

CARACTERIZACIÓN DE PERTURBACIONES EN CALIDAD DE POTENCIA EN REDES ELÉCTRICAS

Jesús Rubén Azor Montoya ¹, Alfredo Antonio Iglesias ², Yoel Xavier Peralta Mamoli ³

¹ Facultad de Ingeniería Universidad de Mendoza, Peatonal Emilio Descotte 750 (5500) Ciudad - Mendoza Argentina, r_azor@yahoo.com, Tel: 54-261-4201872, ² Facultad de Ingeniería Universidad de Mendoza, Peatonal Emilio Descotte 750 (5500) Ciudad - Mendoza Argentina alfredo.iglesias@um.edu.ar, Tel: 54-261-4201872, ³ Yoel Xavier Peralta Mamoli, Facultad de Ingeniería Universidad de Mendoza, Peatonal Emilio Descotte 750 (5500) Ciudad - Mendoza Argentina, yoelperalta@gmail.com, Tel: 54-261-4201872

RESUMEN. En el presente trabajo se comparan de manera experimental distintos procedimientos para el análisis de calidad de potencia en redes eléctricas. Para ello se simula una serie de ondas de valores y tipos determinados por los estándares de calidad de potencia, para luego extraer algunas de sus características por medio de su análisis usando la transformada wavelet discreta (DWT). Estas transformadas se realizan con distintas wavelets madres y en distintos niveles de resolución. Posteriormente, calculando sus normas, se obtienen indicadores significativos que permiten la clasificación de las distintas perturbaciones. Las clasificaciones se realizan por cuatro métodos distintos: red neuronal, red bayesiana, árbol de decisión y máquina con soporte de vectores (SVM). Se han logrado resultados satisfactorios para el conjunto de las ondas simuladas, mediante distintas wavelets madres, y diferentes clasificadores. Finalmente, en base a los resultados experimentales obtenidos, se propone un procedimiento de obtención y clasificación de características de las perturbaciones simuladas de la calidad de potencia, mediante algoritmos de bajo costo computacional.

Palabras Claves- Calidad de potencia, Clasificadores Inteligentes, Transformada Wavelet.

1. INTRODUCCIÓN

El suministro de energía eléctrica en la actualidad, presenta una problemática que lo distingue de los suministros de otros tipos de energía, esto es, que la calidad de potencia en la red eléctrica no solo depende de los proveedores, es decir de cómo se la genera y de cómo se la distribuye, sino que además esta se ve afectada por la forma en que los clientes la usan. El creciente aumento de cargas no lineales en el sistema, entre otros aspectos, hacen que la calidad de potencia en el sistema, sea un problema complejo que se refleja en el incremento del interés que el sector eléctrico tiene en este tema.

Hay diferentes razones para este aumento de interés, entre las principales se encuentran:

El Equipamiento se ha tornado menos tolerante a las perturbaciones de la calidad del servicio eléctrico. Lo mismo ocurre con los procesos de producción respecto al funcionamiento incorrecto de dicho equipamiento, lo que conduce a paradas y a altos costos asociados a estas anomalías, incluso para las de muy corta duración.

A su vez, los equipos producen cada vez más alteraciones de lo que solían hacer en otros tiempos. Esto abarca tanto a los equipos de bajo consumo como a los de alta potencia, alimentados por convertidores electrónicos u otros dispositivos no lineales que producen distorsiones de amplio espectro.

Otra fuente de perturbaciones en la calidad de potencia lo constituyen los equipos de alta eficiencia energética. En este campo se incluyen los variadores de velocidad y las lámparas de bajo consumo que distorsionan formas de onda y a su vez son sensibles a ciertos tipos alteraciones en la calidad de potencia. [1]

Cuando estos problemas de calidad de potencia se convierten en un obstáculo para el uso a gran escala de dispositivos de bajo consumo, la calidad de potencia se convierte además, en un problema ambiental con muchas más consecuencias que las meramente económicas.

El disponer de un mecanismo de detección temprana de la falla, como así también el conocimiento de su posible origen, constituye una herramienta valiosa tanto para empresas prestadoras como para los entes reguladores y clientes del servicio eléctrico.

2. DEFINICIÓN DE CALIDAD DE POTENCIA

Al momento de dar una definición de calidad de potencia, se encuentran varias fuentes que proporcionan diferentes definiciones, a veces contradictorias.

El diccionario de la IEEE (“Institute of Electrical and Electronics Engineers”) define el término como *“power quality is the concept of powering and grounding sensitive equipment in a matter that is suitable to the operation of that equipment”* (calidad de potencia es el concepto relacionado con la alimentación y puesta a tierra de equipos sensibles de modo de lograr la correcta operación de los mismos).

A su vez, la IEC (“International Electrotechnical Commission”) en su norma 61000-4-3 da la definición de *“Characteristics of the electricity at a given point on an electrical system, evaluated against a set of reference technical parameters”* (Características de la electricidad tomadas en cierto punto del sistema eléctrico evaluadas contra un conjunto de parámetros técnicos de referencia). [2]

Esta última definición no está relacionada con el funcionamiento eficaz de los equipos, pero sí con la posibilidad de medir y cuantificar la eficacia del sistema de potencia.

Una perturbación puede ser de voltaje o corriente, pero no es posible la distinción entre ambas ya que cualquier cambio en la corriente ocasiona un cambio en la tensión y viceversa. Cuando se hace algún tipo de distinción entre ellas se utiliza la causa de la misma como criterio de diferenciación: en principio las perturbaciones de voltaje tienen origen en la red eléctrica y afectan potencialmente a los clientes, por otra parte las perturbaciones de corriente tienen origen en el cliente y afectan potencialmente a la red eléctrica.

Clasificación de las perturbaciones

El IEEE tiene como estándar, en lo referido a recomendaciones prácticas para el monitoreo de la calidad de potencia, la norma IEEE Std 1159-1995 “IEEE Recommended Practice for Monitoring Electric Power Quality”.

En ella se dan una serie de definiciones para caracterizar los fenómenos electromagnéticos comunes en sistemas de potencia, y da pautas para facilitar la comunicación entre los diversos sectores de la comunidad de la calidad de potencia.

La recomendación IEEE Std 1159-1995, contiene algunos términos adicionales relacionados con la terminología IEC. Por ejemplo, el término “sag”, se utiliza como un sinónimo para el término “dip” utilizado por la IEC. La categoría de variaciones de corta duración se utiliza para referirse a huecos de tensión e interrupciones breves. El término “swell”, se presenta como la inversa del término “sag” (“dip”). La categoría de variaciones de larga duración se ha añadido en función del estándar ANSI C84.1-1989 [3]. El término “noise”, (ruido) se ha añadido para contemplar los fenómenos de banda ancha. La categoría de distorsión de la forma de onda se utiliza para contemplar los armónicos, los inter armónicos, y la presencia de corriente continua en redes de corriente alterna.

También se contempla un fenómeno adicional del IEEE Std 519-1992 [4] denominado “notching”, (huecos).

La Tabla 1 muestra la categorización y las características de los fenómenos electromagnéticos recomendada para la comunidad de calidad de potencia por la IEEE.

Tabla 1: Categorías típicas de fenómenos electromagnéticos en sistemas de potencia.

Categories	Typical spectral content	Typical duration	Typical voltage magnitude
1.0 Transients			
1.1 Impulsive			
1.1.1 Nanosecond	5 ns rise	< 50 ns	
1.1.2 Microsecond	1 μ s rise	50 ns – 1 ms	
1.1.3 Millisecond	0.1 ms rise	> 1 ms	
1.2 Oscillatory			
1.2.1 Low frequency	< 5 kHz	0.3 - 50 ms	0 - 4 pu
1.2.2 Medium frequency	5 - 500 kHz	20 μ s	0 - 8 pu
1.2.3 High frequency	0.5 - 5 MHz	5 μ s	0 - 4 pu
2.0 Short duration variations			
2.1 Instantaneous			
2.1.1 Sag		0.5 - 30 cycles	0.1 - 0.9 pu
2.1.2 Swell		0.5 - 30 cycles	1.1 - 1.8 pu
2.2 Momentary			
2.2.1 Interruption		0.5 cycles - 3 s	< 0.1 pu
2.2.2 Sag		30 cycles - 3 s	0.1 - 0.9 pu
2.2.3 Swell		30 cycles - 3 s	1.1 - 1.4 pu
2.3 Temporary			
2.3.1 Interruption		3 s - 1 min	< 0.1 pu
2.3.2 Sag		3 s - 1 min	0.1 - 0.9 pu
2.3.3 Swell		3 s - 1 min	1.1 - 1.2 pu
3.0 Long duration variations	Typical spectral content	Typical duration	Typical voltage magnitude
3.1 Interruption, sustained		> 1 min	0.0 pu
3.2 Undervoltages		> 1 min	0.8 - 0.9 pu
3.3 Overvoltages		> 1 min	1.1 - 1.2 pu
4.0 Voltage imbalance		steady state	0.5 - 2%
5.0 Waveform distortion			
5.1 DC offset		steady state	0 - 0.1%
5.2 Harmonics	0 - 100th H	steady state	0 - 20%
5.3 Interharmonics	0 - 6 kHz	steady state	0 - 2%
5.4 Notching		steady state	
5.5 Noise	broad-band	steady state	0 - 1%
6.0 Voltage fluctuations	< 25 Hz	intermittent	0.1 - 7%
7.0 Power frequency variations		< 10 s	

Algunos términos utilizados para las distintas fallas o perturbaciones pueden resumirse entonces en:

"Swell": Cuando la tensión RMS excede la tensión nominal entre un 10-80% para una duración entre 0.5 ciclo a un 1 minuto.

"Dip" (IEC) o "Sag" (IEEE): es la situación opuesta al "swell", en este caso la tensión RMS está por debajo de la tensión nominal entre 10-90% para una duración entre 0.5 ciclo a un 1 minuto.

"Undervoltages" (subtensiones), ocurren cuando la tensión nominal cae por debajo del 90% por más de un minuto.

"Overvoltages" (sobretensiones) ocurren cuando la tensión nominal crece por encima del 110% por más de un minuto.

Otros términos también utilizados en calidad de potencia son:

"Flicker": Variaciones aleatorias o repetitivas en la tensión RMS entre 90-110% de la tensión nominal pueden producir un fenómeno conocido como parpadeo en el equipamiento de iluminación.

"Spikes", "Impulses", o "Surges": Incrementos abruptos, muy breves en tensión, generalmente causados por grandes cargas inductivas al ser desconectadas, o más severamente por rayos de origen atmosférico.

En definitiva, las perturbaciones de calidad de potencia pueden dividirse en dos tipos diferentes: variaciones y eventos.

Las variaciones son perturbaciones de estado estacionario o cuasi estacionario que requieren mediciones continuas. Un ejemplo típico es la variación de la frecuencia del sistema, la cual idealmente es de 50 Hz. pero en la realidad esta magnitud difiere en ± 1 Hz.

Aspectos importantes a tener en cuenta en el análisis de las variaciones son:

- ✓ Extracción de las características.
- ✓ Estadísticas para cuantificar la eficiencia del sistema en cierto punto.
- ✓ Estadísticas para cuantificar la eficiencia del sistema en su totalidad.

Los eventos son perturbaciones repentinas con un principio y un fin. Un ejemplo de este tipo de perturbación es una interrupción, durante la cual la tensión medida vale cero o cerca de cero. Para medir una interrupción es necesario esperar a que ocurra, para ello puede compararse la tensión medida con un umbral, si la misma permanece por un cierto tiempo por debajo del mismo se detecta el inicio de una interrupción. El fin del evento se detecta cuando la tensión se mantiene por encima de un umbral durante un cierto tiempo. La duración de la interrupción se define como la diferencia entre el fin y el inicio del evento. Puede observarse la complejidad de la medida de eventos, analizando los siguientes aspectos:

Se debe definir un método para obtener la magnitud del voltaje de las muestras adquiridas.

Se deben definir umbrales de nivel para detectar el inicio y fin de la interrupción, los cuales pueden ser iguales o diferentes (con histéresis).

Se debe caracterizar el evento, en este caso a través de la duración del mismo.

La medida de calidad de potencia desde el punto de vista específico, de la toma de medidas, no difiere de la medición de tensión o corriente en, por ejemplo, sistemas de control o protección. La diferencia está en el procesamiento y aplicación de dichas medidas.

Un esquema general para llevar a cabo medidas de calidad de potencia, es el que se muestra en la Figura 1:

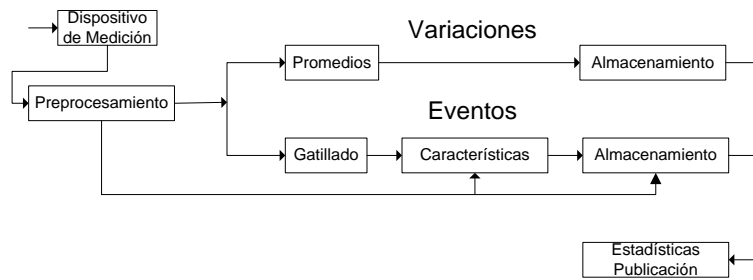


Figura 1: Esquema de medición de calidad de potencia

La diferencia entre eventos y variaciones es inherente al método de procesamiento, no necesariamente al fenómeno físico. Por ejemplo, con respecto al valor RMS de tensión, los eventos a considerar son interrupciones (cortas y largas), sobretensión y bajas tensiones de corta y larga duración. El primer paso es el cálculo del valor RMS sobre una ventana de un ciclo de duración. Pero a diferencia de las variaciones, el resultado no es normalmente almacenado o utilizado, sino que solamente cuando el valor calculado exceda un cierto umbral durante un cierto tiempo, el procesamiento comienza (este proceso se denomina gatillado). Luego, el procesamiento de los eventos consiste en el cálculo de varios índices. Éstos índices incluyen la duración del evento y alguna otra magnitud.

El procesamiento estadístico de los eventos consiste en el cálculo de índices de sitio (número de eventos por año) e índices del sistema (número de eventos por sitio por año).

3. EXTRACCIÓN DE CARACTERÍSTICAS DE LAS PERTURBACIONES O SEÑAL DE FALLA.

El éxito de la clasificación de perturbaciones, depende en gran medida de una adecuada selección del conjunto de características de la señal que se utilicen. Es deseable además, que el conjunto de características seleccionadas pueda modelar y distinguir diferentes clases de trastornos del sistema de energía, como así también, asociarlo a sus diferentes causas subyacentes.

Por otra parte, es importante que las características seleccionadas de la señal de falla, no estén correlacionadas entre sí y que el número total de funciones utilizadas sea pequeño. Si las características están correlacionadas, aportarán información redundante.

Otras cuestiones que se podrían tomar en cuenta incluyen: modelado matemático, estabilidad numérica, baja sensibilidad al ruido, invariabilidad de las transformaciones utilizadas y una clara interpretación física.

Las características de la señal, se pueden clasificar en i) estáticas, con comportamiento estadístico invariable en el tiempo (estacionarias) o ii) dinámicas, no estacionarias.

A modo de ejemplo, las características de la distorsión armónica son estáticas en la mayoría de los casos, y las de las variaciones de tensión son propensas a ser dinámicas.

Vale la pena señalar que algunas de las características pueden ser estáticas aún cuando provengan de señales dinámicas. Tal es el caso de las oscilaciones producidas por eventos transitorios causados por la conexión /desconexión de condensadores a la línea. En este caso, la característica relacionada con el factor de atenuación de la senoide amortiguada del modelo transitorio, es estática [5].

No hay relación directa entre la estacionariedad de una señal y la naturaleza estática/dinámica de una de sus características, todo depende de cómo se selecciona la función que obtiene la característica de la misma.

Si se segmenta un evento, las características de cada segmento son estáticas, mientras que las funciones de un segmento de transición suelen ser dinámicas.

Sin embargo, si las características son dinámicas, entonces se puede considerar el comportamiento en un intervalo de tiempo menor (una "instantánea"), dentro de la cual las características se pueden aproximar como estáticas.

Algunas de las situaciones típicas que se dan en las perturbaciones de calidad de potencia son las siguientes [6]:

- ✓ Armónicos y componentes ínter armónicos, sus frecuencias, magnitudes y fasores.
- ✓ Puntos desencadenantes del eventos (inicio y fin de la transición).
- ✓ Componentes principales de una onda distorsionada.
- ✓ Tensión residual, ángulo de fase, duración y desequilibrio de huecos de tensión.
- ✓ Componentes principales (amplitud, frecuencia, fase inicial y factor de amortiguamiento de transitorios oscilatorios).
- ✓ Distribución espectral de los acontecimientos.
- ✓ Distorsión armónica total y su rango de frecuencias.
- ✓ En sistemas trifásicos, equilibrio /desequilibrio de las fases.
- ✓ Información sobre propagación de la onda de tensión/corriente en disturbios, en diferentes lugares y los niveles de energía del sistema.
- ✓ Estadísticos, distribuciones de probabilidad o histogramas de las perturbaciones.

Esta lista es sólo un pequeño subconjunto de caracterizaciones candidatas y es evidente que puede ser mucho mayor.

Si no hay un conocimiento previo sobre qué características podrían "interpretar mejor" la alteración que se estudia, es común seleccionar varias de ellas, a pesar de que estas funciones pueden estar altamente correlacionadas. La redundancia de las características se puede disminuir a través de una optimización adecuada de las mismas.

La Figura 2, muestra un esquema general y simplificado del proceso a realizar desde la obtención de la señal de falla hasta su clasificación:

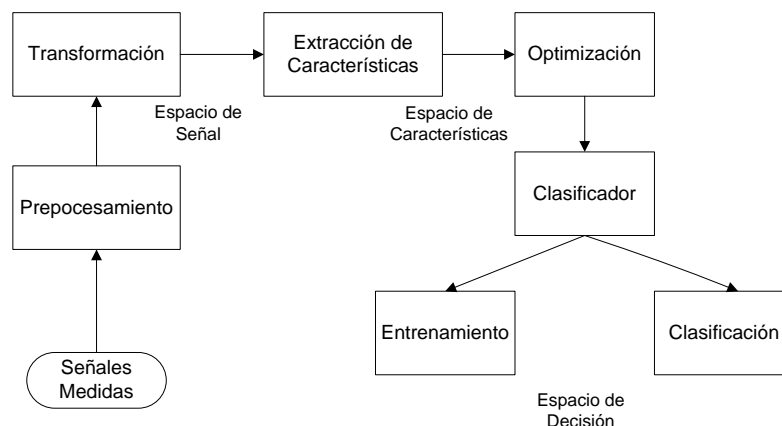


Figura 2: Esquema simplificado para la clasificación de eventos

Las características extraídas de señales no estacionarias por lo general resultan ser funciones del tiempo. Para este tipo de señales se requiere un análisis tiempo-frecuencia (o tiempo-escala) para poder observar la evolución a través del tiempo de las características de las componentes de la señal.

Este análisis se puede realizar mediante métodos no basados en modelos como la STFT (Short Time Fourier Transform) o la DWT (Discrete Wavelet Transform) o en métodos basados en modelos, como AR (Autoregresive), MA (Moving Average), ARMA (Autoregresive Moving Average),

MUSIC (Multiple Signal Clasificación), ESPIRIT (Estimation of Signal Parameters via Rotational Invariance Techniques) y filtros de Kalman extendidos al procesamiento de señales no estacionarias.

Transformada wavelet discreta (DWT)

La transformada discreta de wavelets puede definirse como:

$$W_{j,k} = \frac{1}{2^{j/2}} \int_{-\infty}^{\infty} \psi^*(\tau - k) x(\tau) d\tau$$

Cada wavelet se genera a partir de una función de escalado Φ , definida como:

$$\Phi(x) = \sum_{k=0}^{N-1} h_0(k) \Phi(x - k)$$

Similarmente la wavelet madre se construye a partir de la función de escala:

$$\Psi(x) = \sum_{k=0}^{N-1} (-1)^k h_1(k) \Phi(x + k - N + 1)$$

Y la expansión de una señal transformada queda expresada como:

Donde:

$$f(x) = a_0 + a_1 \Psi(x) + \dots + a_{2^j+k} \Psi(x - k)$$

$$a_0 = \int_{-\infty}^{\infty} f(x) \Phi(x) dx$$

$$a_{2^j+k} = 2^j \int_{-\infty}^{\infty} f(x) \Phi(x - k) dx$$

La señal queda descompuesta en diferentes escalas, cada una de las cuales representa una banda de frecuencias centradas en f_c :

$$f_c = \frac{f_s}{2^n} 2^l \quad l = 0, 1, 2, \dots, n-1$$

Donde f_s es la frecuencia de muestreo y l el número de escala o nivel

En cada paso de la transformada wavelet, se aplica la función de escala a los datos de entrada, y se produce un proceso de diezmado, de modo que si el conjunto de datos original (s) tiene N valores $s(n)$, al aplicar la función de escala de la transformada wavelet se calculan $N / 2$ valores suavizados.

La transformada wavelet puede verse como un banco de filtros:




Figura 3: Transformada wavelet como banco de filtros

Cuyas funciones de transferencia son $H_0(z)$ y $H_1(z)$

Obtenidos estos coeficientes, El escalamiento y las funciones wavelet se calculan tomando el producto interior de los coeficientes y los valores de los datos de la señal a transformar. Para el caso de cuatro coeficientes sería:

Escalado:
$$a_i = h_0 0s_{2i} + h_0 1s_{2i+1} + h_0 2s_{2i+2} + h_0 3s_{2i+3}$$

Wavelet:
$$c_i = h_1 0s_{2i} + h_1 1s_{2i+1} + h_1 2s_{2i+2} + h_1 3s_{2i+3}$$

4. CLASIFICACIÓN DE EVENTOS

En muchos problemas de la vida real no se tiene un conocimiento completo sobre las características de los eventos, por ello una forma práctica de analizar dichas perturbaciones es aprender de los datos disponibles. Para ello se recurre a sistemas inteligentes basados en métodos de aprendizaje. Se dice que un programa aprende de una experiencia E con respecto a una clase de tareas T y medida de rendimiento P si su rendimiento en las tareas T, medido por P, mejora con la experiencia E [7].

En este trabajo se analizan los resultados obtenidos con siguientes métodos de clasificación:

- ✓ Árboles de decisión
- ✓ Perceptrón multicapa
- ✓ Clasificadores bayesianos
- ✓ Máquinas de vectores soporte (SVM)

Árboles de decisión

Los árboles de decisión consisten en la representación del conjunto de entrenamiento como una disyunción de reglas proposicionales.

Un árbol de decisión está formado por nodos internos que representan atributos, ramas que representan posibles valores del nodo del cual se originan y nodos hoja que constituyen las posibles clasificaciones.

La Figura 4 muestra la estructura de un árbol de decisión para la clasificación de ejemplos formados por 6 atributos en 3 diferentes clases.

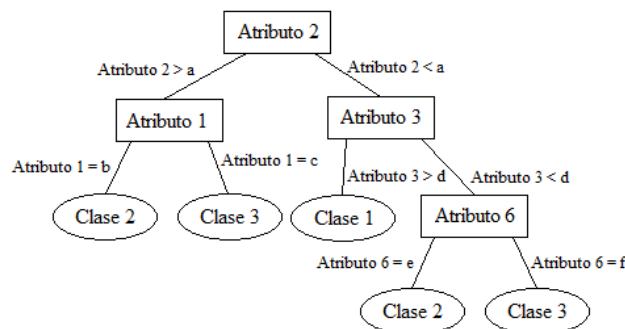


Figura 4: Árbol de decisión

Existen distintos algoritmos para la elaboración de los árboles de decisión, la mayoría de los cuales derivan del algoritmo ID3. Éste realiza la elección del mejor atributo en base a la homogeneidad de la colección de datos, la cual mide por medio de la función Ganancia de información basada en la Entropía de los datos.

Una vez seleccionado el mejor atributo, éste divide al conjunto de entrenamiento inicial de acuerdo a los posibles valores que puede tomar dicho atributo. Se aplican nuevamente los pasos anteriores hasta que la división del subconjunto de datos producto de la separación realizada por el atributo elegido esté formado por ejemplos que representen a una única clase.

Una de las características principales de los árboles es su robustez ante el ruido, un tiempo de entrenamiento relativamente bajo y su bajo costo computacional al momento de la clasificación.

Clasificadores perceptrón multicapa (MLP)

Un Perceptrón multicapa [8] es una red tipo “feedforward”, y normalmente consiste en una capa de entrada, una o varias capas ocultas y una capa de salida, como se muestra en la Figura 5.

Para la clasificación, se emplea una función de activación $f()$ en el campo local asociados a cada neurona. Esto es equivalente a la aplicación de una función no lineal, por ejemplo, una función sigmoidea, cuya entrada es la suma ponderada de los resultados de las neuronas de la última capa, y que produce la salida de la neurona.




Figura 5: Perceptrón Multicapa

Para la clasificación de L clases, se necesitan un total de L neuronas en la capa de salida para generar las salidas $y(j)$, $j = 1, \dots, L$, para representar a todas las clases de decisión posibles.

El número de neuronas en la capa de entrada es generalmente el mismo que el tamaño del vector de la característica (o el tamaño del vector de señal de entrada). El número de neuronas en una capa oculta, como así el número total de capas ocultas están determinadas por la estructura de la red, y pueden variar significativamente para diferentes aplicaciones.

En la fase de aprendizaje, esta red se entrena utilizando algunas técnicas recursivas conocidas en las estadísticas como aproximación estocástica. Uno de los métodos más utilizados para el aprendizaje supervisados de estas redes es el algoritmo de retropropagación (“back-propagation”).

Conforme al mismo, se alimenta la red con un vector etiquetado del conjunto de entrenamiento (inicialmente se asignan a los pesos valores arbitrarios cercanos a cero) y de acuerdo a la función de activación se propagan los resultados hacia adelante obteniendo los valores de salida. En base a ellos y al resultado esperado se calcula el error generalmente recurriendo a métodos de gradiente estocástico como el LMS (Least-Mean Square).

Finalmente este error se propaga hacia atrás (se retropropaga) para el ajuste de los pesos. Este conjunto de pasos se repite una cierta cantidad de veces o hasta alcanzar una cota de error establecida. Una iteración equivale a alimentar la red con todos los elementos del conjunto de entrenamiento.

El algoritmo de entrenamiento de retropropagación es una técnica subóptima, y puede quedarse estancado en un mínimo local en lugar de converger al mínimo global deseado, sin embargo, hay técnicas puntuales que permiten evitar este inconveniente.

Una red de este tipo, puede conducir a una aproximación asintótica de las probabilidades a posteriori subyacente de la clase, siempre que el conjunto de entrenamiento sea lo suficientemente grande y el algoritmo de aprendizaje de retropropagación no se bloquee en un mínimo local. También vale la pena mencionar que una red neuronal sólo está diseñada para reducir al mínimo el error empírico sobre el conjunto de entrenamiento.

Redes bayesianas

Una red bayesiana es una representación gráfica de las dependencias de las variables del sistema, y las probabilidades relativas de estas variables, a través de un grafo dirigido acíclico. Esta red se compone de nodos que representan las variables del sistema y enlaces direccionales que representan probabilidades condicionales, por ejemplo, el vínculo del nodo x_1 al nodo x_2 representa la probabilidad condicional $P(x_2/x_1)$. Las variables tienen vínculos solamente cuando tienen alguna dependencia, las variables independientes no están vinculadas entre sí.

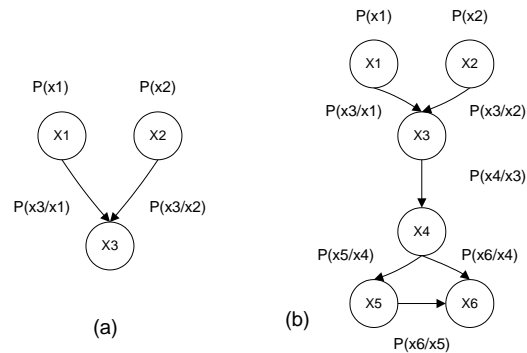


Figura 6: Ejemplos de redes bayesianas

La figura 6 muestra dos ejemplos de red bayesiana. (a) La red describe las probabilidades de un vector de la característica que consiste en tres componentes, de los cuales x_1 y x_2 son independientes y x_3 depende tanto de x_1 y x_2 . (b) En este ejemplo el vector de la característica contiene seis componentes.

Estas redes modelan un fenómeno mediante un conjunto de variables y las relaciones de dependencia entre ellas. Dado este modelo, se puede hacer inferencia bayesiana; es decir, estimar la probabilidad a posteriori de las variables no conocidas, en base a la probabilidad a priori de las variables conocidas.

Además, pueden dar información interesante en cuanto a cómo se relacionan las variables del dominio, las cuales pueden ser interpretadas en ocasiones, como relaciones de causa/efecto.

Máquinas de vectores soporte (SVM)

A menudo en los problemas del mundo real se requieren espacios de hipótesis más complejos que los que utilizan los discriminantes lineales. Las SVM son capaces de encontrar límites no lineales si las clases son linealmente no separables.

El principal interés en el uso de SVMs para clasificación, es el rendimiento de generalización y la complejidad del clasificador, este último en referencia a su aplicación práctica.

Más específicamente, cuando se diseña un sistema de clasificación, es natural que se desee que el clasificador tenga buen desempeño en el conjunto de prueba y no en el conjunto de entrenamiento. Queremos que el clasificador converja a un óptimo global en lugar de alguna posición óptima local. En estos clasificadores también se debe considerar el problema del sobreajuste (“overfitting”). Surge el dilema de usar muchas o pocas muestras de entrenamiento, si utilizamos demasiadas, podríamos tener un clasificador que se sobreajusta.

Sin embargo, si tenemos muy pocas muestras de entrenamiento, no podría ser capaz de obtener la cobertura estadística suficiente para la mayoría de las situaciones posibles. En ambos casos se tiene como resultado un rendimiento pobre en la generalización, es decir, malos resultados con los datos del conjunto de prueba.

Un tema de preocupación es la complejidad computacional. Un clasificador bayesiano es un método elegante que usa las distribuciones de probabilidad a posteriori. Sin embargo, el costo de cómputo es muy alto cuando la dimensión de las características llega a ser grande. Esto a menudo dificulta la aplicación práctica de los clasificadores bayesianos.

Una SVM da una respuesta aceptable a estas cuestiones, ya que minimiza el error de generalización de la prueba. El diseño de una SVM puede ser visto como un problema de optimización con restricciones.

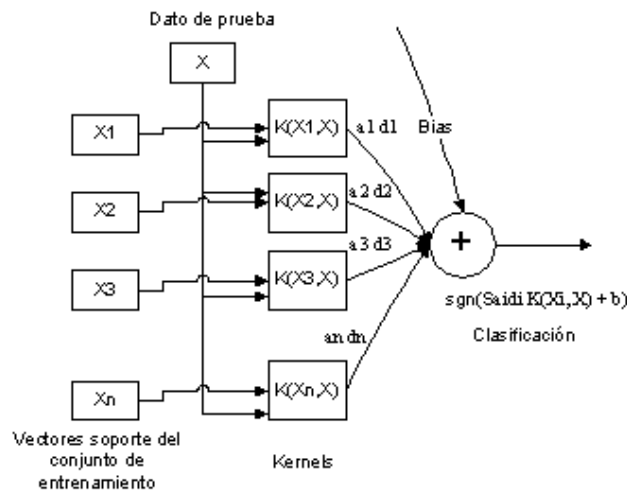


Figura 7: Máquina de vectores soporte

5. SIMULACIÓN DE LAS SEÑALES DE FALLA

Se simularon en forma aleatoria, cuatro tipos de fallas: Sobretensiones (“Swell”), Subtensiones (“Sag”), Cortes breves y transitorios (“Spikes”), mediante la herramienta.

Se utilizaron ventanas (“instantáneas”) de tres segundos de duración y una tasa de muestreo de 128 muestras por ciclo, (6400 muestras por segundo), la señal simulada queda entonces definida por un vector de 19200 componentes.

La amplitud de estas señales en estado normal (antes de la falla) se ha fijado en ± 1024 , anticipándose a una futura implementación en hardware del adquisidor, suponiendo una resolución de 12 bits.

Las Sobretensiones (ST) se simulan con una duración aleatoria comprendida ente 104 ms y 3 seg. Con valores aleatorios comprendidos entre el 10 y el 90% superior al valor nominal (1.1 y 1.9, respectivamente). La figura 8 muestra un ejemplo de estas sobretensiones.




Figura 8: Sobretensión simulada

Las Subtensiones (BT) se simulan del mismo modo, con amplitudes aleatorias comprendidas entre el 10 y 90% inferior al valor nominal (0.1 y 0.9, respectivamente).

Los cortes breves (CO) se simulan de igual manera, con duraciones aleatorias comprendidas entre 104 ms y 3 seg

Los Transitorios (TR) se simulan con una duración aleatoria comprendida entre 10 y 25 ms. Con una amplitud aleatoria comprendida entre el 0 y el 200% del valor nominal de la señal (0 y 2 pu, respectivamente).

Una vez simuladas las señales, se obtienen sus transformadas wavelet con diez niveles de detalle

Por su longitud, estos vectores no resulta útiles como entrada a un clasificador de tamaño razonable, de modo que se calcula la norma estándar de cada vector, como una representación de su energía, de este modo se obtiene un vector de diez componentes para cada falla, lo que permite utilizarlos con cualquiera de los clasificadores propuestos. Así se generan 20 vectores de entrenamiento para cada uno de los cuatro tipos de perturbaciones a analizar.

Para evaluar la performance de distintos tipos de clasificadores, se utiliza la herramienta “Weka”, desarrollada por la Universidad de Waikato Nueva Zelanda, y que puede obtenerse en: <http://www.cs.waikato.ac.nz/ml/weka/>

Mediante esta aplicación, se probaron como clasificadores, un perceptron multicapas, una red bayesiana, una maquina de vectores soporte (SVM) y un árbol de decisión (C4.5).

El experimento se repitió utilizando sobre el mismo conjunto de señales simuladas, 12 wavelet distintas para extraer sus características:

Daubechies: 'db1', 'db2', 'db3', 'db4', 'db6', 'db8' y 'db10'

Coiflets: 'coif1', 'coif2', 'coif3', 'coif4' y 'coif5'

Utilizando 20 ejemplos de cada tipo de perturbación, como conjunto de entrenamiento, y 10 como conjunto de prueba, el porcentaje de aciertos obtenidos para cada clasificador y cada wavelet se presenta en la tabla 2.

En la tabla 2 se observa que el porcentaje de aciertos no varía sustancialmente con el tipo de wavelet utilizada. Se ve además que el árbol de clasificación (indicado como J48) y el perceptron multicapa (MLP) tuvieron mejor desempeño que los otros clasificadores.

En base a los resultados obtenidos, se adopta la wavelet Db4 como un compromiso entre costo computacional (solo cuatro coeficientes), y precisión.

Como uno de los objetivos de este proyecto es implementar un clasificador de fallas eléctricas en un sistema basado en microcontroladores de costo y tamaño razonable, se plantea un algoritmo en lenguaje “C”, que pueda embeberse en sistemas de este tipo.

Tabla 2: porcentaje de aciertos de los distintos clasificadores utilizados

Wavelet	Porcentaje de Aciertos			
	Naive Bayes	J48	MLP	SVM
db1	80	97.5	100	72.5
db2	80	97.5	95	75
db3	85	97.5	100	75
db4	90	100	100	67.5
db6	80	100	97.5	72.5
db8	90	97.5	90	60
db10	92.5	100	97.5	75
coif1	80	100	97.5	70
coif2	90	100	95	82.5
coif3	90	100	100	80
coif4	90	100	100	70
coif5	90	95	100	65

Los datos de la señal muestreada se encuentran en un arreglo $a[]$, de longitud n . El resultado de la transformación queda en el mismo arreglo $a[]$, en la primera mitad el escalado, y en la segunda la wavelet.

```

void transform( double a[], int n )
{
    if ( n >= 4 ) {
        int i, j;
        int half = n >> 1;

        double tmp[] = new double[n];

        i = 0;
        for (j = 0; j < n-3; j = j + 2) {
            tmp[i] = a[j]*h0 + a[j+1]*h1
                + a[j+2]*h2 + a[j+3]*h3;
            tmp[i+half] = a[j]*g0 + a[j+1]*g1
                + a[j+2]*g2 + a[j+3]*g3;
            i++;
        }

        tmp[i] = a[n-2]*h0 + a[n-1]*h1 +
            a[0]*h2 + a[1]*h3;
        tmp[i+half] = a[n-2]*g0 + a[n-1]*g1 +
            a[0]*g2 + a[1]*g3;

        for (i = 0; i < n; i++) {
            a[i] = tmp[i];
        }
    }
}

```

Luego de aplicar el algoritmo anterior a los datos generados y obteniéndose nuevamente las normas de 10 niveles de detalles como vectores de características de cada señal de prueba, y de realizar una simulación similar con los cuatro clasificadores en “Weka” y se obtiene la siguiente matriz de confusión para cada clasificador:

Algoritmo Db4 en "C"																			
NB				J48					MLP				SVM						
	ST	BT	CO	TR		ST	BT	CO	TR		ST	BT	CO	TR		ST	BT	CO	TR
ST	6	0	0	4	ST	10	0	0	0	ST	10	0	0	0	ST	7	0	0	3
BT	0	7	3	0	BT	0	10	0	0	BT	0	4	6	0	BT	0	0	10	0
CO	0	10	0	0	CO	0	0	10	0	CO	4	6	0	0	CO	4	6	0	0
TR	0	0	0	10	TR	0	0	0	10	TR	0	0	0	10	TR	0	0	0	10

Donde se observa que el árbol de decisión clasifico correctamente el 100% de los casos. Lamentablemente el costo computacional de calcular la DWT con diez niveles de resolución, sigue siendo alto, de modo que se complica su implantación en un sistema que deba realizarlo en tiempo real.

A raíz de esto, se propone una forma alternativa de calcular las características de la señal analizada. Si se observa el algoritmo de cálculo de la DWT presentado, se ve que la señal muestreada a analizar se encuentra en un arreglo a[], de longitud n, y las aproximaciones y detalles que resultan del cálculo quedan contenidas en el mismo arreglo, en la primera mitad las aproximaciones, y en la segunda los detalles.

El método que se propone, consiste en dividir este único arreglo de resultados en 16 intervalos iguales, y calcular la norma de cada uno de ellos, como un elemento del vector de características de la señal.

En la figura 9, se observa una señal de prueba de las generadas, y su descomposición en aproximaciones y detalles como un solo arreglo de datos.

Se han representado además los intervalos donde se calculan las 16 normas con las que se alimenta un árbol de decisión, que es el método de clasificación adoptado para este caso.




Figura 9: Señal de falla simulada y su descomposición mediante DWT.

Los resultados de las pruebas de clasificación se ven en la tabla 3, los que resultan satisfactorios, ya que si se considera a los cortes como una baja tensión extrema, el método propuesto tiene un alto porcentaje de clasificaciones correctas.

Con este método se tiene la ventaja de poder extraer un conjunto de características de la señal, con un solo nivel de descomposición de la DWT, incluso el algoritmo de cálculo puede modificarse para entregar directamente el vector de características, sin necesidad de almacenar los resultados de la DWT, lo que implica una optimización importante en el uso de memoria en el proceso de cálculo.

Tabla 3: Matriz de confusión del método propuesto

Nuevo Método con Árbol de Decisión				
	ST	BT	CO	TR
ST	10	0	0	0
BT	0	7	3	0
CO	0	0	10	0
TR	0	0	0	10

6. CONCLUSIONES

El aumento de anomalías en calidad de potencia en las redes eléctricas, debido a la problemática analizada, (cargas alineales etc.) hace necesario contar con mayor información sobre la calidad de potencia en nuestra zona.

La extracción de las características de las perturbaciones mediante la transformada wavelet de Daubechies Db4, el cálculo de sus normas, y su clasificación mediante árboles de decisión arrojan resultados satisfactorios en la mayoría de los experimentos realizados.

El equipamiento que hasta el momento usan las empresas proveedoras y algunos clientes en nuestro medio, es escaso y costoso. Los métodos analizados y propuestos en este trabajo, podrían contribuir a efectuar medidas en forma frecuente, en tiempo real, y a un costo razonable.

La realización de mediciones y registros de la calidad de potencia en nuestras redes, pueden proporcionar la suficiente casuística de eventos para avanzar sobre futuros métodos para determinar el posible origen del fenómeno.

En este trabajo, se aplican los métodos de caracterización de perturbaciones en calidad de potencia, a señales simuladas. Los algoritmos propuestos funcionan bien con éstas señales, quedando como una propuesta a futuro validarlos con registros de señales reales.

REFERENCIAS

1. BOLLEN Math, GU Irene. *Signal processing of power quality disturbances* IEEE Press, 2006 ISBN 978-0-471-73168-9.
2. IEC Technical Committee 77, Working Group 6 (Secretariat) 110-R5, Classification of Electromagnetic Environments. 1991.
3. ANSI C84.1-1989, *American National Standard for Electric Power Systems and Equipment*. 1989
4. IEEE Std 519-1992, *IEEE Recommended Practices and Requirements for Harmonic Control in Electric Power Systems* (ANSI). 1992
5. BOLLEN, M, STYVAKTAKIS, E, and GU, I. "Categorization and analysis of powersystem transients". IEEE Transactions on Power Delivery, 20(3), 2005, pp 2298–2306.
6. BOLLEN, Math, GU Irene. *Signal processing of power quality disturbances* IEEE Press, 2006 ISBN 978-0-471-73168-9.
7. MITCHELL, Tom. *Machine Learning*. McGraw-Hill 1997. ISBN 978-0071154673.
8. FAUSETT, Laurence *Fundamentals of Neural Networks*. Pearson Education, 2006. ISBN 978-8131700532.
5. UMEZAWA, K. et al. "The Influence of flank deviations on the vibration of a helical gear pair transmitting light load". En actas de International Power Transmission and Gearing Conference, American Society of Mechanical Engineers, 1992, DE-Vol. 43-2, pp. 681-688.
6. ISO. *Synchronous belt drives - Automotive belts*. ISO Standard 9010. ISO/IEC Office. Geneva. Switzerland. 1997.
7. U.S. ISBN Agency. *The Digital World and the Ongoing Development of ISBN* [en línea]. New Providence, N.J.: RR Bowker, s.d. [ref. de 16 de agosto 2002]. Disponible en Web: <http://www.isbn.org/standards/home/isbn/digitalworld.asp>.