

Red Neuronal para el Reconocimiento de Patrones de Onda Viajera

FLORES-ALARCÓN, María Susana*†, TORRERO-FLORES, Felipe y TORRERO-PÉREZ, Everardo.

Recibido Julio 13, 2016; Aceptado Septiembre 1, 2016

Resumen

Los eventos de fallas que se llegan a presentar en líneas eléctricas de transmisión de alto voltaje son capturados por equipos denominados Travel Wave Systems (TWS). Estos equipos registran las ondas de alta frecuencia que se generan por vientos, incendios, desgaste de componentes y otros eventos que se llegan a dar en las líneas. A estas ondas se les denomina ondas viajeras y son capturadas en archivos de texto planos. Los cuales al graficarse muestran diferentes patrones de onda, dependiendo del evento que las haya generado. El reconocimiento se hace actualmente en forma empírica, por lo que se emprendió el desarrollo de un prototipo informático con redes neuronales para que ayude en una identificación más rápida y automática por una máquina. Para caracterizar el patrón de onda viajera se elaboró un sistema Web. Este sistema permite descargar en un servidor los archivos con la información en una base de datos. Estos datos se utilizan en el proceso de aprendizaje de la red neuronal supervisada, así como en el reconocimiento de los patrones. Con el algoritmo que se implementó para el aprendizaje el tiempo que se requiere para establecer los pesos de la red neuronal es alto, sin embargo, los tiempos de reconocimiento son más cortos, en relación a métodos estadísticos utilizados para el reconocimiento de patrones.

Red Neuronal, Reconocimiento de Patrones de Onda Viajera, Líneas de Transmisión Eléctricas

Abstract

The fault events that even present on power lines high voltage transmission are captured by devices called Travel Wave Systems (TWS). These devices register high frequency waves generated by winds, fires, wear components and other events come about in the lines. These waves are called traveling waves and are captured in flat text files. Which when graphed show different wave patterns, depending on the event that has generated. The recognition is currently done empirically, so the development of a prototype computer neuronal networks was undertaken to assist in a more rapid and automatic identification by machine. To characterize the pattern of traveling wave a Web system was developed. This system allows a server to download files with information in a database. This data is used in the process of supervised learning neural network and in recognizing patterns. With the algorithm implemented for learning the time required to establish the weights of the neural network is high, however recognition times are very short.

Neuronal Network, Wave Traveling Pattern Recognition, Electrical Transmission Lines

Citación: FLORES-ALARCÓN, María Susana, TORRERO-FLORES, Felipe y TORRERO-PÉREZ, Everardo. Red Neuronal para el Reconocimiento de Patrones de Onda Viajera. Revista de Tecnología e Innovación 2016, 3-8: 83-90

*Correspondencia al Autor (Correo electrónico: susana.flores.alarcon@gmail.com)

†Investigador contribuyendo como primer autor.

Introducción

La energía almacenada por eventos anormales en la capacitancia e inductancia de las líneas de transmisión eléctricas de alto voltaje, generan en el instante mismo de la falla ondas de alta frecuencia conocidas como ondas viajeras. Estas ondas se generan en el punto de falla de la línea y se propagan hacia los extremos de la misma. Las ondas que se producen son de alta frecuencia en el rango de los 20 KHz y 2 Mhz, viajando a una velocidad cercana a la de la luz.

En la empresa en donde se ha obtenido información del comportamiento de estas fallas, se han aplicado algoritmos que ubican el sitio de la falla, sin embargo, la identificación del tipo de falla aún se realiza de forma empírica. Dependiendo del evento que se presenta las ondas viajeras producen un patrón, el cual puede representar un evento de lluvia, de envejecimiento de componentes, modificaciones en el medio ambiente, etc.

Los patrones que se generan al ocurrir un evento en una línea de transmisión, son reconocidos por un experto humano, sin embargo, hacer que las computadoras los reconozcan no es una tarea sencilla, puesto que son problemas que no se pueden resolver creando un diagrama de flujo. Mientras aquellos problemas con una tendencia a sufrir cambios rápidos se les puede dar solución con una Red Neuronal Artificial (RNA), gracias a su capacidad de aprender. Diversos autores han encontrado que las RNA's son apropiadas para resolver problemas de reconocimiento de patrones, clasificación, series de predicción y minería de datos.

Conociendo con anticipación el patrón, la implementación de un algoritmo de RNA's ayudará a una máquina a identificar de una forma automática las fallas ocurridas en las líneas de transmisión eléctricas, permitiendo una atención oportuna del evento que se presenta en la línea eléctrica asegurando y de esta manera ayudar a mantener la disponibilidad del servicio eléctrico.

Materiales y métodos

Las líneas de transmisión eléctricas llegan a presentar disturbios los cuales pueden ser causados por lluvia, incendios, desgaste en los componentes, etc. Para detectar estos eventos Comisión Federal de Electricidad (CFE) tiene instalados en los extremos de las líneas, equipos Travel Wave Systems (TWS). Estos equipos detectan variaciones de alta frecuencia, causados por los eventos que se llegan a presentar. Estas variaciones son grabadas en archivos de texto, utilizando el código ANSI (Figura 1), con rango de valores entre 0 y 255. En las diferentes líneas que componen el archivo de texto se encuentra información de la estación donde se grabó el evento, la fecha, ganancia, circuito, gps, módulo, razón. Después de estas líneas se encuentra una línea de caracteres ANSI, con los valores de voltaje normal de una fase de la línea de transmisión. En las líneas siguientes el equipo TWS grabó los voltajes con valores fuera del valor nominal. Esta secuencia se presenta para cada una de las fases de la línea de transmisión.




Figura 1 Contenido de un archivo .tws.

Un ejemplo de la forma en que llega a tomar un evento se presenta en la Figura 2. Los datos se obtuvieron de un archivo .tws y fueron graficados utilizando un lenguaje de programación para una aplicación Web.




Figura 2 Gráfica de un tipo de falla obtenida con los datos extraídos de un archivo .tws.

Sistema Web para Caracterizar los Archivos Planos .tws

Un sistema Web fue elaborado para concentrar los archivos con problemas en un servidor. Al recibir los archivos, se realiza un preprocesamiento. Con él se obtienen varias características extraídas de los datos del evento que registró el equipo. Los valores que se calculan para cada fase en el preprocesamiento son: total de caracteres para representar el evento, el valor máximo registrado, el valor mínimo, el promedio de los valores, la varianza y el número de eventos fuera del rango nominal, los cuales se almacenan en una tabla de una base de datos en MySQL (Figura 3).

id	fecha	canal	valor	maximo	minimo	promedio	varianza	eventos_fuera_rango
1	2016-08-20	A	1000	1000	0	1000	0	0
1	2016-08-20	B	1000	1000	0	1000	0	0
1	2016-08-20	C	1000	1000	0	1000	0	0
2	2016-08-20	A	1000	1000	0	1000	0	0
2	2016-08-20	B	1000	1000	0	1000	0	0
2	2016-08-20	C	1000	1000	0	1000	0	0

Figura 3 Tabla en donde se almacenan los valores que caracterizan el archivo .tws cargado en el servidor.

La extracción de estas características de un archivo .tws, permitirán entrenar y utilizar una red neuronal para el reconocimiento de patrones de onda viajera similares. El sistema Web además realiza varios estudios de correlación. Un estudio se realiza con la serie de valores calculados, en tanto otro estudio se realiza con los datos tal y cual se encuentran en el archivo de texto. Ello permitió que se pudiera verificar si los estudios estadísticos y los de inteligencia artificial podrían utilizarse para reconcer patrones de onda viajera.

Algoritmo de Convergencia Utilizado en la Implementación de la Red Neuronal Artificial

Las neuronas individuales que componen una RNA, son interconectadas a través de su sinapsis. Estas conexiones permiten comunicar a otras como es procesada la información. No todas las conexiones son iguales, asignándoles un peso. Estos pesos son los que determinan la salida de la RNS, así se puede decir que los pesos forman la memoria de la red.

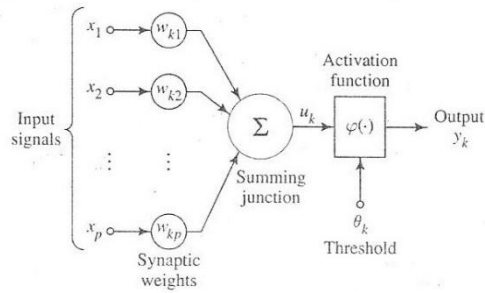


Figura 4 Modelo no lineal de una neurona artificial (tomado del libro Neural Networks: A Comprehensive Foundation).

Para implementar la Red Neuronal Artificial (RNA), se utilizó el modelo del perceptrón, para el cual se identifican los elementos básicos: 1) un conjunto de sinapsis o líneas de conexión, cada una caracterizada por un peso o fuerza. Específicamente una señal x_j en la entrada de la sinapsis j conectada a una neurona k es multiplicada por un peso sináptico w_{kj} , 2) un sumador, para sumar las señales de entrada multiplicadas por el peso de la respectiva sinapsis de la neurona, 3) una función de activación para limitar la amplitud de la salida de una neurona (Figura 4).

Al modelo presentado en la Figura 4, se añade un umbral externo aplicado θ_k que tiene el efecto de bajar la entrada de red de la función de activación. Resultando el modelo matemático para el perceptrón:

$$u_k = \sum_{j=0}^p w_{kj} x_j \quad (1)$$

$$y_k = \varphi(u_k) \quad (2)$$

Considerando una sinapsis con valor:

$$x_0 = -1 \quad (3)$$

Con peso:

$$w_{k0} = \theta_k \quad (4)$$

La neurona se activará o no, dependiendo de la función de activación denotada por $\varphi(\cdot)$ en la Figura 4.

Comúnmente se utilizan tres tipos de funciones básicas de activación:

La función umbral. Este tipo de activación se muestra en la Figura 5 y matemáticamente se tiene:

$$y = \begin{cases} 1 & \text{si } v_k \geq 0 \\ 0 & \text{si } v_k < 0 \end{cases} \quad (5)$$




Figura 5 Función umbral (tomado del libro Neural Networks: A Comprehensive Foundation).

Función lineal por rangos. En este tipo de función se presenta una combinación lineal, si la región lineal de operación es mantenida sin entrar en saturación (Figura 6). Y matemáticamente se expresa:

$$\varphi(v) = \begin{cases} 1 & v \geq \frac{1}{2} \\ v & -\frac{1}{2} < v \leq \frac{1}{2} \\ 0 & v \leq -\frac{1}{2} \end{cases} \quad (6)$$




Figura 6 Función lineal por rangos (tomado del libro Neural Networks: A Comprehensive Foundation).

Función Sigmoide. Es definida como una función que exhibe propiedades de suavidad y asíntóticas y se encuentra definida por:

$$\varphi(v) = \frac{1}{1 + \exp(-av)} \tag{7}$$




Figura 7 Función sigmoide (tomado del libro Neural Networks: A Comprehensive Foundation).

Algoritmo. Lippmann (1987), nos regala el modelo matemático para la convergencia del algoritmo de aprendizaje de corrección de error para un perceptrón de una capa, el cual proporciona una solución apropiada para localizar los pesos del perceptrón de acuerdo a las entradas y salidas que se establezcan para la RNA. A partir de este modelo matemático se deriva el algoritmo de convergencia del perceptrón:

Variables y Parámetros

$X(n) = (p + 1) - by - 1$, es el vector de entrada = $[-1, X_1(n), X_2(n), \dots, X_p(n)]^T$

$W(n) = (p + 1) - by - 1$, es el vector de pesos = $[\theta(n), w_1(n), w_2(n), \dots, w_p(n)]^T$

$\theta(n)$ = Umbral

$y(n)$ = Respuesta actual (cuantificada)

$d(n)$ = Respuesta deseada

η = Parámetro de razón de aprendizaje, constante positiva menor que la unidad

Algoritmo

Paso 1.- Inicialización

Establezca $W(0) = 0$.

Luego ejecute los siguientes cálculos desde $n=1,2,\dots$

Paso 2.- Activación

En el momento n , active el perceptron aplicando el vector de entrada de valores $X(n)$ y respuesta deseada $d(n)$

Paso 3.- Calculo de la respuesta activa

Calcule la respuesta actual del perceptron $y(n) = w^T(n)x(n)$

Paso 4.- Termina el aprendizaje

Si el valor absoluto de la diferencia $y(n) - d(n)$ es menor a error deseado. El algoritmo encontró los pesos adecuados y el algoritmo termina.

Paso 5.- Adaptación del vector de pesos

Actualice el vector de pesos del perceptron

$$w(n + 1) = w(n) + \eta[d(n) - y(n)]X(n)$$

Donde

$$d(n) = \begin{cases} +d(n) & \text{si } x(n) \text{ pertenece a } C1 \\ -d(n) & \text{si } x(n) \text{ pertenece a } C2 \end{cases}$$

Paso 5.- Incremente n en 1 unidad y vaya al paso 2

El algoritmo fue implementado en una aplicación para escritorio, utilizando el Lenguaje C.

Resultados

Una RNA con tres neuronas se implementó para el reconocimiento de tres ejemplares de archivos .tws proporcionados por la empresa eléctrica. Los vectores de datos para la entrada de la red neuronal se formaron con las características extraídas de los archivos: valor máximo, valor mínimo, promedio, varianza, valores fuera de valor nominal:

```
{1.0, 255.0, 0.0, 127.764, .02703, 3140}
{1.0, 211.0, 52.0, 131.04, .008232, 10012}
{1.0, 196.0, 32.0, 127.273, .002283, 123}
```

El entrenamiento se realizó en tres ocasiones para que la RNA proporcionara las siguientes salidas:

```
{0.0, 1.0, 1.0}
{1.0, 0.0, 1.0}
{1.0, 1.0, 0.0}
```

Con el primer vector de salida se identifica el primer vector de entrada, y así sucesivamente.

En la Figura 8, se muestra un proceso de aprendizaje de la RNA, para el primer vector de entrada. El valor .05, es la diferencia entre la salida de la neurona y el valor esperado para la primera entrada (error de época).

Los valores que vienen a continuación del error de época: {107.551587, -0.447, -0.612609, .003235, .002340, .001919}, son los pesos que calculó el algoritmo. Finalmente viene la salida que la neurona arroja al aplicar los tres vectores de entrada con que se cuenta: {.006919, 1.020135, 0.983849}. A esta salida aún no se le aplica la función umbral para acotar los valores de salida.

```
c:\users\lalo_torroro\documents\visual_studio_2012\Projects\Project3\Debug\Project3.exe
0.050000
0.050000
0.050000
0.050000
0.050000
0.050000
0.050000
0.050000
0.050000
0.050000
0.050000
0.050000
107.551587
-0.447000
-0.612609
.003235
.002340
.001919
.006919
1.020135
0.983849
```

Figura 8 RNA entrenada para una salida {0.1.1} y un error de época de 0.05.

La inclusión de equipos que permiten capturar los fenómenos generados por diversos eventos en las líneas de transmisión eléctricas han permitido que éstos se puedan ubicar con bastante precisión, sin embargo, la identificación automática aún no se ha podido realizar. En Flores, Torrero, Urquiza y Torrero (2015), se describen los resultados que se obtuvieron al aplicar estudios de correlación en los archivos proporcionados por la empresa eléctrica, encontrando que una forma de discriminar eventos de anomalías en las líneas, se daba al utilizar todos los caracteres del archivo plano en que el equipo TWS grabó la falla.

El uso de una RNA's en la identificación de patrones de onda viajera es otro proceso que podría utilizarse para la identificación de estos patrones.

Agradecimiento

Gracias al apoyo financiero recibido en la convocatoria 2014 de proyectos de investigación del Tecnológico Nacional de México, ha sido posible llevar a cabo este proyecto.

Conclusiones

Después de elaborar el sistema para cargar archivos y realizar estudios de correlación se llevó a cabo este estudio, logrando con las características extraídas de los archivos .tw5 entrenar una RNA, y obtener una respuesta más rápida que los estudios de correlación para identificar las fallas de aquellos archivos de los que tenemos información.

El número limitado de archivos que se tuvieron para hacer pruebas, no permite generalizar los resultados, tanto en los estudios de correlación, como en el estudio con una RNA, sin embargo, nos ha permitido presentar dos posibles soluciones al reconocimiento de patrones de onda viajera y comparar ambos estudios, encontrando en relación a tiempo de respuesta, mejores resultados en la RNA.

El uso de una RNA abre nuevos caminos para el reconocimiento de estos eventos, faltando estudios para: conseguir más archivos para validar la RNA, revisar otros parámetros para entrenar la red, comparar los resultados al utilizar otra arquitectura de RNA's, como la de retropropagación, incorporar la RNA al sistema Web desarrollado y que ya cuenta con los estudios de correlación, así como iniciar la incursión en las redes neuronales no supervisadas.

Referencias

Bishop, C. (2014). *Neural Networks for Pattern Recognition*. New York: Oxford University Press Inc

Christos, S. & Signos, D. (s.f.). Neural networks. Recuperado de https://www.doc.ic.ac.uk/~nd/surprise_96/journal/vol4/cs11/report.html#Contents.

Fernandes, M., Pinto, J., Dutra, C. & Zimath, L. (2012). Traveling waves – Reliability in fault location. *PAC World. Protection Automation & Control Word*. Recuperado de https://www.pacw.org/issue/september_2012_issue/brazilian_blackout_2012/brazilian_blackout_2012/complete_article/1.html.

Flores, S., Torrero, F., Urquizo, E. & Torrero, G. (noviembre, 2015). Caracterización de archivos planos de patrones de eventos de onda viajera en líneas de transmisión eléctrica. En R.M. presidente. *Congreso Internacional de Investigación de Academia Journals.Com*. Llevado a cabo en Celaya, Gto.

Haykon, S. (2005). *Neural Networks. A Comprehensive Foundation*. Ontario, Canadá: Pearson/Prentice Hall.

Heaton, J. (2008). *Introduction to Neural Networks with Java*. Estados Unidos: Heaton Research.

Meléndez, C. & Torres, F. (2015). Sistema de localización y prevención de fallas mediante el principio de onda viajera. CFE.

MySQL. (2015). *MySQLDocumentation*. Recuperado de <http://dev.mysql.com/doc/>.

Nielsen, M. (2016). Using neural nets to recognize handwritten digits. Recuperado de <http://neuralnetworksanddeeplearning.com/chap1.html>

Schweitzer, E., Guzmán, A. Mangapathirao, M., Skenddzic, V. & Marx, S. (2014). Locating faults by the traveling waves they launch. *2014 67th Annual Conference for Protection Relay Engineers*. Llevado a cabo en Texas A & M University.

Torrero, F. (2016). *Reconocimiento de patrones de onda viajera en líneas de transmisión eléctricas*. (Tesis de maestría). Instituto Tecnológico de La Laguna. Torreón, Coahuila, México.