

DETECCIÓN E IDENTIFICACIÓN DE EVENTOS DE LA CALIDAD DE LA ENERGÍA ELÉCTRICA UTILIZANDO LA TRANSFORMADA WAVELET DISCRETA Y REDES NEURONALES

VALDOMIRO VEGA GARCÍA

*MI (c) Ing. Electricista
Profesor cátedra
Universidad Industrial de Santander.
valdomirovega@hotmail.com*

CÉSAR ANTONIO DUARTE GUALDRÓN

*MPE. Ing. Electricista
Profesor Asistente
Escuela de Ingeniería Eléctrica, Electrónica y Telecomunicaciones
Universidad Industrial de Santander.
cedagua@uis.edu.co*

GABRIEL ORDÓÑEZ PLATA

*Ingeniero Electricista, Dr.
Profesor Titular
Escuela de Ingeniería Eléctrica, Electrónica y Telecomunicaciones
Universidad Industrial de Santander.
gaby@uis.edu.co*

Fecha Recepción: 10 de marzo de 2006

Fecha Aceptación: 23 de mayo de 2006

RESUMEN

En este artículo se estudia la aplicación de la transformada Wavelet discreta (TWD) y redes neuronales en la detección e identificación de eventos de la calidad de la energía eléctrica. Se estudian algunos patrones basados en la TWD propuestos para la identificación de eventos de baja frecuencia como las fluctuaciones de tensión ("flicker") y los armónicos; y para la identificación de eventos de alta frecuencia como los transitorios tipo impulso y los huecos de tensión. Para la detección e identificación se utiliza la función Wavelet Daubichies4 como función base para la transformación, dadas sus características de respuesta en frecuencia y de localización de información en el tiempo. Como clasificador de los eventos se utiliza un esquema basado en redes neuronales (perceptron multicapa) tomando como entrada los patrones de los eventos. Los resultados son satisfactorios (superiores al 80% y 90% de acierto en la mayoría de los eventos) considerando que algunos eventos presentan similitudes en los patrones. Esta estrategia fue integrada en una interfaz gráfica de usuario desarrollada en MatLab® y probada con señales sintéticas las cuales fueron simuladas y almacenadas en una base de datos de perturbaciones.

PALABRAS CLAVE: *Armónicos, calidad de la energía eléctrica, elevaciones de tensión, flicker, huecos de tensión, redes neuronales, monitorización, transformada Wavelet, transitorios.*

ABSTRACT

This paper deals about an application of Discrete Wavelet Transform (DWT) and Neural Networks in detection and identification of power quality events. Some patterns based on DWT are used in order to identify low frequency events like flicker and harmonics, and high frequency events like impulsive transient and sags. The Wavelet Function Daubichies4 is used as a base function because of its frequency response and time information localization properties. A scheme based on neural networks (perceptron multilayer) taking event patterns as inputs is used as event classifier. The results are satisfactory (80 and 90 percent of success for the most events) considering that some events present resemblances in their patterns. This strategy was integrated on a MatLab® Graphical User Interface and tested by using synthetic signals which were simulated and collected in a disturbance database.

KEYWORDS: *Harmonics, power quality, sags, swells, flicker, neural networks, Wavelet Transform, transients, database.*

INTRODUCCIÓN

Dada la importancia de la calidad del servicio de energía eléctrica a nivel mundial y teniendo en cuenta que las perturbaciones electromagnéticas causan pérdidas considerables tanto para la industria como para los usuarios residenciales, es necesario el análisis y caracterización de estos fenómenos para tomar medidas al respecto. Por tanto la monitorización de los eventos de la calidad de la energía eléctrica es fundamental para brindar soluciones a la industria y al sector eléctrico.

Entre las técnicas de procesamiento de señal más utilizadas en la monitorización de la calidad de la energía eléctrica está La Transformada de Fourier (TF) la cual se adapta bien para la monitorización de eventos en estado estacionario, pero presenta limitaciones en el seguimiento de eventos transitorios como los huecos de tensión y/o los transitorios oscilatorios o de tipo impulso. Debido a esto, se ha propuesto la Transformada Wavelet (TW) como una nueva técnica de procesamiento para la monitorización dado que ofrece la posibilidad de realizar un análisis multiresolución tanto en el dominio del tiempo como en el dominio de la frecuencia.

Aprovechando las propiedades de duración efectiva finita, espectro pasa-banda, forma de onda semejante al evento en estudio y ortogonalidad, es posible localizar información en el tiempo y en la frecuencia y así obtener alta correlación cuando ocurren eventos de la calidad de la energía eléctrica y descomponer la señal en diferentes componentes sin que existan solapamientos de energía entre éstas.

Existen varios estudios [1], [2] en los cuales se utiliza la Transformada Wavelet para la detección e identificación de eventos utilizando principalmente la función Wavelet Daubichies 4 como función base para la transformación. Asimismo, se han utilizado las redes neuronales para clasificar los diferentes eventos a partir de los resultados de la Transformada Wavelet de señales obtenidas de eventos sintetizados a partir de modelos matemáticos [3], [4].

En [5] se presenta un análisis de la Transformada Wavelet y su utilidad en la caracterización de algunos fenómenos electromagnéticos. No obstante, no se estudian estrategias de identificación y/o clasificación. En este trabajo se propone continuar con el trabajo realizado, contribuyendo a la comprensión de la utilidad de la Transformada Wavelet y desarrollando un soporte informático para simular la detección, identificación y clasificación de la mayor cantidad posible de eventos o perturbaciones que afectan la calidad de las ondas de tensión y corriente (Power Quality).

En cuanto a los estudios sobre eventos de la calidad de la energía eléctrica, a continuación se describen algunos trabajos realizados sobre el análisis de perturbaciones de la onda de tensión empleando diferentes técnicas de procesamiento de la señal.

En [11] se presenta el estado del arte de las técnicas de procesamiento de señales para la clasificación automática de los eventos de la calidad de la energía. [12] propone la Wavelet Morlet para el análisis de transitorios en sistemas de potencia simulados en EMPT. [13] compara 3 de las nuevas técnicas de procesamiento de señal para el análisis de la calidad de potencia, las cuales son: la Transformada Wavelet Continua, el Análisis Multiresolución y la Transformada Cuadrática. En [14] se plantea un método de detección y clasificación de eventos de la calidad de la potencia basado en reglas heurísticas, implementado en una interfaz gráfica en MatLab. En [15] se propone la Transformada Wavelet utilizando la función base Morlet para supervisar perturbaciones en el sistema de potencia. En este artículo se describen los conceptos matemáticos de la Transformada Wavelet Discreta y se presentan las propiedades que la hacen efectiva para este estudio (calidad de la energía), así como los algoritmos necesarios para el cálculo de la transformada, el esquema de descomposición y reconstrucción, y la respuesta en frecuencia de los filtros utilizados para estas operaciones. Posteriormente se estudian las estrategias para la detección e identificación de los eventos de la calidad de la energía eléctrica utilizando la transformación Wavelet Discreta y se expone la estrategia empleada para la clasificación automática de estos eventos. Finalmente, se presentan los resultados de simulación y las conclusiones de esta investigación.

TRANSFORMADA WAVELET DISCRETA

En esta sección se presentan las definiciones y propiedades de la Transformada Wavelet Discreta, teniendo en cuenta sus ventajas y desventajas frente a otros algoritmos como la Transformada de Fourier y la Transformada de Fourier de Tiempo Corto (TFCT) en cuanto a la detección y clasificación de eventos de la calidad de la energía eléctrica.

La Transformada de Fourier: es adecuada para el análisis de señales estacionarias con componentes frecuenciales constantes; pero no lo es, para el análisis de señales no

$$X(j\omega) = \int_{-\infty}^{+\infty} x(t) e^{-j\omega t} dt \quad (1)$$

estacionarias donde las frecuencias varían con el tiempo [6]. La Transformada de Fourier o Integral de Fourier de una señal $x(t)$ se define como [7]:

Además, debido a que la Transformada de Fourier es adecuada para el análisis de señales estacionarias, es posible considerar las señales no estacionarias como estacionarias en intervalos cortos de tiempo. Es decir, se pueden tomar intervalos de la señal (ventanas) y analizar las componentes de frecuencia de cada intervalo en particular [6]. Para realizar este procesamiento, la señal $x(t)$

$$(G_h x)(b, \xi) = \int_{-\infty}^{\infty} x(t)h(t-b)e^{-j\xi t} dt \quad (2)$$

se multiplica por una función ventana que se desplaza en el tiempo $h(t-b)$ y luego se calcula la TF de este producto, como se expresa en la siguiente ecuación:

Dónde ξ representa las frecuencias que contiene la ventana

$$(G_h x)(b, \xi) = \frac{e^{-j\xi b}}{2\pi} \int_{-\infty}^{\infty} X(j\omega) \overline{H(j(\omega-\xi))} e^{j\omega b} d\omega$$

de la función $x(t)$ cuya ubicación en el tiempo está determinada por la variable b . Aplicando la identidad de Parseval a (2) se obtiene:

De esta forma el algoritmo de la Transformada de Fourier de Tiempo Corto realiza mejores estimaciones que la TF, ya que permite analizar, tanto en tiempo como en frecuencia, señales no estacionarias. No obstante, el análisis se limita a los rangos de tiempo y frecuencia determinados por la duración de $h(t)$ en el tiempo y el ancho de banda de esta ventana en frecuencia, respectivamente. Por tanto, sólo permite apreciar un intervalo definido del evento transitorio que se desee analizar y no es posible precisar adecuadamente su ubicación exacta, ya que las ventanas tanto de tiempo como de frecuencia son de ancho constante.

Para suplir las falencias de la TF y la TFCT es necesario un esquema dinámico donde en un mismo sistema de coordenadas se puedan variar los anchos de ventana de forma simultánea, tanto para la localización en tiempo como en frecuencia, conservando en lo posible la resolución en ambos dominios. Esta característica se logra por medio del análisis-multirresolución tiempo-frecuencia que ofrece la **Transformada Wavelet**.

La Transformada Wavelet Continua (TWC), conocida también como Transformada Integral Wavelet está definida mediante la siguiente **expresión** [8]:

$$(W_\psi x)_{(b,a)} = \frac{1}{\sqrt{a}} \int_{-\infty}^{\infty} x(t) \psi\left(\frac{t-b}{a}\right) dt = \langle x(t), \psi_{a,b}(t) \rangle \quad (4)$$

Dónde \langle, \rangle denota la operación de producto interno; $\psi(t)$ es la "función Wavelet madre" o Wavelet de análisis de la

Transformada Integral Wavelet y la localización en tiempo está determinada por el término:

$$\psi_{a,b}(t) = \frac{1}{\sqrt{a}} \psi\left(\frac{t-b}{a}\right) \quad (5)$$

Siendo a y b los factores de escalamiento y desplazamiento en el dominio del tiempo respectivamente, con a y $b \in \mathfrak{R}$ y $a \neq 0$. En (4) se considera que la función Wavelet utilizada es de valor real.

A partir de (4) es posible reconstruir la función $x(t)$ utilizando la ecuación de "resolución de identidad" [8]:

$$x(t) = \frac{1}{C_\psi} \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} \frac{1}{a^2} (W_\psi x)_{(b,a)} \psi_{a,b}(t) da db \quad (6)$$

Donde $\psi_{a,b}(t)$ representa un conjunto de Wavelets generadas a partir de la "función Wavelet madre" $\psi(t)$, la cual se expande y atenúa o se comprime y amplifica conforme a aumenta o disminuye respectivamente; además $\psi(t)$ se desplaza en el dominio del tiempo conforme b varía (5). La constante C_ψ depende de $\psi(j\omega)$ y está dada por [8]:

$$C_\psi = 2\pi \int_{-\infty}^{\infty} \frac{|\Psi(j\omega)|^2}{|\omega|} d\omega \quad (7)$$

Transformada Wavelet Discreta: La TWD se deriva a partir de la TWC considerando que los parámetros de escalamiento a y de desplazamiento b toman valores discretos:

$a = a_0^j$, $b = k b_0$, a_0^j , con $j, k \in \mathbb{Z}$ y $a_0 > 1$ y $b_0 > 0$. Reemplazando estos valores en (4) se tiene [8]:

$$(W_\psi x)_{(j,k)} = \frac{1}{\sqrt{a_0^j}} \int_{-\infty}^{\infty} x(t) \psi(a_0^{-j}t - kb_0) dt = \langle x(t), \psi_{j,k}(t) \rangle \quad (8)$$

Donde el conjunto de funciones Wavelet $\psi_{j,k}(t)$ está dado por:

$$\psi_{j,k}(t) = \frac{1}{\sqrt{a_0^j}} \psi(a_0^{-j}t - kb_0) \quad (9)$$

Para el caso discreto no existe en general una fórmula de "resolución de identidad", análoga a (6) en el caso continuo, debido a que sólo se conoce la TW para un conjunto discreto de valores de a y b . No obstante, para determinadas "funciones Wavelet madre" y factores a_0 y b_0 apropiados, es posible invertir la transformación mediante la siguiente expresión [8]:

$$x(t) = \sum_{j \in \mathbb{Z}} \sum_{k \in \mathbb{Z}} (W_\psi x)_{(j,k)} \psi_{j,k}(t) \quad (10)$$

De esta manera, la señal $x(t)$ se puede expresar como una combinación lineal de funciones Wavelet escaladas y desplazadas en el tiempo $\psi_{j,k}(t)$.

El caso particular más utilizado para el cálculo de la Transformada Wavelet discreta es con $a_0=2$ y $b_0=1$. Este caso se conoce como escala diádica por la característica de escalamiento en potencias de 2. Para expresar la señal de acuerdo con (10) y realizar un análisis multi-resolución tiempo-frecuencia se requiere que el conjunto de funciones $\psi_{j,k}(t)$ sea ortonormal [6], [8].

ALGORITMOS

En esta sección se presentan los algoritmos básicos de descomposición y reconstrucción de la señal por medio de la función Wavelet, los cuales fueron utilizados en las simulaciones realizadas.

El esquema de descomposición está conformado por dos filtros FIR, con respuestas al impulso a_m y b_m , pasa-bajas y pasa-altas respectivamente; seguido de un diezmado por dos. Por tanto, si a la entrada se tienen las muestras de la señal c_n , a la salida se obtendrán los coeficientes de aproximación c_{n-1} (a partir de la respuesta del filtro pasa-bajas) y de detalle d_{n-1} (a partir de la respuesta del filtro pasa-altas) de la siguiente forma [6]:

$$\begin{cases} c_{n-1,k} = \sum_m a_{m-2k} c_{n,m} \\ d_{n-1,k} = \sum_m b_{m-2k} c_{n,m} \end{cases}$$

Asimismo, a partir de los coeficientes Wavelet es posible reconstruir la señal con un esquema similar, haciendo inserción de ceros entre muestras y luego procesando estas secuencias utilizando filtros FIR, con respuestas al impulso p_m y q_m , pasa-bajas y pasa-altas respectivamente; obteniendo a la salida las muestras de la señal:

$$c_{n,k} = \sum_m \{p_{k-2m} c_{n-1,m}\} + \sum_m \{q_{k-2m} d_{n-1,m}\}$$

En la **Figura 1** se presentan los esquemas de descomposición y reconstrucción.




Figura 1. Esquema de descomposición y reconstrucción

Este conjunto de filtros está determinado por la "función Wavelet madre" seleccionada para la transformación. La expresión dada en (10) es equivalente a (12), sólo que con esta última se descomponen las muestras de la señal.

En la **Figura 2** se presentan la respuesta al impulso y la respuesta en frecuencia de los filtros de descomposición y reconstrucción obtenidos a partir de la función Wavelet Daubechies 4.

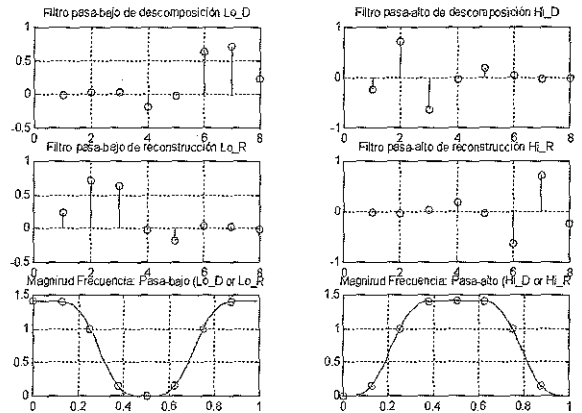


Figura 2. Conjunto de filtros de descomposición y reconstrucción de la secuencia "db4".

DETECCIÓN E IDENTIFICACIÓN DE EVENTOS

En esta sección se analizan las estrategias utilizadas para detectar e identificar los eventos de la calidad de la energía eléctrica con la transformada Wavelet.

Para realizar la detección de los eventos es necesario clasificarlos. En [9] y [10] se clasifican estos eventos de la siguiente manera: transitorios electromagnéticos (tipo impulso y oscilatorio), armónicos, fluctuaciones de tensión (flicker), huecos de tensión (sags, dips), sobretensiones (swells), desbalances de tensión, interrupciones, muescas de tensión (notching) y variaciones de frecuencia.

Teniendo en cuenta esta clasificación de los eventos y empleando el esquema de descomposición se obtienen los coeficientes Wavelet de detalle, el cual permite con el esquema de reconstrucción de estos coeficientes encontrar los detalles de la señal (**Figura 1**). Aplicando nuevamente el esquema de descomposición a la señal de aproximación se pueden encontrar nuevos detalles en otro rango de frecuencias menores al de las frecuencias de los detalles ya calculados. De esta forma se pueden analizar diferentes niveles de detalle (o rangos de frecuencia) de la señal.

En la Figura. 3 se observa la detección de un hueco de tensión de una onda de 60 Hz en el primer nivel de detalle, empleando la función Wavelet daubechies4 "db4".




Figura 3. Descomposición de un hueco de tensión("SAG") en 4 niveles detalle para "db4"

Puede notarse como es posible detectar el inicio y/o final de diferentes perturbaciones en el primer nivel de detalle. Esto se debe a que el inicio o final de las perturbaciones contiene fundamentalmente frecuencias altas, las cuales son detectadas principalmente en la función de detalle del primer nivel de descomposición.

También se pueden identificar los eventos con la energía de los coeficientes Wavelet. A partir de los coeficientes de la TWD se puede calcular la energía de la señal que se encuentra en cada nivel de descomposición. Por tanto, es posible conocer la distribución de la energía de la señal en el rango de frecuencias que exista en cada nivel de descomposición. Dependiendo de la frecuencia de muestreo (F_s) y de la función Wavelet de análisis (db4) se determina el ancho de banda de cada nivel de descomposición. En el caso de los filtros de descomposición para la función Wavelet Daubechies 4 (Figura. 2) los rangos de frecuencia de las funciones de detalle (D) y aproximación (A) se pueden considerar idealmente como se muestran en la Figura. 6 hasta el cuarto nivel de descomposición.




Figura 4. Conjunto de perturbaciones usadas en el análisis

En la Figura. 4 se muestra un conjunto de eventos utilizados en el estudio, y en la Figura. 5 se presentan los detalles respectivos en el primer nivel de descomposición de la transformación Wavelet.




Figura 5. Detalles del primer nivel de las perturbaciones de la Figura 4.



Figura 6. División de las bandas de frecuencias de cada nivel de detalles

La selección de la estrategia de identificación de cada uno de los eventos se basa en las propuestas de [1] y [2]. La estrategia desarrollada en [2] consiste en el cálculo de la desviación estándar de los coeficientes Wavelet de cada nivel de descomposición, tanto para la señal pura (senoidal) como para la señal con perturbación.




Figura 7. Patrón para una señal (trazos) y para una señal con perturbación (sólida) usando desviación estándar.

En la Figura. 7 se aprecia que las diferencias entre el patrón de la señal pura y el patrón de la perturbación (sag Figura. 3) son muy pequeñas. Luego en [2], se utilizan estas diferencias para determinar el tipo de perturbación utilizando una red neuronal, la cual requiere gran cantidad de información de entrenamiento, dado que no existen marcadas diferencias entre los patrones.

El método planteado en [1] se basa en el cálculo de las diferencias de energía por nivel, es decir, se calcula la energía de los coeficientes de cada nivel de detalle (la cual es equivalente a la energía de los detalles de la señal) tanto para la señal sinusoidal pura como para la señal con perturbaciones y luego se comparan mediante la siguiente expresión:

$$dp(j)(\%) = \left[\frac{En_per(j) - En_ref(j)}{En_ref(m)} \right] * 100 \quad (13)$$

Siendo $dp(j)(\%)$ la desviación de la energía de la perturbación $En_per(j)$ con respecto a la energía de la señal de referencia (senoidal pura) $En_ref(j)$ en el nivel de descomposición j . Esta desviación se expresa como un porcentaje de la energía concentrada en el nivel de mayor energía (m) de la señal de referencia, $En_ref(m)$. No obstante, en [1] no se propone utilizar una red neuronal para clasificar los diferentes tipos de perturbaciones.

Aplicando (13) a la perturbación ejemplo (evento sag **Figura 3**), se obtiene el patrón mostrado en la **Figura 8**.




Figura 8. Patrón característico para señal perturbada (sag - sólida) utilizando las desviaciones de energía respecto a una sinusoidal pura - punteada.

Esta es la estrategia de identificación que se ha adoptado para este estudio, dado que permite obtener patrones de los diferentes tipos de perturbaciones con bajo grado de similitud entre los mismos (**Figura 9**), lo cual permite clasificar de manera sencilla los eventos. Sin embargo, debe notarse que los patrones para el evento "swell" y para el flicker tienen características similares. Asimismo, para eventos de un mismo tipo que se presenten en tiempos diferentes, se obtienen variaciones significativas en la magnitud del patrón debido a la no invarianza al desplazamiento de la Transformada Wavelet (expresada en (4)).

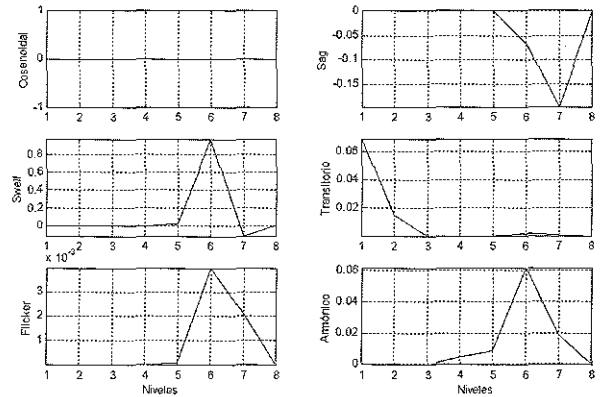


Figura 9. Patrones característicos de las perturbaciones de la Figura 4.

En la **Figura 9** se presentan los patrones hasta el nivel 8 dado que se ha utilizado una frecuencia de muestreo de 7 680 [Hz], lo que significa que idealmente en este nivel ya se encuentran las frecuencias menores a 30 [Hz] y las perturbaciones analizadas en este trabajo no poseen información relevante en este rango de frecuencias.

CLASIFICACIÓN DE EVENTOS: IMPLEMENTACIÓN DE UNA RED NEURONAL

El empleo de Redes Neuronales Artificiales, Lógica Fuzzy o la combinación de ambas para la clasificación de eventos ha sido propuesto en [2], [14] y [16] entre otros.

A partir de los patrones obtenidos utilizando la estrategia seleccionada para identificar los diferentes eventos o perturbaciones, es necesario un esquema de clasificación automática de tales eventos. Para tal labor, en este estudio se entrenó una Red Neuronal Artificial (RNA) para eventos muestreados a razón de 128 muestras por ciclo de 60 Hz, con los siguientes parámetros: red per-ceptrón multicapa (**Figura 10**), función de desempeño feedforward, función de activación tangente sigmooidal, 3 capas ocultas y una de salida y [8 6 4 1] neuronas por capa. Las 8 entradas son los patrones de desviación de energía de 5 tipos de perturbación para 8 niveles de descomposición. La salida es un número entre 1 y 5 que permite clasificar los 5 tipos de perturbación. Los parámetros de la RNA se determinaron de acuerdo con el estudio presentado en [17].

El entrenamiento de la red se realizó con 5 600 entradas (700 entradas para cada neurona de la capa de entrada) y 700 salidas. Para la validación del entrenamiento se utilizaron 1 680 entradas (210 para cada neurona de la capa de entrada) y 210 salidas.




Figura 10. Red neuronal multicapa.

Para el desarrollo de este trabajo se generó una base de datos con 19 430 señales sintéticas considerando un amplio número de variaciones en los parámetros que caracterizan las diferentes perturbaciones (magnitud, punto de inicio en la onda senoidal de 60 Hz, duración, frecuencia característica, etc.). De esta base de señales se seleccionaron las señales utilizadas para el entrenamiento, validación y evaluación del desempeño de la RNA; de tal forma que cada señal se utilizó sólo una vez. Las redes neuronales anteriormente mencionadas se conocen como de aprendizaje supervisado porque necesitan referenciar la salida de cada elemento de entrada. A la par de éstas se encuentran las redes de aprendizaje no supervisado. En este aprendizaje no se requiere presentar patrones de salida deseados. Sin embargo, el algoritmo y la regla de modificación de las conexiones producen vectores de salida consistentes; esto es, la presentación de un patrón aprendido o parecido a él, produce siempre la misma salida. Se considera que el proceso de aprendizaje es capaz de extraer ciertas propiedades estadísticas de los ejemplos de aprendizaje y agruparlos en categorías o clases de patrones similares. No se conoce a priori que salida corresponderá a cada tipo o grupo de patrones de entrada, ni que atributos usará para clasificarlos, por eso son muy útiles como generadores de categorías (clustering) [19].

Para una última prueba se empleó la red de Kohonen, la cual pertenece a la categoría de las redes competitivas o mapas de autoorganización, es decir, con aprendizaje no supervisado de tipo competitivo. Poseen una arquitectura de dos capas (entrada-salida) (una sola capa de conexiones), funciones de activación lineales y flujo de información unidireccional (son redes en cascada). Los mapas autoorganizados, hacen semejanza al comportamiento de las redes competitivas biológicas, que cuando se refuerza una neurona asimismo, se refuerza también las neuronas que están cerca e inhibe la más lejanas utilizando como medida la distancia entre ellas.

El modelo LVQ (algoritmo de cuantificación vectorial adaptable) es una derivación directa de los mapas auto organizados (SOM) con aprendizaje competitivo supervisado. Fue introducido por Kohonen en 1990. Emplea una capa simple de neuronas que compiten entre sí, pero sin relación de vecindad. En el aprendizaje competitivo supervisado, en su forma más general, se "premia" a las neuronas que clasifican correctamente un patrón de entrada, actualizando sus pesos y se "castiga" a las que clasifican mal modificando sus pesos en sentido contrario[18]. Esta red se entrenó con las mismas entradas de la red anterior pero no se necesitaron datos de validación ni de salida. El error máximo permitido fue 0,001 y el número de iteraciones fue 800. Todos estos parámetros se utilizaron para entrenar patrones de señales muestreadas a 128 [m/c] y a 1024 [m/c].

RESULTADOS DE SIMULACIÓN

En este estudio se analizaron eventos muestreados a 128 y 1 024 muestras por ciclo de 60 Hz (m/c) y se entrenaron dos redes neuronales para cada frecuencia de muestreo. Las características de la RNA para 128 [m/c] se especifican en el numeral anterior. La RNA para 1024 [m/c] es similar a la de 128 [m/c] pero con 10 entradas, una salida y [12 8 4 1] neuronas por capa.

Los errores de entrenamiento y validación de la red están dados por el error cuadrático medio (mse) entre las salidas dadas por la red y las salidas correctas para los patrones de entrenamiento y validación (Tabla I).

De la Tabla I puede observarse cómo los errores son menores cuando se tiene mayor información por unidad de tiempo (1024 [m/c]) para cada evento.

Tabla 1. Errores de entrenamiento y validación de las RNAS

Red Neuronal	Error de entrenamiento [mse]	Error de validación [mse]
128 [m/c]	0,0733	0,0991
1024 [m/c]	6,2126e-07	1,6410e-04

Para probar la efectividad del esquema de detección e identificación propuesto, se analizaron 100 señales por cada perturbación (seleccionadas aleatoriamente de la base de datos de señales sintetizadas) y se encontraron los siguientes porcentajes de acierto (Tabla 2).

Tabla 2. Porcentajes de aciertos de las RNAS

Evento a 128 m/c	Porcentaje de acierto[%]	Evento a 1024 m/c	Porcentaje de acierto[%]
Sag	93	Sag	94
Swell	97	Swell	93
Flicker	86	Transitorio Oscilatorio	91
Transitorio Oscilatorio	79	Transitorio Impulso	86
Armónico	95	Muestras de Tensión	81

Como se puede apreciar en la **Tabla 2**, los eventos con menor porcentaje de acierto son el flicker y las muescas de tensión (notch). Esto se debe a que el patrón del flicker es similar al patrón del swell y el del notch presenta semejanza con el del sag. Puede pensarse que el flicker contendría información en un rango de frecuencias menores a 30 Hz. Pero considerando este fenómeno como una modulación entre la señal del 60 Hz y una señal en el rango de 0 a 30 Hz [20], el espectro de este producto en tiempo contiene frecuencias en el rango 60 ± 30 Hz. Por lo tanto, no es posible identificar el flicker con facilidad en frecuencias menores a 30 Hz.

En el caso de la prueba con la red neuronal de Kohonen LVQ, los resultados de pueden apreciar en la **Tabla 3**.

Tabla 3. Porcentajes de aciertos para red KOHONEN LVQ.

Evento a 128 [m/c]	Porcentaje de acierto[%]	Evento a 1024 [m/c]	Porcentaje de acierto[%]
Sag	86	Sag	86
Swell	96	Swell	--
Flicker	--	Transitorio Oscilatorio	83
Transitorio Oscilatorio	93	Transitorio Impulso	53
Armónico	66	Muestras de Tensión	63

Como se puede apreciar en la **Tabla 3**, el porcentaje de acierto es mucho menor en las señales muestreadas a 1024 que en las de 128[m/c], con el inconveniente que se presenta en el fenómeno flicker (128[m/c]) y transitorio oscilatorio (1024[m/c]) donde la red no fue capaz de asignarle un grupo definido y por el contrario le asignaba valores pertenecientes a otros grupos. Estos datos se simularon con Neuro K desarrollado por [19]. Por tanto la mejor estrategia de clasificación la ofrece la primera opción (perceptrón multicapa), la cual fue implementada.

En la **Figura 11** se presenta la interfaz con el usuario del analizador de eventos desarrollada en MatLab®. Esta interfaz es capaz de calcularle a una señal de entrada, la frecuencia de muestreo, el número de períodos, el número de muestras por ciclo y posteriormente las secuencias de aproximación y detalles, la Transformada de Fourier, el patrón y la señal de preevento. Seguido a esto la red neuronal clasifica el evento automáticamente

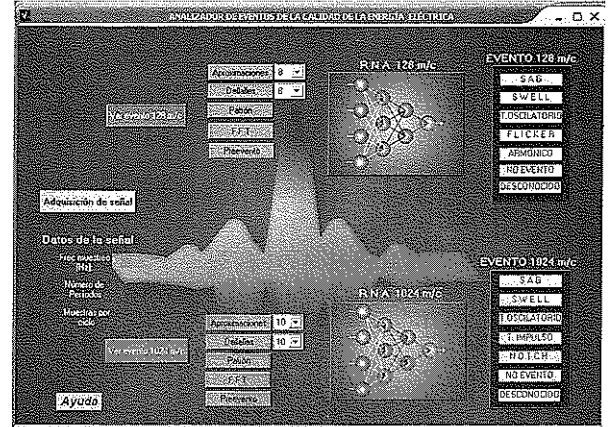


Figura 11. Interfaz con el usuario del analizador de eventos.

CONCLUSIONES

Se ha implementado una técnica para detectar e identificar eventos de la calidad de la energía eléctrica, combinando las ventajas de una estrategia de identificación de eventos basada en la Transformada Wavelet Discreta con las ventajas de las Redes Neuronales Artificiales para clasificar información automáticamente. Una vez clasificado el evento es posible localizarlo a partir de la señal de detalles del primer nivel (**Figura 5**). Asimismo, se generó una base de datos de 19 430 señales sintéticas, con diferentes tipos de eventos y distintas variaciones de los mismos, para que el entrenamiento, validación y evaluación del desempeño de la RNA fuesen realizados considerando la mayor cantidad de posibilidades para las perturbaciones estudiadas.

El porcentaje de acierto obtenido en la evaluación de la estrategia de detección, identificación y clasificación planteada, para la mayoría de los tipos de eventos estudiados, es superior al 80% y 90% en la mayoría de los casos pese a la no invarianza al desplazamiento de la Transformada Wavelet; esta no invarianza provoca cambios en los coeficientes wavelet, cuando el evento es desplazado en el tiempo. Estos cambios se reflejan en la magnitud del patrón al calcular las diferencias de energía por nivel. Este inconveniente se resolvió normalizando los patrones.


Dado que el clasificador de eventos (RNA) no es completamente efectivo cuando los patrones de diferentes eventos son muy similares, es necesario utilizar una estrategia de clasificación que considere otros parámetros de la señal. También cabe resaltar que los patrones obtenidos presentan mayor compatibilidad con las redes supervisadas que con las no supervisadas entre ellas las autoorganizativas.

BIBLIOGRAFÍA

- [1] Resende J.W "Identification of power quality disturbances using the MATLAB wavelet transform toolbox". Universidad Federal de Uberlandia (MG)-Brazil. Pp.8 2001.
- [2] Gaouda, A ; Chikhani, A. "Power quality detection and classification using wavelet-multiresolution signal decomposition " Power Systems, IEEE Transactions on Published: Oct 1,999 Volume: 14 4 , Page(s): 1469 - 1476.
- [3] Cheng Hong, Loh Poh Chiang, S. Elangovan National University of Singapore "Wavelet packets analysis and artificial intelligence based adaptive fault diagnosis" 2002 Pp. 6.
- [4] K. Debnath , M. Negnevitsky , K. Ho, C. Jun School of Engineering University of Tasmania "Recognition of Power Quality Disturbances" 2001
- [5] García Q. Edwin "Armónicos: Aplicación de la Transformada Wavelet para el análisis de transitorios electromagnéticos" Tesis Pregrado UIS . Pp109. 2000
- [6] Chui, Charles K., "Wavelets: a mathematical tool for signal analysis", SIAM, Philadelphia. Pp. 210. 1997
- [7] Alan V. Oppenheim & Alan S. Willsky, "Señales y Sistemas", Editorial Prentice Hall, Segunda Edición . Pp.956. 1998
- [8] Daubechies, Ingrid. "Ten Lectures on Wavelets", Philadelphia: SIAM. (1992). Pp. 357.
- [9] Norma Técnica Colombiana 5000: "Calidad de la potencia eléctrica (CPE). Definiciones y términos fundamentales", Instituto Colombiano de Normas Técnicas (ICONTEC), 2002.
- [10] IEEE Standards coordinating committee 22 on power quality, USA. "IEEE Std 1159-1995: IEEE Recommended practice for monitoring electric power quality", IEEE Standards boards, 1995.
- [11] Flores Rafael A., Member, IEEE "State of the Art in the Classification of Power Quality Events" 10th International Conference in Harmonics and Quality of Power, Brazil, Oct 2002 Pp. 4.
- [12] Heydt, G.T. ; Galli, A.W. " Transient Power Quality Problem Analyzed using Wavelet ", IEEE Transactions on Power Delivery, Vol. 12, No. 2, April 1997. Page(s): 908 -915.
- [13] Poison, O. ; Rioual P. ; Meunier, M. " New Signal Processing Tool Applied to Power Quality Analysis ", IEEE Transactions on Power Delivery, Vol. 14, No. 2, April 1999. Page(s): 561 -915.
- [14] Kezunovic Mladen ; Liao, Yuan "A Novel Software Implementation Concept for Power Quality Study", 2000.
- [15] Shyh-Jier, H. ; Chen-Tao, H. ; Ching-Lien, H. "Application of Morlet Wavelet to Supervise Power System Disturbances", IEEE Transactions on Power Delivery, Vol. 14, No. 1, January 1999. Page(s): 235 -243.
- [16] Xiangxun, Cheng. "Wavelet based detection, localization, quantification and classification of short duration power quality disturbances". IEEE Power Engineering Society Winter Meeting, 2002, Vol. 2, 2002.
- [17] Cormane, Jorge ; Barrera, Victor. "Predicción de corrientes armónicas en ventanas de carga residenciales, mediante modelos neuronales artificiales". Tesis de grado Pp 164, Universidad Industrial de Santander, Bucaramanga 2003.
- [18] Kohonen T. : Self-Organizing Maps. 2ª Ed. Springer-Verlag Berlin Heidelberg. 1997.
- [19] Páez, Carlos; Meneses, Jathinson "Herramienta software para la zonificación de datos, basado en redes neuronales". Tesis de grado Pp 64, Universidad Industrial de Santander, Bucaramanga 2003.
- [20] IEC 6100-4-15 Electromagnetic Compatibility (EMC). Part 4: Testing and measurements technique - Section 15. Flicker-meter. Functional and design specifications. Bureau Central de la Comisión Electrotecnique Internationale, 1997/11.

AUTORES

Valdomiro Vega García. Ingeniero Electricista UIS, Magister en Ingeniería UIS. Becario, Bucaramanga, Colombia. Miembro estudiante IEEE. Profesor Cátedra de la Escuela de Ingenierías Eléctrica, Electrónica y Telecomunicaciones Universidad Industrial de Santander. Investigador GISEL. Áreas de Trabajo: Tratamiento de Señales y calidad del servicio Email: valdomirovega@hotmail.com valdomirovega@ieee.org



César Antonio Duarte Gualdrón. Ingeniero Electricista UIS, Magíster en Potencia Eléctrica UIS, Bucaramanga, Colombia. Profesor Auxiliar de la Escuela de Ingeniería Eléctrica, Electrónica y Telecomunicaciones Universidad Industrial de Santander. Investigador GISEL. Áreas de Trabajo: Tratamiento de Señales, calidad del servicio y formación basada en competencias. Email: cedagua@uis.edu.co.



Gabriel Ordóñez Plata. Ingeniero Electricista, Doctor Ingeniero Industrial UPCO, Madrid, España. Profesor Titular de la Escuela de Ingeniería Eléctrica, Electrónica y Telecomunicaciones Universidad Industrial de Santander. Investigador GISEL. Áreas de trabajo: Tratamiento de Señales, Mediciones Eléctricas, Calidad del Servicio, Gestión Tecnológica y Formación Basada en Competencias. Email: gaby@uis.edu.co.

