

MONITORIZACIÓN NO INTRUSIVA DE CARGAS ELÉCTRICAS MEDIANTE
LA TRANSFORMADA S

HENRY MAURICIO CALA CASTRO

UNIVERSIDAD INDUSTRIAL DE SANTANDER
FACULTAD DE INGENIERÍAS FÍSICO-MECÁNICAS
ESCUELA DE INGENIERÍAS ELÉCTRICA, ELECTRÓNICA Y
TELECOMUNICACIONES
BUCARAMANGA

2014

MONITORIZACIÓN NO INTRUSIVA DE CARGAS ELÉCTRICAS MEDIANTE
LA TRANSFORMADA S

HENRY MAURICIO CALA CASTRO

Trabajo de grado para optar por el título de Ingeniero Electrónico

Director

Ph.D CÉSAR ANTONIO DUARTE GUALDRÓN

Codirectora

Ph.D(c) YULIETH JIMÉNEZ MANJARRÉS

UNIVERSIDAD INDUSTRIAL DE SANTANDER
FACULTAD DE INGENIERÍAS FÍSICO-MECÁNICAS
ESCUELA DE INGENIERÍAS ELÉCTRICA, ELECTRÓNICA Y
TELECOMUNICACIONES
BUCARAMANGA

2014

Tabla de contenido

INTRODUCCIÓN	10
1 Objetivos y alcances del proyecto	12
2 Transformada S	14
2.1 Relación entre la transformada S y la transformada Wavelet	16
2.2 Transformada Discreta S	17
2.3 Autoaliasing	18
3 Extracción de características	23
4 Máquina de soporte vectorial	26
4.1 Transformar la información a valores numéricos.	26
4.2 Escalar los datos.	26
4.3 Seleccionar la función de kernel	27
4.4 Buscar los parámetros adecuados	27
5 Implementación de los algoritmos	29
5.1 Algoritmo de Stockwell	29
5.2 Algoritmo de Stockwell-modificado	31
5.3 Algoritmo basado en la relación entre la transformada S y la transformada Wavelet	33
5.4 Comparación de los tres algoritmos.	34
5.5 Implementación de las máquina de soporte vectorial	39
6 Experimentos y resultados	41
6.1 Base de datos BLUED	41
6.2 Métodos propuestos para eliminar el auto-aliasing	41
6.3 Resultados de clasificación de cargas eléctricas mediante la transformada S	42
7 Conclusiones	47
Referencias	49

Índice de figuras

1	Proyección del consumo de potencia hasta el 2031. Fuente:[8].	10
2	La gráfica en azul es la señal $H[\frac{m}{NT}]$ y la gráfica en rojo es $G(m, n)$. Fuente:autor.	19
3	Diagrama de flujo del algoritmo de Stockwell. Fuente:Autor.	30
4	Diagrama de flujo del algoritmo de Stockwell modificado	32
5	Diagrama de flujo del algoritmo para calcular la transformada S a partir de la transformada Wavelet. Fuente:Autor	34
6	Señal transitoria $h[kT]$ del cambio de estado de un monitor. Fuente:Autor	36
7	Transformada S de la señal transitoria de cambio de estado de un monitor mediante los tres algoritmos propuestos. Fuente:Autor.	37
8	Transformada S de la señal transitoria de cambio de estado de un monitor mediante los tres algoritmos propuestos para $F = 1[kHz]$. Fuente:Autor.	38
9	Diagrama de flujo del algoritmo para la máquina de soporte vectorial. Fuente:autor.	40
10	Señal $h(t) = 1\sin(2\pi(5500t)) + 1\sin(2\pi(1000t))$ muestreada a una frecuencia de $12[kHz]$. Fuente:autor.	42
11	Transformada S de $h(t) = 1\sin(2\pi(5500t)) + 1\sin(2\pi(1000t))$ muestrea- do a una frecuencia de $12[kHz]$. Fuente:Autor.	43

Índice de tablas

1	Comparación de los tres algoritmos	35
2	Electrodomésticos y su numero de señales	42
3	Pruebas con los mejores resultados de precisión en clasificación para cada conjunto de características	44
4	Exactitud en validación cruzada y en clasificación para las nueve pruebas.	44
5	Matriz de confusión prueba 1.	45
6	Matriz de confusión prueba 2.	45
7	Matriz de confusión prueba 3.	45
8	Matriz de confusión prueba 4.	45
9	Matriz de confusión prueba 5.	45
10	Matriz de confusión prueba 6.	46
11	Matriz de confusión prueba 7.	46
12	Matriz de confusión prueba 8.	46
13	Matriz de confusión prueba 9.	46

RESUMEN

TÍTULO:

MONITORIZACIÓN NO INTRUSIVA DE CARGAS ELÉCTRICAS MEDIANTE LA TRANSFORMADA S ¹.

AUTOR:

HENRY MAURICIO CALA CASTRO ²

PALABRAS CLAVE: Transformada S, máquina de soporte vectorial, monitorización no intrusiva de cargas, autoaliasing, Frecuencia de Nyquist, transformada de Fourier, kernel, transformada Wavelet, Frecuencia de muestreo.

DESCRIPCIÓN:

La monitorización no intrusiva de cargas (de sus siglas en inglés NILM) consiste en identificar el consumo individual de potencia de cada electrodoméstico en un hogar con la medida en un solo punto, esto con el fin de identificar la operación individual de los electrodomésticos y generar planes de gestión para regular y controlar el consumo de energía eléctrica. El problema de identificar la operación individual de los electrodomésticos se puede abordar como un problema de clasificación con inteligencia artificial. Para ello se requiere la extracción de características que permitan distinguir los electrodomésticos. En este trabajo la extracción de características está basada en la transformada S, que es una representación tiempo-frecuencia intermedia entre la transformada de Fourier de tiempo reducido y la transformada Wavelet, se emplean combinaciones de características extraídas en el dominio del tiempo y mediante la transformada S para clasificar en búsqueda de la mejor precisión en clasificación. Este documento describe las propiedades e implementación de la transformada S. Así, se calculó la transformada S, para diferentes frecuencias, de señales transitorias originadas por el cambio de estado (encendido, apagado) de diferentes electrodomésticos y se extrajeron varias características para distinguirlos. A partir de las características se generó un clasificador mediante máquinas de soporte vectorial y se evaluó su desempeño. Se consignan los resultados obtenidos para diferentes experimentos donde se analizan las condiciones en las cuales se obtuvieron los mejores resultados en clasificación.

¹Proyecto de Grado.

²Facultad de Ingenierías Físico-Mecánicas. Escuela de Ingenierías Eléctrica Electrónica y Telecomunicaciones. Director: Ph.D César Antonio Duarte Gualdrón. Codirectora: Ph.D(c) Yulieth Jiménez Manjarrés.

ABSTRACT

TITLE:

NONINTRUSIVE LOAD MONITORING USING THE S-TRANSFORM ¹.

AUTHOR:

HENRY MAURICIO CALA CASTRO ²

KEYWORDS: S-transform, support vector machine, nonintrusive load monitoring, autoaliasing, Nyquist frequency, Fourier transform, kernel, Wavelet transform, Sampling rate.

DESCRIPTION:

The nonintrusive load monitoring (NILM) identifies the individual power consumption of each appliance in a home from measurements at a single point, in order to obtain the individual operation of appliances and design management plans to regulate and control the energy consumption. The identification of the individual appliance operation might be approached as a classification problem with artificial intelligence. For that the extraction of characteristics to distinguish the appliances is required. In this project the feature extraction is based on the S transform, a time-frequency representation there is intermediate between the short time Fourier transform and the Wavelet transform.

Characteristics are extracted from time domain and the S-transform searching the combinations which obtain the best accuracy, on this project are described the characteristics implemented, This document describes the properties and implementation of the S-transform. Thus, the S transform is calculated, for different frequencies, of transient signals from the state change (ON/OFF) of the appliances and features are extracted to distinguish them. With the features a classifier is generated through support vector machines and its performance is evaluated. Are describe the experiments where it is analyze the conditions for each case, the conclusions are related with the case with best accuracy.

¹Undergrad project.

²Faculty of Physico-Mechanical Engineering. School of Electrical, Electronics and Telecommunications Engineering. Director: Ph.D César Antonio Duarte Gualdrón. Co-Director: Ph.D(c) Yulieth Jiménez Manjarrés.

INTRODUCCIÓN

La demanda de energía eléctrica aumenta con el crecimiento poblacional y la comercialización de nuevos dispositivos electrónicos. En la figura 1 se observa un crecimiento con tendencia exponencial en la demanda de energía eléctrica para los próximos 15 años, debido a esto es necesario buscar alternativas para suplir la proyección de demanda. Entre las diferentes alternativas propuestas sobresale aumentar la generación de energía eléctrica con nuevas centrales de generación o con el uso de energías alternativas, la cual tiene el inconveniente de necesitar grandes inversiones de capital para crear las nuevas centrales de generación. Otra alternativa planteada consiste en reducir la demanda de energía eléctrica mediante planes de gestión. Para generar los planes de gestión de demanda se necesita obtener información del consumo de los usuarios, la cual puede ser obtenida detalladamente mediante la monitorización de cargas [8], [11].




Figura 1: Proyección del consumo de potencia hasta el 2031. Fuente:[8].

La monitorización de cargas es un proceso para identificar el consumo individual de energía de los electrodomésticos en un hogar, esto con el fin de estudiar las costumbres de consumo de los usuarios y generar planes de gestión

que permitan regular y minimizar el consumo de energía o prevenir fallas en la red eléctrica [11]. Para estimar el consumo de cada electrodoméstico se han desarrollado técnicas de monitorización de cargas, siendo la no intrusiva (NILM del inglés *Nonintrusive load monitoring*), la alternativa más económica en hardware. Es considerada no intrusiva debido a que solo requiere un sensor en el contador principal del hogar, y mediante algoritmos aplicados a los datos, pretende obtener la operación individual de cada electrodoméstico, a diferencia del método intrusivo que requiere sensores en todos los electrodomésticos [8], [2].

Para la monitorización no intrusiva de cargas es necesario obtener características diferenciadoras de cada dispositivo eléctrico para poder diferenciarlos. Se abordó el problema de identificar las cargas a través de sus señales como un problema de clasificación con inteligencia artificial, en donde el rendimiento en la clasificación depende de las características seleccionadas. Para obtener una mejor representación de los datos y facilitar la extracción de características, en este trabajo se utiliza la transformada S, la cual es una representación tiempo-frecuencia de ventana variable con alta resolución en el tiempo para altas frecuencias, y alta resolución en frecuencia para bajas frecuencias [18].

Los resultados obtenidos en este proyecto pueden ser comparados con resultados de clasificación obtenidos con otras transformadas, para deducir la transformación de la información que permita obtener la exactitud de clasificación mas alta para la implementación de un sistema real NILM.

El resto del artículo está estructurado de la siguiente forma: la sección 2 presenta la descripción de la transformada S, se discuten la transformada continua, discreta y el fenómeno del autoaliasing. En las secciones 3 y 4 se describen las características extraídas de señales transitorias de corriente correspondientes al cambio de estado de diferentes electrodomésticos y la máquina de soporte vectorial. La sección 5 describe los algoritmos empleados para implementar de la transformada S y finalmente en las secciones 6 y 7 se discute los experimentos realizados y los resultados y conclusiones obtenidos.

1. Objetivos y alcances del proyecto

Con el incremento en el consumo de energía eléctrica las empresas generadoras deben estar preparadas para suplir la energía necesaria o para buscar alternativas que permitan controlar los picos de consumo, ya que estos pueden generar fallos en las redes eléctricas. Cabe destacar la dependencia del ser humano energía eléctrica, por lo que fallas o apagones generan inconformidad, daños en los equipos eléctricos y accidentes que pueden llegar a ser fatales [11].

Como alternativa para estudiar del consumo de energía eléctrica se a propuesto la monitorización de cargas. Para realizar la monitorización de cargas existen dos alternativas, intrusiva y no intrusivamente, siendo la no intrusiva la forma más económica pero a la vez la más compleja de implementar debido a que solo requiere conexiones en un punto de la casa y mediante estas mediciones el sistema debe reconocer los electrodomésticos funcionando [11]. En la monitorización no intrusiva de cargas se genera un clasificador que identifica los electrodomésticos funcionando a partir de sus señales de naturaleza transitoria o de estado estable. Para poder realizar la labor de clasificación es necesario encontrar características que diferencien un dispositivo de otro. Se pueden emplear transformadas para obtener una mejor representación de la información y facilitar la extracción de las características mencionadas anteriormente, en este proyecto se buscó analizar el desempeño de la transformada S en la extracción de características.

Cabe destacar que se abordó el problema de identificar las cargas a través de sus señales como un problema de clasificación con inteligencia artificial.

En este trabajo de grado se realizó un estudio sobre las definiciones de la transformada S, el anterior estudio partió de la revisión de la literatura y publicaciones internacionales. Se obtuvo las transformadas S de un conjunto de señales transitorias de corriente del cambio de estado de electrodomésticos, las señales de corriente fueron obtenidas de la base de datos BLUED de libre de acceso. Se implementó la transformadas S para diferentes conjuntos de frecuencia y se extrajeron características con el fin de probar diferentes combinaciones en búsqueda de obtener la mayor exactitud posible en clasificación.

En la ejecución de este proyecto se utilizó máquinas de soporte vectorial para resolver el problema de clasificación.

El objetivo de este proyecto fue Analizar el desempeño de la transformada S para la monitorización no intrusiva de cargas eléctricas. El cual comprende el cumplimiento de:

1. Implementar un algoritmo para encontrar la transformada S de señales eléctricas.
2. Seleccionar las características de cargas para diferenciar una carga de otra.
3. Realizar la clasificación de cargas empleando un algoritmo de inteligencia artificial y medir su rendimiento. encontrar la transformada S de señales eléctricas.

2. Transformada S

La transformada S de una señal $h(t)$ está definida por [12]:

$$S(\tau, f) = \int_{-\infty}^{\infty} h(t) \frac{|f|}{\sqrt{2\pi}} e^{-\frac{(\tau-t)^2 f^2}{2}} e^{-i2\pi f t} dt, \quad (1)$$

en donde f es la frecuencia y τ es la localización espectral en el tiempo. La integral descrita en (1) se puede reescribir como la convolucion de dos señales [18], [12].

$$p(\tau, f) = h(\tau) e^{-i2\pi f \tau} \quad (2)$$

$$g_f(\tau) = \frac{|f|}{\sqrt{2\pi}} e^{-\frac{\tau^2 f^2}{2}} \quad (3)$$

$$S(\tau, f) = p(\tau, f) \star g_f(\tau) \quad (4)$$

donde \star denota la operación de convolución. La señal $g_f(\tau)$ es una ventana Gaussiana escalable que se comprime o expande en función de la frecuencia y es deslizante en el dominio del tiempo. Debido a estas propiedades la transformada S ofrece alta resolución en el tiempo para altas frecuencias y alta resolución en frecuencia para bajas frecuencias [12].

Aplicando la propiedad de convolucion de la transformada de Fourier se puede expresar la transformada $S(\tau, f)$ como el producto de las transformadas de $g_f(\tau)$ y $p(\tau, f)$ [18]:

$$S(\alpha, f) = P(\alpha, f) G_f(\alpha) \quad (5)$$

Sea $H(\alpha)$ la transformada de Fourier de la señal $h(t)$. Por la propiedad de traslación en frecuencia de la transformada de Fourier se tiene:

$$P(\alpha, f) = H(\alpha + f) \quad (6)$$

La transformada de Fourier de $g_f(\tau)$ es también una ventana Gaussiana y esta

dada por :

$$G_f(\alpha) = e^{\frac{-2\pi^2\alpha^2}{f^2}} \quad (7)$$

Reemplazando en (5), se tiene:

$$S_f(\alpha) = H(\alpha + f)e^{\frac{-2\pi^2\alpha^2}{f^2}} \quad (8)$$

Ahora se calcula la transformada inversa de Fourier de $S_f(\alpha)$ para obtener la relación entre la transformada S y la transformada de Fourier de la señal $h(t)$ [18]:

$$S_f(\tau) = \int_{-\infty}^{\infty} H(\alpha + f)e^{\frac{-2\pi^2\alpha^2}{f^2}} e^{i2\pi\alpha\tau} d\alpha \quad (9)$$

Por otro lado, la transformada de Fourier de $S_f(\tau)$ esta dada por:

$$S_f(\alpha) = \int_{-\infty}^{\infty} S(\tau, f)e^{-i2\pi\alpha\tau} d\tau \quad (10)$$

Igualando (10) y (8) se obtiene:

$$\int_{-\infty}^{\infty} S(\tau, f)e^{-i2\pi\alpha\tau} d\tau = H(\alpha + f)e^{\frac{-2\pi^2\alpha^2}{f^2}} \quad (11)$$

Para obtener la inversa de la transformada S continua , se puede partir de la relación en (8) centrado el análisis en $\alpha = 0$ [12]. con esto se llega a la expresión:

$$\int_{-\infty}^{\infty} S(\tau, f)d\tau = H(f) \quad (12)$$

Aplicando la transformada inversa de Fourier en la ecuación (12) se llega a la definición de la transformada Inversa continua S. [12].

$$\int_{-\infty}^{\infty} \left[\int_{-\infty}^{\infty} S(\tau, f)d\tau \right] e^{i2\pi ft} df = h(t) \quad (13)$$

Esto indica que se puede recuperar la señal $h(t)$ a partir de su transformada S.

2.1. Relación entre la transformada S y la transformada Wavelet

La transformada Wavelet para una señal $h(t)$ está dada por [7]:

$$W(\tau, d) = \int_{-\infty}^{\infty} h(t) \frac{1}{\sqrt{d}} \psi^*\left(\frac{t-\tau}{d}\right) dt \quad (14)$$

Donde *significa conjugada, $\psi(t)$ es la madre wavelet y d es el factor de escala el cual es equivalente al inverso de la frecuencia f . Se define la madre Wavelet como:

$$\psi(t) = \frac{1}{\sqrt{2\pi}} e^{-\frac{t^2}{2}} e^{i2\pi t} \quad (15)$$

La cual se comprime o expande por un factor de $\frac{1}{d}$ y se traslada en el tiempo para obtener:

$$\psi^*\left(\frac{t-\tau}{d}\right) = \frac{1}{\sqrt{2\pi}} e^{-\frac{(\tau-t)^2}{2d^2}} e^{-i2\pi\frac{(t-\tau)}{d}} \quad (16)$$

Se puede reescribir (16) en términos de f en lugar de d [12].

$$\psi^*(t-\tau, f) = \frac{1}{\sqrt{2\pi}} e^{-\frac{(\tau-t)^2 f^2}{2}} e^{-i2\pi f t} e^{i2\pi f \tau} \quad (17)$$

Reemplazando en (14) se obtiene:

$$W(\tau, f) = \int_{-\infty}^{\infty} h(t) \frac{\sqrt{f}}{\sqrt{2\pi}} e^{-\frac{(\tau-t)^2 f^2}{2}} e^{-i2\pi f t} e^{i2\pi f \tau} dt \quad (18)$$

Comparando (1) y (18), se tiene que la relación entre la transformada Wavelet y la transformada S es:

$$S(\tau, f) = \sqrt{f} e^{-i2\pi f \tau} W(\tau, f) \quad (19)$$

Gracias a esta relación se puede obtener la matriz S a partir de la transformada Wavelet multiplicada por un factor de fase y amplitud. La expresión anterior es diferente a la relación dada en [18] debido a que para poder implementarla en Matlab se utilizó una definición diferente para la madre Wavelet.

2.2. Transformada Discreta S

Sea $H[kT]$, $k = 0, 1, \dots, N - 1$, la señal discreta proveniente de muestrear $h(t)$ con un periodo de muestreo T . La transformada discreta S se obtiene a partir de la definición continua de la transformada S, es decir, la integral en (9) se aproxima mediante la regla del rectángulo para obtener la transformada discreta S de la señal $h[kT]$ [12]:

$$S \left[jT, \frac{n}{NT} \right] = \sum_{m=0}^{N-1} H \left[\frac{m+n}{NT} \right] e^{-\frac{2\pi^2 m^2}{n^2}} e^{\frac{i2\pi mj}{N}} \quad (20)$$

Donde la frecuencia f es equivalente a $\frac{n}{NT}$, N es el número de muestras, el tiempo τ se discretiza en jT y la transformada de Fourier $H(\alpha)$ de la señal $h(\tau)$ es equivalente a $H[\frac{m}{NT}]$ [12].

Para obtener la transformada inversa discreta es necesario realizar una sumatoria en ambos lados de la igualdad en términos de j [18].

$$\sum_{j=0}^{N-1} S \left[jT, \frac{n}{NT} \right] = \sum_{j=0}^{N-1} \sum_{m=0}^{N-1} H \left[\frac{m+n}{NT} \right] e^{-\frac{2\pi^2 m^2}{n^2}} e^{\frac{i2\pi mj}{N}} \quad (21)$$

en donde

$$G(m, n) = e^{-\frac{2\pi^2 m^2}{n^2}} \quad (22)$$

Por propiedades de sumatorias se pueden separar las sumatorias.

$$\sum_{j=0}^{N-1} S \left[jT, \frac{n}{NT} \right] = \sum_{m=0}^{N-1} H \left[\frac{m+n}{NT} \right] e^{-\frac{2\pi^2 m^2}{n^2}} \sum_{j=0}^{N-1} e^{\frac{i2\pi mj}{N}} \quad (23)$$

La expresión $\sum_{j=0}^{N-1} e^{\frac{i2\pi mj}{N}}$ es 0 para todos los valores de m , excepto cuando $m = 0$, para este caso la suma es igual a N [18].

$$\sum_{j=0}^{N-1} S \left[jT, \frac{n}{NT} \right] = NH \left[\frac{n}{NT} \right] \quad (24)$$

Dividiendo N en ambos lados de la igualdad se obtiene una relacion entre la transformada discreta S y la transformada discreta de Fourier de la señal $h[kT]$:

$$\frac{1}{N} \sum_{j=0}^{N-1} S \left[jT, \frac{n}{NT} \right] = H \left[\frac{n}{NT} \right] \quad (25)$$

¹se denota $i = \sqrt{-1}$. asi j no es la constante imaginaria.

Para recuperar la señal original se puede aplicar la transformada inversa de Fourier [18]:

$$\sum_{n=0}^{N-1} \left[\frac{1}{N} \sum_{j=0}^{N-1} S \left[jT, \frac{n}{NT} \right] e^{\frac{i2\pi nkj}{N}} \right] = h[kT] \quad (26)$$

La expresión dada en (26) sugiere que se puede recuperar las muestras $h[kT]$ conociendo únicamente la matriz de la transformada S discreta.

2.3. Autoaliasing

Cuando se muestrea la señal $h(t)$ se obtiene la señal $h[kT]$. El efecto del muestreo en el dominio de la frecuencia produce que la transformada de Fourier de $h[kT]$ se conforme de copias periódicamente repetidas de la transformada de Fourier de $h(t)$ [3]. Además el espectro de la ventana Gaussiana es otra ventana Gaussiana de duración infinita, por lo cual el espectro se extiende por todo el rango de frecuencias. Entonces se produce un traslape de la ventana gaussiana de duración infinita con las frecuencias negativas de la señal $h[kT]$ [12], que se conoce como autoaliasing. En la figura 2a se ilustra este fenómeno, en donde la región sombreada indica el traslape de la ventana Gaussiana con las frecuencias negativas de $h[kT]$. El autoaliasing se presenta cuando la frecuencia de la transformada S se aproxima a la frecuencia de Nyquist, o cuando la ventana Gaussiana se hace muy ancha en altas frecuencias

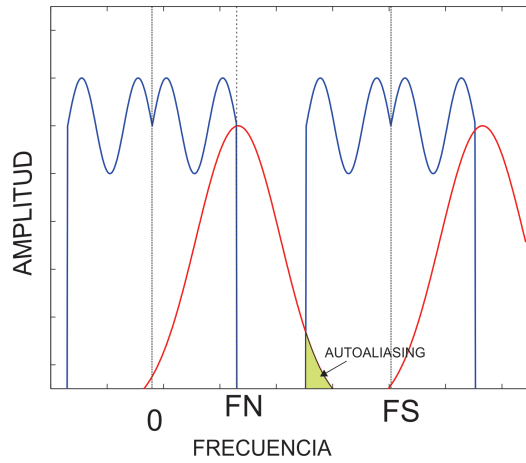
El autoaliasing genera distorsión en alta frecuencia o en las proximidades de la frecuencia de Nyquist y la información contenida en esta región de la transformada S se pierde. Puede producir valores de magnitud elevados. Una gran variedad de características empleadas para clasificar los equipos dependen de las amplitudes máximas y de sus variaciones en el plano tiempo-frecuencia como se explicara mas adelante. Debido a esto realizar la extracción de características sin minimizar los efectos del autoaliasing puede producir valores de características erróneas.

Se propusieron tres alternativas para minimizar los efectos del autoaliasing:

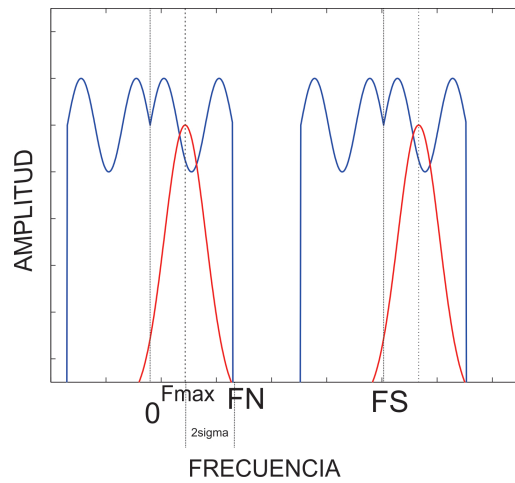
1- Calcular la señal analítica. Considérese $h(t)$ una señal real con transformada

Figura 2: La gráfica en azul es la señal $H[\frac{m}{NT}]$ y la gráfica en rojo es $G(m, n)$.
Fuente:autor.


(a) Autoaliasing cuando la ventana Gaussiana esta centrada a una frecuencia cercana a la de Nyquist.



(b) Relación entre la frecuencia de Nyquist y la frecuencia máxima sugerida.



(c) Relación entre la frecuencia de Nyquist y la frecuencia especial de Nyquist.



de Fourier $H(f)$. Se define la función $H_a(f)$ como:

$$H_a(f) = H(f) + H(f) \cdot \text{sgn}(f) \quad (27)$$

en donde $\text{sgn}(f)$ es la función signo, se observa que $H_a(f)$ es 0 para $f < 0$ y $2H(f)$ para $f > 0$, por lo que $H_a(f)$ solo contiene las frecuencias positivas de $h(t)$. Calculando la transformada inversa de Fourier se tiene:

$$h_a(t) = h(t) + i \left[h(t) * \frac{1}{\pi t} \right] \quad (28)$$

$$\hat{h}(t) = h(t) * \frac{1}{\pi t} \quad (29)$$

En donde $*$ denota la operación de convolución, $\hat{h}(t)$ es la transformada Hilbert de $h(t)$ y $h_a(t)$ es la señal analítica de $h(t)$ [16].

Debido a la simetría del espectro $H(f)$ se puede eliminar las frecuencias negativas mediante el cálculo de la señal analítica sin perder información en la señal. El autoliasing se presenta por el traslape entre la ventana Gaussiana y las frecuencias negativas del espectro de la señal $h[kT]$ (ver figura 2a). Se propone obtener la señal analítica de $h[kT]$ para eliminar las frecuencias negativas de la señal y evitar el traslape con el espectro de la ventana Gaussiana de duración infinita. [12].

2- Limitar la frecuencia de análisis de la transformada S a una frecuencia máxima (F_{max}) de tal forma que la ventana Gaussiana no se superponga con las frecuencias negativas del espectro la señal $h[kT]$ (ver figura 2b). Al centrar la ventana Gaussiana en F_{max} la ventana se debe extender como máximo hasta la frecuencia de Nyquist para evitar el autoaliasing, esto es 2σ puntos desde el centro de la distribución, siendo σ la desviación estándar de la ventana Gaussiana. De (30), se tiene que la desviación estándar está dada por (31).

$$G(m, n) = e^{-\frac{m^2}{2(\frac{n}{2\pi})^2}} \quad (30)$$

$$\sigma = \frac{n}{2\pi} \quad (31)$$

La frecuencia de Nyquist (F_N) se relaciona con la frecuencia máxima (F_{max}) de la siguiente forma [12]:

$$F_{max} + 2\sigma = F_N \quad (32)$$

Al estar centrada la ventana Gaussiana en F_{max} se tiene:

$$F_{max} = n \quad (33)$$

Reemplazando (31) y (33) en (32) se tiene:

$$F_{max} + 2\frac{F_{max}}{2\pi} = F_N \quad (34)$$

Resolviendo para F_{max} :

$$F_{max} = \frac{\pi F_N}{\pi + 1} \quad (35)$$

Por consiguiente la frecuencia máxima a analizar en la transformada S sería $0,758F_N$.

3- Definir una nueva frecuencia especial de Nyquist llamada S_N . En el peor escenario posible, la función gaussiana estará centrada en la frecuencia de Nyquist (ver figura 2c), considerando que la función se extiende 2σ puntos desde su centro. Por lo tanto, se obtiene una relación entre la nueva frecuencia especial de Nyquist S_N y la frecuencia de Nyquist F_N . Se debe considerar que la nueva frecuencia de muestreo F_S es $2S_N$ [18].

$$F_N + 2\sigma = S_N, \quad (36)$$

donde

$$\sigma = \frac{F_N}{2\pi} \quad (37)$$

Reemplazando (36) en (37) y simplificando se obtiene:

$$\frac{(\pi + 1)F_N}{\pi} = S_N \quad (38)$$

En donde:

$$S_N = \frac{F_S}{2} \quad (39)$$

Reemplazando (39) en (38) y resolviendo para F_S se tiene:

$$\frac{2(\pi + 1)F_N}{\pi} = F_S \quad (40)$$

En donde (38) muestra que la frecuencia especial de Nyquist es $1,31F_N$ por lo que la nueva frecuencia de muestreo es $2,62F_N$.

3. Extracción de características

Para realizar la clasificación de los dispositivos eléctricos es necesario extraer características que permitan diferenciar un dispositivo de otro. Se tienen señales transitorias del cambio de estado de diferentes tipos de electrodomésticos. La extracción de características está enfocada en la obtención del mayor porcentaje de exactitud en clasificación. Una forma es extraer diferentes características de las señales para formar un vector de características y probar diferentes combinaciones de estas [18]. A continuación se describen las características extraídas.

1. Extracción de los puntos máximos: Los puntos máximos de una función de dos variables son el set de curvas cuyos puntos son máximos locales en al menos una dimensión. Contienen información geométrica importante de la señal, indican las regiones donde están los puntos más elevados de energía, así mismo como las regiones en donde la amplitud cambia de gradiente. En señales transitorias la amplitud de la señal aumenta hasta un valor pico, y luego decrece hasta llegar a la estabilidad. Mediante la obtención de los puntos máximos se puede detectar dichas variaciones bruscas de energía para caracterizar el patrón de la señal. El contorno de fase es decir la fase de cada valor máximo en el tiempo también fue considerado para la clasificación de cargas eléctricas. Para realizar la extracción de características se pueden utilizar técnicas estadísticas estándares, por lo que se utilizó desviación estándar para medir la dispersión tanto en los puntos máximos como en el contorno de fase [14].
2. Energía: las señales transitorias contienen altas cantidades de energía, las cuales varían según el electrodoméstico. Considerando esto, la energía de las señales transitorias es extraída como una característica para clasificar.

$$Energia = \sum_{-\infty}^{\infty} |h[kT]|^2 \quad (41)$$

3. Factor de cresta: el factor de cresta se define como la relación entre el valor pico y el valor eficaz de una señal. En señales transitorias el factor de cresta permite diferenciar los electrodomésticos con valores picos muy elevados en

relación con su valor eficaz.

4. Duración de la señal: la duración de la señal sirve para distinguir transitorios de corta y larga duración.

La transformada S puede ser considerada como:

$$S_{n,j} = A_{n,j}e^{i\phi_{n,j}}, \quad (42)$$

En donde A es la magnitud y ϕ es la fase. Las características anteriores se calcularon con las siguientes expresiones [10]:

Característica 1: Se calculó la desviación estándar del conjunto correspondiente a la magnitud máxima de cada columna.

$$C_1 = std \{max(A_{n,j} \ j = 0, 1, 2...N - 1)\} \quad (43)$$

Característica 2: Se calculó la energía del vector comprendido por la magnitud máxima de cada columna, elevando al cuadrado cada posición de este vector, y realizando la sumatoria de estos términos [10].

$$C_2 = \sum_{j=0}^{N-1} |max(A_{n,j})|^2 \quad (44)$$

Característica 3: Se calculó la desviación estándar del vector comprendido por la magnitud máxima de cada fila, Considérese M el numero total de filas de la matriz de la transformada S [10]:

$$C_3 = std \{max(A_{n,j} \ n = 0, 1, 2...M - 1)\} \quad (45)$$

Característica 4: se calculó la desviación estándar del vector de contorno de fase.

$$C_4 = std \{\phi_{n,j} \ max(A_{n,j} \ j = 0, 1, 2...N - 1)\} \quad (46)$$

Característica 5: Se obtuvo el factor de cresta dado por [10]:

$$C_5 = \frac{Vp}{V_{eficaz}} \quad (47)$$

Característica 6: se calculó la longitud del vector de la señal $h[kT]$, el cual es proporcional a la duración de la señal [10].

$$C_6 = N \quad (48)$$

4. Máquina de soporte vectorial

La máquina de soporte vectorial es una técnica para la clasificación de datos. Esta consiste en producir un modelo a partir de una serie de características de un conjunto de entrenamiento y sus respectivas clases. Generalmente para NILM las clases son los cambios de estado de los electrodomésticos (encendido, apagado); en este proyecto se consideraron como clases los electrodomésticos en análisis que es la información disponible en la base de datos[5]. Se considera lenguaje supervisado porque las clases son conocidas *a priori* y la máquina puede verificar la exactitud de sus predicciones con los valores conocidos [15]. La máquina de soporte vectorial construye un plano o un hiperplano en un espacio de dimensionalidad alta (puede ser infinito) de tal forma que la distancia entre clases sea la máxima. Para mapear a una dimensión superior se emplean funciones de kernel [5].

Para obtener mejores resultados de clasificación en la máquina de soporte vectorial, se recomienda realizar el siguiente procedimiento.

4.1. Transformar la información a valores numéricos.

La máquina de soporte vectorial, requiere que cada etiqueta sea representada con un vector de números reales. En problemas donde las características de las etiquetas son atributos cualitativos es necesario cuantificarlos, se puede emplear m números para representar m categorías. Por ejemplo, en un problema de tres categorías alto, bajo y mediano, se puede representar el vector como (alto, bajo mediano). A continuación se representa el vector con valores numéricos como (1,0,0) cuando es alto, (0,1,0) cuando es bajo y (0,0,1) cuando es mediano. Básicamente se representa la presencia de un atributo con 1, y 0 la carencia del mismo [5], [4].

4.2. Escalar los datos.

El objetivo del escalamiento es evitar que aquellas características con valores numéricos muy elevados predominen sobre características de rango de valores

más pequeños. Además de esto, grandes valores en los atributos pueden causar problemas numéricos debido a que internamente se ejecuta el producto punto entre los vectores. Es recomendado escalar cada atributo en rangos entre $[-1, 1]$, o $[0,1]$ [5].

4.3. Seleccionar la función de kernel

Entre las funciones básicas de kernel se encuentran:

1. Lineal: $K(x_i, x_j) = x_i^T x_j$
2. Polinomial: $K(x_i, x_j) = (\gamma x_i^T x_j + r)^d, \gamma > 0$
3. Función de base radial: $K(x_i, x_j) = e^{-\gamma |x_i - x_j|^2}, \gamma > 0$
4. Sigmoideo: $K(x_i, x_j) = \tanh(\gamma x_i^T x_j + r)$.

en donde r , d y γ son parámetros de kernel

Para iniciar un estudio se recomienda usar la función de base radial debido a que puede manejar problemas en donde la relación entre las características es no lineal. Además tiene un parámetro menos de ajuste que las funciones polinomial y sigmoidea por lo que su implementación es menos compleja, considerando esto para el desarrollo de este proyecto se utilizó la función de Kernel de base radial [5].

4.4. Buscar los parámetros adecuados

Para implementar la máquina de soporte vectorial con función de kernel de base radial, es necesario seleccionar los parámetros C y γ . C es un parámetro asociado con el error en el problema de optimización resuelto por la máquina de soporte vectorial, y γ una constante de la función de kernel. Es necesario realizar una selección de parámetros de tal forma que el clasificador obtenga la mayor exactitud posible con los C y γ seleccionados [5]. Considerando esto se recomienda realizar una red de búsqueda de los parámetros C y γ . Varias

combinaciones de C y γ son utilizados para generar modelos, al final se selecciona la combinación que haya generado un mayor porcentaje de exactitud como resultado en la validación cruzada. Se ha mostrado que secuencias crecientes exponencialmente para C y γ puede encontrar un buen set de parámetros. Finalmente con el C y el γ que ofrezca la mejor exactitud se genera el modelo [5].

La validación cruzada consiste en dividir los datos en v conjuntos. Se remueve un conjunto de los datos y se calcula el modelo del clasificador con $v - 1$ conjuntos, consecuentemente se prueba con el conjunto removido, por lo que cada conjunto de datos es probado en una sola ocasión. Se obtiene la exactitud de clasificación en validación cruzada, la cual consiste en el porcentaje de aciertos en la clasificación. La validación cruzada puede evitar problemas de sobreajuste del conjunto de entrenamiento con el modelo, que consiste en que el modelo de clasificación memoriza el conjunto de entrenamiento, por lo que el clasificador tendrá un menor rendimiento ante datos desconocidos.

5. Implementación de los algoritmos

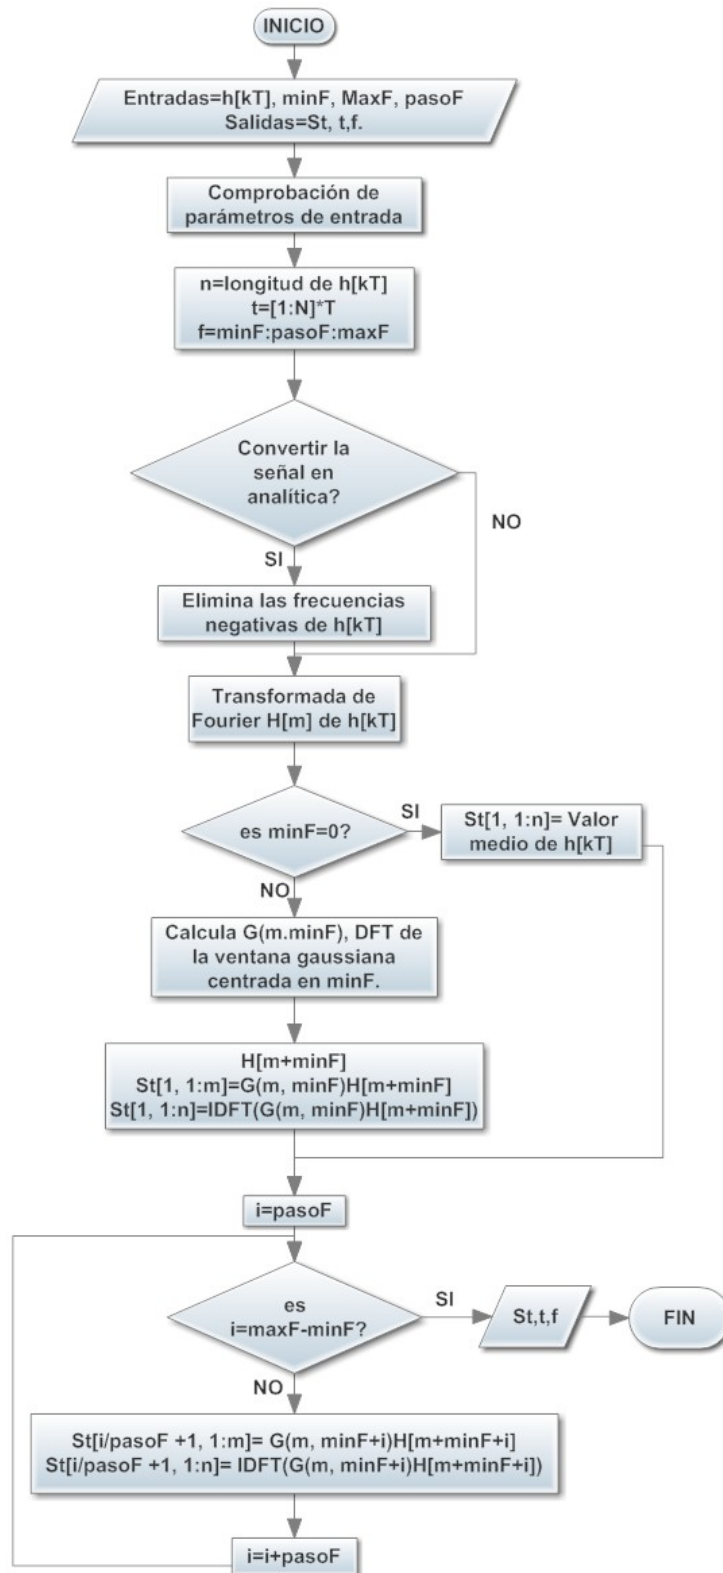
En la literatura internacional se encontró un algoritmo propuesto por Stockwell para implementar la transformada S. Se propusieron dos algoritmos para abordar el problema de la extracción de características cuando el eje de frecuencia esta en forma logarítmica o en escalas.

5.1. Algoritmo de Stockwell

Para implementar la transformada S discreta descrita en (20), se utilizó el algoritmo creado por Robert Glenn Stockwell [13], el cual aprovecha la transformada rápida de Fourier y el teorema de convolucion. Se puede describir el algoritmo en los siguientes pasos.

1. Ingreso de parámetros. Requiere la señal en el tiempo $h(t)$, y opcionalmente se pueden ingresar la frecuencia mínima y máxima, el periodo de muestreo y el paso de frecuencia. Como parámetros de salida se tiene la matriz con la transformada S, el vector tiempo y frecuencia.
2. Comprobación de parámetros para verificar si los parámetros de entrada fueron ingresados correctamente.
3. Generación del vector tiempo, el cual consiste en el número de muestras multiplicadas por el periodo de muestreo.
4. Generación del vector frecuencia, el cual comprende desde la frecuencia mínima hasta la máxima con un paso de frecuencia dado.
5. Si se desea obtener la señal analítica de $h[kT]$ se eliminan sus frecuencias negativas. De lo contrario no se realiza ninguna modificación a $h[kT]$
6. Obtención la transformada rápida de Fourier, $H[m]$ de la señal $h[kT]$.
7. Verificación de la frecuencia mínima. Si la frecuencia mínima es cero se calcula el valor medio de la señal $h[kT]$, y se rellena la primera fila de la matriz de la transformada S con este valor. Se salta al paso 12 posteriormente
8. Si la frecuencia mínima es diferente de cero, se calcula el espectro $G_n(m)$ centrado en la frecuencia mínima n que es la transformada de Fourier de la ventana Gaussiana.

Figura 3: Diagrama de flujo del algoritmo de Stockwell. Fuente: Autor.



9. Desplazamiento en n posiciones del vector $H[m]$ para obtener $H[m + n]$.

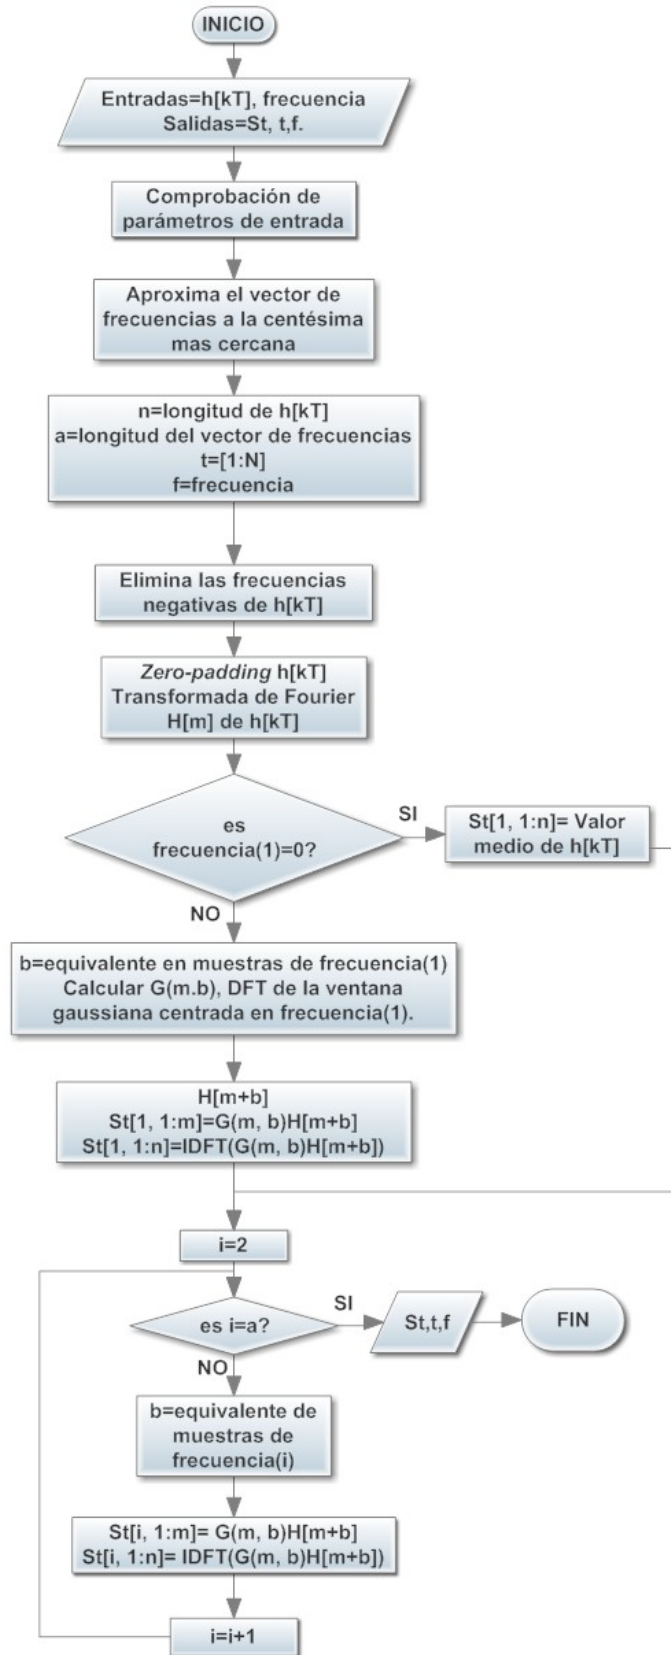
10. Multiplicación del espectro $G(m, n)$ centrado en la frecuencia mínima con $H[m + n]$.
11. Relleno de la primera fila de la matriz de la transformada S, con la transformada inversa de Fourier del producto mencionado en el paso 10.
12. Se Repiten los pasos 8, 9, 10 y 11 para cada valor de frecuencia hasta rellenar todas las filas de la matriz de la transformada S.

5.2. Algoritmo de Stockwell-modificado

Para calcular la transformada S sobre un eje logarítmico de frecuencias, es necesario un algoritmo que permita pasos de frecuencia de 0.01 [Hz] aproximadamente. Debido a que el paso de frecuencia entre muestras en el algoritmo de Stockwell está limitado a $\frac{F_s}{N}$, se modificó dicho algoritmo para obtener un paso de frecuencias menor. Se realizó interpolación en frecuencia mediante *zero-padding* en el dominio del tiempo para obtener un espectro de la señal muestreado a una frecuencia mayor. De esta manera se logró una distancia frecuencial entre muestras aproximadamente de 0.01 [Hz]. El algoritmo se describe en los siguientes pasos:

1. Ingreso de parámetros, requiere la señal $h[kT]$ y el vector de frecuencias. Los parámetros de salida son la matriz de la transformada S, el vector de tiempo y frecuencia.
2. Comprobación de parámetros para verificar si los parámetros de entrada fueron ingresados correctamente.
3. Aproximación de cada frecuencia del vector de frecuencias a su centésima más cercana.
4. Cálculo del vector tiempo, el cual es igual al vector de muestras.
5. Obtención la señal analítica $h[kT]$ eliminando las frecuencias negativas de esta.
6. Realización de *zero-padding* en el dominio del tiempo, hasta obtener un paso de frecuencia entre muestras aproximado de 0.01 [Hz].
7. Obtención de la transformada rápida de Fourier $H[m]$ de la señal $h[kT]$ con *zero-padding*.

Figura 4: Diagrama de flujo del algoritmo de Stockwell modificado



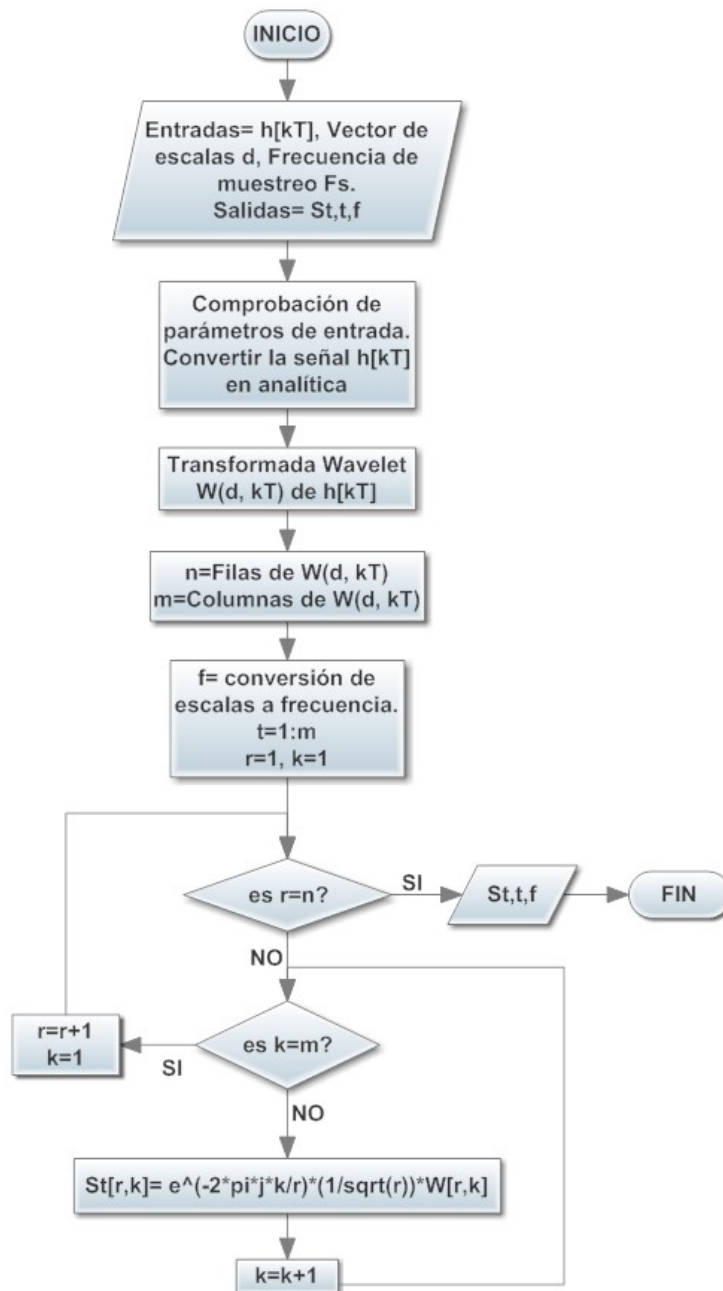
8. Verificación de la frecuencia mínima. Si es cero, se calcula el valor medio de $h[kT]$, y se rellena la primera fila de la matriz de la transformada S con este valor.
9. Si la frecuencia mínima es diferente de cero, se calcula el equivalente en muestras de la frecuencia mínima denotada por n .
10. Cálculo del espectro de la ventana Gaussiana $G(m, n)$ centrado en n .
11. Desplazamiento en n posiciones del vector $H[m]$ para obtener $H[m + n]$.
12. Se multiplica $G(m, n)$ centrado en n con $H[m + n]$.
13. Se rellena la primera fila de la matriz de la transformada S, con la transformada inversa del producto mencionado anteriormente.
14. Se repiten los pasos 9, 10, 11, 12 y 13 para cada valor de frecuencia dado, hasta rellenar las filas de la matriz de la transformada S.

5.3. Algoritmo basado en la relación entre la transformada S y la transformada Wavelet

Se utilizó la relación entre la transformada S y la transformada Wavelet descrita en (19) para implementar la transformada S empleando la Wavelet toolbox de Matlab. El algoritmo es descrito a continuación.

1. Ingreso de una nueva madre wavelet de acuerdo a (15).
2. Ingreso de parámetros de entrada. Los parámetros de entrada son la señal $h(t)$, el vector de escalas y la frecuencia de muestreo. Los parámetros de salida son la matriz de la transformada S, el vector tiempo y frecuencia.
3. Conversión de la señal $h(t)$ en analítica, eliminando las frecuencias negativas para prevenir el autoaliasing.
4. Cálculo de la transformada Wavelet de la señal $h(t)$ para el rango de escalas dado, con la madre wavelet agregada en el paso 1.
5. Transformación del vector de escalas a frecuencias para generar el vector de frecuencias
6. Cálculo del vector tiempo, el cual es proporcional al número de muestras.
7. Multiplicación de la matriz obtenida con la transformada wavelet por el factor $\sqrt{f}e^{-j2\pi f\tau}$ (ver (15)) para obtener la matriz de la transformada S.

Figura 5: Diagrama de flujo del algoritmo para calcular la transformada S a partir de la transformada Wavelet. Fuente:Autor



5.4. Comparación de los tres algoritmos.

La tabla 1 compara los tres algoritmos empleados para calcular la transformada S. Se obtuvo la transformada S de cinco señales transitorias de corriente del cambio de estado de un monitor para medir el promedio del tiempo de implementación.

Tabla 1: Comparación de los tres algoritmos

Algoritmo	Stockwell	R. Wavelet	Stockwell Modif.
Tiempo(s) promedio	0,512 0,0213 0,0007 0,0204 0,0208	0,2320 0,3000 0,1595 0,3104 0,2765	17,51 13,85 13,85 14,00 14,05
Limitaciones	Inflexibilidad debido al paso de frecuencia entre muestras de $\frac{F_s}{N}$.	Parámetro de entrada en escalas. Es necesario identificar las escalas para las frecuencias deseadas	Tiempos elevados para calcular la transformada S.
Implementación	Transformada discreta. S	Convolucion.	Transformada discreta S.

En el algoritmo de Stockwell las frecuencias ingresadas están dadas en muestras. Por ejemplo, si se ingresa una frecuencia mínima igual a 10, es necesario calcular la relación entre las 10 muestras y la frecuencia real. La relación entre la frecuencia real y la frecuencia en muestras es:

$$F_{real} = F_{muestras} \cdot \frac{F_s}{N} \quad (49)$$

Debido a esto las frecuencias de análisis en la transformada S están limitadas a ser múltiplos de $\frac{F_s}{N}$, siendo F_s la frecuencia de muestreo y N el número total de muestras.


El algoritmo de Stockwell modificado tiene un paso de frecuencia entre muestras de aproximadamente $0,01[Hz]$. Esta modificación tiene la finalidad de permitir una mayor flexibilidad en la selección de frecuencias de análisis para la transformada S. Este algoritmo es mucho más lento en su ejecución en comparación con el algoritmo de Stockwell original, debido a que se ejecuta con más puntos de la transformada de Fourier.

Para implementar la transformada Wavelet empleando las herramientas de MATLAB, es necesario el ingreso de las escalas en análisis. Debido a esto, el algoritmo que calcula la transformada S empleando la relación con la transformada Wavelet tiene como parámetro de entrada las escalas, en donde la escala es inversamente proporcional a la frecuencia. El algoritmo que calcula la transformada S empleando la relación con la transformada Wavelet es más lento también que el algoritmo de Stockwell, esto se debe a que el algoritmo

de Stockwell aprovecha la velocidad de la transformada rápida de Fourier, en cambio el otro resuelve la integral de convolución. Sin embargo, el algoritmo de Stockwell modificado es el más lento de los tres.

Se implementó la transformada S usando los tres algoritmos propuestos anteriormente para la señal transitoria de corriente de un monitor en el rango de frecuencias de 0-6[kHz] (ver figura 7). Las figuras 7a, 7b y 7c, muestran la magnitud de la transformada S como resultado de los algoritmos. Comparando la figura 7a y 7b se observa que ambas transformadas son casi idénticas, esto es debido a que provienen del mismo código base y de la misma definición discreta de la transformada S. Las ligeras diferencias en la figura 7c se deben a que la transformada S calculada mediante la relación con la transformada Wavelet es obtenida resolviendo la integral de convolucion, a diferencia del algoritmo de Stockwell el cual aproxima la definición discreta de la transformada S mediante la transformada rápida de Fourier.

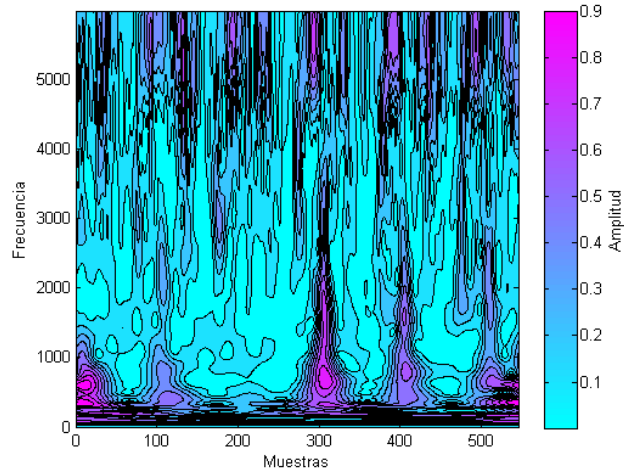
Figura 6: Señal transitoria $h[kT]$ del cambio de estado de un monitor. Fuente:Autor




La figura 8 muestra la magnitud de la transformada S de la misma señal para una frecuencia específica de $F = 1[kHz]$, se observa gran similitud en las figuras 8a, 8b y 8c con ligeras discrepancias en los bordes. Considerando

Figura 7: Transformada S de la señal transitoria de cambio de estado de un monitor mediante los tres algoritmos propuestos. Fuente:Autor.

(a) Algoritmo de Stockwell



(b) Algoritmo de Stockwell modificado



(c) Algoritmo que relaciona la transformada S con la Wavelet






Figura 8: Transformada S de la señal transitoria de cambio de estado de un monitor mediante los tres algoritmos propuestos para $F = 1[kHz]$. Fuente:Autor.


(a) Algoritmo de Stockwell



(b) Algoritmo de Stockwell modificado



(c) Algoritmo que relaciona la transformada S con la Wavelet



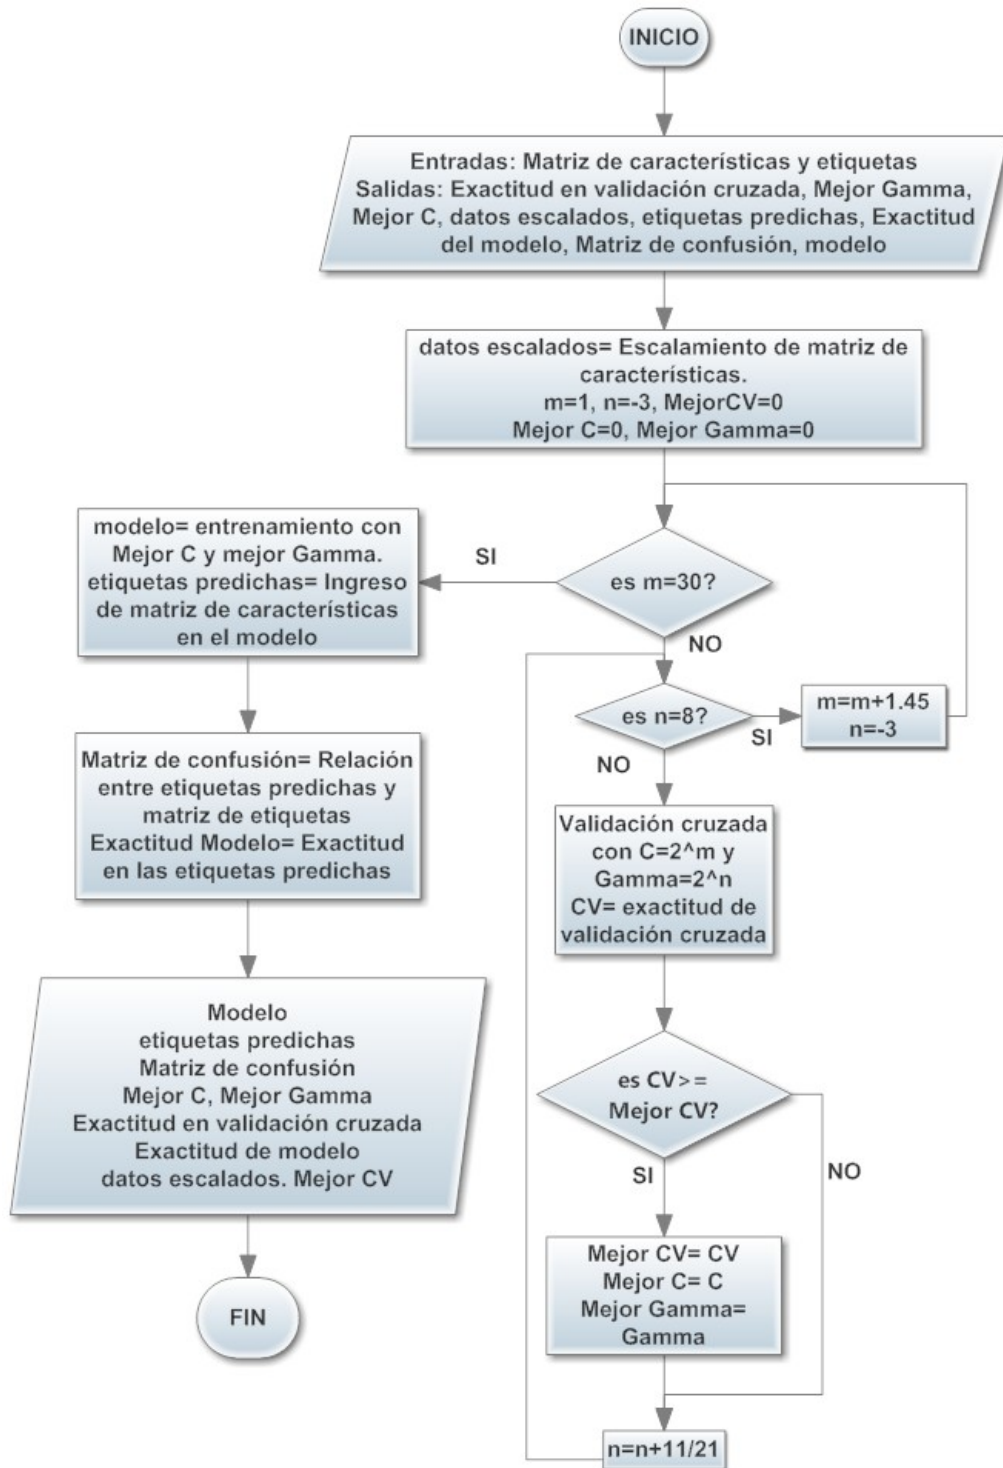
los resultados dados, las transformadas obtenidas con los tres algoritmos son aproximadamente iguales. Debido a esto se puede analizar casi cualquier rango de frecuencia escogiendo el algoritmo adecuado, lo que permite probar diferentes combinaciones en búsqueda de la mayor exactitud posible.

5.5. Implementación de las máquina de soporte vectorial

Para implementar la máquina de soporte vectorial se utilizó la librería LIBSVM [4], la cual ofrece la opción de abordar problemas de clasificación con más de dos clases. A continuación se describen los pasos para obtener el clasificador.

1. Los parámetros de entrada son las matrices de etiquetas o clases y características. Los parámetros de salida son la exactitud en validación cruzada, el mejor γ y C , los datos escalados, las etiquetas predichas, la exactitud del clasificador, el modelo y la matriz de confusión.
2. Se escalan las características en un rango entre 0 a 1.
3. Se crea una red creciente exponencial en base 2 para C y γ .
4. Se entrena y se obtiene un modelo mediante validación cruzada para cada par de (C, γ) en la red creada
5. Se almacena los valores de C y γ que produzcan la mejor clasificación en validación cruzada.
6. Se obtiene el modelo con los valores del paso 5.
7. Se calcula la matriz de confusión con las etiquetas predichas.

Figura 9: Diagrama de flujo del algoritmo para la máquina de soporte vectorial.
Fuente:autor.



6. Experimentos y resultados

6.1. Base de datos BLUED

Se utilizó para los experimentos la base de datos BLUED [1], la cual incluye señales de corriente y de voltaje muestreadas a $12[kHz]$. Las señales fueron tomadas de una casa durante una semana con el fin de probar algoritmos basados en NILM. Los cambios de estado describen la operación de 43 electrodomésticos. El sistema de conexiones para tomar las medidas consiste en un sistema trifilar con dos fases A, B y un neutro (tap central). Las corrientes en ambas fases I_A y I_B y el voltaje de fase V_A fueron recolectados (el voltaje en B se supone igual que V_A con un desfase de 180°) Algunos electrodomésticos fueron conectados a la fase A, otros a la fase B, y el resto (aire acondicionado) a ambas fases [10].


6.2. Métodos propuestos para eliminar el auto-aliasing

El autoaliasing se presenta cuando la frecuencia de la transformada S se aproxima a la frecuencia de Nyquist, para visualizar los efectos del autoaliasing se obtuvo la transformada S de $h(t) = 1\sin(2\pi(5500t)) + 1\sin(2\pi(1000t))$ muestreada a una frecuencia de $12[kHz]$ (ver figura 10). El efecto del autoaliasing tiene mayor intensidad cuando la frecuencia de análisis se aproxima a la frecuencia de Nyquist, debido a esto en la figura 11a se observa distorsión generada en la zona entre $5 - 6[kHz]$ por su proximidad a $\frac{F_s}{2}$, debido a esto no se puede identificar el componente frecuencial de $5,5[kHz]$.

Obteniendo la señal en analítica de $h[kT]$, se remueve las frecuencias negativas de la señal $h[kT]$. En la figura 11b se observa un espectro más definido en donde se distingue la frecuencia posicionada en $5,5[kHz]$. Comparando las figuras 11a y 11b se evidencia claramente la disminución del efecto del autoaliasing empleando señal analítica.

La figura 11c muestra la transformada S de la señal limitando la frecuencia a una frecuencia máxima definida en (35). No se observó efectos del autoaliasing limitando la frecuencia debido a que no se calculó la transformada S en las

Figura 10: Señal $h(t) = 1\sin(2\pi(5500t)) + 1\sin(2\pi(1000t))$ muestreada a una frecuencia de $12[kHz]$. Fuente:autor.



frecuencias donde este fenómeno se presenta con mayor intensidad.

6.3. Resultados de clasificación de cargas eléctricas mediante la transformada S

Se seleccionaron las señales transitorias de cinco electrodomésticos para clasificar:

Electrodoméstico	señales
Lampara de escritorio	13
Computador	9
Televisor	21
Monitor	18
Luces de oficina	26

Tabla 2: Electrodomésticos y su numero de señales

En total se tienen 87 señales transitorias. En búsqueda de la mejor exactitud en clasificación se probaron diferentes combinaciones de vectores de frecuencia y características. La tabla 3 describe los experimentos realizados que generaron los mejores resultados en clasificación para cada conjunto de características.


Los porcentajes de exactitud en clasificacion estan dados por:

$$\%Clasificacion = \frac{aciertos}{Total} \cdot 100, \quad (50)$$


La tabla 4 muestran los porcentajes de exactitud en validación cruzada y de clasificación obtenidos para los experimentos realizados.

Figura 11: Transformada S de $h(t) = 1\sin(2\pi(5500t)) + 1\sin(2\pi(1000t))$ muestreado a una frecuencia de $12[kHz]$. Fuente:Autor.


(a) Sin señal analítica



(b) Con señal analítica



(c) Límitando la frecuencia máxima



Prueba	Algoritmo	Características	Parámetros de entrada	
			rango	Eje
1	Stockwell	1, 2, 3, 4, 5 y 6	0 – 1[kHz]	Lineal
2	trans. S con Wavelet	1, 2, 3, 4, 5 y 6	12 a 256 escalas	Escalas
3	Stockwell	1, 2, 3, 5 y 6	0 – 1[kHz]	Lineal
4	trans. S con Wavelet	1, 2, 3, 5 y 6	12 a 256 escalas	Escalas
5	Stockwell	1, 2, 3 y 6	0 – 6[kHz]	Lineal
6	trans. S con Wavelet	1, 2, 3 y 6	2 a 256 escalas	Escalas
7	trans. S con Wavelet	1, 2, 3 y 6	12 a 256escalas	Escalas
8	Stockwell modificado	1, 2, 3 y 6	1 – 1[kHz]	log base 2
9	trans. S con Wavelet	1, 2, 3 y 6	1 – 6[kHz]	log base 2

Tabla 3: Pruebas con los mejores resultados de precisión en clasificación para cada conjunto de características

Prueba	Exactitud en Validación cruzada	Exactitud en clasificación
1	64,36 %	75,8 %
2	62,06 %	71,3 %
3	63,21 %	77,0 %
4	67,81 %	80,4 %
5	62,68 %	85,0 %
6	64,38 %	81,6 %
7	67,81 %	87,3 %
8	64,36 %	85,0 %
9	65,51 %	90,8 %

Tabla 4: Exactitud en validación cruzada y en clasificación para las nueve pruebas.

La matriz de confusión es una representación de la distribución de las clases predichas enfrentadas con sus valores reales, la diagonal de la matriz muestra las clases predichas correctamente, y cada fila muestra las clases confundidas, esta representación es de gran utilidad para identificar las clases que el clasificador confunde. La tabla 5 hasta la 13 muestran las matrices de confusión para las pruebas realizadas.

Se probaron más combinaciones de características pero con ninguna otra combinación se obtuvo resultados superiores a los presentados anteriormente. Cuando se probó con dos características el algoritmo de Stockwell presentaba exactitud en validación cruzada baja, de alrededor del 50 % y su exactitud en la matriz de confusión decreció, llegando a un 52 % de aciertos.

	1	2	3	4	5	Total
1	9	0	0	3	1	9/13
2	0	0	0	4	5	0/9
3	0	0	20	0	1	20/21
4	0	0	1	14	3	14/18
5	2	0	0	1	23	23/26

Tabla 5: Matriz de confusión prueba 1.

	1	2	3	4	5	Total
1	7	0	0	2	4	7/13
2	0	1	0	4	4	1/9
3	0	0	19	2	0	19/21
4	0	0	1	13	5	13/18
5	0	0	0	1	25	25/26

Tabla 6: Matriz de confusión prueba 2.

	1	2	3	4	5	Total
1	8	0	0	3	2	8/13
2	0	2	0	0	7	2/9
3	0	0	20	0	1	20/21
4	0	0	0	12	6	12/18
5	0	0	0	1	25	25/26

Tabla 7: Matriz de confusión prueba 3.

	1	2	3	4	5	Total
1	8	0	0	3	2	8/13
2	0	2	0	4	3	2/9
3	0	0	19	2	0	19/21
4	0	0	0	17	1	17/18
5	0	0	0	2	24	24/26

Tabla 8: Matriz de confusión prueba 4.

	1	2	3	4	5	Total
1	11	0	0	1	1	11/13
2	0	3	0	1	5	3/9
3	0	0	21	0	0	21/21
4	0	0	0	15	3	15/18
5	0	1	0	1	24	24/26

Tabla 9: Matriz de confusión prueba 5.

Adicionalmente, se analizó la exactitud en clasificación empleando ejes logarítmicos en base dos para la frecuencia en los parámetros de entrada de los algoritmos, para realizar esto se empleó el algoritmo de Stockwell modificado y el algoritmo que relaciona la transformada S con la Wavelet. Se observó que clasificando con 4, 5 y 6 características y para rangos de frecuencia desde 1

	1	2	3	4	5	Total
1	11	0	0	2	0	11/13
2	0	3	0	3	3	3/9
3	0	0	20	1	0	20/21
4	0	0	0	16	2	16/18
5	0	1	0	4	21	21/26

Tabla 10: Matriz de confusión prueba 6.

	1	2	3	4	5	Total
1	11	0	0	1	1	11/13
2	0	6	0	2	1	6/9
3	0	0	21	0	0	21/21
4	1	0	0	14	3	14/18
5	0	1	0	1	24	24/26

Tabla 11: Matriz de confusión prueba 7.

	1	2	3	4	5	Total
1	9	1	0	2	1	9/13
2	0	3	0	3	3	3/9
3	0	0	21	0	0	21/21
4	0	0	0	16	2	16/18
5	0	0	0	1	25	25/26

Tabla 12: Matriz de confusión prueba 8.

	1	2	3	4	5	Total
1	11	0	1	1	0	11/13
2	0	6	0	1	2	6/9
3	0	0	21	0	0	21/21
4	0	0	0	17	1	17/18
5	0	2	0	0	24	24/26

Tabla 13: Matriz de confusión prueba 9.

hasta $1[kHz]$, y desde 1 hasta $6[kHz]$ con eje logarítmico los resultados de exactitud en validación cruzada variaban en el rango de 60 a 65%. Los mayores porcentajes de exactitud en validación cruzada se obtuvieron clasificando con las características 1,2,3 y 6.

7. Conclusiones

- De los métodos propuestos para eliminar el auto-aliasing, la mejor opción es convertir la señal en analítica, debido a que no se pierde la información comprendida en las frecuencias cercanas a la de Nyquist.
- El algoritmo de Stockwell permite calcular la transformada S mas rápido en comparación con los otros dos algoritmos presentados, por lo que si se desea un estudio rápido en clasificación como por ejemplo, para aplicaciones en tiempo real es una buena opción de implementación. Para análisis mas detallados se puede utilizar los algoritmos de Stockwell modificado o el algoritmo que relaciona la transformada S con la Wavelet.
- La función de base radial permite una rápida implementación de la maquina de soporte vectorial, ya que tiene un parámetro menos de ajuste que las demás funciones básicas de Kernel.
- Los mejores resultados en clasificación se obtuvieron empleando el algoritmo que relaciona la transformada S con la transformada Wavelet con una exactitud en validación cruzada de 67,81 %, con cuatro características. Debido a esto se considera que el conjunto de características con mayor rendimiento en clasificación son la desviación estándar en los máximos de las filas de la magnitud de la transformada S, la desviación estándar en los el máximos de las columnas de la magnitud de la transformada S, la energía y la duración de la señal ya que este conjunto obtuvo la mayor exactitud en validación cruzada, así como 87,3 % de aciertos en la matriz de confusión. El algoritmo de Stockwell obtuvo resultados similares empleando estas características produciendo una exactitud en validación cruzada de 62,06 %, lo cual está muy cercana al valor máximo en validación cruzada obtenido (67,81 %). Considerando las ventajas del algoritmo de Stockwell es posible obtener una velocidad de implementación mayor, en comparación con el algoritmo que relaciona la transformada S con la Wavelet, con la desventaja de obtener un porcentaje en validación cruzada relativamente mas bajo.
- Con ejes logarítmicos de frecuencia no se observó un aumento notorio en la

exactitud en clasificación. Considerando el alto tiempo de procesamiento de el algoritmo de Stockwell modificado es mas práctico emplear el algoritmo de Stockwell para obtener porcentajes de clasificación similares.

- Cabe destacar que el electrodoméstico computador fue confundido con el monitor y con las luces de oficina en casi todos los experimentos realizados.
- Para futuros estudios se recomienda, emplear otras técnicas de inteligencia artificial y comparar su exactitud con la obtenida por la maquina de soporte vectorial, ademas proponer nuevas características para analizar su desempeño en clasificación. Tambien Se pueden probar diferentes funciones de Kernel o proponer alguna función de Kernel nueva para la máquina de soporte vectorial, realizar un ajuste de parámetros diferente empleando algoritmos de inteligencia artificial. Finalmente, se recomienda comparar el desempeño de la transformada S con el de otras transformadas, para la extracción de características en aplicaciones de monitorización no intrusiva.

Referencias

- [1] A. FILIP, *BLUED: A Fully Labeled Public Dataset for Event-Based Non-Intrusive Load Monitoring Research*, in second Workshop on Data Mining Applications in Sustainability (SustKDD), no. October 2011,2012 2012.
- [2] AHMED ZOHA, ALEXANDER GLUHAK, MUHAMMAD ALI IMRAN and SUTHARSHAN RAJASEGARAR, *Non-Intrusive Load Monitoring Approaches for Disaggregated Energy Sensing: A Survey*, Center for Communication Systems Research, University of Surrey, Guildford, Department of Electrical and Electronic Engineering, University of Melbourne.
- [3] ALAN V. OPPENHEIM, RONALD W. SCHAFFER and JHON R. BUCK, *Discrete-time Signal processing*, segunda edición, Prentice Hall.
- [4] CHIH-CHUNG CHANG, and CHIH-JEN LIN, *LIBSVM: A Library for Support Vector Machines*, Department of Computer Science National Taiwan University, Taipei, Taiwan.
- [5] CHIH-WEI HSU, CHIH-CHUNG CHANG,, and CHIH-JEN LIN, *A Practical Guide to Support Vector Classification*, Department of Computer Science National Taiwan University, Taipei 106, Taiwan.
- [6] CHIRAG A. NAIK and PRASANTA KUNDU, *Identification of Short Duration Power Quality Disturbances Employing S-transform*, Department of Electrical Engineering S. V. National Institute of Technology Surat, India.
- [7] CHUN-LIN, LIU, *A Tutorial of the Wavelet Transform*.
- [8] ENERGÉTICA, UPME, *Unidad de Planeación Minero. Proyección de Demanda de Energía Eléctrica*, Marzo de 2013.
- [9] JIANMING YU, LEILEI WANG, BO ZHOU and WENBO TIAN, *An Expert System Based on S-transform for Classification of Voltage Dips*, School of Automation and Information Engineering Xi'an University of Technology, China.
- [10] JIMENEZ, YULIETH AND DUARTE, CESAR AND PETIT, JOHANN and CARRILLO, GILBERTO, *Feature Extraction for Nonintrusive Load Monitoring based on S-Transform*, Power Systems Conference 2014.
- [11] MICHAEL ZEIFMAN and KURT ROTH, *Nonintrusive Appliance Load Monitoring: Review and Outlook*.

- [12] R.G. STOCKWELL , *Why use the S-Transform?*, Northwest Research Associates, Colorado Research Associates Division,3380 Mitchell Lane, Boulder Colorado USA 80301.
- [13] R. G. STOCKWELL, *A basis for efficient representation of the S-transform*,Journal Digital Signal Processing archive Volume 17 Issue 1, January, 2007 Pages 371-393 disponible Online en: <http://dl.acm.org/citation.cfm?id=1223069>.
- [14] S. MISHRA, C. N. BHENDE and B. K. PANIGRAHI, *Detection and Classification of Power Quality Disturbances Using S-Transform and Probabilistic Neural Network*.
- [15] S. B. KOTSIANTIS, *Supervised Machine Learning: A Review of Classification Techniques*, Department of Computer Science and Technology University of Peloponnese, Greece.
- [16] SWANHILD BERNSTEIN, JEAN-LUC BOUCHOT, MARTIN REINHARD and BETTINA HEISE, *Generalized analytic signals in image processing: Comparison, theory and their applications*.
- [17] THE MATHWORKS, INC, *Feature Transformation: Multivariate Methods (Statistics Toolbox)*.
- [18] YU-HSIANG WANG, *The Tutorial: S Transform*, National Taiwan University, Taipei, Taiwan.
- [19] YU-HSIU LIN and MEN-SHEN TSAI, *Development of an Improved Time–Frequency Analysis-Based Nonintrusive Load Monitor for Load Demand Identification*, School of Automation and Information Engineering Xi'an University of Technology, China.
- [20] ZHANG RUI,ZHANG TAO, YAO HONGJIAO2 and LIU SHENG, *The Classification and Recognition of Power Quality Disturbance Based on S Transform*, School of Automation Harbin University of Science and Technology Harbin, China