

Efecto de una distorsión de onda achatada sobre un sistema de identificación de cargas basado en características extraídas a través de la transformada de Fourier fraccionaria.

Effect of a flat-top distortion on a load identification system with feature extraction based on Fractional Fourier Transform.

H. Cala¹, Y. Jimenez², R. Torres³ y C. Duarte⁴

¹ Grupo GISEL, Escuela de ingeniería eléctrica, electrónica y de telecomunicaciones, UIS, henrycala1@gmail.com

² Grupo GISEL, Escuela de ingeniería eléctrica, electrónica y de telecomunicaciones, UIS, yulieth.jimenez@correo.uis.edu.co

³ Grupo GOTS, Escuela de Física, UIS, rafael.torres@saber.uis.edu.co

⁴ Grupo GISEL, Escuela de ingeniería eléctrica, electrónica y de telecomunicaciones, UIS, cedagua@uis.edu.co

RECIBIDO: abril 21, 2017. ACEPTADO: junio 02, 2017. VERSIÓN FINAL: noviembre 01, 2017

RESUMEN

Los sistemas de monitorización intrusiva usualmente realizan identificación de carga extrayendo y procesando características de señales agregadas en una casa. El desempeño de estos sistemas depende de las características que se extraigan y se espera que este no cambie considerablemente cuando se presenta distorsión en la red. En este artículo se estudia el efecto de una distorsión de onda de alimentación achatada sobre un sistema de identificación de cargas con extracción de características basada en la transformada de Fourier fraccionaria (FRFT). Tres casos de análisis fueron realizados: uno entrenando con datos sin distorsión y dos añadiendo datos con distorsión en el entrenamiento. El desempeño en la identificación es alto para los tres casos contemplados y mejora cuando el diseño incluye datos tomados bajo alimentación distorsionada. Los resultados son comparados con un sistema que utiliza extracción de características basada en Fourier.

PALABRAS CLAVES: Transformada fraccionaria de Fourier, monitorización no intrusiva de carga, distorsión de onda achatada, identificación de cargas, extracción de características, máquinas de soporte vectorial.

ABSTRACT

Nonintrusive load monitoring systems usually achieve load identification by extracting and processing appliance features from aggregated signals in a house. The identification performance depends on the selected feature set and it is expected that this performance remains under distorted conditions. This paper discusses the effect of a flat-top power supply distortion on a residential load identification system with feature extraction based on fractional Fourier transform (FRFT). Three study cases are developed: one case uses only non-distorted data in the training stage and the other two cases include data with distortion. Identification performance is high for the three cases and it enhances when data under distorted conditions are included in the design. The results are compared with a system with feature extraction based on Fourier.

KEYWORDS: Fractional Fourier transform, Nonintrusive load monitoring, flat-top distortion, load identification, feature extraction, support vector machines.

1 INTRODUCCIÓN

Una reducción significativa en el consumo de energía eléctrica se puede lograr con información del uso de los dispositivos eléctricos en una casa o edificio [1]. Re-

alimentando a los usuarios el costo e impacto social y ambiental relacionado con el uso de cada dispositivo eléctrico, se esperan cambios en sus hábitos que se reflejen en la disminución del consumo de energía [1]. De hecho, estudios muestran que una reducción alrededor

del 10 al 15 % en el consumo de energía residencial se puede obtener aplicando mejores estrategias de gestión de la energía eléctrica [2].

Existen dos enfoques principales para identificar el consumo individual de los dispositivos conectados a la red eléctrica: la monitorización intrusiva de cargas (*ILM: Intrusive Load Monitoring*) y la monitorización no intrusiva de cargas (*NILM: Non-Intrusive Load Monitoring*). Los métodos ILM obtienen el consumo individual de cada dispositivo mediante múltiples sensores acoplados en los puntos de conexión de los electrodomésticos. Por otra parte, los métodos NILM solo requieren un sensor conectado a la red eléctrica, y a través de algoritmos buscan identificar los consumos individuales de los dispositivos [3]. Es por esto que la implementación de un sistema NILM requiere una mayor complejidad computacional en comparación con los métodos ILM pero tiene un menor costo [4]. El método general de un sistema NILM consiste en, inicialmente, identificar los dispositivos activos en un tiempo determinado (identificación de cargas) y luego, describir el consumo promedio de los electrodomésticos utilizando información conocida de las cargas [3]. Con este método, el rendimiento del sistema está determinado por la etapa de identificación de cargas.

Generalmente el proceso de identificación de cargas se realiza extrayendo características de la señal agregada y a través de algoritmos de reconocimiento de patrones se estima qué dispositivo exhibió tales características. Por lo anterior, el rendimiento en la identificación de cargas depende críticamente tanto de las características extraídas como del diseño y selección del clasificador. En la literatura estudiada se encontraron diferentes propuestas para la extracción de características e identificación de cargas.

Algunos trabajos presentan extracción de características en el dominio del tiempo. Yang et al. en [5] utilizan la energía y la envolvente espectral de la potencia instantánea de señales transitorias de los dispositivos como características y presentan el rendimiento de entrenar redes neuronales con algoritmos de propagación hacia atrás (RN-BP) y cuantización del vector de aprendizaje. Chang et al. en [6] utilizan características de potencia activa y reactiva de los dispositivos, emplean algoritmos genéticos para reducir la dimensionalidad del vector y clasificaron mediante RN-BP. Wang et al. en [7] clasifican los dispositivos eléctricos calculando grados de similitud entre los datos de entrenamiento y los datos de entrada utilizando características basadas en el régimen estacionario y transitorio de las señales. Bergman et al. en [8] describen las señales de régimen estacionario mediante la potencia activa y reactiva, y resuelven el problema de clasificación con agrupamiento de datos (*clustering*).

Otros trabajos se basan en representar las señales en otros dominios donde se puedan calcular características

que permiten una mejor identificación de cargas. Chang et al. en [9] y Duarte et al. en [10] comparan el rendimiento al representar las señales eléctricas a través de las transformadas Fourier de corto tiempo (*STFT: Short Time Fourier Transform*) y Wavelet. Chang et al. [9] emplean transitorios de corriente y RN-BP, mientras que Duarte et al. [10] analizan transitorios de tensión y máquinas de soporte vectorial (SVM). Gillis et al. en [11] presentan un enfoque basado en máquinas de aprendizaje semisupervisadas con agrupamiento de datos. La contribución de energía de cada coeficiente Wavelet es utilizada como característica y la clasificación se realiza con árboles de decisión y vecinos cercanos. Jimenez et al. en [12] emplean la transformada Stockwell para representar el régimen transitorio de señales de corriente y posteriormente extraer características que son clasificadas mediante SVM. Srinivasan et al. en [13] aprovechan el análisis de armónicos para extraer características y realiza la identificación de cargas mediante diferentes modelos basados en RN y SVM.

En definitiva, en los sistemas de identificación revisados la extracción de características se realiza en el dominio del tiempo y/o en el dominio transformado, tomando señales de la operación de los dispositivos en régimen estacionario y/o transitorio. Para el régimen estacionario, la representación en armónicos de Fourier es muy utilizada como técnica de extracción debido a que el espectro se mantiene casi invariante en el tiempo, mientras que las transformadas Wavelet, Stockell y STFT permiten representaciones de señales eléctricas variantes en el tiempo y la frecuencia, considerando así información de ambos dominios. En la presente investigación para la extracción de características se emplea la transformada de Fourier Fraccionaria (FRFT) la cual es considerada una generalización de la transformada de Fourier.

Por otro lado, se espera que el sistema de identificación sea robusto ante la presencia de distorsión en la red eléctrica puesto que puede generar errores en la estimación de los sistemas de identificación. La pregunta sobre el efecto de una distorsión de onda achatada sobre los sistemas NILM es de gran interés. Jimenez et al. en [14] analizan el efecto de la distorsión de onda achatada para diferentes conjuntos de características a través de índices de similitud entre los datos con y sin distorsión. Con el fin de indagar acerca de la robustez y fiabilidad en la estimación del sistema de NILM, este trabajo contribuye al analizar el efecto sobre el rendimiento del sistema completo. De este modo, se verifica el rendimiento cuando se presenta una distorsión de onda achatada, que es típica en redes residenciales. Para analizar el efecto de una distorsión de onda achatada en los sistemas planteados se desarrollaron tres casos de análisis donde diferentes bases de datos de señales con y sin distorsión, son utilizadas en



el entrenamiento y la validación. Las características son extraídas de señales de corriente en régimen estacionario representadas mediante la FRFT y la identificación se realiza con SVM. Para propósitos de comparación con un trabajo previo [13], también se implementó un segundo sistema basado en la transformada de Fourier.

El resto del documento está organizado de la siguiente manera. En la sección 2 se establece el problema de identificación de cargas eléctricas. En la sección 3 se detallan los sistemas de identificación implementados y las bases de datos utilizadas para el entrenamiento. La sección 4 muestra los casos de análisis y los resultados obtenidos. Finalmente en la sección 5 se describen las conclusiones del artículo.

2 DESCRIPCIÓN DEL PROBLEMA

El consumo total de potencia para D dispositivos activos en una casa se puede representar como:

$$P_T(t) = P_1(t) + P_2(t) + \dots + P_i(t) + \dots + P_D(t), \quad (1)$$

donde $P_T(t)$ es la potencia total agregada y $P_i(t)$ es la potencia asociada al dispositivo i . En un sistema NILM se busca encontrar $P_i(t)$ para $i = 1, 2, \dots, D$ a través de observaciones de $P_T(t)$. Las variables de la ecuación (1) cambian en el tiempo debido a operaciones de conexión y desconexión de los dispositivos. Además, condiciones ruidosas, la presencia de distorsiones o cambios en las condiciones de operación producen variaciones en los consumos de potencia de los dispositivos.

En un sistema NILM, se identifican las cargas activas en la red eléctrica y se establece el consumo de potencia de cada una. La identificación de cargas consiste en extraer características de la señal agregada y a través de algoritmos de reconocimiento de patrones establecer los dispositivos que exhibieron tales características. El algoritmo de reconocimiento generalmente se selecciona del conjunto de técnicas de aprendizaje de máquina supervisado y sus parámetros, Θ , se ajustan mediante entrenamiento con una base de datos con etiquetas conocidas. Se espera que los datos de entrenamiento incluyan los eventos más probables de cada dispositivo y que el operador de extracción de características sea robusto ante ruido y distorsiones presentes en la red eléctrica.

En las redes eléctricas residenciales es común que la onda de voltaje presente una ligera planicie en sus extremos debido a la operación de cargas no lineales en el sistema, este fenómeno es conocido como distorsión de onda achatada (*flat-top distortion*). Se espera que la exactitud de los sistemas de identificación se conserve cuando está distorsión se presenta en la alimentación de los dispositivos. En [14] se analiza el efecto de la distorsión de

onda achatada para diferentes conjuntos de características a través de índices de similitud entre los datos con y sin distorsión. Un análisis del sistema completo se puede realizar utilizando como métrica el error e . Considerando un modelo de clasificador $\Psi_{\Theta}(v)$ entrenado con una base de datos dada, el error e de estimar las etiquetas l_i de un conjunto de eventos estaría dado por:

$$e = \frac{1}{N} \sum_{i=1}^D \sum_{j=1}^{N_i} b_{ji} \quad (2)$$

con

$$b_{ji} = \begin{cases} 1 & l_i \neq \Psi_{\Theta}(V(x_{ji}(t))) \\ 0 & l_i = \Psi_{\Theta}(V(x_{ji}(t))) \end{cases}$$

donde $V(\cdot)$ es el operador de extracción de características, N_i es el número de eventos del dispositivo i , $N = \sum_{i=1}^D N_i$ es el número total de eventos, x_{ji} es el evento j en la señal agregada asociado al dispositivo i y l_i es la etiqueta numérica asignada a cada dispositivo.

En el presente artículo, se analiza el error e de estimar las etiquetas de un conjunto de datos con distorsión de onda achatada. Tres casos de análisis son desarrollados donde diferentes conjuntos de entrenamiento con y sin distorsión son utilizados para obtener el modelo del clasificador. Esto se realiza con el fin de comprobar los cambios en la predicción de los sistemas cuando datos distorsionados son incluidos en el entrenamiento.

3 SISTEMA DE IDENTIFICACIÓN DE CARGAS

En la Figura 1 se presenta el esquema en bloques del sistema NILM utilizado, se realizaron mediciones del régimen estacionario de señales de corriente y voltaje de la operación simultánea de tres cargas. En total se adquirieron mediciones de 15 combinaciones de tres cargas con alimentación sinusoidal pura y con distorsión de onda achatada. La subsección 3.1 describe la adquisición de las señales y las bases de datos para el entrenamiento de los sistemas. El procesamiento de señales y estimación es realizado fuera de línea (offline), y consiste en extraer características de un evento observado en las mediciones para asignar una etiqueta de las 15 posibles (estimación) con base en esta información. Los métodos de extracción de características planteados se basan en el régimen estacionario de los dispositivos y se describen en las subsecciones 3.2 y 3.3. El clasificador es diseñado usando SVM y las bases de datos contempladas en los casos de análisis de la sección 4.




Figura 1. Estructura general del sistema NILM utilizado. **Fuente.** Elaboración propia.

3.1 Bases de datos

La Figura 2 presenta el esquema implementado para las mediciones de corriente y voltaje de la operación simultánea de tres cargas. Se realizaron mediciones del régimen estacionario con frecuencia de muestreo de 50kHz en donde se contemplaron dos escenarios en la alimentación V_{in} del circuito:

- Base de datos 1: alimentación sinusoidal pura.
- Base de datos 2: alimentación con distorsión de onda achatada.

Se adquirió el mismo número de eventos para ambos escenarios: 375 por combinación, por escenario. Las 15 combinaciones de tres dispositivos seleccionadas para el diseño y validación de los sistemas de identificación se listan en la Tabla 1.




Figura 2. Diagrama de la adquisición de datos. **Fuente.** Elaboración propia.

Tabla 1: Bases de datos utilizadas en entrenamiento y validación de los sistemas de identificación.

Etiqueta	Combinación
1	Lámpara halógena, CFL20W, lámpara LED
2	Bombilla incandescente, lámpara halógena, CFL 9W
3	Bombilla incandescente, CFL 9W, sandwichera
4	Lámpara LED, CFL 20W, plancha
5	CFL 9W, bombilla incandescente, licuadora
6	Lámpara halógena, lámpara LED, ventilador
7	Lámpara halógena, lámpara LED, TV
8	Bombilla incandescente, CFL 20W, Cargador de PC
9	Lámpara halógena, sandwichera, ventilador
10	CFL 20W, licuadora, plancha
11	Bombilla incandescente, sandwichera, TV
12	Refrigerador, lámpara halógena, cargador de PC
13	Lámpara halógena, TV, ventilador
14	CFL 20W, licuadora, cargador de PC
15	Licuadora, sandwichera, TV

Fuente. Elaboración propia

3.2 Extracción de características utilizando la FRFT

La transformada de Fourier Fraccionaria (FRFT) es una generalización de la transformada de Fourier, donde una función f es mapeada a un dominio intermedio entre el tiempo y la frecuencia [15]. La FRFT con orden α de $f(u)$ se define como [16]:

$$\mathcal{F}_\alpha[f(u)](u') = C_\alpha \int_{-\infty}^{\infty} K(u, u') f(u) du, \quad (3)$$

$$K(u, u') = e^{-i\pi u^2 \cot \alpha} e^{2i u u' / \sin \alpha} e^{-i\pi u'^2 \cot \alpha} \quad (4)$$

donde $C_\alpha = \frac{e^{i(\operatorname{sgn}(\alpha)\frac{\pi}{4} - \frac{\alpha}{2})}}{\sqrt{|\sin \alpha|}}$ y $\operatorname{sgn}(\cdot)$ es la función signo. La FRFT satisface las propiedades de conmutatividad, asociatividad y aditividad de índices. Además, a determinados valores de α , la FRFT cumple relaciones especiales con f : cuando $\alpha = \pi/2$ la FRFT corresponde a la transformada de Fourier ordinaria, para $\alpha = 0$ la FRFT es la misma función y para $\alpha = \pi$ es $f(-u)$ [17].

La extracción de características utilizando la FRFT consiste en representar las señales de corriente en 11 dominios fraccionarios con $0 \leq \alpha \leq 2\pi$ y posteriormente extraer información de cada representación. El vector de características V_{FRFT} en la ecuación (5) está conformado por el valor máximo y la desviación estándar de la magnitud de cada representación, $F_r = \operatorname{abs}(\mathcal{F}_\alpha[x(t)])$, $r = 1, 2, \dots, 11$.

$$V_{FRFT} = [\max\{F_1\}, \max\{F_2\}, \dots, \max\{F_{11}\}, \operatorname{std}\{F_1\}, \operatorname{std}\{F_2\}, \dots, \operatorname{std}\{F_{11}\}] \quad (5)$$

3.3 Extracción de características utilizando el análisis de Fourier

En los sistemas eléctricos algunos dispositivos producen diferentes armónicos en la señal de corriente, por lo que esta información puede ser utilizada como características en los sistemas de identificación. Las componentes armónicas en señales estacionarias corresponden al valor de la transformada de Fourier en frecuencias múltiplos de la frecuencia fundamental del sistema. En [13] se han implementado sistemas de identificación utilizando como características la magnitud de los armónicos impares de la señal de corriente. Para propósitos de comparación esta misma extracción de características se implementa utilizando los 50 primeros armónicos impares de las señales de corriente de los dispositivos. El vector de características V_{Fou} empleando Fourier está conformado por los armónicos de la señal, así:

$$V_{Fou} = [h_1, h_2, \dots, h_{50}] \quad (6)$$

donde h_k es el k ésimo armónico impar de $x(t)$.

4 RESULTADOS

Tres casos de análisis fueron desarrollados para comprobar experimentalmente el rendimiento de los sistemas de identificación cuando se presenta distorsión de onda achatada en la alimentación. Inicialmente, los sistemas son entrenados con la base de datos 1 y la validación es realizada con la base de datos 2. Posteriormente información de la base de datos 2 es incluida en el entrenamiento de los sistemas de identificación y la validación se realiza con los datos no incluidos en el entrenamiento de la base de datos 2. La exactitud p en la estimación de los sistemas de identificación para los casos contemplados esta dada por [18]

$$p = \frac{TP + TN}{TP + FP + TN + FN}, \quad (7)$$

donde $TP + TN$ son los datos estimados correctamente y $TP + FP + TN + FN$ es el número total de datos. El error estándar S asociado a p es [18]

$$S = \sqrt{\frac{p(1-p)}{TP + FP + TN + FN}}. \quad (8)$$

Con un nivel de confianza de 0,95 la exactitud real se encuentra en un intervalo $p \pm 1,96S$ [18].

La selección de parámetros de los clasificadores es realizada con validación cruzada de 10 particiones, donde ambos sistemas implementados en cada casos de estudio obtuvieron 100% de exactitud en validación cruzada en el entrenamiento. Los tres experimentos realizados se describen en el resto de esta sección.

4.1 Caso A

Los sistemas de identificación son entrenados con la base de datos 1 utilizando los conjuntos de características descritos en la sección 3.2 y 3.3. Posteriormente, se evalúa el desempeño de los sistemas en la identificación de la base de datos 2, obteniendo los resultados que se muestran en la Tabla 2. El sistema de identificación con características utilizando la FRFT logra una exactitud de $98,67 \pm 0,30\%$, lo que sugiere experimentalmente que la técnica de extracción de características es robusta ante la distorsión de onda achatada en la alimentación. Las Tablas 3 y 4 muestran las matrices de confusión para los sistemas de identificación con características a través de Fourier y la FRFT respectivamente. El sistema de identificación con características utilizando Fourier no logra estimar correctamente ningún evento de las combinaciones 7 y 13, en cambio el sistema basado en la FRFT solo presenta error en la estimación para la combinación 10.

Tabla 2: Exactitud en la identificación de cargas para el caso A.

características	error (%)	Exactitud(%)
Basada en FRFT	0,15	$98,67 \pm 0,30$
Basada en Fourier	0,61	$70,26 \pm 1,20$

Fuente. Elaboración propia

Tabla 3: Matriz de confusión del sistema de identificación con características basadas en FRFT para el caso A

	(1)	(2)	(3)	(4)	(5)	(6)	(7)	(8)	(9)	(10)	(11)	(12)	(13)	(14)	(15)
(1)	375	0	0	0	0	0	0	0	0	0	0	0	0	0	0
(2)	0	375	0	0	0	0	0	0	0	0	0	0	0	0	0
(3)	0	0	375	0	0	0	0	0	0	0	0	0	0	0	0
(4)	0	0	0	375	0	0	0	0	0	0	0	0	0	0	0
(5)	0	0	0	0	375	0	0	0	0	0	0	0	0	0	0
(6)	0	0	0	0	0	375	0	0	0	0	0	0	0	0	0
(7)	0	0	0	0	0	0	375	0	0	0	0	0	0	0	0
(8)	0	0	0	0	0	0	0	375	0	0	0	0	0	0	0
(9)	0	0	0	0	0	0	0	0	375	0	0	0	0	0	0
(10)	0	0	0	75	0	0	0	0	0	300	0	0	0	0	0
(11)	0	0	0	0	0	0	0	0	0	0	375	0	0	0	0
(12)	0	0	0	0	0	0	0	0	0	0	0	375	0	0	0
(13)	0	0	0	0	0	0	0	0	0	0	0	0	375	0	0
(14)	0	0	0	0	0	0	0	0	0	0	0	0	0	375	0
(15)	0	0	0	0	0	0	0	0	0	0	0	0	0	0	375

Fuente. Elaboración propia

Tabla 4: Matriz de confusión del sistema de identificación con características basadas en Fourier para el caso A

	(1)	(2)	(3)	(4)	(5)	(6)	(7)	(8)	(9)	(10)	(11)	(12)	(13)	(14)	(15)
(1)	300	0	0	75	0	0	0	0	0	0	0	0	0	0	0
(2)	0	229	0	0	0	0	58	0	0	88	0	0	0	0	0
(3)	0	0	375	0	0	0	0	0	0	0	0	0	0	0	0
(4)	0	0	0	375	0	0	0	0	0	0	0	0	0	0	0
(5)	0	0	0	0	19	0	0	0	10	0	0	0	0	346	0
(6)	0	0	0	0	0	375	0	0	0	0	0	0	0	0	0
(7)	0	0	0	0	0	0	0	0	0	0	0	0	0	375	0
(8)	0	0	0	0	0	0	375	0	0	0	0	0	0	0	0
(9)	0	0	0	0	0	0	0	375	0	0	0	0	0	0	0
(10)	0	0	0	0	0	0	0	0	375	0	0	0	0	0	0
(11)	0	0	0	0	0	0	0	0	0	375	0	0	0	0	0
(12)	0	0	0	0	0	0	0	0	0	0	375	0	0	0	0
(13)	0	0	0	0	0	0	0	0	0	0	0	375	0	0	0
(14)	0	0	0	0	86	0	0	0	260	0	0	0	0	29	0
(15)	0	0	0	0	0	0	0	0	0	0	0	0	0	0	375

Fuente. Elaboración propia

4.2 Caso B

Los sistemas de identificación son entrenados con información de las bases de datos 1 y 2, el 98% de los datos de entrenamiento pertenecen a la base de datos 1 y el 2% restante a la base de datos 2. Luego, se evalúa el desempeño de los sistemas en la identificación de las muestras restantes de la base de datos 2. En la Tabla 5 se muestran los resultados de exactitud en la identificación obtenidos para cada sistema. El rendimiento en la estimación del algoritmo con características utilizando Fourier mejora considerablemente a un valor de $98,78 \pm 0,28\%$ y

el sistema con características utilizando la FRFT obtiene 100% de exactitud. Lo anterior muestra experimentalmente que incluir información de la base de datos 2 en el entrenamiento mejora el rendimiento en la identificación de datos con distorsión de onda achatada en la alimentación. En este caso de análisis no se consideró relevante presentar las matrices de confusión debido a que los sistemas logran un alto rendimiento en la predicción.

Tabla 5: Exactitud en la identificación de cargas para el caso B.

características	error (%)	Exactitud(%)
Basada en FRFT	0	100
Basada en Fourier	0,14	98,78 ± 0,28

Fuente. Elaboración propia

4.3 Caso C

Se entrenan los sistemas de identificación con la base de datos 1 y una muestra por cada clase de la base de datos 2. Lo anterior para comprobar el rendimiento de los sistemas cuando solo un evento de la base de datos 2 por combinación es incluida en el entrenamiento. En la Tabla 6 se listan los resultados obtenidos, la exactitud en identificación es mayor en ambos sistemas en comparación con el caso de análisis A. Estos resultados muestran que el rendimiento en la identificación de datos con distorsión incrementa sí un evento de este escenario por combinación es incluido en el entrenamiento.

Tabla 6: Exactitud en la identificación de cargas para el caso C.

características	error (%)	Exactitud(%)
Basada en FRFT	0	100
Basada en Fourier	0,32	93,62 ± 0,63

Fuente. Elaboración propia

5 CONCLUSIONES

En este trabajo se comprueba experimentalmente el efecto de una distorsión de onda achatada en la alimentación de los dispositivos sobre dos sistemas de identificación de cargas: uno con extracción de características mediante Fourier y otro mediante transformada fraccional de Fourier. Para analizar este efecto, se analizan tres casos donde se varía el conjunto de entrenamiento y se prueba el sistema con un conjunto de datos distorsionados.

Cuando se entrena sin datos distorsionados (Caso A), se obtienen exactitudes de 70,26% y 98,67% para el sistema basado en Fourier y FRFT, respectivamente. Cuando en el 2% de los datos de entrenamiento se incorporan muestras del escenario con distorsión (Caso B), se logran exactitudes de 98,78% y 100%, respectivamente. Por úl-

timo, al incluir en el conjunto de entrenamiento un evento con información distorsionada por cada aparato (Caso C), se logra una exactitud en la estimación de 93,62% y 100%, respectivamente.

El sistema con extracción de características utilizando la FRFT mantiene un alto rendimiento comparado con que el que utiliza Fourier, aun cuando se presenta la distorsión en la fuente de alimentación. Para ambos tipos de sistemas la exactitud aumenta cuando se agregan datos de mediciones con distorsión en el entrenamiento, incluso con una información poco significativa, como en el caso C. Esto sugiere que en el entrenamiento del sistema con características utilizando la FRFT no se requieren datos cuando se presenta una distorsión de onda achatada. El sistema logra un alto rendimiento en la identificación de este escenario y su rendimiento mejora cuando el volumen de la base de datos incrementa.

REFERENCIAS

- [1] C. Fischer, "Feedback on household electricity consumption: a tool for saving energy?" *Energy efficiency*, vol. 1, no. 1, pp. 79–104, 2008.
- [2] K. Ehrhardt-Martinez, K. A. Donnelly, S. Laitner *et al.*, "Advanced metering initiatives and residential feedback programs: a meta-review for household electricity-saving opportunities." American Council for an Energy-Efficient Economy Washington, DC, 2010.
- [3] I. Abubakar, S. Khalid, M. Mustafa, H. Shareef, and M. Mustapha, "An overview of non-intrusive load monitoring methodologies," in *Energy Conversion (CENCON), 2015 IEEE Conference on*. IEEE, 2015, pp. 54–59.
- [4] A. Zoha, A. Gluhak, M. A. Imran, and S. Rajasegarar, "Non-intrusive load monitoring approaches for disaggregated energy sensing: A survey," *Sensors*, vol. 12, no. 12, pp. 16 838–16 866, 2012.
- [5] H.-T. Yang, H.-H. Chang, and C.-L. Lin, "Design a neural network for features selection in non-intrusive monitoring of industrial electrical loads," in *2007 11th International Conference on Computer Supported Cooperative Work in Design*. IEEE, 2007, pp. 1022–1027.
- [6] H.-H. Chang, P.-C. Chien, L.-S. Lin, and N. Chen, "Feature extraction of non-intrusive load-monitoring system using genetic algorithm in smart meters," in *e-Business Engineering (ICEBE), 2011 IEEE 8th International Conference on*. IEEE, 2011, pp. 299–304.
- [7] X. Wang, D. Lei, J. Yong, L. Zeng, and S. West, "An online load identification algorithm for non-

- intrusive load monitoring in homes,” in *Intelligent Sensors, Sensor Networks and Information Processing, 2013 IEEE Eighth International Conference on*. IEEE, 2013, pp. 1–6.
- [8] D. C. Bergman, D. Jin, J. P. Juen, N. Tanaka, C. A. Gunter, and A. K. Wright, “Distributed non-intrusive load monitoring,” in *Innovative Smart Grid Technologies (ISGT), 2011 IEEE PES*. IEEE, 2011, pp. 1–8.
- [9] Y.-C. Su, K.-L. Lian, and H.-H. Chang, “Feature selection of non-intrusive load monitoring system using stft and wavelet transform,” in *e-Business Engineering (ICEBE), 2011 IEEE 8th International Conference on*. IEEE, 2011, pp. 293–298.
- [10] C. Duarte, P. Delmar, K. W. Goossen, K. Barner, and E. Gomez-Luna, “Non-intrusive load monitoring based on switching voltage transients and wavelet transforms,” in *Future of Instrumentation International Workshop (FIW), 2012*. IEEE, 2012, pp. 1–4.
- [11] J. M. Gillis and W. G. Morsi, “Non-intrusive load monitoring using semi-supervised machine learning and wavelet design.”
- [12] Y. Jimenez, C. Duarte, J. Petit, and G. Carrillo, “Feature extraction for nonintrusive load monitoring based on s-transform,” in *Power Systems Conference (PSC), 2014 Clemson University*. IEEE, 2014, pp. 1–5.
- [13] D. Srinivasan, W. Ng, and A. Liew, “Neural-network-based signature recognition for harmonic source identification,” *IEEE Transactions on Power Delivery*, vol. 21, no. 1, pp. 398–405, 2006.
- [14] Y. Jimenez, C. Duarte, J. Petit, J. Meyer, P. Schegner, and G. Carrillo, “Steady state signatures in the time domain for nonintrusive appliance identification,” *Ingeniería e Investigación*, vol. 35, pp. 58–64, 2015.
- [15] L. B. Almeida, “The fractional fourier transform and time-frequency representations,” *IEEE Transactions on signal processing*, vol. 42, no. 11, pp. 3084–3091, 1994.
- [16] A. McBride and F. Kerr, “On namias’s fractional fourier transforms,” *IMA Journal of applied mathematics*, vol. 39, no. 2, pp. 159–175, 1987.
- [17] H. M. Ozaktas, M. A. Kutay, and D. Mendlovic, “Introduction to the fractional fourier transform and its applications,” *Advances in imaging and electron physics*, vol. 106, pp. 239–291, 1999.
- [18] M. Bramer, *Principles of data mining*. Springer, 2007, vol. 180.

