

Modelo de predicción de demanda de energía eléctrica mediante técnicas Set-Membership

Jimena Diaz^a, Jose Vuelvas^a, Fredy Ruiz^{a,*}, Diego Patino^a

^aDepartamento de Ingeniería Electrónica, Pontificia Universidad Javeriana, Carrera 7, No. 40-62, Bogotá, Colombia.

Resumen

En este artículo se propone un modelo para la predicción de demanda de energía eléctrica a corto plazo empleando técnicas de estimación Set Membership. El modelo está compuesto por una componente periódica y una componente no-lineal auto-regresiva generada por un modelo no-paramétrico adaptable que incorpora datos recientes al conjunto de identificación en cada iteración del algoritmo. El modelo es evaluado en un caso de estudio con más de 13,000 muestras de demanda horaria a lo largo de tres años, registradas en un municipio rural de Colombia. El desempeño del estimador se compara con un modelo lineal auto-regresivo y un modelo Set Membership con conjunto de identificación fijo. Los resultados muestran que el estimador propuesto logra predecir la demanda de energía con un error RMS inferior al 2.5 % en datos de validación, empleando solo un 5 % de los datos disponibles para la construcción del modelo.

Palabras Clave:

Gestión y demanda energética, filtrado adaptativo, identificación de sistemas

A Set-Membership approach to short-term electric load forecasting

Abstract

This work presents a model for the short-term forecast of electric load, based on Set-Membership techniques. The model is formed by a periodic component and an adaptive non-linear autoregressive component. The identification set of the non-linear model is increased at each estimation step. The model is evaluated in a case study with more than 13,000 samples of hourly sampled energy demand, registered during three years at a rural town in Colombia. The performance of the estimator is evaluated and confronted to a linear autoregressive model and a standard Set-Membership model with fixed identification set. Results show that the proposed estimator is able to predict demand with an RMS error below 2.5 % for validation data, using just a 5 % of the available dataset for the model identification.

Keywords:

Electric load management, Adaptive filtering, System identification.

1. Introducción

En los últimos años el consumo de energía eléctrica ha aumentando de forma significativa debido a la industrialización y al aumento de dispositivos eléctricos en los hogares (Parkpoom et al., 2004). Dado que en la generación de energía eléctrica predominan fuentes provenientes de combustibles fósiles, existe una presión mundial para migrar la producción a fuentes renovables y modernizar los sistemas eléctricos con el objetivo

de reducir la producción de gases de efecto invernadero (Lopes et al., 2007). Sin embargo, la integración de fuentes renovables no controlables plantea retos mayores a la operación de los sistemas de potencia (Ueckerdt et al., 2015).

En la búsqueda de soluciones para mejorar la eficiencia y resiliencia de las redes eléctricas ha surgido el concepto de micro-red (Alam et al., 2012). Éstos sistemas están formados por grupo de recursos interconectados de generación y consu-

*Autor para correspondencia: ruizf@javeriana.edu.co

mo de energía, que algunas veces integran fuentes no convencionales (solar y/o eólica) y unidades de almacenamiento (baterías y vehículos eléctricos), ver por ejemplo (Bordons et al., 2015). Estas soluciones presentan alta variabilidad en la generación, debido a las fluctuaciones que presentan las fuentes renovables. Una de las formas de compensar estas fluctuaciones es integrando sistemas de control que mantengan el balance en la red. Para funcionar adecuadamente, estos sistemas requieren, en su mayoría, modelos de predicción de demanda en circuitos de pequeña y mediana escala. Por ejemplo, en (He et al., 2016), el pronóstico del consumo eléctrico en redes eléctricas permite realizar la gestión de la demanda, la integración de energías renovables, la planificación y programación del almacenamiento de la energía.

De acuerdo con (He et al., 2016) y (Oliveira et al., 2011), algunos factores externos causan gran influencia en la predicción de la demanda eléctrica, tales como elementos climáticos (época del año, la temperatura, la lluvia, etc.), factores temporales (vacaciones, año nuevo, etc.) y factores atípicos (huelgas, días de fiesta, etc.). Adicionalmente, la predicción de demanda se puede efectuar en tres niveles: Predicción a corto plazo (*Short Term Load forecasting-STLF*) que abarca un horizonte de segundos a horas (1 día), predicción a mediano plazo (*Medium Term Load forecasting-MTLF*) que tiene un horizonte de horas a semanas (1 día a 1 año) y predicción a largo plazo, cuyo horizonte es de años (1 a 10 años) (Alfares and Nazeeruddin, 2002). En este trabajo se desarrollan modelos de predicción a corto plazo.

En la literatura se encuentra diversas soluciones que permiten realizar la predicción de demanda a corto plazo. Estos modelos varían en su complejidad y la información requerida para resolver el problema de estimación. Algunos modelos se basan en principios físicos de las cargas que consumen la energía, entre ellos (Acosta et al., 2011) y (Mikati et al., 2012). Estas soluciones son útiles cuando la cantidad de cargas es reducida. En los casos en que no es posible caracterizar individualmente las cargas, las aproximaciones más usadas son la regresión múltiple, modelos auto-regresivos con entradas exógenas (ARX), métodos por lógica difusa, filtros de Kalman, sistemas expertos, redes neuronales artificiales (RNA), entre otras (Alfares and Nazeeruddin, 2002). Las soluciones estadísticas requieren para su desarrollo y sintonización que la demanda sea modelada como un proceso estocástico, mientras que las soluciones construidas como sistemas inteligentes no requieren el modelado previo de la demanda, debido a que aprenden a partir de la información contenida en datos históricos. En particular, las RNA presentan algunas ventajas como el aprendizaje adaptable y la capacidad de generalización (Nose-Filho et al., 2011), encontrándose varias investigaciones en torno a este enfoque (Singh et al., 2015; Yalcinoz and Eminoglu, 2005; Dwijayanti and Hagan, 2013). También se encuentran alternativas con modelos híbridos, en donde se combinan dos o más representaciones con el fin de encontrar una nueva que presente mejor desempeño. Por ejemplo, varios autores (Sadai et al., 2014; Hanmandlu and Chauhan, 2011; Hu et al., 2015; Kapgate and Mohod, 2014; He et al., 2016), realizan la predicción a corto plazo empleando redes neuronales, sistemas expertos o lógica difusa, junto a un modelo estadístico. Tanto las aproximaciones estadísticas como aquellas basadas en sistemas inteligentes

basan sus soluciones en una hipótesis de comportamiento estocástico de los fenómenos que generan los datos.

Una de las limitaciones de los métodos basados en sistemas inteligentes es el requerimiento de una gran cantidad de datos para la sintonización de los modelos. Además, los algoritmos de sintonización requieren la solución de problemas de optimización con alta carga computacional. Este trabajo propone el desarrollo de modelos no lineales para la predicción de la demanda eléctrica a corto plazo basados en la teoría de estimación Set Membership descrita en (Milanese and Novara, 2004). Las técnicas Set Membership son útiles para la construcción de modelos a partir de datos con los que no es posible garantizar que la fuente de información presenta un comportamiento estocástico y en situaciones en las que no se cuenta con grandes cantidades de datos históricos. La hipótesis fundamental en esta aproximación es que los datos están afectados por ruido acotado en algún tipo de norma. Este tipo de señal es conocida como UBB (*Unknown But Bounded*) por su sigla en inglés. En este trabajo se asume que las medidas de demanda de energía están acotadas por ruido de amplitud limitada, sin requerir consideraciones sobre sus características estocásticas.

Los modelos desarrollados están compuestos por una componente periódica, construida a partir de un análisis espectral de la serie de tiempo y una componente auto-regresiva generada por un modelo no-paramétrico construido mediante el método de identificación propuesto por (Milanese and Novara, 2005). Se presentan dos tipos de modelos tipo caja negra. El primero se construye a partir de un conjunto de datos de tamaño fijo, obtenido al inicio del experimento. El segundo es un modelo adaptable que incorpora datos frescos al conjunto de identificación en cada iteración del algoritmo.

Dado que los modelos desarrollados son no-paramétricos, no se requiere de algoritmos complejos de estimación. En este trabajo se describen los algoritmos para estimar los dos únicos parámetros requeridos por el método propuesto. Además, se muestra cómo estos métodos son capaces de generalizar el comportamiento de la serie de tiempos a partir de muy pocos datos. Por otro lado, se propone un modelo en el que los datos frescos pasan a ser parte de la base de datos que representa el modelo no-paramétrico y cómo esta modificación permite mejorar considerablemente el desempeño del estimador.

La metodología propuesta es aplicada a un caso de estudio en Colombia y comparada con un modelo de predicción lineal. Particularmente, se estudia este enfoque para la serie de consumo horario de energía eléctrica en el municipio de Quebradanegra (Colombia). Se dispone de más de 13.000 muestras de consumo a lo largo de tres años. De éstos, menos del 10 % de las muestras son empleadas para la estimación de los modelos, mostrando que estas técnicas son mucho más eficientes en comparación con modelos como las redes neuronales, que requieren una gran cantidad de datos en la fase de entrenamiento. Los resultados muestran que los modelos basados en técnicas Set Membership ofrecen un desempeño superior al predictor lineal y además, que el modelo adaptable mejora el desempeño ante días y valores atípicos. En promedio, el error de estimación se reduce en un 20 % respecto al desempeño de un modelo lineal, cuando se emplea el modelo Set Membership estándar. Mientras que el modelo Set Membership adaptable propuesto en este trabajo reduce el error promedio en un 50 %.

El artículo está organizado de la siguiente manera: Sección 2: Algoritmo de estimación Set Membership adaptable; Sección 3: Presentación del caso de estudio y sus resultados; Sección 4: Conclusiones y trabajos futuros.

2. Estimación Set Membership

En esta sección se explica brevemente el método de estimación de modelos no-lineales mediante técnicas Set Membership, para luego presentar el algoritmo adaptable propuesto en este trabajo.

2.1. Teoría de estimación Set Membership no lineal

Este método de identificación de sistemas dinámicos no-lineales ha sido descrito detalladamente para sistemas con entradas exógenas en (Milanese and Novara, 2004) y para modelos de series de tiempo en (Milanese and Novara, 2005).

Considérese un sistema NARX (no lineal auto-regresivo con entradas exógenas), expresado de la forma:

$$y_t = f_0(w_t) \tag{1}$$

donde $w_t = [y_{t-1} \cdots y_{t-n_y} u_t \cdots u_{t-n_u}]$ es el vector de entradas y salidas pasadas, siendo y_t la salida y u_t la entrada en el tiempo t , respectivamente. n_y y n_u indican la cantidad de valores pasados de entrada y salida que definen el orden del sistema.

Suponiendo que la función f_0 que describe al sistema es desconocida, se quiere encontrar una estimación \hat{f} de f_0 dado un conjunto de mediciones:

$$\tilde{y}_t = f_0(\tilde{w}_t) + d_t \quad t = 1, \dots, N \tag{2}$$

donde \tilde{y}_t y \tilde{w}_t son mediciones ruidosas de la salida y del vector de entradas y salidas pasadas en el instante t . d_t es el error en el modelo (1) causado por el ruido en los datos.

A pesar de que la función f_0 que representa el sistema es desconocida, se realizan las siguientes hipótesis:

- f_0 es una función Lipschitz-continua y su gradiente está acotado por una constante γ , i.e.,

$$f_0 \in F(\gamma) \doteq \{f \in C_1(W) : \|f'(w)\| \leq \gamma, \forall w \in W\} \tag{3}$$

donde $f'(w)$ corresponde al gradiente de $f(w)$, $\|x\| \doteq \sqrt{\sum_{i=1}^n x_i^2}$ es la norma euclidiana y W es un conjunto acotado que define el dominio de f .

- El error en el modelo está acotado en norma infinito por la señal ε_t

$$D^N \in D \doteq \{[d_1, \dots, d_N] : |d_t| \leq \varepsilon_t, t = 1, \dots, N\}. \tag{4}$$

En la teoría de estimación Set Membership es importante identificar el conjunto de sistemas factibles (*Feasible Systems Set-FSS*), es decir, el conjunto de todos los sistemas consistentes con las hipótesis, eqs. (3) and (4), y los datos, eq. (2):

$$FSS^N = \{f \in F(\gamma) : |\tilde{y}_t - f(\tilde{w}_t)| \leq \varepsilon_t, t = 1, \dots, N\}$$

Un resultado fundamental en esta formulación es que, si las hipótesis son ciertas, se cumple que: $FSS^T \neq \emptyset$ y $f_0 \in FSS^T$. Es decir que el verdadero sistema pertenece al conjunto de sistemas factibles. Adicionalmente, se tiene que para cualquier valor de su argumento $w \in W$, $f_0(w)$ está acotada como:

$$\underline{f}(w) \leq f_0(w) \leq \bar{f}(w), \forall w \in W \tag{5}$$

siendo:

$$\bar{f}(w) = \sup_{f \in FSS^N} f(w) \tag{6}$$

$$\underline{f}(w) = \inf_{f \in FSS^N} f(w) \tag{7}$$

$\underline{f}(w)$ y $\bar{f}(w)$ son cotas de $f_0(w)$, evaluadas como:

$$\bar{f}(w) = \min_{t=1, \dots, N} (\bar{h}_t + \gamma \|w - \tilde{w}_t\|) \tag{8}$$

$$\underline{f}(w) = \max_{t=1, \dots, N} (\underline{h}_t - \gamma \|w - \tilde{w}_t\|) \tag{9}$$

$$\bar{h}_t = \tilde{y}_t + \varepsilon_t \tag{10}$$

$$\underline{h}_t = \tilde{y}_t - \varepsilon_t \tag{11}$$

La estimación óptima de $f_0(w)$ está dada por:

$$\hat{f}_c(w) = \frac{\bar{f}(w) + \underline{f}(w)}{2} \tag{12}$$

Además, en (Milanese and Novara, 2004) se demuestra que:

- $\bar{f}(w)$ y $\underline{f}(w)$ son cotas óptimas de $f_0(w)$.
- $\bar{f}(w)$ y $\underline{f}(w)$ son Lipschitz continuas.
- \hat{f}_c es una aproximación óptima de f_0 para toda norma $L_p(W)$ con $p \in [1, \infty]$.

donde el criterio óptimo es:

$$\hat{f}_{opt} = \arg \inf_{\hat{f}} \sup_{f \in FSS^N} \|f - \hat{f}\|_p. \tag{13}$$

Observación: El enfoque Set Membership permite obtener un modelo no-paramétrico. Es decir, el modelo está embebido en los datos y depende únicamente de los valores de ε_t y γ . El siguiente teorema permite validar (o invalidar) cualquier pareja de estos valores.

Teorema 1. *Las condiciones necesarias y suficientes que garantizan que $FSS^T \neq \emptyset$, a partir de los datos disponibles en (2), son:*

- *Condición necesaria:*

$$\bar{f}(\tilde{w}_t) \geq \underline{h}_t, t = 1, \dots, N. \tag{14}$$

- *Condición suficiente:*

$$\bar{f}(\tilde{w}_t) > \underline{h}_t, t = 1, \dots, N. \tag{15}$$

Demostración: Ver (Milanese and Novara, 2004).

En el caso en que la cota del error se considere invariante con el tiempo, este teorema permite construir una superficie en el espacio (ε_t, γ) , la cual separa los parámetros inválidos de aquellos compatibles con los datos. Dicha superficie viene expresada como:

$$\gamma^*(\varepsilon_t) = \inf_{FSS^N \neq 0} \gamma, \quad (16)$$

ε_t y γ deben ser seleccionados dentro de la región de valores válidos.

Una vez definidas y validadas las hipótesis sobre ε_t y γ , la calidad de un estimador se mide como el error resultante sobre datos nuevos, no usados para construir el modelo. En particular se evalúa el error cuadrático medio (RMSE),

$$RMSE = \sqrt{\frac{\sum_{t=1}^N (\tilde{y}_t - \hat{y}_t)^2}{N}} \quad (17)$$

y el error porcentual absoluto medio (MAPE),

$$MAPE = \frac{1}{N} \sum_{t=1}^N \left| \frac{\tilde{y}_t - \hat{y}_t}{\tilde{y}_t} \right| * 100 \quad (18)$$

Éstas son las medidas más empleadas en la literatura de estimación de demanda eléctrica.

A continuación se presenta un algoritmo que permite construir una superficie de validación de la forma (16) a partir de un conjunto de datos de la forma (2).

Nótese que el algoritmo 2.1 presenta cuatro lazos anidados para validar una serie de hipótesis (ε, γ) a partir de un conjunto de datos con N muestras. Los dos ciclos internos deben recorrer en su totalidad el conjunto de identificación, por lo que su complejidad es al menos $O(N^2)$. Este proceso es computacionalmente demandante, sin embargo, se trata del proceso de validación de hipótesis que se realiza fuera de línea para ajustar el modelo.

Una vez definidos los parámetros (ε, γ) , se cuenta con un modelo no-paramétrico que permite estimar la salida futura del sistema dado un vector cualquiera de datos pasados de entrada y salida. El siguiente algoritmo permite evaluar la estimación óptima de $f_0(w)$, para cualquier nuevo valor de entrada w .

El algoritmo 2.2 contiene un único ciclo que recorre el conjunto de datos de identificación. Su complejidad es $O(nN)$ donde n es la dimensión del vector w . En caso de que el conjunto de identificación resulte demasiado grande y el tiempo de cálculo sea prohibitivo para su aplicación en línea, existen métodos de ejecución rápida de modelos tipo Set Membership, ver por ejemplo (Castano and Ruiz, 2013).

2.2. Modelo Set Membership adaptable

En este apartado se propone un modelo adaptable basado en la teoría de estimación Set Membership. A diferencia del modelo presentado en la sección anterior, en el cual el conjunto de datos de identificación definido en (2) es fijo y el algoritmo 2.2 evalúa las cotas óptimas de estimación sobre las N muestras disponibles, en el modelo propuesto el conjunto de identificación es actualizado con nuevas muestras en cada iteración de la predicción.

El algoritmo 2.3 muestra cómo se ejecuta la solución adaptable propuesta. Nótese que en este algoritmo se ejecutan dos ciclos que recorren conjuntos diferentes de muestras entrada-salida. El primer ciclo, indizado por j , recorre las N muestras disponibles en el conjunto de identificación. Mientras que el segundo ciclo, indizado por k , recorre las M muestras obtenidas en las ejecuciones pasadas del estimador entre $t - M$ y $t - 1$.

Algoritmo 2.1 Validación de hipótesis

function Validación

for $\varepsilon = \text{minerror} : \text{maxerror}$

// para un intervalo de error de modelos dado //

$q=1;$

$\gamma^U = \gamma_{\text{max}}$

$\gamma^L = \gamma_{\text{min}}$

$\Delta\gamma = \gamma^U - \gamma^L$

$\gamma = (\gamma^U + \gamma^L)/2$

while $\Delta\gamma \geq \text{tol}$

$\text{flag} = 0;$

for $i = 1 : N$

// para todas las muestras del conjunto de identificación//

$w = \tilde{w}_i;$ // para el dato i -ésimo //

$f_u = +\infty;$ // Cota superior //

$f_d = -\infty;$ // Cota inferior //

for $j = 1 : N$

if $i \neq j$

// Cotas dados $(\tilde{w}_j, \tilde{y}_j)$ //

$f_s = \tilde{y}_j + \varepsilon + \gamma \|w - \tilde{w}_j\|;$

$f_i = \tilde{y}_j - \varepsilon - \gamma \|w - \tilde{w}_j\|;$

// Actualización de cotas //

$f_u = \min(f_u, f_s);$

$f_d = \max(f_d, f_i);$

end if

end for

// Verificación de condición suficiente //

if $f_u \leq \tilde{y}_i - \varepsilon;$ // hipótesis falsa //

$\text{flag} = 1;$

Break;

end if

end for

if $\text{flag} == 1;$ // hipótesis falsa //

$\gamma^L = \gamma;$

else ; // hipótesis valida //

$\gamma^U = \gamma;$

end if

$\Delta\gamma = \gamma^U - \gamma^L;$

$\gamma = (\gamma^U + \gamma^L)/2;$

end while

$P_q = [\varepsilon, \gamma];$

$q++;$

end for

end function

Algoritmo 2.2 Ejecución modelo Set Membership

```

function  $\hat{f}_c = SM(w, \gamma, \varepsilon)$ 
    // Definición de cotas //
     $f_u = +\infty$ ; // Cota superior //
     $f_d = -\infty$ ; // Cota inferior //
    for  $j = 1 : N$ 
        // Cotas dados ( $\tilde{w}_j, \tilde{y}_j$ ) //
         $f_s = \tilde{y}_j + \varepsilon + \gamma \|w - \tilde{w}_j\|$ ;
         $f_i = \tilde{y}_j - \varepsilon - \gamma \|w - \tilde{w}_j\|$ ;
        // Actualización de cotas //
         $f_u = \min(f_u, f_s)$ ;
         $f_d = \max(f_d, f_i)$ ;
    end for
    // Evaluación de estimación central //
     $\hat{f}_c = (f_u + f_d) * 0,5$ 
end function
    
```

Algoritmo 2.3 Set Membership adaptable

```

function  $f_c = SM(w_t, \gamma, \varepsilon)$ 
    // Definición de cotas //
     $f_u = +\infty$ ; // Cota superior //
     $f_d = -\infty$ ; // Cota inferior //
    for  $j = 1 : N$ 
        // Cotas dados ( $\tilde{w}_j, \tilde{y}_j$ ) //
         $f_s = \tilde{y}_j + \varepsilon + \gamma \|w - \tilde{w}_j\|$ ;
         $f_i = \tilde{y}_j - \varepsilon - \gamma \|w - \tilde{w}_j\|$ ;
        // Actualización de cotas //
         $f_u = \min(f_u, f_s)$ ;
         $f_d = \max(f_d, f_i)$ ;
    end for
    for  $k = 1 : M$ 
        // Cotas dados ( $\bar{w}_k, \bar{y}_k$ ) //
         $f_s = \bar{y}_{t-k} + \varepsilon + \gamma \|w - \bar{w}_{t-k}\|$ ;
         $f_i = \bar{y}_{t-k} - \varepsilon - \gamma \|w - \bar{w}_{t-k}\|$ ;
        // Actualización de cotas //
         $f_u = \min(f_u, f_s)$ ;
         $f_d = \max(f_d, f_i)$ ;
    end for
    // Evaluación de estimación central //
     $f_c = (f_u + f_d) * 0,5$ 
    // Actualización de conjunto de datos //
     $\bar{y} = [\bar{y}_{2:M-1}; \bar{y}_{t-1}]$ 
     $\bar{w} = [\bar{w}_{2:M-1}; \bar{w}_{t-1}]$ 
end function
    
```

Este incremento en las muestras disponibles permite reducir el error de predicción debido a que los datos que se agregan al conjunto de identificación contienen información del com-

portamiento reciente de la serie de tiempo. En cuanto a la complejidad computacional del algoritmo, esta se incrementa como $O(n(N + M))$ dado que los dos ciclos requeridos para obtener la estimación se ejecutan de forma secuencial. Es importante resaltar que para que este modelo sea válido, se debe cumplir que las nuevas muestras de demanda no invaliden los valores de ε_t y γ . De esta manera no se requiere ejecutar nuevamente el algoritmo de validación, lo cual incrementaría la complejidad del mismo, limitando su aplicación en línea.

3. Caso de estudio: Quebradanegra

En esta sección se describe la aplicación de los algoritmos de estimación presentados, en la predicción de demanda horaria de energía eléctrica en datos reales. Primero se describe la base de datos empleada y el tratamiento de los datos antes de la construcción de los modelos. A cada conjunto de datos se le realizó la eliminación de las componentes periódicas, el manejo de los valores atípicos y la normalización. En segundo lugar, se muestra el desempeño ofrecido por cada estimador y se analizan los resultados.

3.1. Descripción de los datos y procesamiento preliminar

Los datos utilizados en este caso de estudio corresponden a la demanda horaria de energía eléctrica del municipio de Quebradanegra, localizado en la región central de Colombia, con una altitud de 1244 metros sobre el nivel del mar y una temperatura media de 19°C. La base de datos disponible contiene los datos de demanda de energía con resolución horaria en el periodo comprendido entre Febrero de 2014 hasta Febrero de 2016 de la subestación Útica, circuito de Quebradanegra. Además, se cuenta con datos climatológicos como radiación solar y temperatura para el periodo entre Enero y Diciembre de 2014. La información de la demanda eléctrica fue suministrada por la Empresa de Energía de Cundinamarca (EEC) y los datos meteorológicos por el Instituto de hidrología, meteorología y estudios ambientales de Colombia (IDEAM).

En la Tabla 1 se presenta el número de muestras que se tienen para cada año; los datos de la demanda de energía eléctrica horaria se muestra en la Figura 1; mientras que las variables meteorológicas como la radiación solar horaria, radiación solar promedio y temperatura horaria, del año 2014 se presentan en la Figura 2.

Tabla 1: Número de muestras disponibles por año

Año	Muestras (N)
2014	7896
2015	3936
2016	1440

En las figuras 1 y 2 se evidencia la presencia de algunos valores atípicos. Además, debido a fallas tecnológicas, existen intervalos de tiempo en donde no hay información registrada. Por ejemplo, el registro de temperatura para el año 2014 presenta registro de 0°C durante 130 muestras del mes de enero.

Las muestras fueron separadas en varios conjuntos de datos, en los que no se presentan más de tres datos ausentes de forma consecutiva. Esta agrupación se muestra en la Tabla 2. Allí se

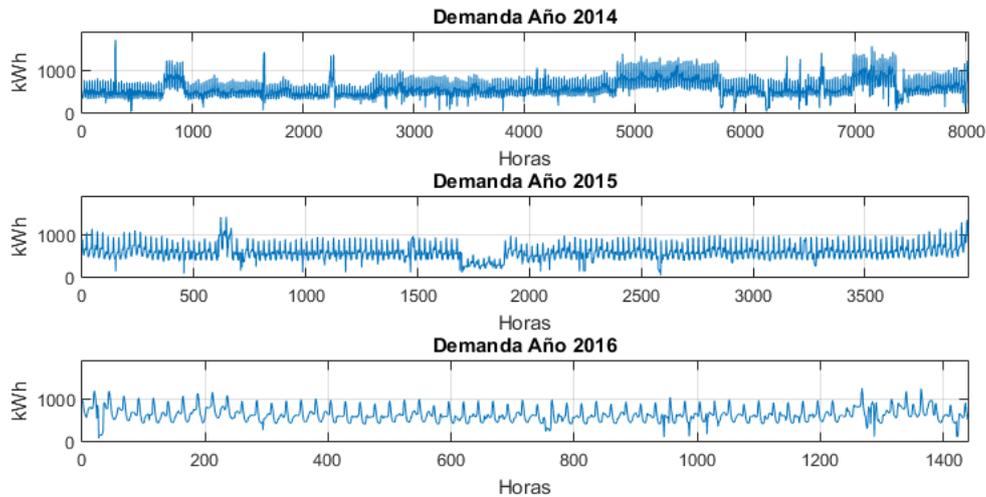


Figura 1: Muestras de demanda de energía eléctrica disponibles

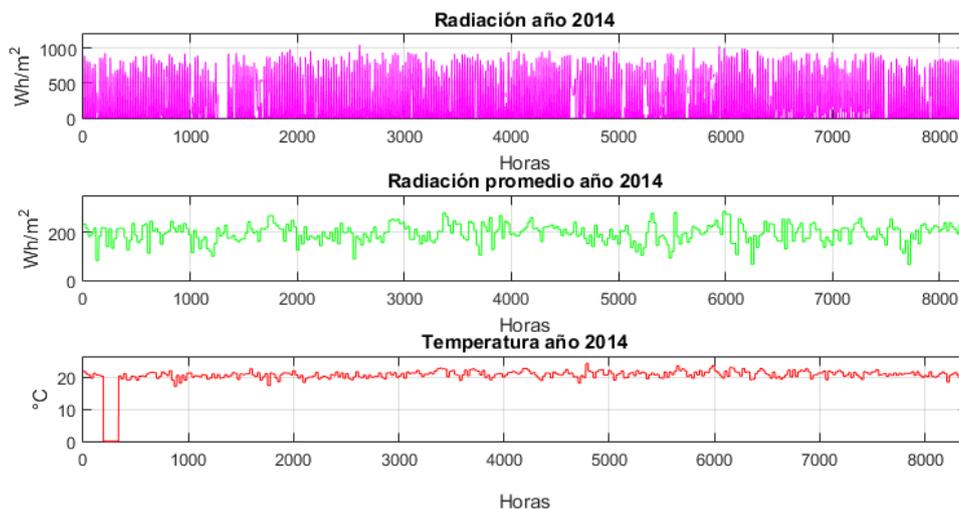


Figura 2: Variables meteorológicas disponibles para el año 2014

señala el tamaño de cada conjunto y los eventos significativos, donde Fest hace referencia a la cantidad de días festivos en el intervalo; Atípicos corresponde a los días que presentan más de 3 horas consecutivas con valores muy altos y Out indica el número de datos que se encuentran con valores en cero.

Los datos disponibles fueron divididos en conjuntos cuyo tamaño depende de la disponibilidad de datos continuos sin muestras faltantes. Los dos conjuntos más extensos se seleccionan como datos de identificación. El conjunto denominado **D1** corresponde al mes de marzo de 2014 y contiene 880 muestras. El conjunto **D2** corresponde al mes de agosto de 2014 y contiene 648 muestras. Estos dos conjuntos contienen el 11 % de los datos y como se verá más adelante, resultan suficientes para construir modelos de predicción de demanda para el caso de estudio. El restante 89 % de la información se emplea para realizar la validación de los modelos.

Debido a que la serie de tiempo presenta componentes periódicas, se procede a realizar un procesamiento preliminar de la información con el fin de eliminar esta componente de la si-

guiente manera:

- Los datos presentan un valor promedio diferente de cero, correspondiente a la demanda media de energía horaria. Para contrarrestar esto, se realiza la sustracción de la media aritmética a cada uno de los valores de la serie de tiempo:

$$\tilde{y}_t^{mean} = \frac{1}{N} \sum_{t=1}^N \tilde{y}_t \quad (19)$$

Se debe resaltar que en la evaluación de la media se emplea todo el conjunto de datos disponible.

- Para eliminar la estacionalidad se busca una representación de la función mediante una combinación lineal de m armónicas a partir de un análisis espectral de los datos. El modelo periódico es de la forma:

$$\hat{y}_t^p = \sum_{i=0}^m (\alpha_i \text{sen}(f_i t) + \beta_i \text{cos}(f_i t)) \quad (20)$$

$$\begin{pmatrix} \hat{y}_1^p \\ \hat{y}_2^p \\ \hat{y}_3^p \\ \vdots \\ \hat{y}_N^p \end{pmatrix} = \begin{pmatrix} \text{sen}(f_1 t_1) & \cdots & \text{sen}(f_m t_1) & \text{cos}(f_1 t_1) & \cdots & \text{cos}(f_m t_1) \\ \text{sen}(f_1 t_2) & \cdots & \text{sen}(f_m t_2) & \text{cos}(f_1 t_2) & \cdots & \text{cos}(f_m t_2) \\ \text{sen}(f_1 t_3) & \cdots & \text{sen}(f_m t_3) & \text{cos}(f_1 t_3) & \cdots & \text{cos}(f_m t_3) \\ \vdots & \ddots & \vdots & \vdots & \ddots & \vdots \\ \text{sen}(f_1 t_N) & \cdots & \text{sen}(f_m t_N) & \text{cos}(f_1 t_N) & \cdots & \text{cos}(f_m t_N) \end{pmatrix} \begin{pmatrix} \alpha_1 \\ \vdots \\ \alpha_m \\ \beta_1 \\ \vdots \\ \beta_m \end{pmatrix}, \tag{21}$$

Donde \hat{y}_t^p es la estimación de la componente periódica de la demanda para el tiempo t , f_i cada una de las frecuencias donde la serie presenta energía y α_i y β_i son coeficientes que se deben estimar a partir de los datos.

Dado un conjunto de datos, la ecuación (20) se puede escribir de forma matricial como se muestra en la expresión (21), siendo N el tamaño del conjunto de datos.

Para identificar las m frecuencias $[f_1, f_2, \dots, f_m]$ presentes en la serie de tiempo, se realiza un análisis espectral de los datos del conjunto **D1**. El periodograma se muestra en la parte superior de la Figura 3. Los picos marcados indican las componentes con mayor energía que en este caso corresponden a periodos de 24, 12, 8, 6, 5, 4 y 3.5 horas. Finalmente, para estimar los coeficientes del modelo (20) se formula un problema de mínimos cuadrados, minimizando la distancia entre la demanda medida luego de sustraer la media y la señal periódica:

$$\{\alpha_i, \beta_i\} = \arg \min_{\alpha, \beta} \sum_{t=1}^N (\tilde{y}_t - y^{mean} - \hat{y}_t^p)^2 \tag{22}$$

A partir de los coeficientes α_i y β_i obtenidos como solución de (22) se genera una nueva serie de tiempo \tilde{y}_t^{np} , eliminando la componente periódica:

$$\tilde{y}_t^{np} = \tilde{y}_t - \hat{y}_t^p - y^{mean}. \tag{23}$$

La Figura 3 en la parte inferior muestra el resultado de la eliminación de la componente periódica en un subconjunto de **D1**.

Para la eliminación de los valores atípicos aún presentes en la serie se emplea un filtro de media móvil, (Dang, 2014). Finalmente, se efectúa una normalización respecto al máximo valor de la serie:

$$\tilde{y}_t^e = \frac{\tilde{y}_t^{np}}{scale} \tag{24}$$

Siendo $scale = \max |\tilde{y}_j^{np}|, j = 1, 2, \dots, N$.

3.2. Estimadores de la serie de tiempo

Una vez procesados los datos se construyen los modelos auto-regresivos que permiten obtener la predicción de demanda horaria. Se desarrollan tres modelos: una primera aproximación mediante un estimador lineal, una segunda aproximación empleando un modelo no lineal Set Membership a partir de un conjunto de datos fijo y por último, un modelo Set Membership no lineal adaptable.

A partir de los conjuntos **D1** y **D2** descritos previamente, se realiza la construcción de los modelos y su validación cruzada. Finalmente, el desempeño de los predictores se evalúa empleando la totalidad de los datos disponibles.

3.2.1. Modelo lineal

En principio, se construye un filtro de Wiener que permite estimar la demanda de la siguiente hora mediante un modelo auto-regresivo (AR) de la forma:

$$\hat{y}_t^l = \sum_{i=1}^n \theta_i \tilde{y}_{t-i}^e + \eta_t, \tag{25}$$

asumiendo que η_t es ruido blanco Gaussiano.

La estructura de este modelo está definida por la cantidad n de valores pasados de la variable \tilde{y}^e que se emplean para obtener la estimación. Para determinar el mejor orden n se construyen modelos de diferentes ordenes, entre $n = 1$ y $n = 6$, a partir de los conjuntos de datos **D1** y **D2**, seleccionados para la estimación. Enseguida se evalúan los errores RMSE y MAPE, definidos en (17) y (18), empleando validación cruzada. Los errores obtenidos se muestran en la Figura 4. Se observa que para el

Tabla 2: Grupos de datos de demanda eléctrica usados para la construcción y validación de estimadores

Año	Mes	Día inicio	Día Fin	Nº Datos	Eventos Significativos	Año	Mes	Día inicio	Día Fin	Nº Datos	Eventos Significativos
2014	Febrero	1	28	672	1 Atípico	2014	Agosto.1 (D2)	8	30	648	1 Fest, 9 Out, 4 Atípicos
2014	Febrero.1	14	28	360	8 Out	2014	Octubre	1	31	744	1 Fest, 1 Atípico
2014	Marzo	1	7	168	4 Atípicos	2014	Noviembre	1	30	720	2 Fest
2014	Marzo.1 (D1)	23	28	880	2 Atípicos	2014	Diciembre	1	31	744	4 Fest, 5 Out, 1 Atípico
2014	Abril	4	30	648	Semana Santa	2015	Enero	1	31	744	2 Fest, 1 Out
2014	Abril.1	4	10	240	-	2015	Febrero	1	28	672	-
2014	Abril.2	11	20	240	Semana Santa	2015	Marzo	1	28	672	1 Fest, 1 Out
2014	Abril.3	21	30	168	-	2015	Octubre	16	31	384	-
2014	Mayo.1	1	20	480	1 Fest, 4 Atípicos	2015	Noviembre	1	30	720	2 Fest, 1 Atípico
2014	Mayo.2	24	31	192	1 Atípico	2015	Diciembre	1	31	744	4 Fest
2014	Junio	1	30	720	3 Fest, 9 Out	2016	Enero	1	31	744	2 Fest, 2 Out
2014	Julio	1	31	744	3 Atípicos	2016	Febrero	1	29	696	2 Atípicos
2014	Agosto	1	22	528	5 Fest, 2 Out						

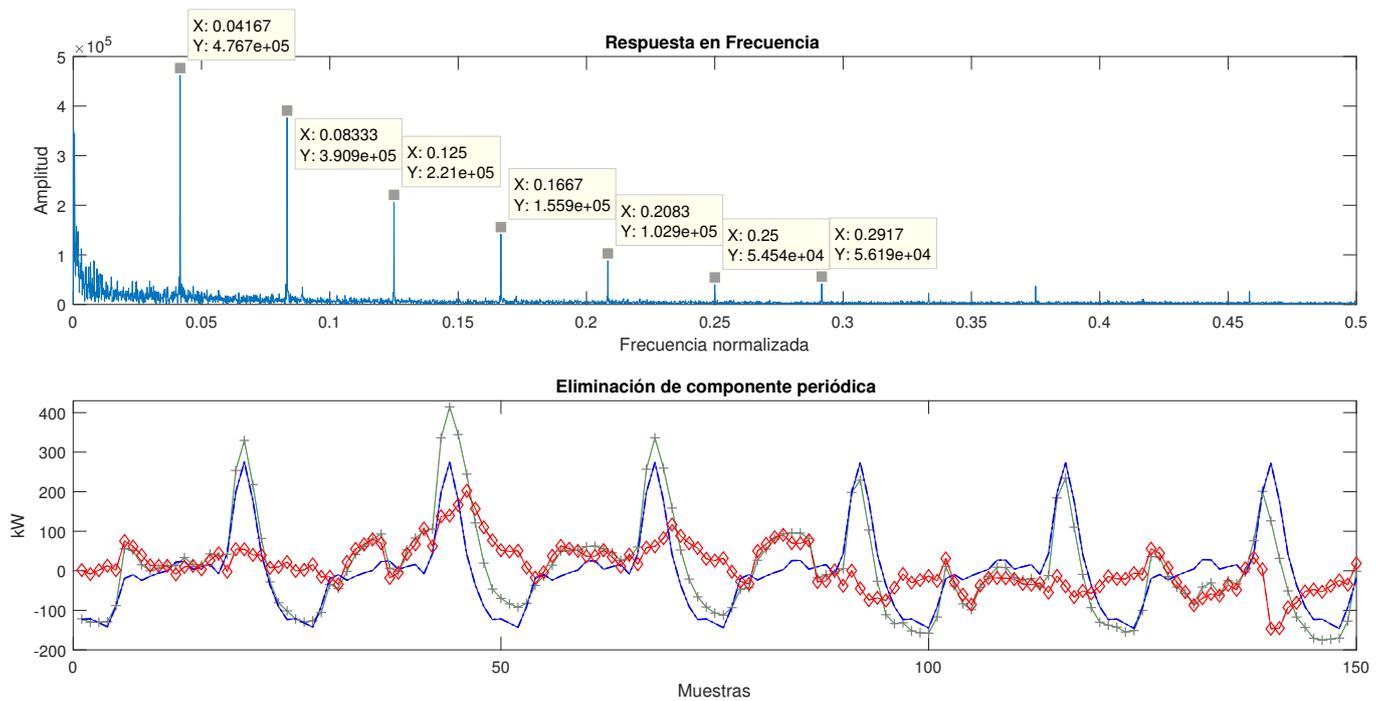


Figura 3: (Arriba) Espectro de la serie de tiempo **D1**. (Abajo) Serie de tiempo medida (+), aproximación periódica (línea continua), residuo no periódico (\diamond).

modelo obtenido a partir de los datos **D1** el error se reduce significativamente al pasar de 2 a 3 valores pasados de la señal en el regresor, tanto el RMSE como el MAPE se reducen en 1,3%. Sin embargo, no se presenta una mejora considerable al incrementar la longitud por encima de 3. Para el modelo obtenido a partir del conjunto de datos **D2** el error sobre los datos de identificación no varía significativamente con el orden n , mientras que el error sobre datos nuevos aumenta un 1,4% al pasar de 2 a 3 regresores.

Con base en el análisis anterior se selecciona un orden $n = 3$ y se realiza la validación de los filtros de Wiener en los conjuntos de datos de la Tabla 2 no usados para la construcción de los modelos. Los resultados se muestran en la Figura 5, en donde se evidencia que los porcentajes de error son menores para el filtro diseñado a partir del conjunto **D1**, siendo el MAPE promedio de 3,9% en comparación con un error del 5,7% obtenido al emplear el conjunto **D2** para construir el filtro.

Adicionalmente, se realizaron otras pruebas que incluyen variables meteorológicas como variables del modelo lineal. Los resultados indican que la inclusión de estas variables no mejora los porcentajes de error en validación. Por consiguiente, se establece que es suficiente emplear la demanda de las 3 horas anteriores para realizar una predicción adecuada de la demanda de energía eléctrica. Asimismo, se puede afirmar que el conjunto de datos **D1** contiene más información que **D2**, debido a que los porcentajes de error calculados en validación siempre son menores para dicho conjunto.

3.2.2. Modelo no lineal Set Membership

En este caso, el objetivo es construir un modelo no-lineal autoregresivo de la forma:

$$\hat{y}_t^{SM} = \hat{f}([\tilde{y}_{t-1}^e, \tilde{y}_{t-2}^e, \dots, \tilde{y}_{t-n}^e]) + d_t \quad (26)$$

siguiendo la formulación presentada en la Sección 2.

En primer lugar, se realiza la validación y selección de las hipótesis sobre ε^t y γ para diferentes longitudes n del regresor. Para esta prueba se emplea el conjunto de datos **D1** considerando que obtuvo mejor desempeño con los filtros de Wiener construidos a partir de este conjunto. Los resultados se presentan en la Figura 6. Allí se puede apreciar que todas las superficies de validación presentan una pendiente alta para valores pequeños de ε^t y luego el mínimo valor validado de γ decrece lentamente al aumentar la cota del error. Sin embargo, cuando se usan 6 o más valores pasados de la demanda en el regresor, γ^* continúa decreciendo, lo que indica un sobre-ajuste del modelo a los datos.

Para seleccionar una dimensión del regresor que no genere sobre-ajuste se efectúa la validación cruzada entre los modelos obtenidos a partir de los conjuntos **D1** y **D2**. Empleando los valores validados de ε^t y γ encontrados para cada regresor, se calcula el error RMSE sobre el conjunto no usado para construir el modelo. En las Tablas 3 y 4 se muestra el error de validación y los valores de ε^t y γ empleados para cada conjunto de datos. A partir de esta prueba se determina trabajar con un regresor de dimensión 2, dado que el error en validación aumenta al usar más valores pasados de demanda en el modelo.

Para evitar que nuevos datos invaliden las hipótesis, los valores de γ validados son incrementados en un 10% para cada modelo, estableciendo como parámetros definitivos los presentados en la Tabla 5.

En una etapa siguiente, se adicionan como entrada al modelo las variables meteorológicas mostradas en la Figura 2, obteniendo un predictor de la forma,

$$\hat{y}_t^{SM} = \hat{f}([\tilde{y}_{t-1}^e, \tilde{y}_{t-2}^e, \dots, \tilde{y}_{t-n}^e, \tilde{u}_{t-1}, \tilde{u}_{t-2}, \dots]) + d_t \quad (27)$$

Donde \tilde{u}_t corresponde a las señales meteorológicas medidas en

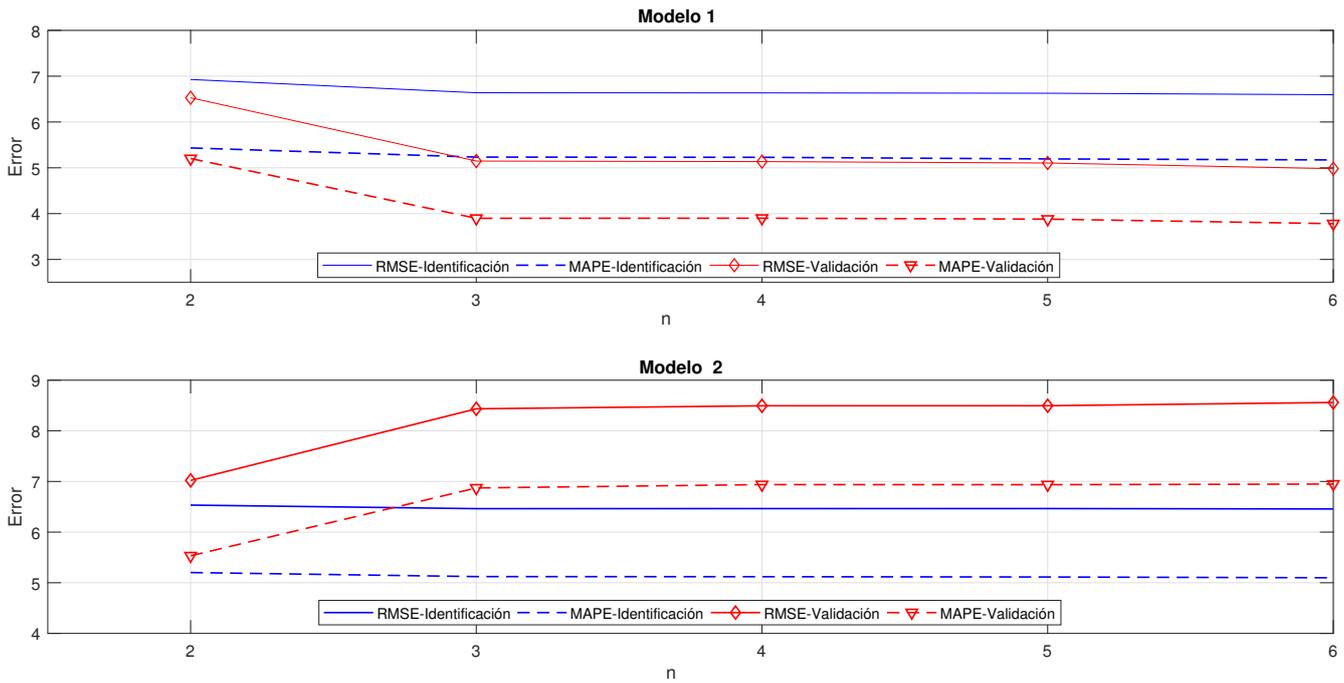


Figura 4: Errores RMS y MAPE en validación usados determinar el orden del Filtro de Wiener. Conjunto de datos **D1** (arriba) y **D2** (abajo).

el tiempo t . El objetivo es disminuir el error de estimación al incluir esta información en la predicción.

Tabla 3: Error en validación para el modelo Set Membership construido a partir de **D1**

n	ϵ^t	γ	% RMSE	MAPE
2	0.09	4.02	2.99	2.33
3	0.05	3.81	3.44	2.70
6	0.05	1.70	5.19	4.40
9	0.04	1.77	6.21	5.41
12	0.03	1.39	6.93	6.12
18	0.12	0.77	7.99	6.97

Dado que se dispone de 3 señales diferentes: temperatura, radiación solar instantánea y radiación solar promedio, es posible construir diferentes arreglos de señales como ingreso \tilde{u}_t . La Tabla 6 muestra las posibles combinaciones de entradas evaluadas y la Tabla 7 muestra el error sobre los datos de identificación, cuando se incluyen variables meteorológicas en modelos de diferente orden. Se verifica que el error sobre el conjunto de identificación disminuye respecto al modelo que solo usa la demanda pasada como entrada. Sin embargo, el error sobre el conjunto de datos de validación muestra un comportamiento diverso.

En la Tabla 8 se presentan los errores sobre el conjunto de validación al fijar $n = 2$ como longitud del regresor para todas las entradas. Se puede afirmar que al incluir las variables meteorológicas, el error ante datos nuevos aumenta en todos los casos. Nótese que el mejor desempeño se obtiene con el conjunto **Var 1**, es decir cuando solo se usa la demanda como entrada. En consecuencia, se concluye que para el comportamiento de la

demanda en el caso de estudio, las variables meteorológicas no contienen información relevante y resulta más efectivo realizar la predicción sólo con la información de la demanda de energía eléctrica.

Tabla 4: Error en validación para el modelo Set Membership construido a partir de **D2**

n	ϵ^t	γ	% RMSE	MAPE
2	0.16	4.96	4.74	3.81
3	0.12	3.27	5.12	4.08
6	0.10	2.45	7.07	5.08
9	0.07	2.06	9.19	6.78

Tabla 5: Valores validados y seleccionados de ϵ y γ

Datos	ϵ^t	γ validado	γ seleccionado
D1	0.09	4.02	4.42
D2	0.16	4.96	5.45

3.2.3. Modelo no lineal Set Membership adaptable

Una vez definida la estructura y los parámetros del modelo no lineal, se implementa la estrategia adaptable propuesta en el algoritmo 2.3. Para cada conjunto de validación (Tabla 2), el conjunto de datos se incrementa a medida que el estimador se ejecuta, es decir que M se inicia como $M = 0$ y se incrementa a medida que se ejecuta el algoritmo sobre cada conjunto de validación. Los errores RMSE y MAPE sobre cada uno de los conjuntos disponibles (Tabla 2) se presentan en la Figura 7. A partir de estos resultados se puede afirmar que el modelo Set Membership adaptable presenta el mejor desempeño.

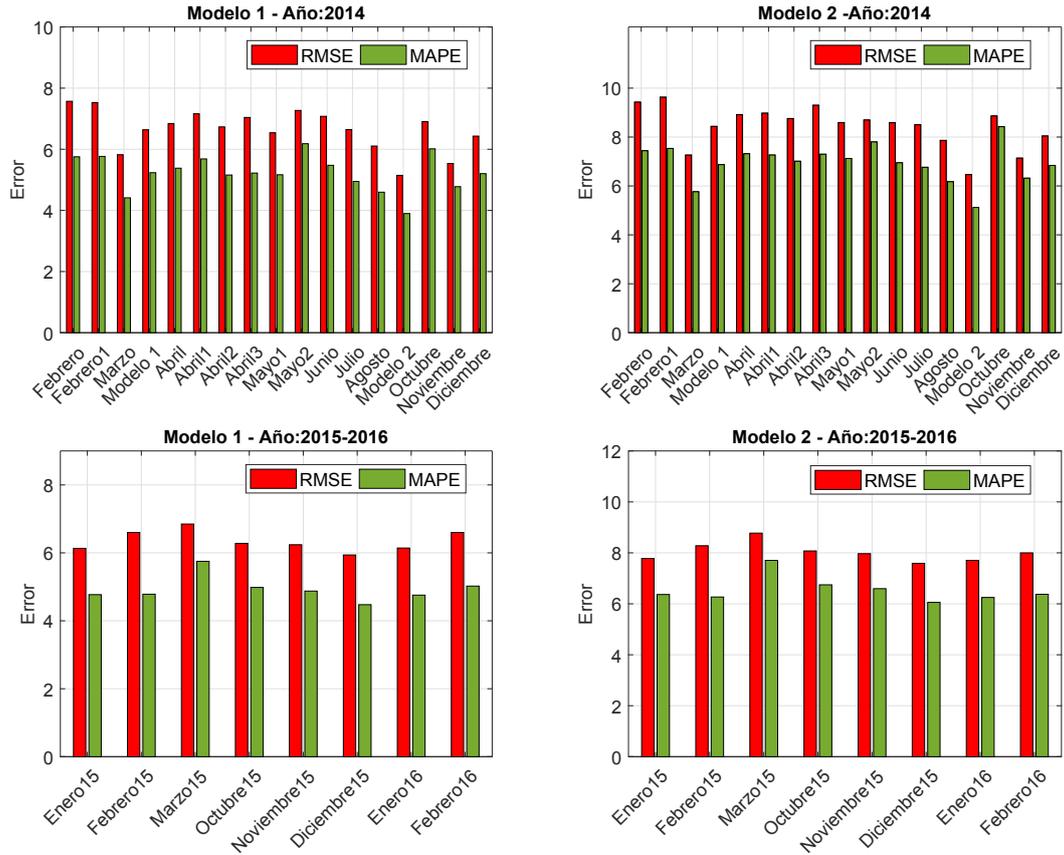


Figura 5: Error de predicción de los modelos lineales Conjunto de datos **D1** (izquierda) y **D2** (derecha)

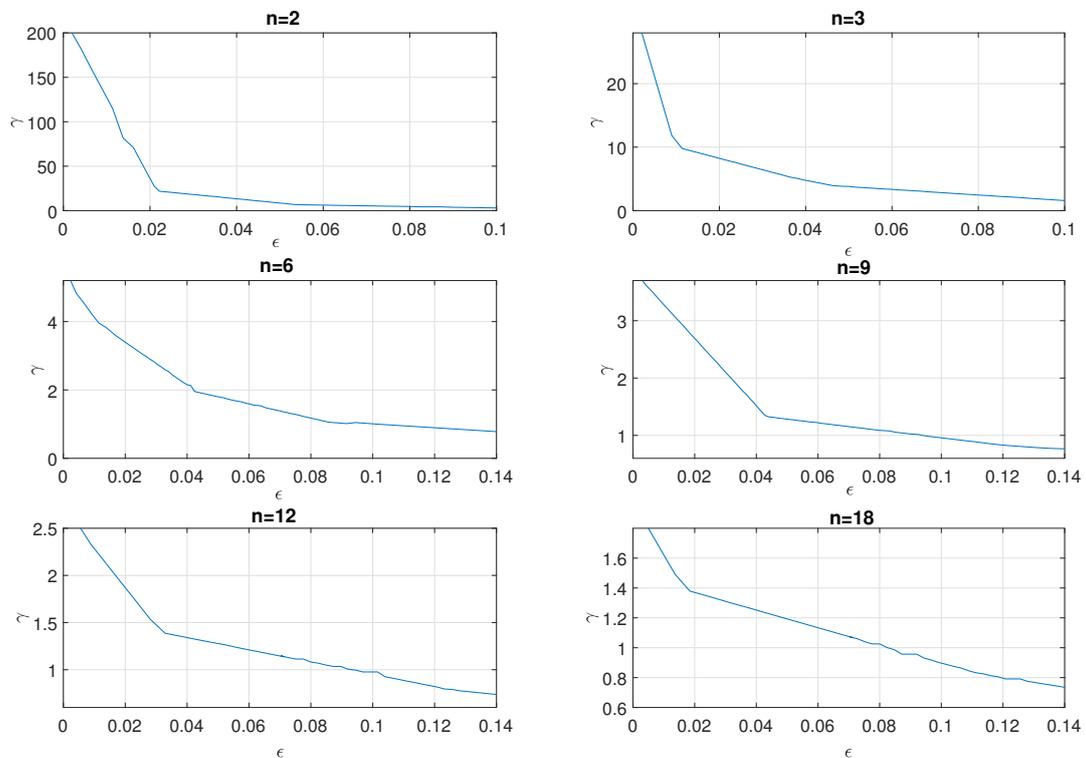


Figura 6: Resultado de la validación de hipótesis sobre ϵ^l y γ con base en **D1**.

El modelo adaptable obtenido a partir de **D1**, presenta un MAPE inferior al del modelo SM original en 21 de los conjuntos de validación. En promedio la reducción de error fue del 1.5 %. Por su parte, el modelo adaptable obtenido a partir del conjunto **D2** presentó una reducción de error del 0.66 %, decrementando el MAPE en los 24 grupos de validación.

Tabla 6: Conjuntos de variables meteorológicas disponibles

Nombre	Variabes asociadas
Var 1	Solo Demanda
Var 2	Temperatura
Var 3	Radiación
Var 4	Radiación Promedio
Var 5	Radiación y radiación promedio
Var 6	Radiación y Temperatura
Var 7	Temperatura y radiación promedio

Evaluando los errores obtenidos, es de resaltar que los porcentajes de error más bajos se logran con el modelo 1, concluyendo que las muestras de esta representación contienen más información que permite una mejor adaptación a los posibles cambios que se puedan presentar al momento de realizar la predicción de la demanda eléctrica. Un claro ejemplo de esto se evidencia al momento de predecir el mes de Febrero-2014, el cual muestra el día más atípico de toda la serie de tiempo que se evaluó y cuyos valores de demanda de energía eléctrica están muy lejanos de los días vecinos. El modelo **D1** es capaz de predecir este cambio inesperado, mientras que el modelo **D2** no se adapta a este, presentando el mayor porcentaje de error de predicción de demanda en este mes.

Tabla 7: Error RMS sobre datos de identificación incluyendo variables meteorológicas para diversas longitudes de regresor.

Var	n = 2	n = 3	n = 6	n = 9
1	1.65	1.57	1.38	1.29
2	1.21	1.12	1.11	0.76
3	1.13	1.02	0.98	0.66
4	1.65	1.56	1.69	1.29
5	1.13	1.02	0.98	0.66
6	1.12	1.01	0.97	0.65
7	0.70	0.57	0.58	0.26

Tabla 8: Errores de validación incluyendo variables meteorológicas para n = 2

Var	RMSE	MAPE
1	4.74	3.74
2	9.96	6.56
3	6.53	5.30
4	5.61	5.13
5	8.06	7.12
6	6.51	5.51
7	9.83	9.83

En la Figura 8 se muestra la predicción de demanda para tres tipos de días: bueno, regular y mal desempeño, obtenidas con el modelo **D1**. Para un día de buen desempeño el MAPE más bajo es de 1.3 % obtenido con el modelo SM adaptable, comparado con 1.5 % que se obtiene con el modelo SM original. Mientras que en el día de mal desempeño se tiene un MAPE de 8.4 % con el modelo SM adaptable y 14.5 % con el modelo SM original.

La Figura 9 resume el comportamiento de los tres estimadores desarrollados a partir del conjunto **D1**. Para cada modelo se presenta el MAPE promedio sobre todos los conjuntos de validación, el error máximo y el error mínimo. Se observa que el modelo SM original presenta la mayor variabilidad. Aunque su error promedio es menor que el del modelo lineal, en algunos conjuntos presenta un error muy alto, llegando a ser el doble del error presentado por el estimador lineal. Por otro lado, el modelo SM adaptable es el que presenta mejor desempeño y consistencia.

4. Conclusiones

En este trabajo se desarrolló un método de estimación no lineal por técnicas Set Membership aplicado a la predicción de la demanda de energía eléctrica. Se propuso una modificación que permite al modelo Set Membership adaptarse a la información ofrecida por datos recientes. Se elaboró un caso de estudio donde la técnica propuesta mostró mejor desempeño en términos de error de predicción, al compararlo con un modelo lineal autorregresivo y una aproximación estándar Set Membership. Asimismo, una ventaja destacable de este nuevo algoritmo es que requiere pocos datos para efectuar el proceso de identificación. Estos beneficios se deben a que el modelo se alimenta de la predicción de la demanda que se realiza en los instantes previos, permitiendo que se adapte al comportamiento que van teniendo los datos.

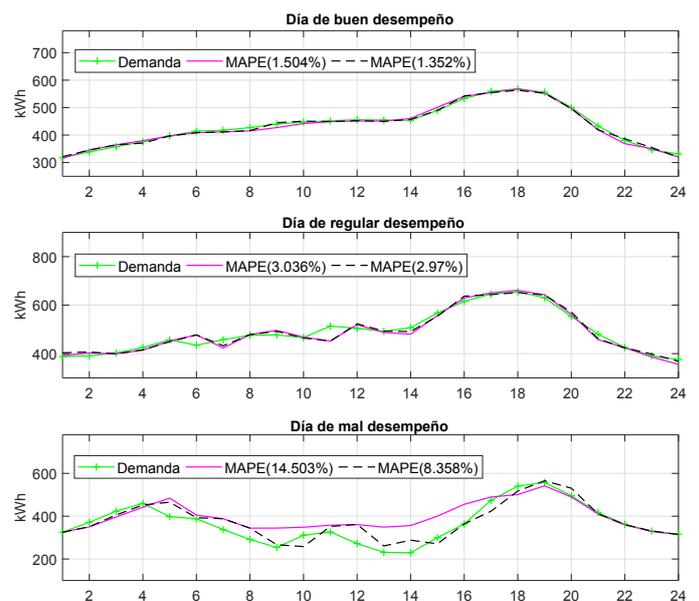


Figura 8: Ejemplo de comportamiento de los estimadores obtenidos a partir de **D1**.

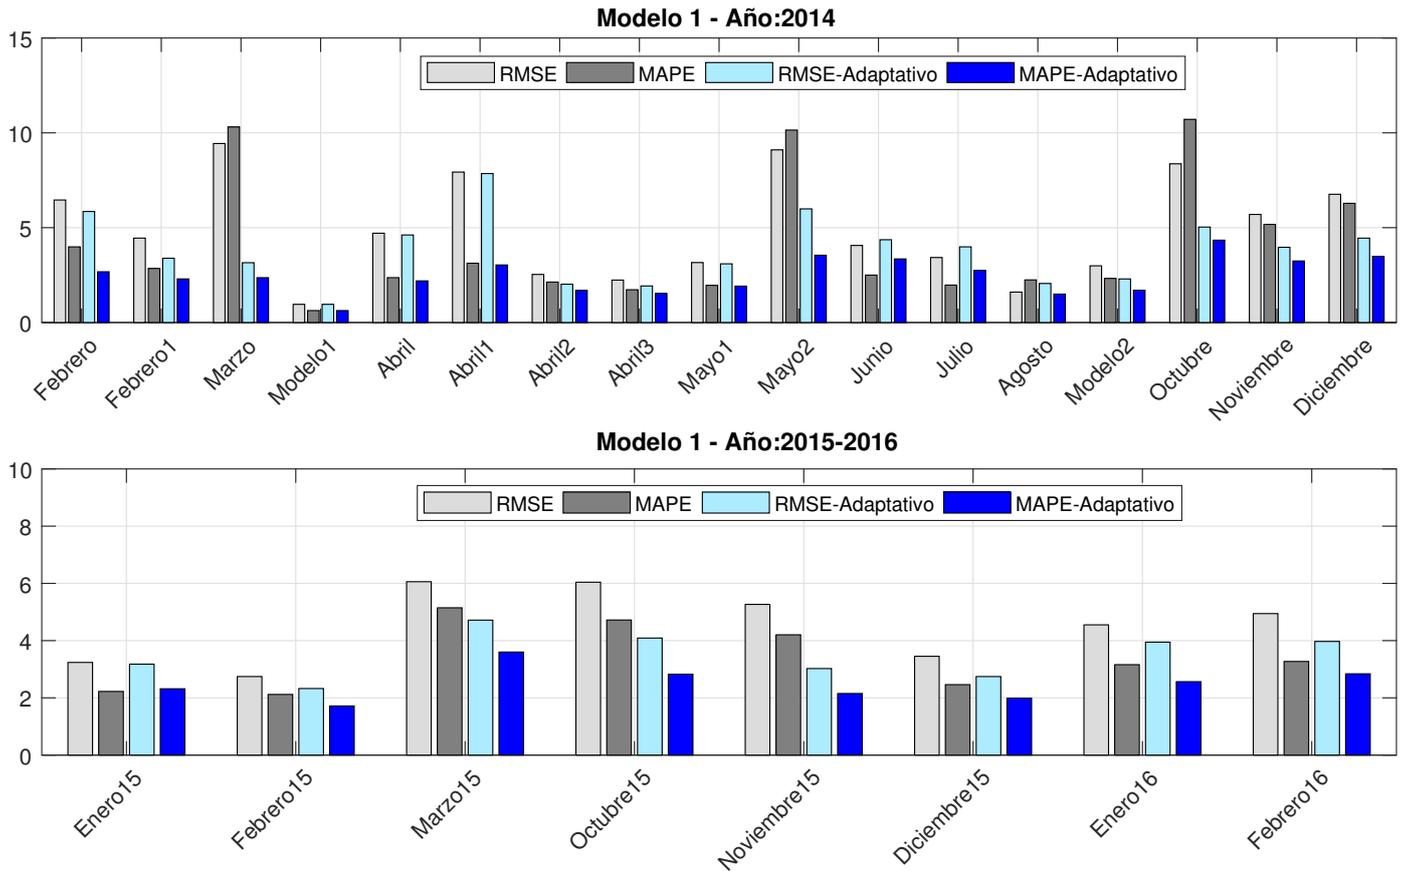


Figura 7: Error en validación sobre todos los datos disponible para los modelos no-lineales estimados a partir de D1.

Con respecto al caso de estudio, las variables meteorológicas propias del municipio donde se tomaron los datos no aportaron información relevante a la predicción. Los mejores resultados se obtuvieron empleando únicamente como variable de entrada los valores previos de demanda eléctrica. La dimensión del regresor requerido es menor al utilizar un modelo no lineal, en comparación con un modelo auto-regresivo lineal.

Como trabajos futuros se propone evaluar el modelo desarrollado con datos de demanda de cargas ubicadas en zonas con mayor variabilidad climática para determinar si el modelo Set Membership está en capacidad de utilizar esta información en la predicción.

Agradecimientos

Este trabajo fue financiado por el Fondo de Ciencia, Tecnología e Innovación del Sistema General de Regalías (SGR), Gobernación de Cundinamarca (Colombia), convenio especial de cooperación No. SCTeI 016 de 2015. El trabajo de Jimena Díaz fue financiado por una beca del Departamento de Cundinamarca-Fundación CEIBA a través del Proyecto *Fortalecimiento del Departamento de Cundinamarca en sus Capacidades de Investigación en Ciencia, Tecnología e Innovación*.

Referencias

Acosta, A., González, A., Zamarreno, J., Álvarez, V., 2011. Modelo para la predicción energética de una instalación hotelera. *Revista Iberoamericana de Automática e Informática Industrial RIAI* 8 (4), 309 – 322. DOI: <https://doi.org/10.1016/j.riai.2011.09.001>

Alam, A., Upadhyay, S., Murthy, C. H., Reddy, M. J. B., Jana, K. C., Mohanta, D. K., 2012. Reliability evaluation of solar photovoltaic microgrid. In: *Environment and Electrical Engineering (EEEIC), 2012 11th International Conference on*. pp. 490–495. DOI: 10.1109/eeeic.2012.6221427

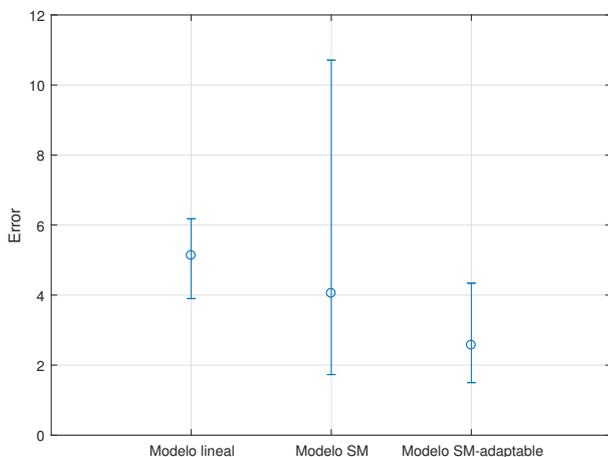


Figura 9: Resumen del error RMS en datos de validación para los tres estimadores desarrollados. Error promedio (o), error máximo (τ) y error mínimo (⊥).

- Alfares, H. K., Nazeeruddin, M., 2002. Electric load forecasting: Literature survey and classification of methods. *International Journal of Systems Science* 33 (1), 23–34.
DOI: [10.1080/00207720110067421](https://doi.org/10.1080/00207720110067421)
- Bordons, C., Torres, F. G., Valverde, L., 2015. Gestión Óptima de la energía en microrredes con generación renovable. *Revista Iberoamericana de Automática e Informática Industrial RIAI* 12 (2), 117–132.
DOI: <https://doi.org/10.1016/j.riai.2015.03.001>
- Castano, J., Ruiz, F., 2013. Set membership identification of an excimer lamp for fast simulation. *Control Engineering Practice* 21 (1), 96–104.
DOI: <https://doi.org/10.1016/j.conengprac.2012.09.013>
- Dang, H. Q., 2014. Time series outlier detection in spacecraft data. Ph.D. thesis, Knowledge Engineering Group, TU Darmstadt.
- Dwijayanti, S., Hagan, M., 2013. Short Term Load Forecasting Using a Neural Network Based Time Series Approach. 2013 1st International Conference on Artificial Intelligence, Modelling and Simulation (1), 17–22.
DOI: [10.1109/AIMS.2013.11](https://doi.org/10.1109/AIMS.2013.11)
- Hanmandlu, M., Chauhan, B. K., 2011. Load forecasting using hybrid models. *IEEE Transactions on Power Systems* 26 (1), 20–29.
DOI: [10.1109/TPWRS.2010.2048585](https://doi.org/10.1109/TPWRS.2010.2048585)
- He, Y., Xu, Q., Wan, J., Yang, S., 2016. Short-term power load probability density forecasting based on quantile regression neural network and triangle kernel function. *Energy* 114, 498–512.
DOI: [10.1016/j.energy.2016.08.023](https://doi.org/10.1016/j.energy.2016.08.023)
- Hu, Z., Bao, Y., Xiong, T., Chiong, R., 2015. Hybrid filter-wrapper feature selection for short-term load forecasting. *Engineering Applications of Artificial Intelligence* 40, 17–27.
DOI: [10.1016/j.engappai.2014.12.014](https://doi.org/10.1016/j.engappai.2014.12.014)
- Kapgate, D., Mohod, S., 2014. Hybrid wavenet model for short term electrical load forecasting. In: 2014 Conference on IT in Business, Industry and Government (CSIBIG). No. 1. pp. 1–8.
DOI: [10.1109/CSIBIG.2014.7057008](https://doi.org/10.1109/CSIBIG.2014.7057008)
- Lopes, J. P., Hatziargyriou, N., Mutale, J., Djapic, P., Jenkins, N., 2007. Integrating distributed generation into electric power systems: A review of drivers, challenges and opportunities. *Electric Power Systems Research* 77 (9), 1189–1203.
DOI: <https://doi.org/10.1016/j.epsr.2006.08.016>
- Mikati, M., Santos, M., Armenta, C., 2012. Modelado y simulación de un sistema conjunto de energía solar y eólica para analizar su dependencia de la red eléctrica. *Revista Iberoamericana de Automática e Informática Industrial RIAI* 9 (3), 267–281.
DOI: <https://doi.org/10.1016/j.riai.2012.05.010>
- Milanese, M., Novara, C., 2004. Set Membership identification of nonlinear systems. *Automatica* 40 (6), 957–975.
DOI: [10.1016/j.automatica.2004.02.002](https://doi.org/10.1016/j.automatica.2004.02.002)
- Milanese, M., Novara, C., Nov 2005. Set membership prediction of nonlinear time series. *IEEE Transactions on Automatic Control* 50 (11), 1655–1669.
DOI: [10.1109/TAC.2005.858693](https://doi.org/10.1109/TAC.2005.858693)
- Nose-Filho, K., Lotufo, A. D. P., Minussi, C. R., 2011. Short-Term Multinodal Load Forecasting Using a Modified General Regression Neural Network. *IEEE Transactions on Power Delivery* 26 (4), 2862–2869.
DOI: [10.1109/TPWRD.2011.2166566](https://doi.org/10.1109/TPWRD.2011.2166566)
- Oliveira, M. O., Marzec, D. P., Bordin, G., Bretas, a. S., Bernardon, D., 2011. Climate change effect on very short-term electric load forecasting. 2011 IEEE Trondheim PowerTech 190, 1–7.
DOI: [10.1109/PTC.2011.6019249](https://doi.org/10.1109/PTC.2011.6019249)
- Parkpoom, S., Harrison, G., Bialek, J., 2004. Climate change impacts on electricity demand. 39th International Universities Power Engineering Conference, 2004. UPEC 2004. 3 (Table I), 1342–1346.
DOI: [10.1109/UPEC.2004.192393](https://doi.org/10.1109/UPEC.2004.192393)
- Sadaei, H. J., Enayatifar, R., Abdullah, A. H., Gani, A., 2014. Short-term load forecasting using a hybrid model with a refined exponentially weighted fuzzy time series and an improved harmony search. *International Journal of Electrical Power & Energy Systems* 62 (from 2005), 118–129.
DOI: [10.1016/j.ijepes.2014.04.026](https://doi.org/10.1016/j.ijepes.2014.04.026)
- Singh, N. K., Singh, A. K., Tripathy, M., 2015. A comparative study of BPNN, RBFNN and ELMAN neural network for short-term electric load forecasting: A case study of Delhi region. 9th International Conference on Industrial and Information Systems, ICIIS 2014.
DOI: [10.1109/ICIINFS.2014.7036502](https://doi.org/10.1109/ICIINFS.2014.7036502)
- Ueckerdt, F., Brecha, R., Luderer, G., 2015. Analyzing major challenges of wind and solar variability in power systems. *Renewable Energy* 81, 1–10.
DOI: <https://doi.org/10.1016/j.renene.2015.03.002>
- Yalcinoz, T., Eminoglu, U., 2005. Short term and medium term power distribution load forecasting by neural networks. *Energy Conversion and Management* 46 (9-10), 1393–1405.
DOI: [10.1016/j.enconman.2004.07.005](https://doi.org/10.1016/j.enconman.2004.07.005)