

Enfoque del empleo de las redes neuronales de base radial en las redes eléctricas inteligentes en la UTM.

Ney Balderramo Velez, Lenin Cuenca Alava, Yolanda Llosas Albuerne, Julio Cesar Mera Maciás,
Universidad Técnica de Manabí,

ney_101991@hotmail.com, lcuenca@utm.edu.ec, yillosas@utm.edu.ec, jcmera@utm.edu.ec,

Abstract— In the presented work, an analysis of the use of artificial intelligence is proposed, as a way to solve the problems that arise in the daily work of electrical networks. By implementing the distributed generation with contributions from generating elements with the incorporation of renewable energy sources in them, as well as connection of consumer elements in different points of the network, conflicts are established regarding the transmission of electrical energy in the different scenarios. It is therefore essential to manage the direction in which energy is transmitted in the network, as well as the organized connection and disconnection of each of the elements, the creation of intelligent decision-making elements, to what is called Intelligent Electrical Network (Smart Grids). For the decision making it is proposed to use artificial intelligence techniques, and according to the experience in the work of transmission lines it has been selected to work with the topology of radial-based neural networks to undertake the different tasks regarding the intelligent decision.

Index Terms— electrical networks, smart grids, distributed generation, transmission line, renewable energy

I. INTRODUCCIÓN

En la actualidad es común escuchar y presenciar los avances tecnológicos en las edificaciones, ya sea en los sistemas de infraestructura como en el diseño eléctrico, esto se debe a la incorporación de sistemas inteligentes que pasan a ser el factor de mayor importancia en cualquier edificación moderna. En [1], se expone un trabajo sobre el Presente y Futuro de los Sistemas Eléctricos en el cual realiza un análisis de lo que son las redes eléctricas inteligentes y una proyección a corto y mediano plazo de sus avances en cuestiones tecnológicas y de integración, permitiendo conocer los avances tecnológicos que han tenido las redes eléctricas inteligentes “Smart Grid” desde su implementación. Pero no todo es tan fácil para la obtención de un sistema inteligente, según [2] ya que en su trabajo, Evolución de las Redes Eléctricas Hacia Smart Grid en Países de la Región Andina, realiza un análisis de la problemática que se presenta en la configuración de los sistemas eléctricos de potencia actual y los requerimientos necesarios para la implementación de una Smart Grid.

La Inteligencia Artificial (IA) es una de las técnicas para la

obtención de un sistema inteligente, en el cual resulta más interesante a medida que aumenta la tecnología y los requerimientos de la sociedad. Por tal razón son muchas las técnicas y herramientas utilizadas en la IA, tal es el caso de [6], donde se estudian aplicaciones de las herramientas de la IA como lo son las Redes Neuronales Artificiales (RNA); además [7]; corrobora el extenso campo de utilización de la IA en su trabajo investigativo, en el cual determina las amplias aplicaciones de las RNA. En este sentido en el trabajo presentado se plantea el empleo dentro del campo de las herramientas de las redes neuronales, las conocidas redes de base radial que brindan la oportunidad de dar un tratamiento robusto a los problemas inherentes a las líneas de transmisión eléctricas.

II. DESARROLLO

En el enfoque de este método se utiliza un modelo de funcionamiento normal para detectar la desviación de esa condición, y a través de un módulo de decisión elaborar una señal de diagnóstico. Para esta tarea se utiliza un esquema que responda ante varias señales de entrada provenientes de la red como se muestra en la figura 1.

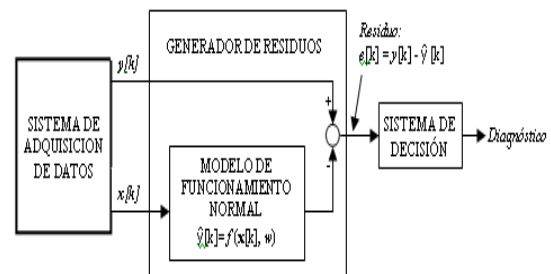


Fig. 1 El Enfoque Basado en Modelos.

El bloque de Adquisición de Datos está formado por el módulo de medición y registro de las variables que determinan el funcionamiento del sistema bajo diagnóstico. En el caso de la red eléctrica las variables son la corriente, el voltaje, el factor de potencia y la impedancia, entre otras. Se le denomina $y[k]$ al vector de las variables dependientes o de salida del sistema, que contienen las desviaciones respecto al funcionamiento normal.

El vector $x[k]$ agrupa a las variables independientes que son las entradas al Modelo de Funcionamiento Normal.

El modelo de funcionamiento normal, en principio, puede ser de cualquier tipo, incluyendo los modelos en base a redes neuronales artificiales y es el encargado de procesar el vector de variables independientes para obtener el de las variables dependientes esperadas $\hat{y}[k]$, que solo contienen valores de funcionamiento normal, que serán comparados con el vector de salida $y[k]$, proveniente del sistema de adquisición de datos. Este proceso recibe el nombre de Generación de Residuos, representado por el vector $e[k]$ denominado Residuo.

Por lo general esta red suele ser de tipo Perceptrón Multicapas, que se utiliza cuando se dispone de suficiente cantidad de datos del sistema, que reflejan el comportamiento tanto de las entradas como de las salidas, para enfrentar el proceso de entrenamiento en una forma confiable, mediante el método de retropropagación de errores.

La mayor ventaja de la utilización del Perceptrón Multicapas para generar el modelo de funcionamiento normal, utilizando el método de retropropagación de errores, es su capacidad para aproximar cualquier función. El éxito de la tarea se garantiza con escoger una configuración adecuada para la red. En el caso de la red con una sola capa oculta solo es necesario escoger el número adecuado de neuronas en la capa oculta, lo que engendra dificultad, debido a que no existe un método racional para ello [11], siendo necesario apegarse al método de prueba y error. La determinación de una estructura de la red adaptada al sistema que se modela depende, entonces, de la experiencia del desarrollador. La red Perceptrón Multicapas es un excelente aproximador de funciones, aunque es imposible determinar una configuración óptima para cada aplicación.


Después de generar el vector de residuos, se utiliza un mecanismo de decisión para determinar la ocurrencia y localización del fallo. La determinación de la ocurrencia del fallo puede ser implementada, mediante lógica de umbrales, utilizando umbrales fijos o adaptativos. También se puede implementar mediante pruebas estadísticas, como en [12].

La tarea principal del módulo de decisión es el aislamiento del fallo, que consiste en clasificar los residuos en un número de patrones distinguibles, correspondientes a diferentes situaciones o a la localización del componente fallado. Así, el módulo de decisión puede basarse en el principio de reconocimiento de patrones. El reconocimiento de patrones implica ciertas acciones iniciales basadas en la observación de los datos de entrada. A la entrada que representa un patrón se le conoce como vector de medida o vector característico. La función obtenida mediante un sistema de reconocimiento de patrones es el encuadre del vector característico de entrada en una de las varias clases de decisión. En el diagnóstico de fallos, estas clases de decisión son los diferentes tipos y localizaciones de fallos que ocurren en el sistema.

En calidad de mecanismo de reconocimiento de patrones se pueden emplear varias técnicas entre las que se encuentran, también, las redes neuronales artificiales. Una de las ventajas de las redes neuronales tipo mapas autoorganizados y tipo redes de base radial es su capacidad de particionar el espacio de entrada para resolver problemas de clasificación. Así, se puede utilizar una red neuronal como clasificador o reconocedor de

patrones, para particionar el espacio de patrones de residuos y activar señales de alarma.

Este enfoque presenta un número de pasos que conforman el procedimiento a seguir para su utilización:



Paso 1: Diseño de la representación E/S.

- ❖ Selección de las variables de salida que han de ser estimadas.
- ❖ Selección de las variables de entrada: Identificación.

Paso 2: Generación de los conjuntos de entrenamiento y prueba.

- ❖ Solo han de considerarse situaciones de funcionamiento normal.
- ❖ Este enfoque no requiere tener conocimiento del comportamiento de los componentes en estado de anomalías.

Paso 3: Aprendizaje.

- ❖ Ajuste de los modelos de funcionamiento normal: Estructura y parámetros.
- ❖ Descripción estadística de los residuos en condiciones de funcionamiento normal.

Paso 4: Validación.

- ❖ El sistema se valida bajo condiciones de funcionamiento normal y anómalo para evaluar su sensibilidad.

A. La Red Neuronal Artificial con Función de Base Radial

La red neuronal artificial con función de base radial constituye un clasificador universal. Este tipo de red se ha asociado, tradicionalmente, con una arquitectura simple de tres capas, como se muestra en la figura 2. Cada capa de la arquitectura está completamente conectada con la capa que le sigue. La capa oculta se compone de un conjunto de nodos, que se caracterizan por tener asociadas funciones de activación de tipo radial, denominadas Funciones de Base Radial. Cada función recibe como entrada todos los patrones.

Las funciones de base radial se centran en un punto del espacio de entrada. Las salidas de estas funciones se combinan, linealmente, mediante ponderaciones para generar la salida de la red neuronal. Otra característica importante de las funciones de base radial es que generan una respuesta local, en contraposición a la respuesta global característica de la función sigmoide, puesto que su salida solamente depende de la

distancia que existe entre la entrada y el centro de cada función de base radial.

Las funciones de base radial de la capa oculta presentan una estructura que se puede representar de la siguiente manera:




Fig. 2. Arquitectura de las Redes Neuronales Artificiales con Funciones Base Radial.

$$\phi(x) = \phi((x - c_i)^T \cdot R^{-1} (x - c_i))$$

Ecuación. 1.

Donde ϕ es la función de base radial utilizada, $\{c_i \mid i = 1, 2, \dots, c\}$ es el conjunto de centros de las funciones de base radial y R es una métrica. El término $(x - c_i)^T \cdot R^{-1} (x - c_i)$ representa la distancia desde la entrada x al centro c en la métrica definida por R . Aunque existen varios tipos de funciones de base radial, la función gaussiana es la más utilizada, combinada con la métrica euclidiana.

En el caso de la función gaussiana con métrica euclidiana, la salida de la red se da por:

$$F(x) = \omega_o + \sum_{i=1}^c \omega_i \cdot \exp\left(-\frac{\|x - c_i\|^2}{r^2}\right)$$

Ecuación. 2.

Donde c es el número de funciones base radial utilizadas, $\{c_i \mid i = 1, 2, \dots, c\}$ son los pesos sinápticos, $\|\cdot\|$ denota la norma euclidiana y r es el radio de la función radial.

El algoritmo de aprendizaje de las redes neuronales con funciones base radial es un proceso incremental y evolutivo. El fundamento matemático sobre el que se basa dicho proceso es el denominado selección de subconjuntos y consiste en comparar los modelos que se obtienen de escoger, de entre un mismo conjunto de elementos candidatos, distintos subconjuntos de elementos.

B. Diagnóstico Utilizando Redes Neuronales Artificiales

Dado un conjunto de muestras $S = \{(x[1], y[1]), \dots, (x[N], y[N])\}$ con $x \in R^n$ y $y \in R$, donde, R^n es un conjunto numérico (reales, imaginarios, difusos, fraccionarios, etc.), pueden ser también variables que representen a un proceso en específico, o sea, variables asignadas a señales de entradas o salidas que representen una acción determinada del proceso, R es un conjunto numérico que puede pertenecer o no al conjunto R^n , y $p(x, y)$ es una estimación de la función de probabilidad con el estimador de Parzen que representa la probabilidad de que la red converja al par (x, y) , es decir, que cuando se aplique la entrada x se obtenga la salida esperada \hat{y} , se puede estimar el

valor de la salida $\hat{y}(x)$ para la red en funcionamiento normal a través de la función de regresión generalizada.

$$\hat{y} = \frac{\int_{-\infty}^{+\infty} y \cdot p(x, y) dy}{\int_{-\infty}^{+\infty} p(x, y) dy}$$

Ecuación. 3.

La ecuación 3 revela la existencia de una relación, al menos probable, entre la salida real y la salida esperada a través de la probabilidad de que la salida real converja a la esperada. Nótese que cualquiera de las dos variables puede sustituirse por una función de la otra y el residuo.

Figura. 3. La Red Neuronal Artificial con Función de Base Radial.

Como se muestra en la figura 3 para señales de entrada $X^*1 \dots X^*n$ que pasan a través de una capa de funciones lineales, se obtiene en la salida de éstas el valor de entrada normalizado. Luego cada una de las señales de entrada va hacia la capa oculta o intermedia que son funciones de base radial tipo gaussiana, con rango de salida entre 0 y 1 dado por la expresión (2.4).

$$a_i(x) = \frac{1}{(\sqrt{2\pi}\sigma_i)^n} \cdot \exp\left(-\frac{(x - x_i)^T (x - x_i)}{2\sigma_i^2}\right)$$

Ecuación. 4.

Las salidas de la capa oculta son, a su vez, las entradas a las neuronas de la capa de salida de la red. La capa de salida, en la figura 3, esta formada por 2 elementos, el primero de los cuales es una neurona con función de activación lineal, que aporta el valor del residuo del vector de entrada analizado por la red y el segundo elemento es un sumador que permite obtener a su salida una estimación del valor del error total, el que multiplicado por el inverso de la cantidad de salidas de la capa oculta, da la probabilidad con que ocurre el residuo obtenido en la primera salida. En otras palabras, la red obtiene la desviación que proviene de tener que realizar una actuación en cuanto a la toma de decisión en la red eléctrica inteligente.

Incluir el modelo de la figura 3 en el bloque de decisión de la figura 1 requiere que esta última se modifique, quedando como se muestra en la figura 4.




Figura. 4. Modelo de Redes de Base Radial en el Sistema de Decisión.

A continuación se detalla el funcionamiento de cada elemento del modelo propuesto. El esquema tiene dos características esenciales: La primera es que está dotado de adaptabilidad, en el sentido de que el valor máximo permisible del residuo varía para cada conjunto de variables de entrada o lo que es lo mismo, para cada estado de funcionamiento del sistema y la segunda es la robustez dada por la capacidad de determinar el grado de pertenencia del residuo al estado del sistema e incorporarlo a la decisión.

Modelo de Funcionamiento Normal: El funcionamiento normal del sistema se modela mediante técnicas de identificación de sistemas no lineales, utilizando una red neuronal artificial del tipo Perceptrón Multicapas como aproximador funcional. El procedimiento de modelado consiste en el entrenamiento mediante el método de retropropagación de errores y da por resultado la estructura y los parámetros de la red. Cuando se utiliza una red con una sola capa oculta, que se recomienda en aras de la robustez del modelo, la determinación de la estructura de la red se reduce a determinar el número de neuronas de la capa oculta.

Modelo de la función de probabilidad del vector de entradas: Para la estimación de la función de probabilidad $p(x)$, según la cual se distribuye el vector de entradas en el conjunto de entrenamiento, se utiliza una red de base radial.

Los valores bajos de $p(x)$ indican una representación pobre de la situación actual en el conjunto de entrenamiento, el vector de entradas no representa el proceso, lo que implica una baja fiabilidad de la estimación \hat{y} .

Si se define una cota inferior de extrapolación p_{min} :

- ❖ $p(x) < p_{min} \Rightarrow$ Situación (vector de entradas) desconocida.
- ❖ $p(x) > p_{min} \Rightarrow$ Situación conocida (región de confianza).

Modelo de la Cota Máxima de los Residuos: Si el residuo que se obtiene de la comparación de las salidas reales y esperadas es menor que la cota máxima de los residuos, entonces se dice que la red da una respuesta dentro del rango considerado como salida normal. Si ocurriera lo contrario, entonces se considera fuera de rango y la respuesta de la red indica la existencia de una salida anómala. Todo lo anterior queda resumido de la siguiente forma:

$$e = y - \hat{y} < e_{\max} \Rightarrow \text{salida normal}$$

Ecuacion. 4.

$$e = y - \hat{y} > e_{\max} \Rightarrow \text{salida anómala}$$

Ecuacion. 5.

La cota máxima de los residuos se estima, también, mediante una red neuronal artificial con neuronas de base radial, a partir del vector de entradas. Cada condición de operación o estado del sistema tendrá su propia cota. La varianza local del residuo se estima en cada unidad radial a partir de:

$$S^2_{e,i} = \frac{\sum_{k=1}^N a_i[k] \cdot e^2[k]}{\sum_{k=1}^N a_i[k]}$$

Ecuacion. 6.

Donde:

- ❖ $e^2[k]$ Desviación cuadrática de cada una de las neuronas de la capa intermedia de la red.
- ❖ $a_i[k]$ Salida de cada una de las neuronas de la capa intermedia.
- ❖ $S^2_{e,i}$ Desviación cuadrática media para cada neurona de la capa intermedia de la red.

La varianza del residuo se estima entonces mediante regresión generalizada:

$$S^2_e[k] = \frac{\sum_{i=1}^h a_i[k] \cdot S^2_{e,i}}{\sum_{i=1}^h a_i[k]}$$

Ecuacion. 7.

Como cota máxima de los residuos se toma, finalmente, igual al doble de la desviación estándar:

$$e_{\max}(x[k]) = 2S_e(x[k])$$

Ecuacion. 8.

El hecho de tomar el error igual al doble de la desviación estándar significa, desde el punto de vista estadístico, que la significación del error en la determinación de los residuos es no mayor que el 5 %.

Sistema de decisión: De acuerdo a las definiciones dadas antes, se puede establecer con claridad, el intervalo de confianza de la salida real del sistema, mediante el valor de la salida esperada y el valor de la cota máxima de los residuos ($\hat{y} \pm e_{\max}$) con una certeza o grado de confianza del 95 %. A partir del citado intervalo de confianza y del valor de la probabilidad de pertenencia del vector de entrada al conjunto de entrenamiento se definen 2 reglas básicas para establecer la existencia de un fallo.

Si “condición de operación conocida” ($p(x) > p_{min}$): región de confianza.

“Salida normal”

- $(y \in \hat{y} \pm e_{\max}) \Rightarrow$ **funcionamiento normal**

“Salida anómala”

- $(y \notin \hat{y} \pm e_{\max}) \Rightarrow$ **actuar**

Si “condición de operación desconocida” ($p(x) < p_{min}$):

- Nueva condición de operación.
- Anomalía en un componente externo

III. CONCLUSIONES

En el trabajo presentado se pone en evidencia como a partir del empleo de las redes neuronales artificiales podemos elaborar y diseñar sistemas decisores que nos garanticen una operatividad eficiente y robusta de los sistemas de transmisión eléctrica.

Se han empleado como elementos de trabajo para la toma de decisión, que conformarían luego el sistema de la red eléctrica inteligente, la topología de redes neuronales de base radial, con las cuales se tiene experiencia de su empleabilidad en la

solución de diferentes tareas en cuanto a toma de decisión en sistemas eléctricos.

IV. REFERENCIAS BIBLIOGRÁFICAS

- [1] S. M. Ochoa, "Smart grids: presente y futuro del sistema eléctrico," 2012.
- [2] A. G. Peralta Sevilla and F. Amata Fernández, "Evolución de las Redes Eléctricas hacia Smart Grid en Países de la Región Andina," *Rev. Educ. en Ing.*, vol. 8, pp. 1–14, 2013.
- [3] K. Akira *et al.*, "A study on estimation method of reactive power control of DGs in distribution systems with a large amount of PVs," *Power Plants Power Syst. Control*, pp. 387–392, 2012.
- [4] A. A. Álvarez, *Sistema de agentes para control de stock de almacén basado en identificación por radiofrecuencia*. 2011.
- [5] J. A. Iglesias Martínez, "Modelado automático del comportamiento de agentes inteligentes," Jan. 2010.
- [6] S. Montelíer, A. Borroto, M. De Armas, J. Gomez, C. Perez, and O. Goza, "Estimación de cargas térmicas de climatización de hoteles mediante simulación y redes neuronales artificiales," *Energética*, vol. XXXI, no. 3, pp. 13–18, 2010.
- [7] H. Galán Asencio and A. Martínez Bowen, "Inteligencia artificial . Redes neuronales y Aplicaciones," p. 8, 2010.
- [8] S. P. Daza, "Redes Neuronales Artificiales. Fundamentos, modelos y aplicaciones," p. 390, 2000.
- [9] F. Villada, D. R. Cadavid, and J. D. Molina, "Pronóstico del precio de la energía eléctrica usando redes neuronales artificiales Electricity price forecasting using artificial neural networks," pp. 111–118, 2008.
- [10] E. Barrero, B. Fernández, and O. Llanes, "' Propuesta de procedimiento para configurar una red neuronal artificial de Base Radial con aplicaciones en el diagnóstico de fallos,'" no. December 2014, pp. 60–75, 2014.
- [11] B. Martín, D. Brío, A. Sanz Molina, T. Pollán Santamaría, and Y. N. Medrano Marqués, "REDES NEURONALES Y SISTEMAS BORROSOS: UN LIBRO DE TEXTO EN ESPAÑOL," 1997.
- [12] A. Muñoz San Roque, "Aplicación de técnicas de redes neuronales artificiales al diagnóstico de procesos industriales," p. 1, 1996.