

**Evento:** XXII Jornada de Pesquisa - Participante ESTRANGEIRO

**ESTUDIO DE LA VARIACION ESTACIONAL DE LA RESISTENCIA DE LAS  
PUESTAS A TIERRA UTILIZANDO INTELIGENCIA ARTIFICIAL<sup>1</sup>  
ESTIMATION OF SEASONAL VARIATION OF GROUND RESISTANCE  
USING ARTIFICIAL INTELLIGENCE**

**Corina Maria Feltan<sup>2</sup>, Aldo Luis Caballero<sup>3</sup>, Angel Paolo Quintana<sup>4</sup>, Dario  
Ivan Yuchechen<sup>5</sup>**

<sup>1</sup> Trabajo de Investigación

<sup>2</sup> Docente Investigadora de la Universidad Nacional de Misiones feltan@fio.unam.edu.ar

<sup>3</sup> Director. Docente Investigador de la Universidad Nacional de Misiones  
aldoluiscaballero@gmail.com

<sup>4</sup> Docente investigador de la Universidad Nacional de Misiones UNaM  
quintanaangelpaolo@gmail.com

<sup>5</sup> Estudiante de la carrera de Ingenieria electromecánica de la Universidad Nacional de Misiones  
darioyuchechen@gmail.com

**Resumen**

El objetivo de este trabajo es un desarrollo metodológico para la estimación de la resistencia de puesta a tierra mediante el uso de técnicas de inteligencia artificial, utilizando redes neuronales - RNA-. El valor de la resistencia de puesta a tierra depende en gran medida del sistema de puesta a tierra y las características del suelo. Teniendo en cuenta que el valor de la resistividad del suelo fluctúa durante el año, la resistencia de puesta a tierra varía en proporción a esta última. Se escoge esta metodología aprovechando la capacidad de las RNA para reconocer relaciones lineales y no lineales entre diversos parámetros. Se estima la resistencia de puesta a tierra tomando en cuenta las mediciones de la resistividad y la precipitación acumulada. Con este propósito las RNA 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 demuestran la eficacia de la metodología propuesta.

**Palabras Clave:** Sistemas de puestas a tierra - Redes Neuronales Artificiales - Red de retropropagación - Perceptrón multicapa

**Keywords:** Ground resistance; Artificial neural networks; Back propagation algorithm; Multilayer perceptrons

**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

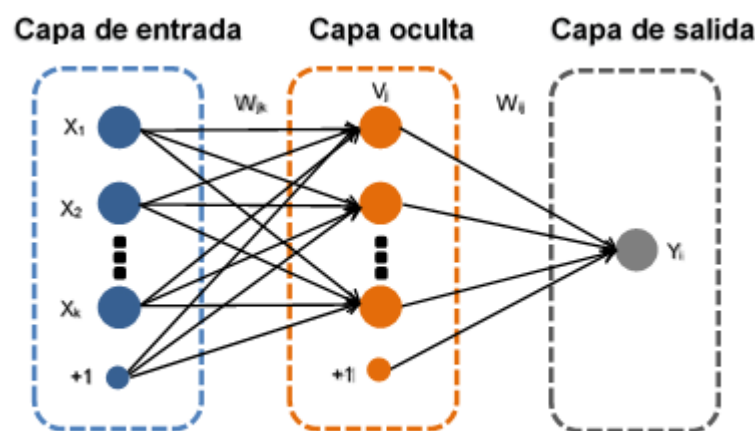
**Evento:** XXII Jornada de Pesquisa - Participante ESTRANGEIRO

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 (Nicora 2013).

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 (Sarajcev; Petar; Vujevic 2009) (IEEE 2012) (Caballero 1999). 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 (Banton; Cimon; Seguin; 1997) (Gonos; Moronis; stathopulos 2006) (Androvitsaneas, et al. 2014)

### 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, de las cuales,  $X_1$  es la lluvia promedio en mmca caída la semana anterior a la medición,  $X_2$  es la lluvia diaria correspondiente al día que se predice 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 (Wenner 1916), con un espaciado entre electros de 1 m y 2 m respectivamente y  $X_5$  es la resistencia promedio en ohm durante la semana precedente. El vector de salida de la RNA es la resistencia de puesta a tierra estimada  $R_{test}$  en ohm

La puesta a tierra en la que se mide la resistencia de puesta a tierra  $R_t$  consiste en un dispensor tipo jabalina de 1,5 m.

Antes de proceder al entrenamiento de la red neuronal se normalizan los datos para asegurar la convergencia y evitar problemas de saturación durante el entrenamiento de la RNA, para ello se

**Evento:** XXII Jornada de Pesquisa - Participante ESTRANGEIRO

utiliza la siguiente expresión:

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

Para el entrenamiento de la red se utiliza el algoritmo de retropropagación Back-Propagation, se selecciona este método por su capacidad de aproximador universal de funciones, El problema planteado posee seis variables a correlacionar y se hace difícil encontrar una solución por los métodos tradicionales debido a que no dispone de un modelo matemático (Hertz; Krogh; Palmer 1991).

La función de costo 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 utilizada es la función 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  $\eta$  es la tasa de aprendizaje,  $\alpha$  es el *momentum*

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

donde 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 (Hertz; Krogh; Palmer 1991)

Se adiciona un momento para agilizar la convergencia de la red y evitar las oscilaciones ya que incorpora cierta inercia al algoritmo variando sus parámetros (Rumerhart; Hinton; Williams 1986) La cantidad de neuronas en la capa oculta  $N$  es seis y los parámetros  $\eta=0.01$  y  $\alpha=0.65$ , para los parámetros de la función de activación  $f(x) = \tanh(a_i, x)$  se utilizaron  $a_1 = 1.2$  para la función de activación de la capa oculta y  $a_2 = 0.2$  para la función de activación de la capa de salida (Asimakopoulou 2015)

### Resultados y Discusión

La metodología descrita en la sección anterior fue realizada en Matlab y es aplicada para la determinación de la resistencia de puesta a tierra.

Se ensayaron varias configuraciones de la red, con distintas  $N$  pero los resultados no variaban significativamente para valores mayores al utilizado, pero si se incrementaba muy significativamente el tiempo de máquina requerido.


Se entreno la red con un conjunto de valores y luego fue testado con otro conjunto (ambos disjuntos), para estimar que error esperar de esa RN A para un conjunto de datos que vengan de

**Evento:** XXII Jornada de Pesquisa - Participante ESTRANGEIRO

esa distribución se repitió el procedimiento varias veces (bootstrapping), cada vez con un conjunto de datos diferentes de training y testing (resampling, muestras tomadas al azar cada vez). Luego, para cada resampling se estimaron el error cometido por medio del error cuadrático medio, luego se calculó el error promedio y su desvío estándar.

Se calculó el valor del índice de correlación entre los datos experimentales y los valores estimados de la resistencia de puesta a tierra dando el mismo un valor de 0,86.

En la figura 2 puede observarse los resultados obtenidos.



**Figura 2:** Valores estimados Vs valores medidos

## Conclusiones

La red neuronal fue entrenada y validada para estimar la resistencia de puesta a tierra, con un buen grado de estimación, en función de los datos de resistividades aparentes y las lluvias caídas. Para futuros trabajos la red no posee limitaciones en el número de entradas pudiéndose incorporar valores experimentales obtenidos en un tiempo más prolongado, como así también incorporar nuevos parámetros como el contenido de agua del suelo y tipo y tamaño de la puesta a tierra.

Hay que tener en cuenta que el rendimiento de las RNA depende de los parámetros con que ha sido entrenada, por lo tanto, una red entrenada puede llegar a dar resultados incorrectos si los valores de entrada difieren sustancialmente de los valores de los parámetros con que ha sido entrenada la red.

Esta herramienta puede ser usada como un complemento para el cálculo y diseño de los sistemas de puesta a tierra, teniendo en cuenta el hecho que la resistencia de puesta a tierra varía durante el año y las mediciones de su variación muchas veces puede resultar onerosa o no estar disponible.

**Evento:** XXII Jornada de Pesquisa - Participante ESTRANGEIRO

## Referencias

1. 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.
2. 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.
3. 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.
4. CABALLERO, Aldo. Las puestas a tierra en los sistemas eléctricos. Editorial Universitaria. Colección Cátedra. 1999. p.81-87.
5. GONOS, I. F.; MORONIS, A. X.; STATHOPULOS, I. A. Variation of Soil Resistivity and Ground Resistance during the Year. Proc. 28th Int. Conf. Lightning Protection, 2006, p 740-744.
6. HERTZ, John; KROGH, Anders; PALMER, Richard G. Introduction to the theory of neural computation. Basic Books,1991.
7. 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.
8. RUMERHART, D. E.; HINTON, G. E.; WILLIAMS, R. J. Learning representations by back-propagation errors. Nature, 1986, vol. 323, p. 533-536.
9. 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.
10. 81-2012- IEEE. Guide for Measuring Earth Resistivity, Ground Impedance, and Earth Surface Potentials of a Grounding System. 2012.