

Educational Software for Power Quality Analysis

D. De Yong, C. Reineri, and F. Magnago, *Senior Member, IEEE*

Abstract— This paper presents educational software that allows users to generate, detect and classify electrical power disturbance signals using a Wavelet Transform and Neural Networks based algorithm. This software includes four main modules: a) Signal Acquisition Module that allows the incorporation of waveforms stored in a data base; b) Generation Module which permits the generation of diverse disturbed waveforms; c) Detections Module provides tools to analyze different disturbance detection algorithms and d) Classification Module that determines the disturbance type using different pattern classification methods.

Keywords— Power Quality, Simulation Software, Neural Network, Wavelet Transform.

I. INTRODUCCION

EN LOS últimos años, con la aparición de dispositivos altamente sensibles a las variaciones en la forma de onda de las señales de tensión y corriente, la problemática que involucra la calidad de energía (PQ, Power Quality) ha cobrado creciente interés tanto para los usuarios como para las compañías proveedoras de energía eléctrica.

La norma IEC establece como Calidad de Energía a un conjunto de parámetros que definen las propiedades de la calidad de la energía entregada a los usuarios en condiciones normales de operación en términos de continuidad de la provisión y características de la señal de voltaje (simetría, frecuencia, magnitud y forma de onda) [1]

Se denomina a un evento de PQ a una variación en las formas de onda de tensión o corriente dentro de las cuales se pueden destacar los huecos, fluctuaciones, interrupciones momentáneas, distorsiones, pulsaciones y muescas. Estos eventos tienen diversos orígenes dentro de los cuales se pueden encontrar, entre otros, las fallas o cortocircuitos en la red, conexión intempestiva de grandes cargas, conexión de bancos de condensadores, dispositivos de conmutación de estado sólido, cargas altamente no lineales, cargas electrónicamente conmutadas, sistemas de potencia no balanceados, control de iluminación, computadoras y centros de procesamiento, bombas hidráulicas, rectificadores e inversores industriales.

Las mencionadas perturbaciones tienen como consecuencia la generación de pérdidas económicas muy importantes tanto para los usuarios como para la empresa distribuidora de energía. Por este motivo es necesario contar con un sistema de monitoreo que permita la detección, clasificación e identificación de los eventos que provocan un detrimento en la calidad de la energía.

Tradicionalmente las perturbaciones eran analizadas por medio de la inspección visual de las señales, de manera tal que el conocimiento de los ingenieros jugaba un rol crítico en el proceso de monitoreo de los Sistemas Eléctricos de Potencia (SEP). Los ingenieros eran abrumados con una enorme cantidad de información lo que hacía que esta metodología fuera poco eficiente y, en muchas ocasiones, poco eficaz. Por este motivo resultó evidente que, para determinar las causas y fuentes de las perturbaciones, se debía contar con un sistema de monitoreo que permitiera la detección y clasificación de las mismas de manera automática y en tiempo real, procesando solo la información relevante.

Por otro lado, dentro del área académica afin a los SEP, siempre ha sido una preocupación motivar a los alumnos para que estudien distintos aspectos de los sistemas eléctricos de potencia, introducirlos a nuevas tecnologías y exponerlos a situaciones reales dentro de esta área. Para lograr estos objetivos, es muy importante implementar laboratorios educativos que representen lo más aproximado posible a casos reales.

El objetivo principal de este trabajo, es el de desarrollar un sistema de monitoreo para ser utilizado como herramienta educativa que permita a los usuarios la evaluación y comparación de diferentes algoritmos de detección y clasificación de eventos de calidad de energía.

Esta herramienta, desarrollada en MATLAB, permite la generación de perturbaciones y su posterior evaluación empleando algoritmos basados en la Transformada Wavelet y Redes Neuronales Artificiales.

El presente trabajo se organiza de la siguiente manera: La Sección II explica las etapas que conforman un sistema de monitoreo y las técnicas que mayoritariamente se emplean en cada una ellas. La Sección III expone los conceptos teóricos básicos que fundamentan la aplicación de la Transformada Wavelet y las Redes Neuronales como métodos de detección y clasificación respectivamente La Sección IV presenta el desarrollo software de monitoreo. Finalmente, la Sección V exhibe las conclusiones obtenidas.

D. D. Yong, Universidad Nacional de Río Cuarto (UNRC), Río Cuarto, Córdoba, Argentina, ddyong@ing.unrc.edu.ar

F. Magnago, Universidad Nacional de Río Cuarto (UNRC), Río Cuarto, Córdoba, Argentina, fmagnago@ing.unrc.edu.ar

C. Reineri Universidad Nacional de Río Cuarto (UNRC), Río Cuarto, Córdoba, Argentina, ddyong@ing.unrc.edu.ar

II. SISTEMA DE MONITOREO DE EVENTOS DE CALIDAD DE ENERGÍA

Todo sistema de monitoreo de eventos de calidad de energía está conformado las tres etapas ilustradas en la Fig. 1.




Figura 1. Esquema general de un sistema de monitoreo.

Los eventos de calidad de energía se presentan de manera esporádica dentro de una red por lo que un sistema de monitoreo debe ser capaz de muestrear, analizar y descartar la información que represente al sistema en un estado de operación normal, procesando solamente aquella información relativa a los eventos que se pretenden detectar.

El principal objetivo del módulo de detección es el de identificar la presencia de una perturbación dentro de un set de datos almacenados, ya sea de una base de datos de tiempo real, de una base de datos históricos o simplemente de datos de prueba generados con el fin de evaluar el algoritmo de detección.

Como objetivo secundario, pero no menos importante, el módulo de detección debe ser capaz de procesar la información minimizando la cantidad de datos que luego será enviada al módulo de clasificación.

Existen diversos métodos que se utilizan para la detección de perturbaciones en una señal dentro de los cuales se destaca la Transformada de Fourier [2], Transformada Rápida de Fourier [3], Transformada Gabor Wigner [4], Transformada S [5], Transformada Wavelet [6], Paquete de Transformadas Wavelet [7], Método del filtro senoidal [8] y Filtro de Kalman [9].

A su vez, el módulo de clasificación se encarga de realizar un mapeo entre los datos generados en el proceso de detección con algún patrón de perturbación conocido. Si bien recientemente han surgido métodos de clasificación más robustos (SVM [10], Hidden Markov Model [11], Gabor Wigner [12], Lógica Difusa [13], etc), las Redes Neuronales han sido ampliamente utilizadas en los procesos de clasificación [14] y representan una buena herramienta para ser utilizada con fines educativos.

Muchos de los aspectos relacionados al análisis y administración de sistemas eléctricos de potencia requieren del conocimiento de parámetros que caractericen el estado de las ondas de tensión y corriente. Esta información puede ser empleada por los fabricantes para diseñar los componentes de red eléctrica, por los entes reguladores para establecer indicadores de calidad de energía, por los usuarios para realizar reclamos o bien por las empresas proveedoras de energía para efectivizar penalizaciones. El módulo de caracterización es el encargado de calcular estos indicadores basándose en las señales perturbadas.

III. CONCEPTOS TEÓRICOS

A. Transformada Wavelet Multiresolución

Debido a la naturaleza no estacionaria algunas de las perturbaciones analizadas en este trabajo la Transformada Wavelet (WT) ha probado ser una herramienta muy eficiente para extraer características importantes de las señales que ayudan a identificar el fenómeno en el dominio del tiempo y, a su vez, brinda información esencial para el proceso de clasificación de los eventos de calidad de energía.

Básicamente la Transformada Wavelet es una herramienta matemática, similar a lo que Transformada de Fourier representa para las señales estacionarias, que descompone la señal en diferentes escalas, con diferentes niveles de resolución por medio de la traslación y dilatación de una única señal prototipo.

Esta función, denominada wavelet madre $\psi_{u,s}(t)$, puede dilatarse o contraerse por medio de un parámetro dado por la siguiente la ecuación Eq (1):

$$\psi_{u,s}(t) = \frac{1}{\sqrt{s}} \psi\left(\frac{t-u}{s}\right) \quad (1)$$

La transformada wavelet de una señal de energía finita $x(t)$ a escala s y posición u se determina por la correlación de la señal $x(t)$ con la wavelet $\psi_{u,s}$ está dada por la Eq (2)

$$W\{x(u,s)\} = Wx\{u,s\} = \int_{-\infty}^{\infty} x(t) \cdot \psi_{u,s}(t) \delta t = \int_{-\infty}^{\infty} x(t) \cdot \frac{1}{\sqrt{s}} \psi\left(\frac{t-u}{s}\right) \delta t \quad (2)$$

Para el análisis de señales discretas $x[k]$ existe una herramienta denominada Transformada Wavelet Discreta (DWT por sus siglas en inglés). Esta transformada se utiliza para descomponer una señal discreta en diferentes niveles de resolución. La DWT viene dada por la ecuación Eq (3)

$$x(t) = \sum_k a_{j_0}[k] 2^{\frac{j_0}{2}} \varphi_{j_0,k}(2^{j_0}t - k) + \sum_k \sum_{j=j_0}^{\infty} d_j[k] 2^{\frac{j}{2}} \psi_{j,k}(2^j t - k) \quad (3)$$

la cual se puede simplificar en:

$$x(t) = \sum_k a_{j_0}[k] \varphi_{j_0,k}(t) + \sum_k \sum_{j=j_0}^{\infty} d_j[k] \psi_{j,k}(2^j t) \quad (4)$$

donde a_{j_0} es el nivel 0 del coeficiente de escalamiento, d_j es el coeficiente wavelet a una escala j , $\varphi(t)$ y $\psi(t)$ son funciones de escala y la función wavelet respectivamente y k es el coeficiente de traslación.

La traslación y escalado de la wavelet madre presentada en la Eq (3) $\psi(2^j t - k)$ es muy útil en el Análisis Multi Resolución (MRA) para construir una imagen tiempo-frecuencia de la señal. La descomposición MRA se usa para alcanzar dos importantes objetivos en el análisis de perturbaciones. El primer objetivo es la propiedad de localización en tiempo de cualquier fenómeno transitorio. Estos fenómenos aparecen más claramente en los coeficientes que representan las altas frecuencias como puede verse en la Fig. 2. En dicha figura se

aprecia la presencia de grandes coeficientes en el tiempo en que la perturbación aparece. El segundo objetivo de un análisis MRA es el de dividir el espectro de frecuencias de una señal en diferentes bandas para obtener información de su distribución de energía.

El teorema de Parseval es de gran utilidad para extraer información de energía de una señal. Este teorema establece una relación entre la energía total de la señal $x(t)$ y la energía asociada a cada uno de los coeficientes de la descomposición wavelet. El teorema de Parseval se presenta en la Eq(5)

$$\int |x(t)|^2 = \sum_{l=-\infty}^{\infty} |a[l]|^2 \sum_{j=0}^{\infty} \sum_{k=-\infty}^{\infty} |d_j[k]|^2 \quad (5)$$




Figura 2. Ejemplo de localización temporal de un evento.

B. Red Neuronal Back-Propagation

Las redes Neuronales Artificiales (ANN por sus siglas en inglés) han probado ser una buena herramienta para resolver problemas complejos como la aproximación de señales no lineales y clasificación de patrones.

El problema abordado en este trabajo es un problema típico de clasificación de patrones ya que, a cada patrón de entrada, la ANN debe ser capaz de asociarlo a un patrón de salida determinado.

La ANN Backpropagation es particularmente muy eficiente a la hora de realizar una clasificación de patrones. Esta red presenta un tipo de aprendizaje supervisado por lo que se debe contar con un set conocido de patrones de entrada asociado a la salida esperada para cada uno de ellos.

El primer paso en el diseño de la red consiste en encontrar la arquitectura óptima que resuelva un determinado problema. Para ello debe definirse la cantidad de capas ocultas y la cantidad de neuronas que conforman cada capa. Además, se debe definir la función de transferencia empleada en la capa oculta y la capa de salida. Las funciones de transferencia más comúnmente empleadas son la función lineal, sigmoidea, sigmoidea logarítmica, función umbral y la función gaussiana.

Una vez configurada la arquitectura se da lugar a la fase de entrenamiento donde la red aprende a relacionar patrones de entrada con patrones de salida esperados. Para ello, los pesos de todas las conexiones entre las neuronas son inicializados aleatoriamente. Luego, se presenta un patrón a la entrada y la ANN devuelve un patrón de salida. Este patrón de salida se compara con el patrón esperado y se calcula un error. El proceso se repite para cada patrón del set de entrenamiento calculando un error para cada salida. El error se propaga luego desde la capa de salida hacia las capas ocultas. Cada conexión recibe una proporción del error total en función de su contribución relativa. Este proceso se repite para todas las

capas hasta que todas las neuronas hayan recibido una fracción del error en función de su contribución al error total. Finalmente se actualizan los pesos de cada neurona en busca de minimizar la diferencia entre la salida obtenida y la salida esperada y la red converge cuando se alcanza un cierto error.

El error de convergencia de la red es una medida de cuanto se asemeja la salida esperada a la salida obtenida. Este error puede ser fijado antes de entrenar la red. Si al finalizar el set de entrenamiento la red no converge con un error de convergencia esperado, el proceso se repite nuevamente y un nuevo error de convergencia es calculado. El parámetro denominado época cuenta la cantidad de veces que el set de entrenamiento es presentado en su totalidad a la red. Este parámetro también se fija antes de comenzar la fase de entrenamiento de modo que esta etapa puede finalizar cuando el error esperado es alcanzado o bien cuando se cumple la cantidad de épocas pre-establecida.

Existe también un parámetro que suele ajustarse antes de comenzar el entrenamiento el cual se denomina ratio o tasa de aprendizaje. Este parámetro está relacionado con la velocidad en que la red aprende la relación entre los patrones de entrada y salida. Un valor grande de este parámetro implica una alta velocidad de convergencia pero el entrenamiento se vuelve inestable y muchas veces no converge. Por otro lado, una baja tasa de aprendizaje hace que el entrenamiento se vuelva lento pero se aumenta la probabilidad de evitar que el entrenamiento no converja.

IV. IMPLEMENTACIÓN DEL ANALIZADOR DE CALIDAD DE ENERGÍA

El software desarrollado está compuesto cuatro módulos: Adquisición, Generación, Detección de Eventos y Caracterización de Eventos. El panel principal es ilustrado en la Fig. 3.



Figura 3. Menú principal del programa desarrollado.

A continuación se detalla la funcionalidad de cada módulo:

A. Módulo de adquisición de señales

Mediante este módulo el usuario puede incorporar señales almacenadas en una base de datos para su posterior análisis. Estas señales pueden haber sido obtenidas del muestreo de una señal real.

La Fig. 4 muestra la ventana que sirve de interfaz entre el usuario y la base de datos donde se encuentran los datos. Esta ventana permite al usuario incorporar datos, graficarlos o exportarlos en un archivo ASCII.

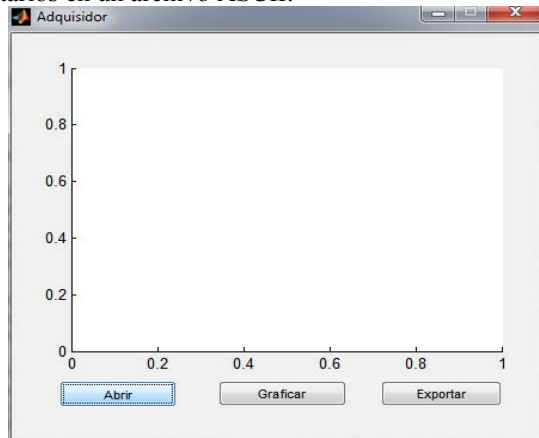


Figura 4. Ventana de adquisición y visualización de señales.

B. Módulo de generación de señales

Un sistema de monitoreo en tiempo real debe ser capaz de detectar y clasificar la presencia de una perturbación en la red de manera casi instantánea.

Debido a que el software fue desarrollado con fines educativos, es bueno contar con un set de prueba libre de ruidos de medición cuyo análisis escapa de los fines del presente trabajo. Para ello, se desarrolló el módulo de generación de señales el cual permite crear formas de onda que incluyen diferentes tipos de perturbaciones.

La Fig. 5 muestra la interface gráfica que se obtiene al presionar la opción *Generador de señales* de la pantalla mostrada en la Fig. 3. Esta interface permite generar nueve de los tipos de perturbaciones más comunes en un SEP: Huecos, Swell, Armónicos, Interrupción, Transitorios, Flickers, Notch, Armónicos y Huecos y Armónicos y Swell.

A modo de ejemplo, la Fig. 6 muestra la interface gráfica destinada a la generación de una perturbación tipo Hueco la cual permite el ingreso de varios parámetros característicos del evento de en cuestión.

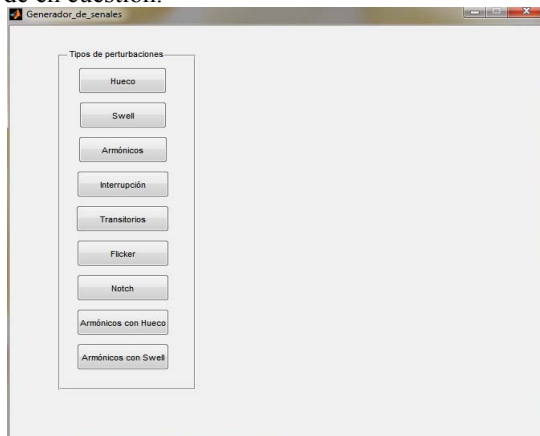


Figura 5. Menú principal, módulo generación de señales.

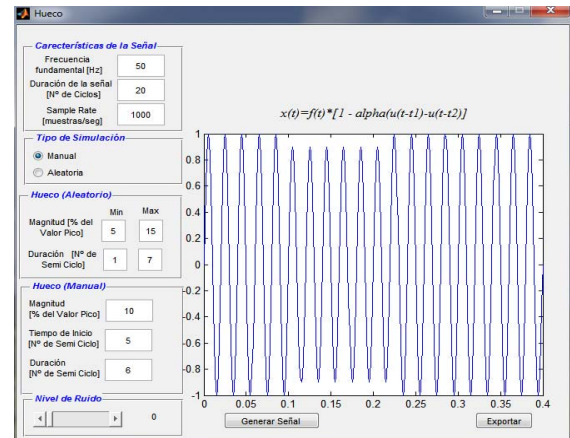


Figura 6. Generación de un Hueco.

La interface permite el ingreso de características de la señal sin perturbar como la frecuencia fundamental que por defecto es de 50 Hz, la duración de la muestra, representada por la cantidad de ciclos muestreados y la frecuencia de muestreo.

Además, la interface permite seleccionar el tipo de generación de la perturbación, el cual puede ser Manual o Aleatoria. Al seleccionar la opción Manual el software utilizará los parámetros ingresados en la sección *Hueco Manual*. Del mismo modo, al seleccionar la opción Aleatoria el software empleará los parámetros ingresados en la sección *Hueco Aleatorio*.

La interface gráfica presenta dos secciones para el ingreso de parámetros que caracterizan la perturbación: Para la generación Manual de la perturbación el software presenta un área donde el usuario puede configurar la magnitud y duración del evento. Del mismo modo, para la generación Aleatoria, se pueden definir los valores mínimos y máximos para la amplitud y duración del evento. Es importante destacar que, por tratarse de perturbaciones no estacionarias, los armónicos no pueden ser caracterizados por el parámetro *duración*. Para tal caso, el software no permite el ingreso de este valor.

La barra deslizante *Nivel de Ruido* permite al usuario ajustar el ruido blanco aditivo presente en la señal generada.

Mediante el botón *Generar Señal* el usuario puede generar y graficar la señal de prueba.

Finalmente, presionando el botón *Exportar Señal* el usuario puede generar un archivo ASCII el cual contendrá el vector señal y el vector tiempo.

La Fig. 7 muestra otro ejemplo ilustrativo, donde la interface gráfica permite la generación del tipo de perturbación Armónicos.

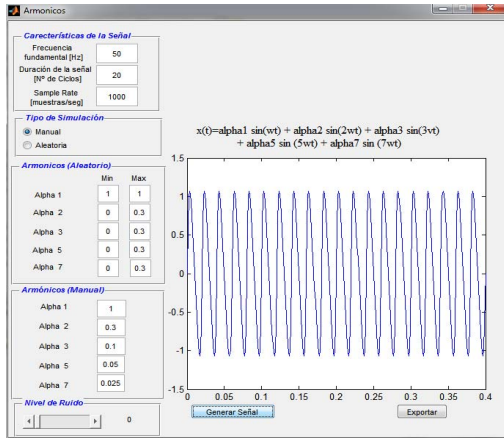


Figura 7. Generación de armónicos.

C. Modulo Detección de Eventos

El objetivo de este módulo es proporcionar al estudiante de herramientas para evaluar algoritmos de detección de eventos de calidad de energía. Por medio de este módulo se puede analizar la señal empleando algoritmos basados en diferentes métodos de procesamiento de señales como la Transformada de Fourier dependiente del tiempo, Transformada S, Transformada Wavelet o Paquetes de Transformada Wavelet.

La Fig. 8 ilustra un algoritmo de detección basado en la Transformada Wavelet Discreta (DWT). Este algoritmo adquiere las muestras de la señal, las transforma utilizando la DWT y proporciona como resultado un vector de diez componentes que caracterizan al evento y, en caso de existir una perturbación de corta duración, calcula el tiempo de inicio y fin del evento.

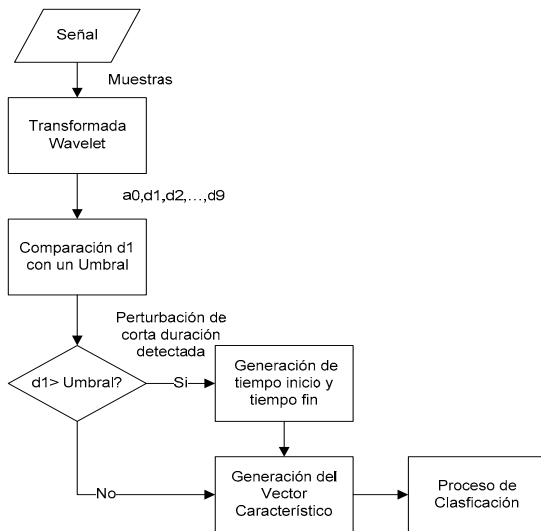


Figura 8. Diagrama general algoritmo de detección.

Para ilustrar este proceso, las Fig.s 9 y 10 muestran la descomposición de las perturbaciones presentadas anteriormente en las Fig. 5 y 6 utilizando la transformada madre Dabuchie 4 de nueve niveles.

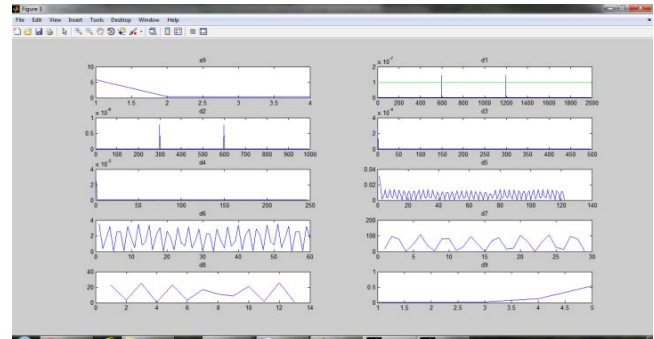


Figura 9. Descomposición TW de un Hueco.

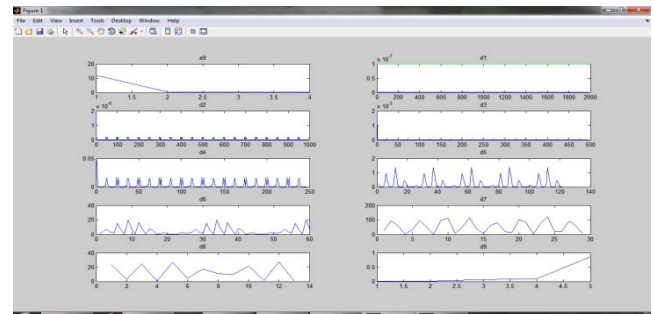


Figura 10. Descomposición TW de una señal con armónicos.

En el proceso, se utiliza el coeficiente d1 (coeficiente de más alta frecuencia de la Transformada Wavelet) para detectar eventos de corta duración. Estos datos se comparan con un valor umbral preestablecido.

En caso de detectar una perturbación no estacionaria el algoritmo utiliza el proceso *Generación tiempo de inicio y tiempo de fin* localizar en el tiempo la perturbación y determinar su duración.

Finalmente, el proceso *Generación del Vector Característico*, emplea los diez vectores de la Transformada Wavelet para generar un vector de diez componentes denominado Vector Característico como se muestra en la Eq. (6) [15]. El principal objetivo de este proceso es reducir la cantidad de información que se entrega a la etapa de clasificación. Cada componente de este vector se corresponde con la diferencia de las energías de cada nivel de la Transformada Wavelet de la señal perturbada y la señal sin perturbación. La energía de cada nivel se calcula mediante el teorema de Parseval presentado en Eq(5)

$$\text{Vector Característico} = \begin{bmatrix} Ed_9 \text{ sen} \\ Ed_8 \text{ sen} \\ Ed_7 \text{ sen} \\ Ed_6 \text{ sen} \\ Ed_5 \text{ sen} \\ Ed_4 \text{ sen} \\ Ed_3 \text{ sen} \\ Ed_2 \text{ sen} \\ Ed_1 \text{ sen} \\ Ea_0 \text{ sen} \end{bmatrix} - \begin{bmatrix} Ed_9 \text{ perturbada} \\ Ed_8 \text{ perturbada} \\ Ed_7 \text{ perturbada} \\ Ed_6 \text{ perturbada} \\ Ed_5 \text{ perturbada} \\ Ed_4 \text{ perturbada} \\ Ed_3 \text{ perturbada} \\ Ed_2 \text{ perturbada} \\ Ed_1 \text{ perturbada} \\ Ea_0 \text{ perturbada} \end{bmatrix} \quad (6)$$

D. Clasificación de Eventos

El objetivo de este módulo del programa es proporcionar al estudiante un conjunto de herramientas que le ayuden en la

tarea de aprendizaje de los distintos métodos empleados para la clasificación de patrones de eventos de calidad de energía.

Existen métodos que probaron ser eficaces en la tarea de clasificación de patrones dentro de los cuales se encuentran las redes neuronales artificiales (ANN). Este trabajo presenta a la ANN Backpropagation como método para asociar cada Vector Característico proveniente de la etapa de detección en un determinado patrón de perturbación.

La red Backpropagation presenta muy buenas características para clasificar patrones. Estas redes emplean un entrenamiento supervisado por lo que permite asociar patrones de entrada a las clases de perturbación que se desea obtener como salida. La red será entrenada para detectar los siguientes patrones de perturbaciones: Hueco, Swell, Armónicos, Transitorios, Armónicos con Hueco, Armónicos con Swell, Interrupción.

Para el entrenamiento de la red se emplea un set de perturbaciones conocido y se mapea cada tipo de perturbación con un código de salida de la red que lo identifique.

La arquitectura de la ANN configurada cuenta con una capa de entrada de diez neuronas, una única capa oculta de ocho neuronas y una capa de salida de tres neuronas.

La red se entrena con una tasa de entrenamiento de 0.4, una función de transferencia tan-sigmoide para la capa oculta, una función escalón para la capa de salida, 1000 épocas como parámetro máximo de iteración del algoritmo de entrenamiento y un error objetivo de 1×10^{-6} .

En la mayoría de los casos se obtuvo una convergencia de la red antes de las 400 épocas aunque existen ocasiones en las cuales el algoritmo de entrenamiento queda atascado en un mínimo local. En este caso, el entrenamiento finaliza cuando la cantidad de épocas configurada expira. Este es un problema inherente a toda ANN y se soluciona entrenando nuevamente la red hasta que la convergencia se logre.

Una vez entrenada, fue probada con un set de datos compuesto por señales en donde se presentaban todos los tipos de eventos estudiados en este trabajo. La red clasificó correctamente el 100% de las muestras de entrada.

V. CONCLUSION

Se desarrolló un software con fines educativos, basado en MATLAB, para mejorar el proceso de enseñanza en los temas relacionados al monitoreo de eventos de Calidad de Energía.

El software fue diseñado de manera modular de forma que se pueda incorporar fácilmente algoritmos de clasificación y detección basados en métodos distintos a los abordados en este trabajo.

Este software puede ser empleado como base para el desarrollo de un sistema de monitoreo en tiempo real.

La utilización de este software permitió que, de manera rápida, los estudiantes se familiarizaran con el estado del arte en temas referidos a la detección y clasificación de eventos de Calidad de Energía.

AGRADECIMIENTOS

Este trabajo fue realizado gracias al aporte de la Universidad Nacional de Río Cuarto, MinCyT-Cba y CONICET.

Se agradece la colaboración de Federico Aguirre.

REFERENCIAS

- [1] IEEE Std 1159-2009 IEEE Recommended Practice for Monitoring Electric Power Quality.
- [2] Roscoe, A.J.; Burt, G.M.; McDonald, J.R.; "Frequency and fundamental signal measurement algorithms for distributed control and protection applications," *Generation, Transmission & Distribution, IET*, vol.3, no.5, pp.485-495, May 2009.
- [3] Heydt, G.T.; Fjeld, P.S.; Liu, C.C.; Pierce, D.; Tu, L.; Hensley, G.; , "Applications of the windowed FFT to electric power quality assessment," *Power Delivery, IEEE Transactions on*, vol.14, no.4, pp.1411-1416, Oct 1999.
- [4] Soo-Hwan Cho, Gilsoo Jang, Sae-Hyuk Kwon, "Time-Frequency Analysis of Power-Quality Disturbances via the Gabor-Wigner Transform" *Power Delivery, IEEE Transactions*, Jan 2010.
- [5] Fengzhan Zhao; Rengang Yang; "Power-Quality Disturbance Recognition Using S-Transform," *Power Delivery, IEEE Transactions on*, vol.22, no.2, pp.944-950, April 2007.
- [6] Santoso, S.; Powers, E.J.; Grady, W.M.; Hofmann, P." Power quality assessment via wavelet transform analysis" in *Power delivery IEEE Transaction*. April 1996.
- [7] Liyan Liu, Zhezhao Zeng, "The Detection and Location of Power Quality Disturbances Based on Orthogonal Wavelet Packet Transform", *Deregulation and Restructuring and Power Technologies, 2008. DRPT 2008. Third International Conference*. April 2008.
- [8] Radil, T.; Ramos, P.M.; Serra, A.C. "Detection and extraction of harmonic and non-harmonic power quality disturbances using sine fitting methods" *Harmonics and Quality of Power, 2008. ICHQP 2008. 13th International Conference*. October 2008.
- [9] Dash, P.K.; Chilukuri, M.V. "Hybrid S-Transform and Kalman Filtering Approach for Detection and Measurement of Short Duration Disturbances in Power Network" *Power Delivery, IEEE Transactions*. April 2004.
- [10] Whei-Min Lin, Chien-Hsien, Chia-Hung Lin, "Detection and Classification of Multiple Power-Quality Disturbances With Wavelet Multiclass SVM", *Power Delivery, IEEE Transactions*. October 2008.
- [11] Jaehak Chung; Powers, E.J.; Grady, W.M.; Bhatt, S.C., "Power disturbance classifier using a rule-based method and wavelet packet-based hidden Markov model" *IEEE Transactions*. January 2002.
- [12] Panigrahi, Pandi, "Optimal feature selection for classification of power quality disturbances using wavelet packet-based fuzzy k-nearest neighbour algorithm" *IET Generation, Transmission & Distribution*. April 2008
- [13] Chilukuri, M.V.; Dash, P.K., "Multiresolution S-transform-based fuzzy recognition system for power quality events" *Power Delivery, IEEE Transactions*. April 2004.
- [14] Machado, Bezerra, Paelaes Use of Wavelet Transform and Generalized Regression Neural Network (GRNN) to the Characterization of Short-Duration Voltage Variation in Electric Power System", *Latin America Transactions, IEEE*. June 2009
- [15] Peisheng Gao, Weilin Wu, "Power Quality Disturbances Classification using Wavelet and Support Vector Machines" *Intelligent Systems Design and Applications, 2006. ISDA '06. Sixth International Conference*. October 2006.



David Marcelo De Yong es graduado en la carrera Ingeniería en Telecomunicaciones en la Universidad Nacional de Río Cuarto, Córdoba, Argentina en 2006. Actualmente trabaja como becario del CONICET en el área de calidad de energía y Redes Eléctricas Inteligentes. Sus áreas de interés se orienta a los sistemas de comunicaciones aplicados en redes eléctricas inteligentes.



distribución.

Claudio Ariel Reineri se graduó como Ingeniero Mecánico Electricista por UNRC (Argentina) en 1990 y obtuvo su doctorado en Ingeniería Industrial en UPV (España) en 2000. Es miembro del Instituto de Protecciones de Sistemas Eléctricos de Potencia (IPSEP) de la Fac. de Ingeniería de UNRC desde 1992. Las investigaciones del Dr. Reineri, profesor de ingeniería eléctrica en UNRC, se orientan a calidad de potencia y protecciones de los sistemas de



Fernando Magnago (SM' 2003) es graduado como magister y Doctor en la Universidad de Texas A&M. Fernando trabaja en Nexant Inc desde el año 2000 donde se desempeña como desarrollador de software. Adicionalmente se desempeña como profesor titular en la Universidad Nacional de Río Cuarto, Argentina. Sus áreas de interés incluyen el modelado, analisis económico,

operación y planificación de Sistemas Eléctricos de Potencia.