

IEL1-I-2003 - 05
IEL1-I-2003 - 27

GENERACIÓN DE PATRONES DE FENÓMENOS ASOCIADOS A CALIDAD DE
LA POTENCIA UTILIZANDO LA TRANSFORMADA WAVELET Y REDES
NEURONALES

PRESENTADO POR:
JUAN CAMILO CABRERA TRUJILLO
JUAN DAVID TABOADA VELÁSQUEZ

UNIVERSIDAD DE LOS ANDES
FACULTAD DE INGENIERÍA
DEPARTAMENTO DE INGENIERÍA ELÉCTRICA Y ELECTRÓNICA
GRUPO DE CALIDAD DE LA POTENCIA ELÉCTRICA
Bogotá, Junio de 2003

IEL1-I-2003 - 05
IEL1-I-2003 - 27

GENERACIÓN DE PATRONES DE FENÓMENOS ASOCIADOS A CALIDAD DE
LA POTENCIA UTILIZANDO LA TRANSFORMADA WAVELET Y REDES
NEURONALES

PRESENTADO POR:
JUAN CAMILO CABRERA TRUJILLO
JUAN DAVID TABOADA VELÁSQUEZ

TRABAJO DE GRADO

Asesores

ING. MARÍA TERESA RUEDA DE TORRES M.E.
ING. GUSTAVO ANDRÉS RAMOS M.E.

UNIVERSIDAD DE LOS ANDES
FACULTAD DE INGENIERÍA
DEPARTAMENTO DE INGENIERÍA ELÉCTRICA Y ELECTRÓNICA
GRUPO DE CALIDAD DE LA POTENCIA ELÉCTRICA
Bogotá, Junio de 2003

TABLA DE CONTENIDO

1. INTRODUCCIÓN.....	5
2. MARCO TEORICO	7
2.1. Transformada Discreta Wavelet (DWT)	7
2.2. Multiple Layered Perceptron (MLP)	9
3. PROCEDIMIENTO	11
3.1. Procedimiento Generación de Patrones	11
3.2. Procedimiento Reconocimiento de Patrones	13
3.2.1. Bases de datos	13
3.2.2. Algoritmos	14
4. RESULTADOS	17
5. IMPLEMENTACIÓN DE SOFTWARE	27
6. CONCLUSIONES	29
7. BIBLIGRAFÍA	32

TABLA DE FIGURAS

Figura 1 Esquema del análisis wavelet	7
Figura 2 Wavelet madre creada por Daubechies	8
Figura 3 Esquema de la Transformada Wavelet	8
Figura 4 Arquitectura de la MLP	10
Figura 5 Error de Entrenamiento	14
Figura 6 Error de Validación	15
Figura 7 Error de Verificación	15
Figura 8 Corte	17
Figura 9 Swell	18
Figura 10 Sag	18
Figura 11 Armónico	19
Figura 12 Transiente	19
Figura 13 Patrones de Cortes	20
Figura 14 Patrones de Swells	21
Figura 15 Patrones de Sags	21
Figura 16 Patrones de Armónicos	22
Figura 17 Patrones de Transientes	22
Figura 18 Interfaz de usuario	27
Figura 19 Tutorial	28

1. INTRODUCCIÓN

Todo proyecto integral de energía con miras al siglo XXI debe ser concebido bajo el ambiente de Calidad de la Potencia Eléctrica, con lo cual se asegura un voltaje senoidal y un suministro de energía confiable que garantice el correcto funcionamiento de los equipos electrónicos, los cuales están manejando procesos críticos y de gran importancia para el buen funcionamiento y servicio al cliente, que una entidad debe representar para la sociedad colombiana contemporánea.

Debido a la proliferación de cargas no lineales en las redes eléctricas, se han generado ciertas perturbaciones en las señales de voltaje y corriente que es lo que se define como fenómenos asociados a la calidad de la potencia, tales como: sags, swells, armónicos, cortes y transientes. La aparición de estos fenómenos ha hecho que surjan ciertos riesgos para los usuarios de las redes eléctricas tales como la quema de equipos, la caída de bases de datos y otros que les pueden representar pérdidas millonarias. Las regulaciones vigentes cada vez son más estrictas con la generación de estas perturbaciones, lo cual ha llevado a que la detección de estos problemas sea un factor importante para poder evitar todas las posibles consecuencias que estas perturbaciones puedan conllevar, ya sea desde pérdida de equipos o información, hasta sanciones por el incumplimiento de las normas.

El objetivo de este trabajo es presentar un modelo de generación de patrones de fácil identificación a partir de las muestras de los diferentes fenómenos. Estos patrones en realidad son pequeños en cuanto a cantidad de datos se refiere, lo cual puede ser muy eficiente a la hora de implementar algún algoritmo computacional para su reconocimiento, ya que de hecho, la misma onda eléctrica en sí, es un patrón, pero

con gran cantidad de datos, es decir, se habla de muestras de 512 o 1024 datos aproximadamente.

A continuación se presentan las definiciones de la norma IEEE 1159 de los fenómenos asociados a calidad de la potencia que se tratan en el estudio:

- **Sag:** Un decremento en el voltaje o la corriente (rms) a la frecuencia de potencia por una duración de 0.5 ciclos a 1 minuto. Valores típicos son entre 0.1 y 0.9 pu.
- **Swell:** Un incremento en el voltaje o la corriente (rms) a la frecuencia de potencia por una duración de 0.5 ciclos a 1 minuto. Valores típicos son entre 1.1 y 1.8 pu.
- **Armónico (componente):** Una componente de orden mayor que uno de la serie de Fourier de una cantidad periódica.
- **Corte:** Desaparición del suministro de voltaje en una o más fases. Usualmente calificado por un término adicional indicando la duración de la interrupción.
- **Transiente:** Dícese del fenómeno o cantidad que varía entre dos estados estables consecutivos durante un intervalo de tiempo que es corto comparado con la escala de tiempo de interés. Un transiente puede ser un impulso unidireccional de cualquier polaridad o una onda oscilatoria amortiguada con el primer pico de cualquier polaridad.

Para la generación de estos patrones, se utilizaron las propiedades de la transformada discreta Wavelet, junto con el Teorema de Parseval, ya que como se verá más adelante, lo que se hizo fue encontrar una desviación en niveles de energía de la señal seno pura de 60 Hertz, con los diferentes fenómenos en estudio.

La segunda parte del proyecto consiste en desarrollar una herramienta para realizar el reconocimiento de los fenómenos mencionados anteriormente, utilizando la teoría de las redes neuronales.

2. MARCO TEORICO

Debido a la composición del proyecto, el marco teórico se presenta en dos temas principales que son, la transformada discreta wavelet, con la cual se hace el procesamiento de la señal para generar los patrones, y las redes neuronales, cuya utilidad está en poder reconocer diferentes patrones.

2.1 Transformada Discreta Wavelet (DWT)

Las técnicas de análisis wavelet emplean regiones de tamaño variable, es decir, para el análisis de las señales deja usar durante largo tiempo intervalos donde se necesita mucha información que precisa poca frecuencia y pequeñas regiones donde la información necesita altas frecuencias, figura 1.




Figura 1. Esquema del análisis wavelet

El análisis wavelet es capaz de mostrar aspectos de la señal que otras técnicas como la transformada de Fourier que se usa para estudios puramente frecuenciales no logran encontrar, debido a que son especializadas.

La transformada wavelet consiste en comparar la señal con ciertas funciones wavelet, las cuales se obtienen a partir de las wavelet madre, figura 2.

La comparación permite obtener unos coeficientes que son susceptibles de interpretación y posterior manipulación. En cualquier caso, un requisito básico es la posibilidad de invertir la transformada, recuperando la señal a partir de esos coeficientes wavelet calculados. El esquema de descomposición y reconstrucción se presenta en la figura 3.



Figura 2 Wavelet madre creada por Daubechies.

El cálculo de la transformada wavelet para todas las posibles escalas supone una gran cantidad de información. Escoger solo aquellas escalas y posiciones que resulten interesantes para ciertos estudios es una tarea difícil. Si se escogen aquellas escalas y posiciones basadas en potencias de dos, los resultados serán más eficaces. Este análisis se denomina DWT.




Figura 3. Esquema de la Transformada Wavelet.

Para muchas señales la información más importante se encuentra en las frecuencias bajas, mientras que en las altas frecuencias se encuentran los detalles o matices de la señal. Por ejemplo, en el caso de la voz humana, si se eliminan las componentes de altas frecuencias, la voz suena diferente pero se sigue entendiendo su mensaje. En cambio, si lo que se eliminan son las componentes de bajas frecuencias, el mensaje se vuelve irreconocible. Por eso el análisis wavelet permite descomponer la señal en aproximaciones y detalles. Este filtrado proporciona el doble de datos de los que son necesarios, este problema se soluciona con la operación de *downsampling*, el cual consiste en eliminar la mitad de los datos obtenidos.

El proceso de reconstrucción, también denominado síntesis, se encarga de la obtención de la señal a partir de los detalles y aproximaciones. Éste proceso se lleva a cabo con la transformada wavelet discreta inversa.

2.2 Multiple Layered Perceptron (MLP)

La red neuronal denominada Multiple Layered Perceptron (MLP) es una de las arquitecturas más básicas y conocidas que se encuentran en la literatura y recibe ese nombre debido a que utiliza varias capas de neuronas para ejecutar la tarea de reconocimiento de patrones. En la figura 4. se muestra la arquitectura de la red MLP con 2 capas de neuronas que fue la que se implementó en este estudio. No se pensó en añadir mas capas a la red ya que por un lado los resultados que se obtuvieron con esta arquitectura fueron bastante buenos, y por otro, que el teorema de Hornik-Stinchcombe-White enuncia que una red neuronal con dos capas de neuronas es suficiente para aproximar tan precisamente como se desee

un mapeo continuo acotado de un espacio dimensional finito a otro, claro esta, dependiendo de la suficiencia de neuronas en la capa media.




Figura 4. Arquitectura de la MLP

Se hubiera podido pensar en usar alguna arquitectura de red neuronal que pudiera presentar cierta invarianza en el tiempo ya que se estaba trabajando en este dominio con las señales de voltaje, pero con el procesamiento DWT los patrones ya no dependen del tiempo sino de la energía de la señal. Además, con el tratamiento de señal que se hizo por medio de la DWT (Transformada Discreta Wavelet) no solo se redujo el tamaño del vector de entrada, de 1024 a 10 datos, sino que también se obvió, por así decirlo, la necesidad de tener una red invariante en el tiempo, o con la capacidad de guardar información sobre la señal en tiempos anteriores.

3. PROCEDIMIENTO

De igual forma esta parte describirá los procedimientos que se utilizaron tanto para la generación de patrones (Transformada Discreta Wavelet), como para el reconocimiento de estos (Redes Neuronales).

3.1 Procedimiento Generación de Patrones

Inicialmente fue necesario generar por medio de EXCEL las muestras de los fenómenos a evaluar, transientes, armónicos, sags y swells, para esta primera aproximación. Se implementaron programas en Visual Basic los cuales generaban muestras de 1024 datos de una manera aleatoria generando hasta 200 muestras de cada fenómeno para así poder hacer la validación de los patrones obtenidos. Luego se desarrolló un programa en MATLAB para implementar el análisis de los fenómenos. Este programa cumple con los siguientes pasos generales, los cuales se tomaron de la referencia [1]:

Paso 1: Cálculo de los coeficientes aproximados y detallados de la señal en el dominio de wavelet.

$a_j(n)$: Coeficientes aproximados de la señal en el nivel “j”.

$b_j(n)$: Coeficientes detallados de la señal en el nivel “j”.

Paso 2: Cálculo de la distribución de energía por niveles de la señal en estudio siguiendo el Teorema de Parseval. Usando la ecuación 1 se realizó el cálculo de la distribución de energía:

$$\sum_{n=1}^N |f(n)|^2 = \sum_{n=1}^N |a_j(n)|^2 + \sum_{j=1}^J \sum_{n=1}^N |d_j(n)|^2 \quad \text{Ecuación 1.}$$

$F(n)$ es la señal a estudiar en el dominio del tiempo. N es el número total de muestras por señal.

$$\sum_{n=1}^N |f(n)|^2 : \text{Energía total de la señal } f(n).$$

$$\sum_{n=1}^N |a_j(n)|^2 : \text{Energía total concentrada en el nivel "j" de la versión aproximada}$$

de la señal.

$$\sum_{j=1}^J \sum_{n=1}^N |d_j(n)|^2 : \text{Energía total concentrada en la versión detallada de las señales}$$

desde el nivel 1 hasta el "j".

Paso 3: El procedimiento descrito en los pasos 1 y 2 se realiza de igual forma para la señal fundamental (seno puro).

Paso 4: Cálculo de la desviación entre las distribuciones de energía por niveles de la señal fundamental y la señal en estudio. Para este cálculo se utilizaron las siguientes fórmulas y criterios,

$$des(j)(\%) = \left[\frac{en_fu(j) - en_fe(j)}{en_fu(j)} \right] * 100 \quad \text{Ecuación 2.}$$

En donde "j" es el nivel de la transformada wavelet.

$des(j)(\%)$: Desviación entre las distribuciones de energía de la señal a estudiar y su señal seno fundamental correspondiente para cada nivel de la transformada wavelet.

$en_fe(j)$: Distribución de energía concentrada en cada nivel de la transformada wavelet de la señal a estudiar.

$en_fun(j)$: Distribución de energía concentrada en cada nivel de la transformada wavelet de la señal fundamental.

$en_fun(7)$: Energía concentrada en el nivel 7 (el cual concentra la mayor cantidad de energía) de la señal fundamental (seno puro).

3.2. Procedimiento Reconocimiento de Patrones

3.2.1. Bases de Datos

A partir de los patrones que se generaron por medio del procesamiento de la señal utilizando la Transformada Discreta Wavelet (DWT) se construyó la base de datos con la cual se entrena, valida y verifica la red posteriormente.

Luego de esta tarea se realizó un análisis de correlación entre los diferentes niveles Wavelet para determinar su relevancia a la hora de realizar el reconocimiento por parte de la red. De acuerdo a este análisis, se podrían eliminar los niveles 1, 2, 3, 7 y 9 como parte de las entradas a la red para así tener solamente 5 de ellas que fue lo que precisamente se hizo. Inclusive se hubiese podido extraer de las gráficas de los patrones parte de este resultado puesto que como se puede observar en la referencia [1], la desviación en los niveles 1, 2 y 3 es muy cercana a cero para todas las señales estudiadas.

La base total fue de 800 muestras, con 200 muestras por cada fenómeno, normalizando cada uno de los niveles con su desviación estándar y su media. Para realizar el entrenamiento, validación y verificación se tomó el 60%, 25% y 15% del número total de muestras, de tal forma que hubiera la misma cantidad de muestras por fenómeno en cada una de las

bases de datos. Posteriormente se generaron todas las bases de datos de forma aleatoria, finalizando así esta etapa del trabajo.

3.2.2. Algoritmos

Para el entrenamiento de una red MPL, existen diferentes algoritmos entre los cuales están los de gradiente y entre ellos el Back Propagation y el Forward Propagation. Asimismo, se tienen otros algoritmos tales como los de optimización aleatoria (Matyas y el Solis-Wets). Para este trabajo realizado se utilizó el algoritmo para entrenamiento Back Propagation el cual por ser de gradiente, siempre va en la dirección en la que minimiza el error, pero tiene la desventaja que puede caer en mínimos locales, lo cual se puede resolver realizando muchas corridas variando el paso de la derivada.

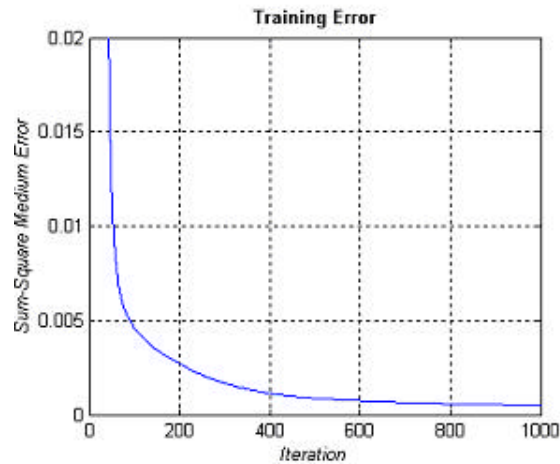


Figura 5. Error de Entrenamiento

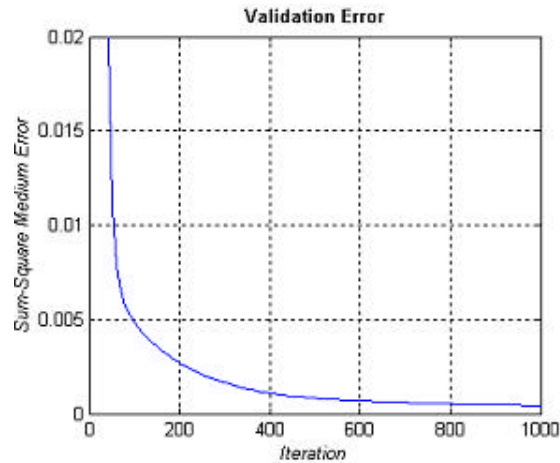


Figura 6. Error de Validación

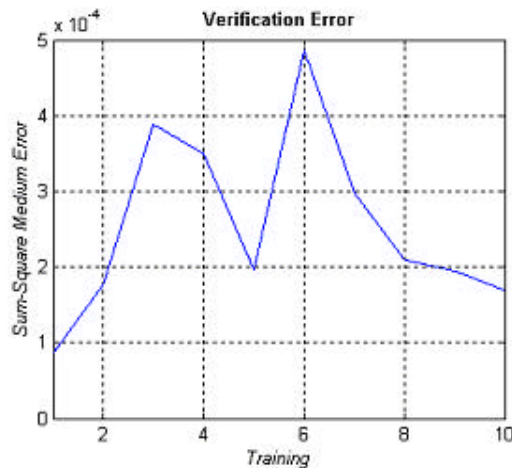


Figura 7. Error de Verificación

Las figuras 5, 6 y 7 muestran el comportamiento de los errores de entrenamiento, verificación y validación en el proceso de entrenamiento de la red neuronal. Como los muestran las gráficas los errores tanto de entrenamiento como de validación disminuyen rápidamente en cada iteración, pero el de verificación es muy variable. Esto es debido a que cada valor de la gráfica es para un entrenamiento diferente, pero como el orden de magnitud de los datos es tan pequeño, la red trabajaría

satisfactoriamente para cada uno de los pesos obtenidos en los entrenamientos graficados. Cabe anotar que la validación se hizo cada diez iteraciones correspondientes al entrenamiento.

La implementación de los algoritmos se hizo en Visual C++. Se realizaron dos programas, el primero de ellos entrena, valida y verifica la red siguiendo el algoritmo de entrenamiento anteriormente mencionado y el segundo programa, simplemente lo que hace es evaluar la red con los pesos generados a partir del entrenamiento que se realizó con las bases de datos. De esta forma, con este segundo programa es posible hacer la identificación de los fenómenos de calidad de potencia estudiados diferentes a los que se encuentran en la base de datos.

Además, los algoritmos implementados permiten realizar análisis de relevancia y generar las matrices de confusión para poder observar los resultados, los cuales a su vez dependen de un umbral predeterminado para que reconozca o no el tipo de patrón.

El método de relevancia utilizado sigue la Ecuación 3.

$$\lambda_n = \sum_{m=1}^M w_{nm}^2 \quad \text{Ecuación 3.}$$

Esta ecuación indica la suma de los pesos de la primera capa asociados a cada entrada de la red. Si la suma de pesos es pequeña, significa que los pesos también tienen un valor bajo, lo cual refleja la poca relevancia de esa entrada para la identificación del patrón a reconocer. Por el contrario, si la suma es grande, la entrada es relevante.

4. RESULTADOS

Para la obtención de los patrones se probaron varios de los filtros que están implementados en MATLAB, pero el que proporcionó los mejores resultados, es decir patrones más consistentes, fue el Daubechies4. Las figuras 8, 9, 10, 11 y 12 presentan el tipo de señales que fueron sometidas al análisis wavelet, en donde la ordenada dependiente es la amplitud en voltaje de la señal, y la independiente es el número de la muestra o lo que sería el tiempo.




Figura 8. Corte




Figura 9. Swell




Figura 10. Sag

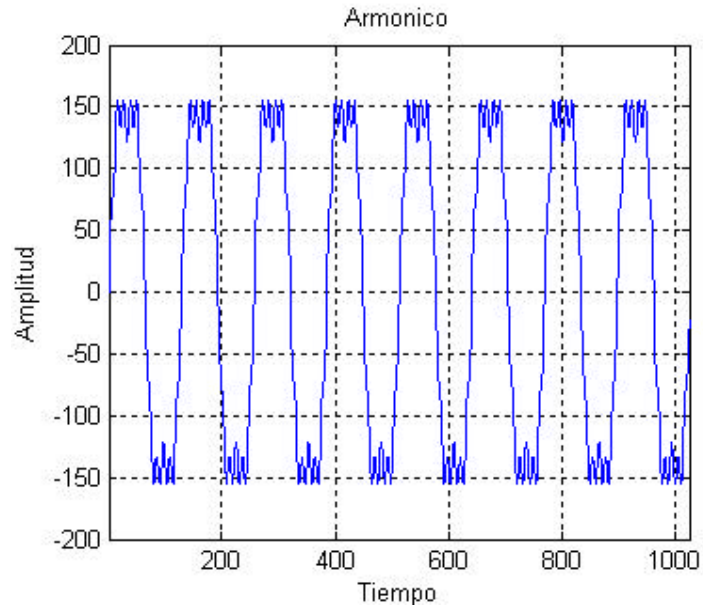


Figura 11. Armónico

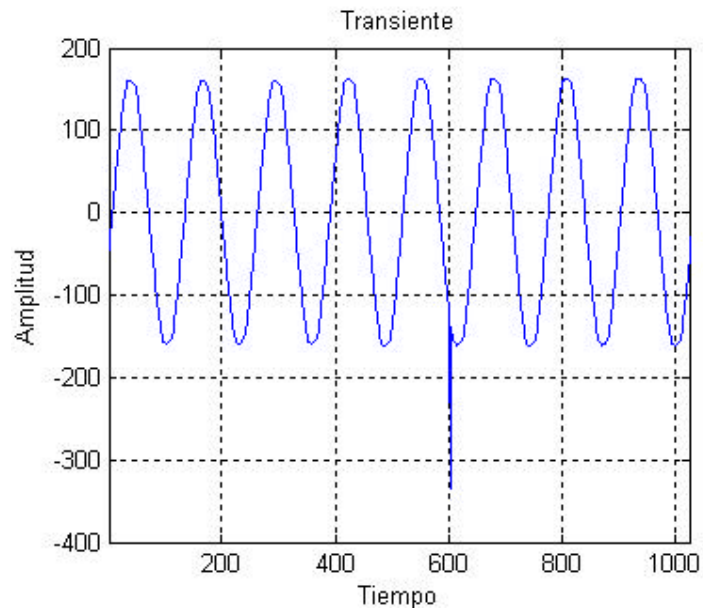


Figura 12. Transiente

Los patrones que se obtuvieron para cada uno de los fenómenos se ilustran en las figuras 13, 14, 15, 16 y 17. En cada figura se encuentran los patrones de cinco señales diferentes, y como se puede observar el patrón obtenido es bastante

consistente, esto es, los patrones de las señales de un mismo tipo son muy similares pero al compararlos con los de las demás presentan diferencias significativas que los hacen diferenciables.

Como se citó anteriormente, el procedimiento que se siguió fue tomado en gran parte de la referencia [1], sin embargo, los resultados obtenidos varían considerablemente. Los patrones que se encontraron para las clases de fenómenos analizados son incluso más diferenciables en ciertos casos como en las señales con armónicos, ya que la desviación de energía presentada en la referencia anteriormente mencionada es muy cercana a cero en este tipo de fenómeno.




Figura 13. Patrones de Cortes

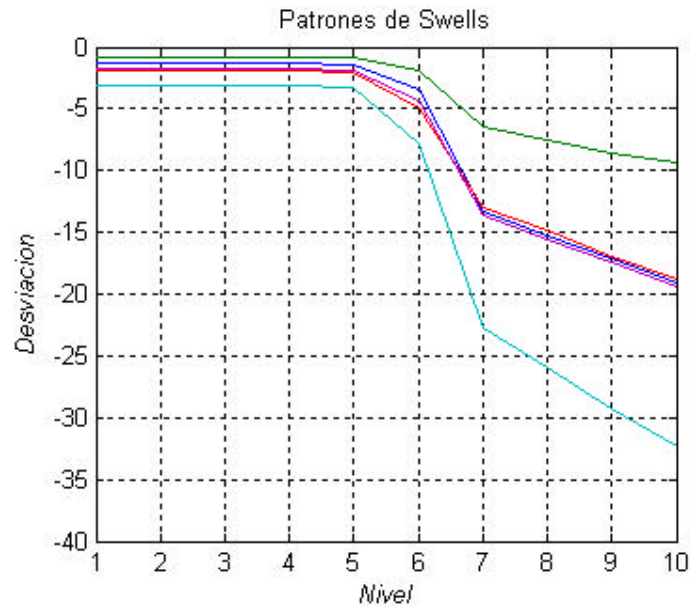


Figura 14. Patrones de Swells

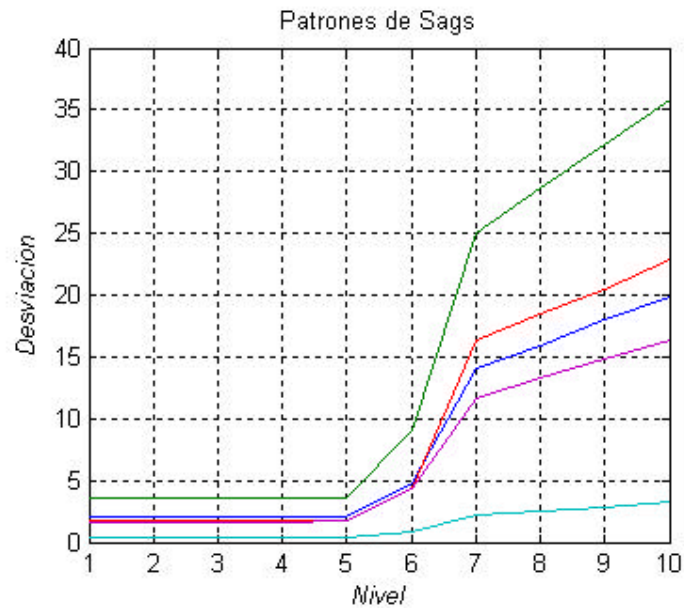


Figura 15. Patrones de Sags

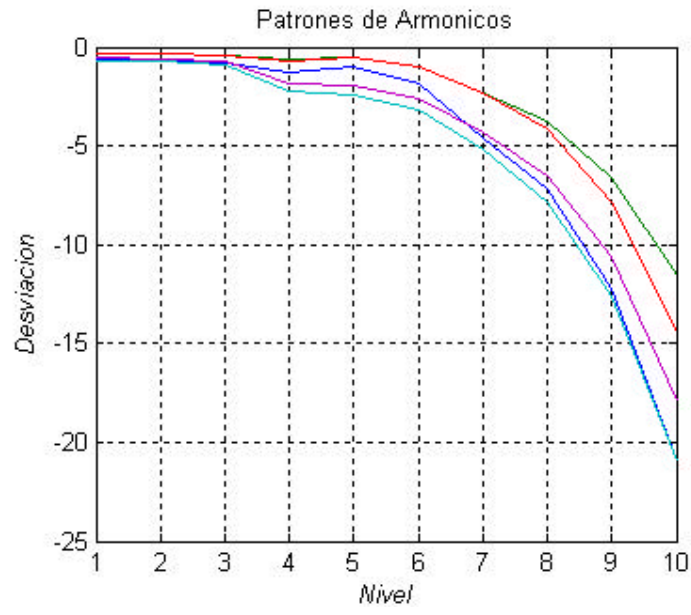


Figura 16. Patrones de Armónicos

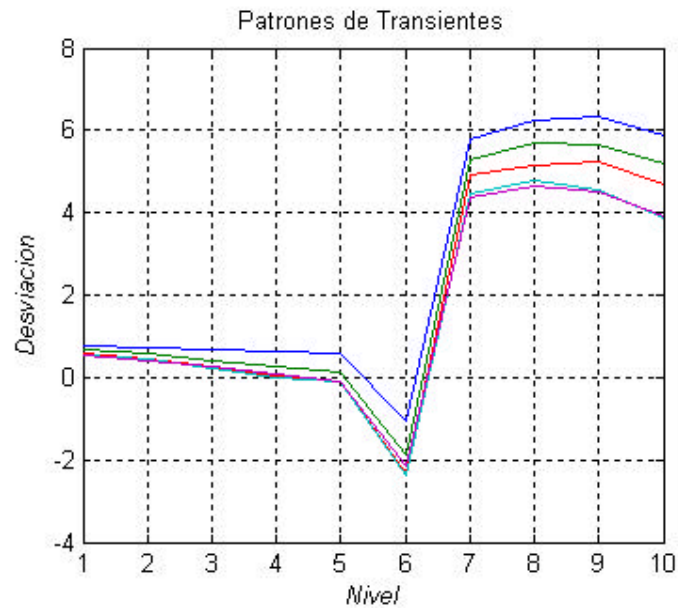


Figura 17. Patrones de Transientes

En cuanto a la parte de reconocimiento de los patrones por medio de la red neuronal.

Los resultados que se presentan en las tablas 1, 2, 3, 4, 5 y 6 representan la efectividad que tiene la red implementada para realizar el reconocimiento de los diferentes patrones al variar el número de neuronas en la capa media de la red, y con un umbral preestablecido de 0.8. También se presenta un análisis de la relevancia utilizando el criterio anteriormente mencionado para cada uno de los casos, y los errores cuadráticos medios de entrenamiento, validación y verificación asociados.

T1 = Armónicos
T2 = Transientes
T3 = Sags
T4 = Swells
T5 = Cortes
Umbral = 0.8

Para 5 Neuronas

Tabla 1. Matriz de Confusión

	T1	T2	T3	T4	T5	NN	TOTALES
T1	47	0	0	0	0	3	50
T2	0	50	0	0	0	0	50
T3	0	0	48	0	0	2	50
T4	0	0	0	47	0	3	50
T5	0	0	0	0	49	1	50

Resultados del Analisis de Relevancia

Lambda(1) 8.862050
Lambda(2) 2.331997
Lambda(3) 181.104721
Lambda(4) 78.764079
Lambda(5) 105.472238

Error de Entrenamiento: 0.000466
Error de Validación: 0.000400
Error de Verificación: 0.000735

Para 10 Neuronas

Tabla 2. Matriz de Confusión

	T1	T2	T3	T4	T5	NN	TOTALES
T1	47	0	0	0	0	3	50
T2	0	49	0	0	0	1	50
T3	0	0	50	0	0	0	50
T4	0	0	0	47	0	3	50
T5	0	0	0	0	48	2	50

Resultados del análisis de relevancia

Lambda(1) 22.338883
Lambda(2) 13.783865
Lambda(3) 94.935287
Lambda(4) 100.184990
Lambda(5) 120.921663

Error de Entrenamiento: 0.000699
Error de Validación: 0.000670
Error de Verificación: 0.001123

Para 15 Neuronas

Tabla 3. Matriz de confusión

	T1	T2	T3	T4	T5	NN	TOTALES
T1	47	0	0	0	0	3	50
T2	0	49	0	0	0	1	50
T3	0	0	50	0	0	0	50
T4	0	0	0	47	0	3	50
T5	0	0	0	0	49	1	50

Resultados del análisis de relevancia

Lambda(1) 27.519106
Lambda(2) 13.503126
Lambda(3) 94.825110
Lambda(4) 110.539154
Lambda(5) 127.310934

Error de Entrenamiento: 0.000571
Error de Validación: 0.000546
Error de Verificación: 0.000959

Para 20 Neuronas

Tabla 4. Matriz de confusión

	T1	T2	T3	T4	T5	NN	TOTALES
T1	46	0	0	0	0	4	50
T2	0	47	0	0	0	3	50
T3	0	0	50	0	0	0	50
T4	0	0	0	47	0	3	50
T5	0	0	0	0	48	2	50

Resultados del análisis de relevancia

Lambda(1) 29.120654
Lambda(2) 18.173263
Lambda(3) 107.161130
Lambda(4) 122.924156
Lambda(5) 159.380828

Error de Entrenamiento: 0.000533
Error de Validación: 0.000443
Error de Verificación: 0.000443

Para 25 neuronas

Tabla 5. Matriz de confusión

	T1	T2	T3	T4	T5	NN	TOTALES
T1	47	0	0	0	0	3	50
T2	0	48	0	0	0	2	50
T3	0	0	50	0	0	0	50
T4	0	0	0	47	0	3	50
T5	0	0	0	0	48	2	50

Resultados del análisis de relevancia

Lambda(1) 30.093439
Lambda(2) 17.974282
Lambda(3) 105.693526
Lambda(4) 123.525602
Lambda(5) 151.440433

Error de Entrenamiento: 0.000631
Error de Validación: 0.000574
Error de Verificación: 0.001026

Para 30 Neuronas

Tabla 6. Matriz de confusión

	T1	T2	T3	T4	T5	NN	TOTALES
T1	46	0	0	0	0	4	50
T2	0	47	0	0	0	3	50
T3	0	0	50	0	0	0	50
T4	0	0	0	47	0	3	50
T5	0	0	0	0	48	2	50

Resultados del análisis de relevancia

Lambda(1) 41.578573
Lambda(2) 28.027160
Lambda(3) 93.450574
Lambda(4) 136.541698
Lambda(5) 151.136399

Error de Entrenamiento: 0.000584

Error de Validación: 0.000523

Error de Verificación: 0.001017

Estos fueron los resultados que se obtuvieron utilizando cinco entradas en la red neuronal, es decir los niveles 4, 5, 6, 8 y 10. A pesar de que son satisfactorios en cuanto a porcentaje de reconocimiento se refiere, con el fin de mejorarlos se incluyó otra entrada correspondiente al nivel 1, y se entrenó la red neuronal con cinco neuronas. Al realizar la verificación se alcanzó un reconocimiento del cien por ciento de las muestras que constituían esta base. Por obvias razones no se probó con más neuronas y este fue el diseño final.

5. IMPLEMENTACIÓN DE SOFTWARE

Adicionalmente se implementó un software en Visual Basic 6.0 el cual recopila todo lo comentado anteriormente, es decir, en el programa se carga una señal y este automáticamente genera los patrones y reconoce los mismos identificando que tipo de anomalía o fenómeno presenta la señal cargada. Además genera un reporte indicativo con las posibles causas, consecuencias y soluciones al problema detectado en particular. A continuación se muestra la interfaz del programa el la cual se carga una distorsión armónica y se observa todo el análisis que el programa realiza.

Es de anotar que el programa se realizó en Ingles para efectos universalización.

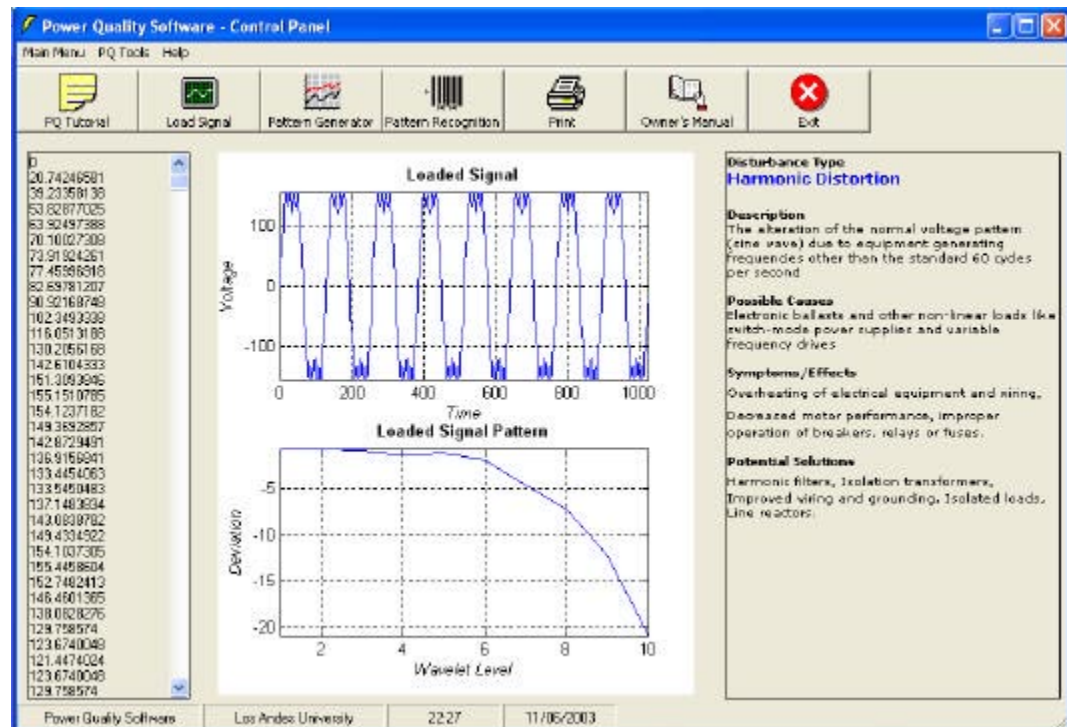


Figura 18. Interfaz de usuario

El programa presenta varias utilidades. Entre ellas está una bastante importante ya que permite al usuario antes, durante o después de la ejecución del programa tener acceso a un tutorial de calidad de la potencia, orientado al tema de estos fenómenos en particular. A continuación se presenta una muestra de esto.

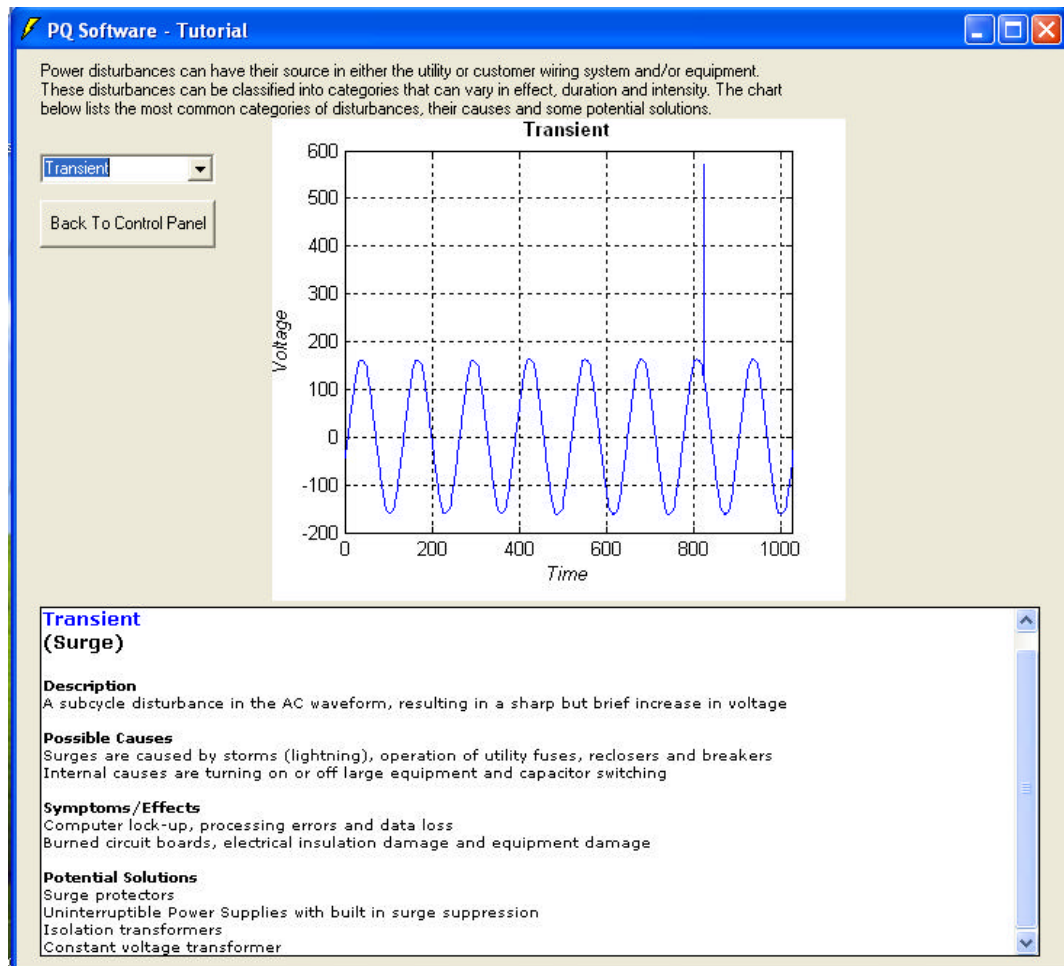


Figura 19. Tutorial

6. CONCLUSIONES

- Con este estudio se ha podido demostrar que utilizando algunas herramientas de MATLAB relacionadas con la teoría de la DWT es posible generar patrones. Estos patrones permiten la identificación de los fenómenos relacionados con calidad de la potencia tales como: transientes, armónicos, sags y swells, corroborando de cierta forma el trabajo expuesto en la referencia [1].
- Es de anotar que las señales utilizadas para el estudio de estos fenómenos no son reales si no generadas por EXCEL. Se optó por ello, debido a que las señales reales con las que se contaba, muestreadas por un dispositivo de redes, eran mixtas, es decir, contenían más de un fenómeno de calidad de la potencia a la vez. Obviamente el programa desarrollado en MATLAB está en capacidad de generar salidas para los diferentes tipos de combinaciones de fenómenos. Sin embargo, sin saber si estas señales mixtas generan algún tipo de patrón ya que esto no hacía parte del trabajo original, pero podría convertirse en un estudio futuro.
- El Departamento de Ingeniería Eléctrica de la Universidad de los Andes, cuenta con una herramienta de análisis que le permite reforzar sus prácticas de laboratorio en los cursos de calidad de la potencia y también le sirve de apoyo para analizar problemas específicos de la industria.
- Este modelo se puede volver más eficiente si se implementa alguna herramienta que realice automáticamente el reconocimiento de estos fenómenos a partir de los patrones generados con este trabajo. Esta futura etapa del proyecto permitirá generar patrones diferenciables que no utilicen mucha información tal como se logró con la DWT.
- El cumplimiento de los objetivos fue muy satisfactorio de acuerdo a lo esperado. La red reconoce perfectamente los cuatro fenómenos eléctricos que representan los

patrones de entrada. Se logra reducir el uso de los recursos computacionales utilizados por medio de la herramienta WAVELET, lo que agiliza la ejecución de los algoritmos y permite realizar más pruebas.

- Es importante anotar que la efectividad en el reconocimiento de los patrones no es proporcional al número de neuronas que la red utilice. Al aumentar el número de ellas los resultados no varían significativamente, lo cual no justifica tener mayor número. De este modo la solución ideal sería con solo 5 neuronas, ya que el procesamiento de información es menor entre menor sea el número de neuronas utilizadas, lo que repercute en una mayor eficiencia computacional.
- En algunos casos se puede observar que las variables de relevancia para algunas entradas no son tan altas, por lo que se podría tratar de eliminar algunas entradas y observar los resultados para verificar la exactitud de estos, buscando reducir el tamaño de la red.
- Este trabajo se complementaría muy bien con la toma de señales reales que contengan más de un fenómeno eléctrico como los que se analizaron en este estudio, para implementar señales reales en los algoritmos y lograr implementar trabajos de campo y solucionar problemas reales. Si se llegaran a encontrar buenos resultados sería algo importante tratar de implementar todo el sistema para crear un dispositivo de análisis de redes con un software que le permitiera el usuario identificar las posibles fuentes de las fallas.
- El trabajo futuro a realizar no es menos importante que el acá presentado ya que consiste obviamente, en practicarle mejoras a los algoritmos. Cada vez existen más formas de agilizar los algoritmos ya realizados, luego es tarea que no se puede olvidar.

IEL1-I-2003 - 05

IEL1-I-2003 - 27

Las reformas a lo algoritmos permitirán reducir mas aun el tiempo de ejecución y recursos computacionales utilizados.

- Los aportes hechos al grupo de investigación en calidad de la potencia eléctrica son relevantes ya que abre una ventana de estudios muy amplia y entrega una herramienta computacional que brinda a los estudiantes el poder analizar de manera más rápida y precisa algunos fenómenos asociados a la calidad de la potencia .

7. BIBLIOGRAFÍA

- [1] Resende J.W., Chaves M.L.R. and Penna C. Universidade Federal de Uberlandia (MG)-Brazil. "Identification of Power Quality Disturbances Using the MATLAB Wavelet Transform Toolbox", 2001.
- [2] Laboratorio de Tratamiento Numérico de la Señal y de la Imagen. Universidad de Oviedo, España. "Análisis de Señales Mediante Wavelets".
- [3] Gaouda, A. M., Salama, M. M. A., Sultan M. R., Chikhani, A . Y., Power quality detection and classification using wavelet-multiresolution signal decomposition, *IEEE Transactions on Power Delivery*, Vol. 14, No. 4, October 1999, p. 1469-1476.
- [4] – Penna, C., Detection and classification of power quality disturbances using the wavelet transform – *M. Sc. Dissertation*, June 2000, Universidade Federal de Uberlandia, Brazil.
- [5] Carl G. Looney, PATTERN RECOGNITION USING NEURAL NETWORKS Theory and Algorithms for Engineers and Scientists, Oxford University Press, 1997.