor de la resistencia de puesta a tierra.

Se probaron varias configuraciones de la red con distintos números de neuronas, pero los resultados no variaron significativamente para valores mayores que $N = 6$. Se observó que para valores mayores de N el tiempo necesario para entrenar la RNA aumenta significativamente.

Una vez entrenado el algoritmo, se presentó a la red un set de valores que no fueron utilizados para su entrenamiento, evaluándose positivamente la generalidad del método con un índice de correlación de 86%. Teniendo en cuenta las incertidumbres que caracterizan el comportamiento de las puestas a tierra, así como los resultados obtenidos con la aplicación de los métodos clásicos, se puede considerar que el método desarrollado satisface los objetivos propuestos.

En la figura 2 puede observarse los resultados obtenidos.

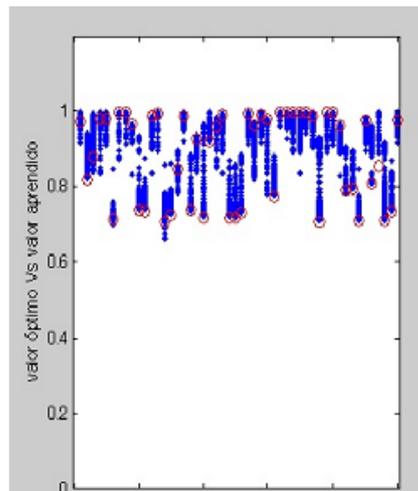


Figura 2: Valores estimados Vs valores medidos

Conclusiones

La RNA fue desarrollada, entrenada y validada para estimar la resistencia de puesta a tierra, con un grado de aproximación aceptable, en función de los valores de resistividad aparente en función del régimen de lluvias.

La RNA desarrollada no posee limitaciones en cuanto al número de entradas, pudiéndose



incorporar otros parámetros y variables para extender su aplicación a configuraciones y condiciones diversas, en la búsqueda de soluciones más generales.

Si bien los resultados logrados son alentadores, teniendo en cuenta que el rendimiento de las RNA depende de los parámetros con que ha sido entrenada, es importante continuar y profundizar estos estudios, con vistas al desarrollo de una herramienta capaz de contribuir a resolver los problemas que todavía hoy subsisten en relación con los sistemas de puesta a tierra.

Referencias

1. NICORA, M. Gabriela, et al. Electric atmospheric activity in Argentina, a study for estimating the annual death rate by lightning. Lightning Protection (XII SIPDA), 2013 International Symposium on. IEEE, 2013. p. 340-344.
2. SARAJCEV, Petar; VUJEVIC, Slavko. A review of methods for grounding grid analysis. En Software, Telecommunications & Computer Networks, 2009. SoftCOM 2009. 17th International Conference on. IEEE, 2009. p. 42-49.
3. 81-2012- IEEE. Guide for Measuring Earth Resistivity, Ground Impedance, and Earth Surface Potentials of a Grounding System. 2012.
4. CABALLERO, Aldo. Las puestas a tierra en los sistemas eléctricos. Editorial Universitaria. Colección Cátedra. 1999. p. 81-87.
5. BANTON, O.; CIMON, M.-A.; SEGUIN, M.-K. Mapping field-scale physical properties of soil with electrical resistivity. Soil Science Society of America Journal, 1997, vol. 61, no 4, p. 1010-1017.
6. GONOS, I. F.; MORONIS, A. X.; STATHOPOULOS, I. A. Variation of Soil Resistivity and Ground Resistance during the Year. Proc. 28th Int. Conf. Lightning Protection, 2006, p 740-744.
7. ANDROVITSANEAS, Vasilios P., et al. Wavelet neural network for ground resistance estimation. High Voltage Engineering and Application (ICHVE), 2014 International Conference on. IEEE, 2014. p. 1-5.
8. WENNER, Frank. A Method of Measuring Earth Resistivity. US Bur. Standards Sei. Paper, 1916, no 258. p 469-478.
9. HERTZ, John; KROGH, Anders; PALMER, Richard G. Introduction to the theory of neural computation. Basic Books, 1991.
10. RUMERHART, D. E.; HINTON, G. E.; WILLIAMS, R. J. Learning representations by back-propagation errors. Nature, 1986, vol. 323, p. 533-536.
11. ASIMAKOPOULOU, Fani E., et al. Estimation of the earth resistance by Artificial Neural Network model. IEEE Transactions on Industry Applications, 2015, vol. 51, no 6, p. 5149-5158.
12. ASIMAKOPOULOU, Fani E., et al. Estimation of seasonal variation of ground resistance



using Artificial Neural Networks. Electric Power Systems Research, 2013, vol. 94, p. 113-121.