



**Pronóstico de demanda neta de energía incorporando generación solar distribuida:
Un enfoque basado en optimización**

AARÓN JOSÉ CASADIEGOS OSORIO

Tesis de maestría presentada para optar al título de Magíster en Ingeniería

Asesor

Mejía Giraldo, Diego Adolfo

Universidad de Antioquia

Facultad de Ingeniería

Maestría en Ingeniería

Medellín, Antioquia, Colombia

2023

Cita	Casadiegos Osorio [1]
Referencia Estilo IEEE (2020)	[1] A. Casadiegos Osorio, “Pronóstico de demanda neta de energía incorporando generación solar distribuida: Un enfoque basado en optimización”, Tesis de maestría, Maestría en Ingeniería, Universidad de Antioquia, Medellín, Antioquia, Colombia, 2023.



Maestría en Ingeniería.

Grupo de Investigación Manejo Eficiente de la Energía (GIMEL).

Centro de Investigación Ambientales y de Ingeniería (CIA).



Centro de Documentación de Ingeniería (CENDOI)

Repositorio Institucional: <http://bibliotecadigital.udea.edu.co>

Universidad de Antioquia - www.udea.edu.co

El contenido de esta obra corresponde al derecho de expresión de los autores y no compromete el pensamiento institucional de la Universidad de Antioquia ni desata su responsabilidad frente a terceros. Los autores asumen la responsabilidad por los derechos de autor y conexos.

Resumen

Los datos de demanda corruptos y la alta penetración de generación distribuida (GD) en el sistema eléctrico, puede representar grandes problemas al momento de realizar el pronóstico de demanda. La forma como se abarquen estos problemas, en las metodologías de pronóstico, puede significar la diferencia entre un sistema con apagones, pérdidas económicas y baja estabilidad o un sistema confiable, estable y de alto rendimiento económico. Por esto es de gran importancia que se desarrollen metodologías, para robustecer los modelos de pronóstico de demanda eléctrica, cuando se tienen datos corruptos y alta penetración de GD. En este trabajo se presentan dos estrategias para abarcar la alta penetración de GD y otras tres para los datos corruptos. Cuando se tiene alta incertidumbre por la penetración de la GD, se resalta la efectividad de utilizar la “GD-media” para realizar un ajuste “ex-post” al pronóstico; mientras que, al tener grandes porcentajes de datos corruptos, se muestra que combinar la función objetivo *huber* o *norma* – l_1 y las restricciones de energía o pendiente de la demanda, con una arquitectura horaria del modelo, puede ser la diferencia en los métricas de evaluación. Finalmente se concluye que estos dos enfoques que se trabajaron por separado, pueden ser combinados, con el fin de probar su desempeño en un sistema interconectado que viene evolucionando a grandes pasos.

Palabras Claves

Pronóstico, demanda eléctrica, corto plazo, optimización, robustez, daños en los datos, demanda detrás del medidor, big data, generación distribuida (DG), aprendizaje automático, energía renovable.

Este manuscrito es dedicado a mis familiares y amigos que siempre han estado presentes en mi proceso de formación.

Índice general

Resumen	1
1. Introducción	7
2. Modelos de regresión robustos para el pronóstico de demanda eléctrica: Un enfoque basado en estrategias de optimización.	11
2.1. Modelos propuestos	12
2.1.1. Variables explicativas.	12
2.1.2. Función objetivo.	12
2.1.3. Restricciones.	13
2.1.4. Arquitectura.	13
2.2. Caso de estudio	14
2.2.1. GEFCOM2017 Data	14
2.2.2. Configuración de modelos propuestos	14
2.2.3. Modelos comparativos	15
2.2.4. Método de evaluación comparativa	16
2.2.5. Resultados con datos originales	17
2.2.6. Resultados con datos corruptos	18
2.3. Conclusiones	22
3. Pronóstico de demanda eléctrica a muy corto plazo, integrando la generación solar distribuida	25
3.1. Abstract	25
3.2. Introduction	25
3.2.1. Motivation	25
3.2.2. Literature review	26
3.3. Methodology	27
3.3.1. Base case forecast strategy	28
3.3.2. Solar DG as regressor variable	28
3.3.3. Mean DG ex-post correction	28
3.4. Results	29
3.4.1. Data	29
3.4.2. Scenarios of Solar DG in Colombia	29
3.4.3. Model training	30
3.4.4. Results using base case forecast strategy	30

3.4.5. Results using solar DG as regressor variable	31
3.4.6. Results using Mean DG ex-post correction	32
3.4.7. Strategy comparisson	32
3.5. Conclusions	33
Conclusiones	37
Apéndices	39
A. Otras publicaciones	41
Agradecimientos	45
Bibliografía	50
Abreviaciones	51

Introducción

Uno de los mayores retos del mercado eléctrico, radica en que la energía debe ser generada en el momento que es consumida. Debido a esto, los operadores de red deben ser muy conscientes de cuáles son los cambios que va presentando el sistema eléctrico interconectado (de ahora en adelante llamado sistema), con el fin de reaccionar a esos cambios de manera eficiente y oportuna. Algunos de los cambios que se presentan diariamente, por mantenimiento o fallas en el sistema, son: salidas de líneas, transformadores, generadores, salida de grandes cantidades de demanda; pero uno de los factores que más cambian diariamente, es el comportamiento natural de la demanda. Cambios que se manifiestan a lo largo del día debido a las costumbres, tradiciones y comportamiento de las poblaciones y las industrias. En la Figura 1.1, se observa que la demanda es baja al iniciar el día, lo cual es causado por que las personas están durmiendo; a medida que avanza el día se ve un aumento progresivo que termina en un pico máximo, que se da generalmente entre las 18 y 22 horas, debido a que es el momento donde se hace oscuro y las personas utilizan la energía eléctrica para sus actividades nocturnas. Este es el comportamiento típico de la demanda, y los operadores deben estar familiarizados con este.




Figura 1.1: Dos días de demanda típica de un sistema de transmisión. Construcción propia

Para el operador es de vital importancia tener, de antemano, conocimiento del comportamiento de la demanda con el objetivo de mantenerla en equilibrio con la generación. Si se pierde

ese equilibrio puede presentarse: disminución o aumento de la frecuencia de la red, lo que causa daños a los equipos; desabastecimiento de algunos lugares, que puede poner en riesgo sectores económicos locales, o incluso vidas (desabastecimiento eléctrico en hospitales y clínicas); y lo más riesgoso, pueden presentarse apagones tan drásticos que traigan consigo black-outs, es decir, desabastecimiento total del sistema.

Los operadores de red y la industria eléctrica ha desarrollado muchas herramientas, que le permiten controlar los imprevistos que se puedan presentar. Unas de esas herramientas, que cumple un papel primordial en el control eficiente de los sistemas, es el pronóstico de la demanda eléctrica a corto plazo [1], debido a que, con base en un buen pronóstico, se pueden tomar decisiones oportunas, previniendo que se presenten situaciones de riesgo. Incluso se obtienen beneficios económicos, en la operación y control del sistema eléctrico, con un buen pronóstico de demanda [2]. Para mostrar con mayor detalle estos beneficios, en la Figura 1.2, se muestra una relación de causalidad, donde a partir de mejorar el pronóstico de demanda se puede generar impactos en ámbitos mayores. Como se puede observar el mejoramiento de las técnicas de pronóstico tienen un efecto ascendente, iniciando por mejorar la planeación de la operación del sistema y terminando incluso en el fortalecimiento de los desarrollo científico. Por otro lado, fortalecer el desarrollo científico en este ámbito, trae beneficios que fortalecen la eficiencia de la operación del sistema y que finalmente se traduce en reducción de gastos económicos, como: menor empleo de reserva rodante, reducción de desabastecimiento de la demanda, menores costos de operación, menores penalizaciones a los agentes del mercado por incumplir reglamentos, entre otros.

El pronóstico de demanda eléctrica en las últimas décadas ha presentado cambios, gracias a la integración de nuevas fuentes de generación distribuidas (GD). Se espera que estas fuentes tengan una mayor participación en el mercado, gracias a los incentivos de los gobiernos, al decrecimiento de los costos en las tecnologías que permiten su implementación y a las preocupaciones medioambientales [3]. Esta integración trae consigo beneficios para el sistema interconectado eléctrico, pero introduce cambios en la demanda complicados de prever, disminuyendo la confiabilidad de los pronósticos realizados con los métodos tradicionales [4]. Por ende, es necesario contribuir a desarrollar nuevas herramientas, que basadas en los avances realizados hasta el momento, ayuden al mejoramiento del manejo de los sistemas interconectados de energía.

Con lo anterior en mente, el problema de investigación que se afrontará está enfocado en evaluar nuevas alternativas de pronóstico, que busquen disminuir el error entre el pronóstico y el valor real de la demanda, al integrar la generación solar distribuida (GSD). Lo cual dependerá de las técnicas de optimización que se utilicen y de la forma en cómo se integre la GSD en estas. Para lo anterior, hay que tener claro que al realizar el pronóstico se pueden diferenciar varias funciones de pérdida, que son útiles para minimizar los errores del modelo a pronosticar. Algunos ejemplos de estas funciones pueden ser encontrados en [5].

Es importante aclarar, que cuando se habla de modelo se hace referencia al modelo, que permite hacer la predicción; mientras que, si se habla de metodología, se hace referencia a todo el procedimiento completo de análisis, imputación, filtrado de datos, optimización y evaluación del modelo.

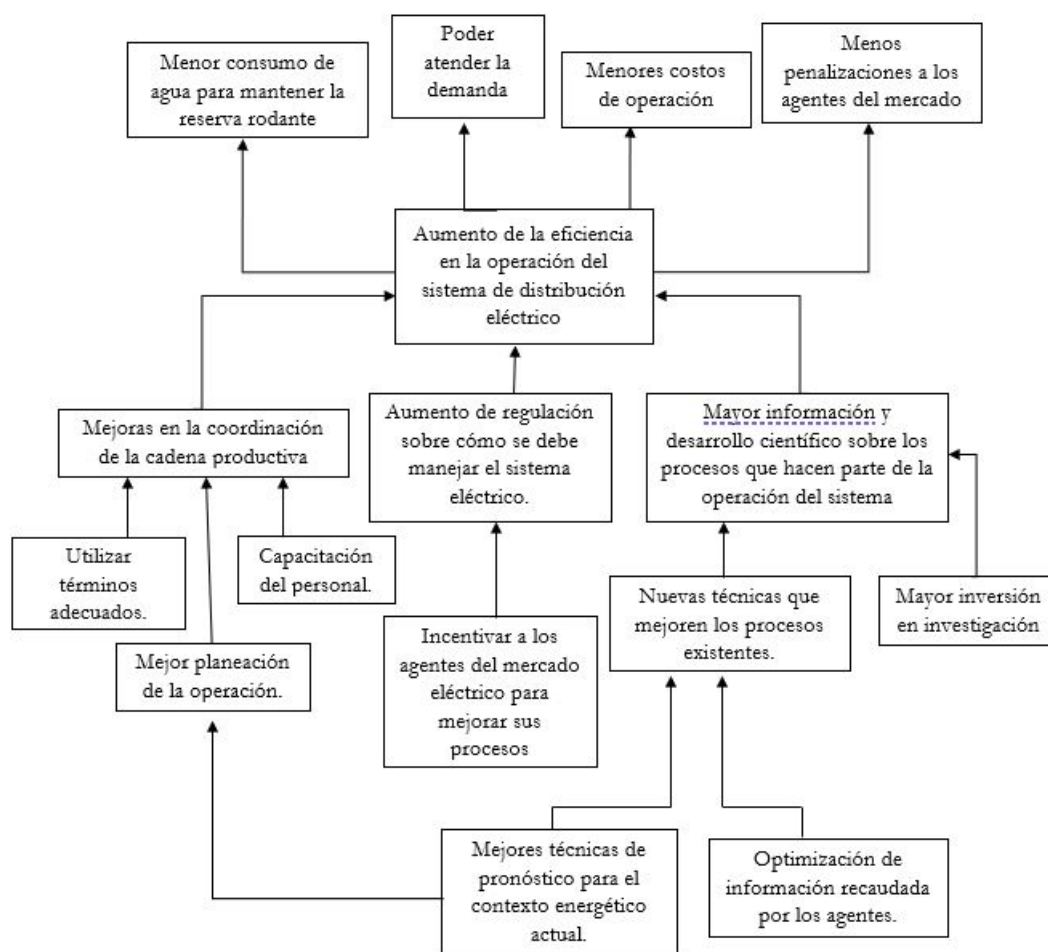


Figura 1.2: Arbol de beneficios. Construcción por pias

Capítulo 2

Modelos de regresión robustos para el pronóstico de demanda eléctrica: Un enfoque basado en estrategias de optimización.

La información histórica de demanda eléctrica, es un insumo primordial para el desarrollo de modelos de pronósticos a corto plazo. Conociendo el comportamiento pasado de la demanda, se puede predecir su futuro [6]. Sin embargo, si la información de demanda histórica cuenta con datos corruptos, los modelos de pronóstico pueden equivocarse gravemente, subestimando o sobrestimando la demanda, causando problemas en el sistema de transmisión interconectado (inestabilidad, apagones y pérdidas monetarias) [7]. Algunas causas de corrupción en los datos son: errores involuntarios de las personas encargadas de transmitir la información, problemas de comunicación en los sistemas informáticos, daños en la infraestructura física que permite la recolección y transmisión de la información de demanda, o incluso, ataques cibernéticos dirigidos específicamente a corromper la información utilizada para pronosticar la demanda eléctrica.

En este capítulo, se presenta detalladamente la metodología y los resultados que busca generar modelos robustos ante corrupción en los datos. Se considera que la falta de metodologías robustas ante datos corruptos permite proponer modelos de pronóstico de demanda eléctrica a partir de diferentes estrategias de optimización, que entreguen pronósticos más robustos. Estos modelos propuestos sirven como alternativa a las técnicas de imputación y filtrado, comúnmente utilizadas en estadística, debido a que disminuye la complejidad en el análisis de los datos y aumenta la rapidez para presentar resultados de pronósticos. En particular, las principales contribuciones de este capítulo son:

- El desarrollo de modelos de pronóstico con arquitectura horaria, los cuales buscan tener una mayor generalización de la demanda.
- La inclusión de restricciones en los modelos de optimización que se usan para calcular los modelos de pronóstico. Restricciones que buscan dar robustez ante datos corruptos.

El resto de este capítulo está organizado de la siguiente manera. La sección 2.1 presenta las tres estrategias desarrolladas para implementar los modelos propuestos. La sección 2.2 describe la información utilizada para poner a prueba los modelos y discute los resultados. Finalmente, las conclusiones son expuestas en la sección 2.3.

2.1. Modelos propuestos

En esta sección se presenta la fundamentación teórica de los modelos de pronóstico propuestos. Los cuales, en general, buscan mantener un comportamiento robusto del pronóstico, ante corrupción en los datos de entrenamiento. Inicialmente, se presentan las variables explicativas del modelo. Luego, se proponen tres estrategias para hacer más robusto el modelo, las cuales pueden ser combinadas. La primera, desde la función objetivo. La segunda, agregando restricciones al modelo (para el conocimiento de los autores, esto no se ha reportado en la literatura sobre modelos de predicción de demanda eléctrica). La tercera, desde la arquitectura del modelo, pudiendo ser “Horario” o “Único”.

2.1.1. Variables explicativas.

Todos los modelos propuestos en el documento están compuestos por las mismas variables explicativas. Se dividen en datos históricos de la demanda y variables exógenas. Es decir, la demanda y_t del periodo $t \in \tau$ (siendo τ el conjunto de periodos horarios), es modelada como función del comportamiento de la demanda pasada, considerando diferentes datos históricos:

- Historia inmediata: $y_{t-1}, y_{t-2}, \dots, y_{t-k}$; siendo k , la cantidad de rezagos horarios.
- Historia semanal: $y_{t-168}, y_{t-169}, \dots, y_{t-336}, y_{t-337}, \dots, y_{t-n(168)-j+1}$; donde j es el # de rezagos horarios, tomados a partir del rezago $n(168)$ y n el # de semanas anteriores.

Se utilizará $y_{[t]}$ para denotar los datos históricos de demanda. La demanda y_t también es parametrizada en términos de las variables exógenas $x_{1,t}, x_{2,t}, \dots, x_{k,t}$. Considerando variables meteorológicas. Además, de los efectos calendario que indican el día de la semana, los días festivos y los días cercanos a festivos. En general, los modelos de pronóstico presentados en este documento se pueden representar en función de las variables explicativas, así: $y_t = f(y_{[t]}, x_{1,t}, x_{2,t}, \dots, x_{k,t} | \beta) + \epsilon_t$. Donde β son los coeficientes estimados.

2.1.2. Función objetivo.

Con el fin de reducir la influencia de los desfases causados por datos corruptos, al momento de entrenar, se proponen las funciones de penalización del error: norma- l_1 (2.1), norma- l_2 (2.2) y la función “Huber” (2.3). En la norma- l_2 , al estar elevada al cuadrado, se da más relevancia a los errores grandes; en el caso de “Huber”, da menos importancia a la minimización de los errores al cuadrado, dependiendo de la parametrización que se plantee; Mientras, la norma- l_1 , solo tiene en cuenta la minimización de los errores absolutos, asignando la misma importancia a todos los errores, sin importar su tamaño.

$$\text{minimizar } \sum_{t \in \tau} | \tilde{y}_t - y_t | \quad (2.1)$$

$$\text{minimizar } \sum_{t \in \tau} (\tilde{y}_t - y_t)^2 \quad (2.2)$$

$$\text{minimizar } \sum_{t \in \tau} \Phi_{hubt} \quad (2.3)$$

$$\Phi_{hubt} = \begin{cases} (\tilde{y}_t - y_t)^2, & |\tilde{y}_t - y_t| \leq M \\ M(2|\tilde{y}_t - y_t| - M), & |\tilde{y}_t - y_t| > M \end{cases} \quad (2.4)$$

Siendo: \tilde{y}_t , la demanda histórica utilizada para entrenar; y_t , el modelo de pronóstico que se busca entrenar; M , un parámetro de la función “Huber” que delimita cuando se usa la función valor absoluto y la cuadrática.

2.1.3. Restricciones.

Las restricciones se plantean con el objetivo de mantener los pronósticos dentro de valores típicos dados por la historia.

- Energía típica diaria (ED): $|\sum_{h \in H} (y_{h,d}) - \bar{y}_d| \leq n_1 \sigma_d$,
 $\forall d \in D$.

Siendo d , el tipo de día ($D = \{\text{lunes}, \dots, \text{domingo}\}$); h , la hora del día ($H = \{0, 2, \dots, 24\}$); $y_{h,d}$, la demanda modelada en la hora h del día d ; \bar{y}_d , la demanda media; σ_d , la desviación estándar de los datos históricos en el día d ; n_1 , el parámetro que indica el número de desviaciones estándar permitidas.

- Energía típica horaria (EH): $|y_{h,d} - \bar{y}_{h,d}| \leq n_2 \sigma_{h,d}, \forall h \in H, \forall d \in D$.

Siendo, $\bar{y}_{h,d}$ y $\sigma_{h,d}$, la demanda media y la desviación estándar de los datos históricos en la hora h , del día d , respectivamente; n_2 , el parámetro que indica el número de desviaciones estándar permitidas con respecto a la energía media horaria del día en cuestión. Se mantienen los mismos conjuntos D y H , de la restricción anterior.

- Pendientes típicas de la demanda (PT): $|y_{h,d} - y_{h-1,d}| \leq n_3 \cdot \max(|\tilde{y}_h - \tilde{y}_{h-1}|), \forall h \in H, \forall d \in D$.

Donde, $y_{h-1,d}$, es la demanda modelada una hora antes de h en el día d ; $\max(|\cdot|)$, indica el valor absoluto de la pendiente máxima; \tilde{y}_h , la demanda histórica que se da en la hora h ; \tilde{y}_{h-1} , la demanda histórica que se da una hora antes de h .

2.1.4. Arquitectura.

La arquitectura del modelo es una idea fundamental en este documento. Se pretende analizar el desempeño de los modelos cuando se especifican de forma general a cualquier hora del día, o cuando se enfocan en cada hora por separado.

Única.

Consiste en una arquitectura básica, que solo tiene un modelo general, capaz de pronosticar cualquier hora del día. Donde, el pronóstico de demanda producido por un modelo con esta arquitectura, es denotado por: $\hat{y}_{t+m|t} = \hat{f}(y_{[t]}, \{x_{j,t+m|t}\}_{j \in J} | \hat{\beta})$; donde, $\hat{y}_{t+m|t}$, representa el modelo entrenado para pronosticar el horizonte horario $t+m$; el conjunto J , representa las variables exógenas en; y $\hat{\beta}$, corresponde a los parámetros estimados.

Horaria.

Esta arquitectura es más compleja, debido a que permite pronosticar cada hora del día, con un modelo enfocado a esa hora en específico. Donde, el pronóstico de demanda producido por un modelo con esta arquitectura, es denotado por: $\hat{y}_{t+m|t}^h = \hat{f}\left(y_{[t]}, \{x_{j,t+m|t}\}_{j \in J} \mid \hat{\beta}_h\right)$; donde, $\hat{y}_{t+m|t}^h$, representa los 24 modelos horarios entrenados para cada hora h utilizado para pronosticar el horizonte horario $t+h$; J y m , tienen el mismo significado que en el modelo único; y $\hat{\beta}_h$, cuenta con parámetros estimados para cada hora h del día.

2.2. Caso de estudio

Esta sección presenta la formulación de un caso de estudio que permite evaluar el desempeño de los modelo propuesto, comparándolo con los modelos encontrados en la literatura. Para esto se usan algunos datos de la Global Energy Forecasting Competition 2017 (GEFCom2017). Se muestra la precisión de los modelos de pronóstico utilizando los datos originales y la simulación de los datos corruptos.

Toda la implementación de los modelos propuestos y los comparativos se realiza en el software Python (versión 3.9.7) en un computador de mesa equipada con un procesador Intel(R) core i7-8700 de 3.20 GHz, RAM de 15.8 GB y Microsoft Windows 10 Pro. La modelación de los problemas de optimización se realizaron en el Pyomo (version 6.4.0). Los solver utilizados para resolver los problemas de optimización fueron Mosek, gurobpy y ipopt.

2.2.1. GEFCom2017 Data

La información utilizada para este estudio, fueron los datos de la etapa de clasificación de la GEFCom2017 [8]. Esta serie de datos cuenta con la información real publicada por ISO New England (ISONE), donde se presentan datos de demanda y temperatura, del mercado y de cada una de las ocho zonas que abarca ISONE. El conjunto de datos incluye 15 años de información, desde el año 2003 al 2017. Para el análisis desarrollado en este documento, se tomó cerca de 1.6 años de datos de demanda de tiempo real [MW] del ISONE; además de la temperatura seca del aire [F°] y la temperatura de rocío [F°]. Los datos para el entrenamiento de los modelos puestos a prueba, comprenden desde el 2015-01-23 hasta el 2016-08-04. Los siguientes quince días, desde el 2016-08-05 hasta el 2016-08-19, se utilizan como datos de prueba para medir la precisión de cada pronóstico; realizando el pronóstico 15 días adelante.

2.2.2. Configuración de modelos propuestos

Como se mencionó en la sección 2.1, los modelos propuestos están configurados a partir de tres estrategias. Para este caso de estudio estas tres estrategias se combinaron, para formar 50 modelos diferentes. Se proponen 25 modelos de arquitectura horaria y 25 de arquitectura única. Cada grupo de 25, se divide en 5 grupos, de 5 modelos finales. Dependen de su función objetivo y de 5 configuraciones de restricciones. En la tabla 2.1, se muestra la configuración de los 50 modelos y se nombran desde el modelo 1, hasta el modelo 50. Para los modelos de función objetivo Huber,

Arq	Modelo	Sin R	EH	ED y EH	PT	ED, EH y PT
Horaria	l_1	M1	M2	M3	M4	M5
	l_2	M6	M7	M8	M9	M10
	Hu (1)	M11	M12	M13	M14	M15
	Hu (2)	M16	M17	M18	M19	M20
	Hu (3)	M21	M22	M23	M24	M25
Única	l_1	M26	M27	M28	M29	M30
	l_2	M31	M32	M33	M34	M35
	Hu (1)	M36	M37	M38	M39	M40
	Hu (2)	M41	M42	M43	M44	M45
	Hu (3)	M46	M47	M48	M49	M50

Cuadro 2.1: Modelos propuestos

se tomaron tres valores de paramentros M, diferentes: para Hu (1), $M = 0.001$; para Hu (2), $M = 0.004$; para Hu (3), $M = 0.02$.

Las variables explicativas, de datos históricos, utilizadas para este caso de estudio fueron: rezagos de historia inmediata y_{t-k} , con $k = 10$; rezagos de historia semanal $y_{t-n(168)-j+1}$, con $n = 3$ y $j = 6$, pero exceptuando los rezagos y_{t-169} , y_{t-337} , y_{t-505} , los cuales empeoraban el pronóstico. Las variables exogena $x_{k,t}$ utilizadas fueron: temperatura seca del aire [F°], temperatura de rocío [F°] (cada una elevada al exponente uno, dos y tres); las variables dummies de efecto calendario que indican si la demanda se da en un día martes, miércoles, jueves, viernes, sábado o domingo; las variables dummies que indican si la demanda se da en un día festivo no lunes o un día festivo lunes; y las variables dummies que indican si la demanda se da en un día lunes, martes, miércoles, jueves, viernes, sábado o domingo cercano a un día festivo. Para finalmente contar con 46 variables exogenas.

2.2.3. Modelos comparativos

Con el fin de realizar la evaluación del desempeño de los modelos propuestos, estos fueron comparados contra 5 modelos, comúnmente utilizados para el pronósticos de series de tiempo y de demanda eléctrica. Se debe tener en cuenta que para hacer una comparación valida, todos los modelos en este artículo comparten las mismas variables descritas en la sección 2.2.2.

- MCO: El problema de optimización de MCO tiene el mismo planteamiento matemático del modelo único, que se muestra en la sección 2.1.2, para la norma- l_2 , pero sin restricciones [5].
- Lasso: Modelo de regularización que busca minimizar los errores de sobre ajuste, atenuar los efectos de correlación y minimizar el efecto de las variables menos relevantes. Para lo anterior se minimiza la suma absoluta de las magnitud de los coeficientes encontrados a partir de MCO. El modelo de optimización del Lasso se puede escribir como [9]:

$$\text{minimizar } \sum_{t \in \tau} (\tilde{y}_t - y_t)^2 + \lambda \left\| \hat{\beta} \right\|_1 \quad (2.5)$$

Donde λ , permite controlar el grado de penalización de los coeficientes. Cuando el λ aumenta,

Modelo	Módulo de python
MCO	<code>sklearn.linear_model.LinearRegression</code>
Lasso	<code>sklearn.linear_model.LassoCV</code>
Elastic Net	<code>sklearn.linear_model.ElasticNetCV</code>
Prophet	<code>prophet.Prophet</code>
SVR	<code>sklearn.svm.SVR</code>

Cuadro 2.2: Módulos de Python utilizados para la implementación

mayor es la penalización y se excluyen más variables predictoras.

- Elastic Net: Modelo de regularización que busca el mismo objetivo que el modelo Lasso. Para lo cual, penaliza los coeficientes encontrados a partir de MCO, combinando la norma- l_1 y la norma- l_2 de la suma de los coeficientes. Este modelo de optimización se puede escribir como [10]

$$\text{minimizar } \sum_{t \in \tau} (\tilde{y}_t - y_t)^2 + \lambda \left(\alpha \|\beta\|_1 - (1 - \alpha) \|\beta\|_2^2 \right) \quad (2.6)$$

Donde α , permite controlar cada una de las penalizaciones. Cuando el α es cero aplica la penalización norma- l_2 y cuando es uno, aplica *normal* - l_1 .

- Prophet: Es un procedimiento de pronóstico de series de tiempo desarrollado por facebook. Su algoritmo es basado en modelos aditivos generalizados. Según los autores esta metodología es robusta ante datos faltantes y valores atípicos; por ese motivo fue utilizado como metodología de comparación [11].
- SVR: Este modelo de optimización busca identificar un hiperplano regresor que se ajuste a el conjunto de datos de entrenamiento. Este modelo tiene un parámetros de error que crean una intervalo al rededor del hiperplano, el cual busca abarcar la mayoría de los datos de entrenamiento. También, tiene un parámetro de que representa las desviaciones que se permiten alrededor del intervalo inicial [12]. Para efectos de este caso de estudio los parámetros utilizados para configurar este modelo fueron: kernel, 'linear'; degree, 4; gamma, 'scale'; C, 29.857017122840976.

En la tabla 2.2, se especifican los módulos de Python que se utilizaron para realizar el pronóstico con los modelos comparativos. Se aclara que los hiperparametros necesarios para cada modelo, fueron calculados a partir de metodologías de validación cruzada, implementadas con el módulo Sklearn.

2.2.4. Método de evaluación comparativa

Para saber la precisión de los pronósticos resultantes de cada modelo se utilizó la métrica del error porcentual absoluto medio (MAPE). El cual mide el error absoluto del pronóstico en términos porcentuales. En la eq.(2.7), se presenta la especificación matemática del MAPE:

$$MAPE = \frac{100\%}{n} \sum_{t=1}^n \frac{A_t - F_t}{A_t} \quad (2.7)$$

Donde, A_t y F_t son las demandas horarias reales y pronosticadas, respectivamente. Un valor del MAPE pequeño indica mayor precisión del pronóstico.

2.2.5. Resultados con datos originales

Se realizó una búsqueda de hiperparámetros para los modelos propuestos con datos sin corrupción. Para los modelos de arquitectura horaria: con EH, $n_2 = 63,30$; con ED y EH, $n_1 = 101,10$ y $n_2 = 63,30$; con PT, $n_3 = 3$; con ED, EH y PT, $n_1 = 29,10$ y $n_2 = 50,69$. Para los modelos de arquitectura única: con EH, $n_2 = 92,70$; con ED y EH, $n_1 = 88,50$ y $n_2 = 92,70$; con PT, $n_3 = 3$; con ED, EH y PT, $n_1 = 8,70$ y $n_2 = 78,60$.

En la tabla 2.3, se presenta la comparativa de los MAPEs, para los modelos implementados. Estos MAPEs son calculados con los datos de prueba. se resaltan con gris los menores MAPE, mostrándose que el mejor pronóstico cuando no se tienen datos corruptos lo realizan los modelos M2 (modelo de arquitectura horaria, con función objetivo *norma* - l_1 y restricción EH) y M3 (modelo de arquitectura horaria, con función objetivo *norma* - l_1 , restricciones ED y EH). Mientras, que el peor resultado fue para los modelo comparativos Lasso y SVR, resaltados en un recuadro gris. Esto muestra que las restricciones pueden ayudar a dar mayor precisión al pronóstico, sobre todo con las funciones objetivos que tienen involucrada la norma- l_1 . La función objetivo que mejores resultados presenta, cuando no se tienen restricciones, es la norma- l_2 . El modelo de comparación con mejor rendimiento fue el MCO, pero no superó los resultados de ninguno de los modelos con arquitectura horaria. Lo anterior muestra que la arquitectura horaria, propuesta en este artículo, representa una mejoría para los modelos de pronóstico de demanda eléctrica.

En los resultados, también se puede observar que sin datos corruptos, las restricciones EH o la combinación entre ED y EH, producen los mismos MAPEs, sin importar la función objetivo o la arquitectura; lo que nos muestra que la restricción ED no está haciendo ningún efecto en el pronóstico sin datos corruptos. Al agregar solo la restricción PT en la arquitectura horaria, se observa una disminución de la precisión de entre 0.01 y 0.02 por ciento, en comparación con el modelo sin restricción; mientras que en el modelo de arquitectura única se ve una mayor disminución de la precisión, de cerca del 0.4 por ciento. Lo que da cuenta de que la restricción PT, limita algunos cambios en las pendientes que normalmente se pueden dar, disminuyendo la precisión del pronóstico, cuando no se tienen datos corruptos. Lo mismo pasa cuando se utilizan las tres restricciones propuestas, incluso el efecto se ve con un aumento mayor de los MAPEs.

En la tabla 2.3, se puede observar que todos los modelos de la arquitectura horaria realizaron un pronóstico más preciso que los modelos de arquitectura única. Estos resultados pueden explicarse, debido a que la arquitectura horaria realiza una mayor generalización a la hora de pronosticar. Para mayor claridad, se muestra la gráfica 2.1, donde se pueden observar los valores de los coeficientes β de cada rezago de la historia inmediata, para el modelo M1 (arquitectura horaria) y para el modelo M26 (arquitectura única). En la caso de la arquitectura horaria se cuenta con 24 coeficientes por cada variable explicativa, mientras que con la arquitectura única, se cuenta solo con un coeficiente, que debe resumir lo que hacen los 24 coeficientes de la arquitectura horaria. Siendo así como los modelos de arquitectura horaria realizan un aprendizaje más generalizado de los datos de entrenamiento.

Arq	Modelo	Sin R	EH	ED y EH	PT	ED, EH y PT
Horaria	l_1	2.85	2.75	2.75	2.87	3.09
	l_2	2.83	2.92	2.92	2.84	3.02
	Hu (1)	2.90	2.81	2.81	2.90	3.13
	Hu (2)	2.85	2.79	2.79	2.87	3.06
	Hu (3)	2.83	2.86	2.86	2.84	3.06
Única	l_1	3.70	3.63	3.63	4.14	4.17
	l_2	3.61	3.49	3.49	4.05	4.07
	Hu (1)	3.70	3.63	3.63	4.13	4.16
	Hu (2)	3.69	3.63	3.63	4.14	4.17
	Hu (3)	3.64	3.54	3.54	4.04	4.06
	MCO	3.61				
	Lasso	4.46				
	E.N.	4.03				
Prophet	8.94					
SVR	6.08					

Cuadro 2.3: MAPEs calculados con datos de prueba originales

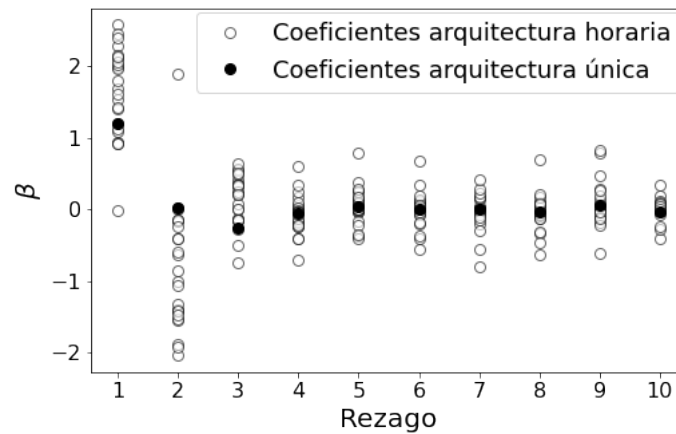


Figura 2.1: Coeficientes de los modelos M1 y M26 de arquitectura horaria y única, respectivamente, entrenados con datos originales. Construcción propia.

2.2.6. Resultados con datos corruptos

Cuando los datos históricos de demanda, utilizados para entrenar los modelos de pronóstico son llevados a cero, se pueden tener predicciones menores a la demanda real. Esta diferencia podrían generar un planeación del despacho energético menor al necesario para suplir las necesidades de los consumidores, lo que causaría graves efectos en la estabilidad de la tensión y la frecuencia del sistema de transmisión, llegando incluso a producir apagones en el sistema. Por esto es necesario que los modelos propuestos estén preparados para este tipo de datos corruptos.

Para poner a prueba los modelos implementados, una porción p de la demanda de entrenamiento fue llevada a cero de forma deliberada. Esta porción p de la información, fue seleccionada aleatoriamente, variando desde 5% hasta 45% en pasos de 5%. Creando, así, 9 bases de datos nuevas, que se mantienen iguales para todos los modelos. La figura 2.2 muestra, en un rango de 7 días, las afectaciones que sufre la demanda histórica cuando se tiene 20 por ciento de la




Figura 2.2: 20% de demanda de entrenamiento corrupta. Construcción propia.

información en cero.

Los hiperparámetros de los 50 modelos propuestos fueron recalculados con las nuevas bases de datos simuladas. Pero no se calcularon para cada una de las 9 bases de datos; el recálculo se realizó solo con las bases de datos con 25 y 45 por ciento de afectación. Cuando se puso a prueba los modelos con datos corruptos entre el 5 y 15 por ciento, se utilizaron los hiperparámetros encontrados con la base de datos original. Para las bases de datos con datos corruptos entre el 20 y el 35 por ciento, se utilizaron los hiperparámetros calculados con 25 por ciento de afectación. Finalmente, para las bases de datos con datos corruptos del 40 y el 45 por ciento, se utilizaron los hiperparámetros calculados con 45 por ciento de afectación.

Los resultados de los MAPEs calculados para cada modelo propuesto, se muestran en el mapa de calor presentado en la figura 2.3. Los MAPEs con un mejor rendimiento se muestran en un color verde claro; a medida que aumenta el valor del MAPE el color verde realiza una transición progresiva a un color azul. Como era de esperarse, a medida que aumenta el porcentaje de corrupción en los datos, el MAPE también va aumentando en todos los modelos, pero se observa que los modelos con función objetivo norma- l_2 , son los que peor desempeño muestran. Lo cual puede ser explicado, porque en la norma- l_2 , a los errores altos en los datos se les asigna más importancia, haciendo que los modelos entrenados con esta función objetivo pierdan precisión, llegando a MAPEs de casi el 50%, cuando se tienen afectaciones del 45%.

De la figura 2.3, se puede destacar que los modelos con arquitectura horaria, en general, muestran un mejor desempeño que los de arquitectura única, para porcentaje de corrupción de hasta el 35%. Solo cuando se empieza a tener corrupción de más del 40%, los modelos que no tienen restricciones, muestran mejores resultados para los de arquitectura única; sin embargo, para los de arquitectura horaria, se sigue teniendo mejores resultados cuando se usa la restricción PT. Cuando se tiene un porcentaje de corrupción del 45%, los modelos de arquitectura única y sin restricciones, son los que presentan los mejores resultados. Esto puede ser explicado porque, como se muestra en la figura 2.4, al aumentar el porcentaje de datos corruptos, el valor de los coeficientes




Figura 2.3: Mapa de calor con MAPEs para modelos propuestos. Construcción propia.

de los rezagos, en los modelos horarios, tienden a ser más cercanos a cero; perdiendo su capacidad de generalización, ya que pierden relevancia las variables explicativas asociadas a la historia de la demanda y ganan importancia las variables exógenas. En la figura 2.4, se comparan los coeficientes de los modelos M5 (modelo de arquitectura horaria, con función objetivo $norma - l_1$, restricciones ED, EH y PT) y M26 (modelo de arquitectura única, con función objetivo $norma - l_1$ y sin restricciones), cuando se entrenan con la base de datos con el 40% de los datos corruptos.

Siguiendo con los resultados que se muestran en la figura 2.3, se puede ver que los mejores resultados se presentan con los modelos que cuentan con la función objetivo $norma - l_1$ y Hu (1). Lo cual se da debido a que la $norma - l_1$ mantiene el mismo nivel de importancia para los errores altos y para los errores bajos; lo mismo pasa con la función Hu (1), ya que en estos modelos, por el valor de M , se le da mas importancia a la $norma - l_1$ que a la $norma - l_2$.

Observando el promedio para cada modelos, que se presenta en las últimas dos columnas de la figura 2.3. Se destacan los modelos M14 (modelo de arquitectura horaria, con función objetivo $Huber(M = 0,001)$ y restricciones PT), con un promedio de 5,11% y M36 (modelo de arquitectura única, con función objetivo $Huber(M = 0,001)$ y sin restricciones), con un promedio de 7,25%. Es importante aclarar que cuando se analiza el promedio de los MAPEs, el desempeño de 12 modelos de arquitectura horaria, son superiores que el mejor modelo de arquitectura única. Lo cual, al igual que en los resultados sin datos corruptos, muestra que la arquitectura horaria presenta ventajas que mejoran los resultados de los pronósticos, brindando robustez ante afectaciones, malintencionadas, en los datos. Además, se observa que agregar restricciones, como estrategia para dar robustez ante datos corruptos, también es efectivo, sobre todo cuando se combina con la arquitectura horaria.




Figura 2.4: Coeficientes de los modelos M5 y M26 de arquitectura horaria y única, entrenados con 40% de datos corruptos. Construcción propia.




Figura 2.5: Mapa de calor con MAPEs para mejor modelo propuesto (en promedio) VS los modelos comparativos. Construcción propia.

En la figura 2.5, a partir de un mapa de calor, se equiparan los resultados de los modelos comparativos y el mejor modelo (en promedio) propuesto. Este nuevo mapa de calor conserva la misma estructura de colores que el de la figura 2.3. Se puede observar que desde un porcentaje de corrupción bajo, el modelo M14, se destaca sobre los modelos comparativos, teniendo un MAPE menor en, cerca del 4%. Cuando el porcentaje de corrupción va aumentando, la diferencia en el desempeño también va aumentando hasta ser cercana a una ventaja del 10% del MAPE, diferencia que se presenta con el mejor modelo de comparación. El desempeño de los modelos MCO, Lasso y Elastic Net, no es destacable debido a que su función objetivo está basada en la norma- l_2 , la cual como se explicó anteriormente, no tiene un buen desempeño cuando se tiene errores en los datos. En cuanto a la metodología prophet, la cual según sus creadores, puede ser usada para series de tiempo corruptas o con datos faltantes, fue la que peor desempeño mostró. Por el contrario, podríamos decir que SVR es el modelo que mejor desempeño muestra, con relación a los demás modelos comparativos, debido a que en su función objetivo se tienen presente las desviaciones que tiene el modelo con los valores de entrenamiento. Pero a pesar del buen resultado del modelos SVR, sus MAPEs están bastante alejados de los mejores modelos con ambas arquitecturas.

Para mostrar con mayor claridad los resultados del desempeño de los modelos más representativos, se muestra la figura 2.6. En esta figura se puede observar como cambia el MAPE, a medida que se aumenta el porcentaje de datos corruptos. Se destaca el desempeño del modelo M14, el cual, desde un porcentaje de corrupción del 5 hasta 40 siempre mantuvo el MAPE menor a 7,5%,




Figura 2.6: MAPEs de 4 modelos representativos a medida que aumenta el porcentaje de datos corruptos. Construcción propia.

mostrando el buen desempeño de los modelos con arquitectura horaria que cuentan con restricciones. En cuanto a los modelos con arquitectura única, el mejor desempeño, en promedio, lo mostró el modelo M36, el cual a pesar de que los MAPEs en su mayoría fueron mayores al 5 %, es el que ante 45 % de datos corruptos, presentó la mejor robustez. Entre los modelos comparativos que se utilizaron, el que tuvo mejor desempeño fue SVR, pero sin tener resultados destacables; llegando a tener diferencias de cerca del 9 % del MAPE con respecto al modelo M14. Finalmente, en la figura 2.6, también se muestra el progreso del MAPE del modelo MCO, el cual es muy utilizado en la literatura para entrenar modelos de pronóstico, pero en este caso es uno de los que peor desempeño muestra, sobre todo porque no es robusto datos corruptos.

Como se mencionó al principio de esta sección, al tener porcentaje de los datos de entrenamiento en cero, el pronóstico puede estar por debajo de la demanda real. Algo que se puede observar en la figura 2.7, donde se muestra el pronóstico para la demanda con 30 % de datos de entrenamiento corruptos. Los modelos que no son robusto, como el SVR, presentan el comportamiento de subestimar la demanda; mientras que los modelos como el M14, que tienen una estructura pensada en su robustez, muestran un alto desempeño. El modelo M14, al tener una arquitectura horaria y la restricción PT, se evitan la subestimación de la demanda y los grandes desbalances en los cambios de pendiente. El modelo M36, a pesar de que tiene un buen desempeño, se observa que los mayores errores se cometen en los cambios de pendiente.

2.3. Conclusiones

La corrupción en los datos históricos, pueden causar graves afectaciones al pronóstico de demanda eléctrica. En este trabajo, se buscó dar robustez a los modelos de pronóstico, ante datos corrompidos de forma mal intencionada. Para cumplir este objetivo se implementaron tres estrategias que estaban enfocadas en: la función objetivo, la arquitectura y las restricciones de un




Figura 2.7: Pronóstico a 15 días de los modelos M36, M14 y SVR, con 30% de datos corruptos. Construcción propia.

modelo de optimización. Estas tres estrategias se podían combinar, permitiéndonos probar 50 modelos diferentes. Se mostró que los modelos típicos utilizados para hacer pronósticos y que están pensados para dar robustez bajo anomalías en los datos, como Lasso, Elastic Net o SVR, no son tan efectivos en el pronóstico de demanda con datos históricos corruptos; mientras que los modelos propuestos, que no tienen como función objetivo la norma- l_2 , son capaces de producir pronósticos de demanda mucho más precisos y confiables.

Las mayores contribución de este trabajo son: la estrategia de crear un modelo de arquitectura horaria y la estrategia de agregar restricciones al modelo de optimización. Con estas dos estrategias, se crearon varios modelos de pronóstico que presentan una alta precisión, cuando se tienen datos históricos corruptos. El modelo que mejor resultados presentó fue el que combinaba la función Huber (con $M = 0.001$), la arquitectura horaria y la restricciones que se enfocan en el cambio de la pendiente de la demanda. Este modelo presenta, para porcentaje de corrupción menores a 30%, MAPEs menores al 5%, algo que los modelos de arquitectura única solo pudieron lograr cuando se tenía un porcentaje de corrupción del 5% o menos. Se pudo determinar que las restricciones son mas relevantes para los modelos, cuando se empiezan a corromper los datos. Esta mejoría se da con mayor relevancia en los modelos de arquitectura única.

Los modelos Lasso, MCO y Elastic Net, por tener una función objetivo que tiene en cuenta el error del modelo al cuadrado, no son recomendables para entrenar modelos con datos históricos corruptos. El SVR fue el modelo de comparación con mejor desempeño, pero no fue competitivo en comparación con los modelos propuestos. Para futuros trabajos, se puede involucrar estas estrategias de entrenamiento para realizar pronósticos de demanda eléctrica que tengan alta penetración de generación distribuida. Como se mencionó anteriormente estas estrategias busca robustecer los modelos, para que no subestimen la demanda, cuando se tiene información en cero, y el efecto de

la alta penetración de GD en la red es bajar la demanda, haciendo que los modelos puedan tener errores de subestimación.

Pronóstico de demanda eléctrica a muy corto plazo, integrando la generación solar distribuida

En este capítulo se presenta el artículo *Very-Short Term Electricity Demand Forecasting Integrating Solar Distributed Generation*. Su nombre traducido al español le da nombre a este capítulo. Fue publicado en el *2021 IEEE International Conference on Engineering Veracruz (IEEE ICEV 2021)*. Sus autores son: Aarón Casadiegos-Osorio, Diego Mejía-Giraldo, Cristian Grajales-Espinal, Jorge Esteban Tobón-Villa y se puede encontrar con el DOI: 10.1109/ICEV52951.2021.9632643. En este artículo, se publicó la metodología propuesta para la integración de la generación distribuida en el pronóstico de demanda eléctrica.

3.1. Abstract

This paper presents different mathematical models to integrate solar distributed generation (DG) into very-short term demand forecasting processes in Colombia. The proposed models can forecast up to 4032 5-minute periods (two weeks) of net demand. To do so, historical data, calendar effects and meteorological data have been considered to define mathematical models. Also, different strategies and models like recurrent neural networks, generalized additive models, and ordinary least squares to incorporate the effect of solar DG have been carefully evaluated and compared. Multiple scenarios of solar DG penetration levels, previously elaborated by “The Mining and Energy Planning Unit (UPME)”, have been analyzed in order to explore the potential future advantages and drawbacks of the employed models and strategies. Results have shown that our models can forecast 4032 periods of net demand with MAPEs within 1.29% and 3.8%.

3.2. Introduction

3.2.1. Motivation

Recently, the growth of distributed generation (DG) sources has been noticeable in Colombia. In 2012, neither solar power nor autogeneration projects were installed in the Colombian system. Only 57 MW of cogeneration projects were installed in 2012 according to [13]. However, according to the power system operator [14], solar power, cogeneration, and autogeneration installed capacities climbed to 40.86 MW, 149 MW, and 122.94 MW respectively. Also, as a consequence of the fiscal incentive policy promoted by the Colombian legislation [15], the decrease in installation

costs of solar generation projects [16], and the search of an environmentally friendly energy mix, higher amounts of DG are expected.

Although the transition to renewable sources provides potential benefits to the power system and society, it also brings challenges when it comes to power system operation. As long as DG penetration levels, resulting demand—after subtracting DG generation—to be met by the generation system, displays a different daily pattern when compared to traditional demand curves. The difference between natural system demand and DG is known as net demand [17]. Additionally, net demand has a stronger random component given the DG participation; this is what makes it difficult to forecast. Therefore, according to [4] and [18], conventional methods applied to net demand forecasting are not accurate enough.

Traditionally, probabilistic and statistical models have been employed for net demand forecasting assuming that DG has no relevant effects. In California, it has been observed that significant DG penetration might yield to relevant pattern changes in the daily demand curve. This pattern has been referred to as “duck curve.” During daytime, when DG participation increases, net demand decreases. However, at the start of night-time when DG goes to zero, net demand drastically increases in a short period of time as illustrated in Fig. 3.1. This demand pattern encourages the design and construction of different strategies to consider DG as an important element within the forecasting technique.




Figura 3.1: Duck curve. Extraída de [19].

3.2.2. Literature review

Electric demand forecasting techniques has been the focus of research and investigation in the last decades. Reviews like [18], [20], and [21] explain, classify, and highlight advantages of different tools and strategies able to guarantee high performance metrics. Different models have been reported in the literature such as regression [21], [22], [23]; autoregressive models [24]; neural networks [25], [26]; generalized additive models (GAM) [27]. Also, a review of probabilistic

approaches for demand forecasting has been provided in [1].

Although a significant portion of electric demand forecasting studies has not considered DG, the situation has recently changed due to installation of DG resources. Indeed, power market institutions (ISOs, RTOs, TSOs of United States and Australia) met to discuss approaches and strategies to consider DG in the net demand forecasting processes [28].

In [29] and [30], authors have explained reasons why traditional demand forecasting approaches do not properly represent solar DG. These techniques are commonly based on least squares when it comes to estimate model coefficients [31]. According to [29], these coefficients capture historical average patterns of data employed for model training. Thus, such coefficients, do not produce appropriate net demand estimations in non-typical days when it is either extremely sunny or cloudy.

Also, in [4] two factors causing imprecision in predictive models are discussed: absence of essential variables and non-stationarity of the demand time series due to the continuous increasing DG capacity. In fact, one of the major conclusions of [32] is that if DG level surpasses 5%, traditional forecasting strategies may display a poor predictive performance.

In [33], a solar PV and net demand forecasting strategy is proposed. Authors have stated that such an approach provides better results than models currently employed by the Italian transmission system operator. Authors focus on forecast of solar generation employing an approach that combine meteorological-based models [34] and statistical or stochastic machine learning techniques [35].

This paper, therefore, presents multiple mathematical models like recurrent neural networks (RNN), long-short term neural networks (LSTM), generalized additive models (GAM), linear regression (LR), for net demand forecasting. Also, a set of different strategies and regressors to incorporate solar DG are employed. These models have been constructed and tested under different penetration levels of solar DG. In the end, a case study is presented where the proposed approach is applied to forecast electricity net demand of the Northern (Caribbean) area in Colombia.

The rest of this document is organized as follows. Section 2 presents the relevant theories and the implementation of the proposed model. Section 3 describes the information used to test the methodology and the prediction results. Finally, the main conclusions are summarized in Section 4.

3.3. Methodology

In general, this work focuses on demand forecasting considering the effects of distributed generation (DG) from solar PV. To do so, a series of forecasting methods, exposed in the literature and industry applications, have been considered and modified. The goal is to extract the maximum benefit of them in order to properly model demand reductions under significant penetration of solar resources; and thus establish recommendations and conclusions based on our comparisons and results.

Three strategies are assessed in this net demand forecasting routine. The first strategy considers the forecast of net demand based on its historical data and on meteorological variables. The rest are based on adjustments to the forecast, similar to what reference [29] has proposed.

3.3.1. Base case forecast strategy

Model training is performed using historical data of demand and exogenous variables. That is, demand y_t of period t is modeled as a function of its own past behavior considering different history data blocks:

- Immediate history: $y_{t-1}, y_{t-2}, \dots, y_{t-k}$; where k is the # five-minute of lags,
- One-week history: $y_{t-2016}, y_{t-2017}, \dots, y_{t-2016-j+1}$, where j is the # of 5-minute lags taken from the week before, and
- Mutlitple-day history: $y_{t-288}, y_{t-576}, \dots, y_{t-288m}$; where m is the # of previous days.

For simplicity, we will use $y_{[t]}$ to denote history blocks of available demand data. Demand y_t is also parameterized in terms of exogenous variables $x_{1,t}, x_{2,t}, \dots, x_{n,t}$. Among exogenous variables, we have considered calendar effects (dummy variables to represent types of day) and the hour (1 to 24) corresponding to the period to forecast. Additionally, a set of meteorological variables (ambient temperature, solar radiation, wind speed, and humidity). In general, our forecast models can be represented as:

$$y_t = f(y_{[t]}, x_{1,t}, \dots, x_{n,t} | \beta) + \varepsilon_t \quad (3.1)$$

where function $f(\cdot)$ and true coefficients β are to be estimated using different forecast models: LR, GAM, RNN, LSTM neural networks.

Once models are effectively trained, the forecast of exogenous variables at period t , namely $x_{j,t+h|t}, \forall j \in \mathcal{J}$ is needed to forecast net demand in future 5-minute periods $h = 1, 2, \dots, N$. Thus, the demand forecast produced by every model, denoted as $\hat{y}_{t+h|t}$ is computed as in eq. (3.2):

$$\hat{y}_{t+h|t} = \hat{f}\left(y_{[t]}, \{x_{j,t+h|t}\}_{j \in \mathcal{J}}, \hat{\beta}\right), \quad \forall h = 1, 2, \dots, N. \quad (3.2)$$

where $\hat{\beta}$ is the corresponding set of estimated parameters.

3.3.2. Solar DG as regressor variable

In this case, we have also considered the forecast of solar DG $\hat{g}_{t+h|t}$ as part of the regressor variables as shown in (3.3):

$$\hat{y}_{t+h|t} = \hat{f}\left(y_{[t]}, \{x_{j,t+h|t}\}_{j \in \mathcal{J}}, \hat{g}_{t+h|t}, \hat{\beta}\right), \quad \forall h = 1, 2, \dots, N. \quad (3.3)$$

3.3.3. Mean DG ex-post correction

In this approach, once net demand has been forecasted as explained in (3.2), a correction step is developed. Coefficients $\hat{\beta}$ are estimated using data representing multiple meteorological conditions. This might cause models to provide net demand forecasts close to the net demand resulting of assuming ‘‘average’’ meteorological conditions, which could not reflect the situation of a sunny day far from average days [29]. This motivates the introduction of a correction term based on the deviation of solar generation from its typical values as shown in (3.4):

$$\hat{y}_{t+h|t}^c = \hat{y}_{t+h|t} + \bar{g}_{t+h} - \hat{g}_{t+h|t}, \quad \forall h = 1, 2, \dots, N, \quad (3.4)$$

where $\hat{y}_{t+h|t}^c$ represents the adjusted net demand forecast. Historical mean of solar DG is denoted by \bar{g}_{t+h} , and $\hat{g}_{t+h|t}$ represents the forecast for period $t + h$ of solar DG and is available at period t .

3.4. Results

3.4.1. Data

This paper presents results using data of actual 5-minute demand of the northern region in Colombia recorded between September 1, 2017 and September 30, 2018. Data was provided by the Colombian Independent System Operator XM, which was collected aggregating measurements from SCADA systems. Data basically represents gross demand since there was no evidence of significant solar DG in Colombia between 2017 and 2018.

3.4.2. Scenarios of Solar DG in Colombia

Since solar DG is still under development in Colombia, we have constructed scenarios of solar DG penetration similar to what is mentioned in [36]. It was assumed that solar DG installed capacity could be 10 %, 20 %, or 30 %. For each of these scenarios, we constructed hypothetical 5-minute solar DG curves based on the model presented in [37]. This model employs solar irradiance, ambient temperature, nominal system power, maximum observed irradiance, energy performance of the installation which is calculated according to [38].

Once solar DG scenarios were constructed, net demand scenarios were created and computed as the difference between gross demand and simulated solar DG. Fig. 3.2 and Fig. 3.3 illustrate solar DG and resulting net demand respectively under different scenarios of solar DG penetration levels.




Figura 3.2: Scenarios of solar DG between June 2, 2018 and June 4, 2018

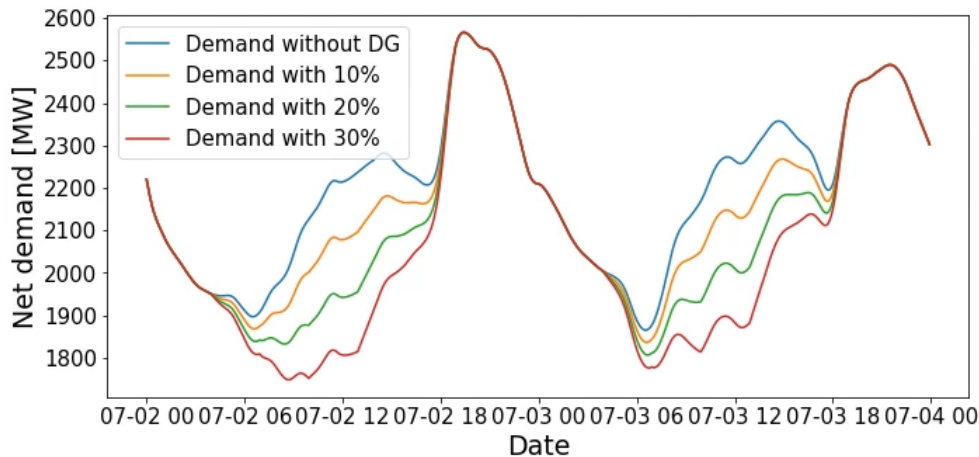


Figura 3.3: Net demand for Caribe area between June 2, 2018 and June 4, 2018.

3.4.3. Model training

A dataset containing demand data from september 1, 2017 to July 6, 2018 was employed for model training. This amount of data represents 95 % of the entire dataset. Test dataset contains data from July 7, 2018 to July 21, 2018. Ambient temperature, solar radiation, humidity, and wind speed are the meteorological variables employed as regressors in the models. These data were obtained from six different geographical locations in the Caribbean region in Colombia. In order to have a unique time series for each meteorological variable, a weighted average of the variables was used. Weights were adjusted proportional to the electricity demand of each location.

Based on the base model structure explained in 3.3.1, the training process employed $k = 15$ five-minute lags related to immediate net demand history, $j = 3$ five-minute lags of the same period a week before, and $m = 14$ lags of the same period of the fourteen previous days. Also, model hyperparameters are specified in Table 3.1.

3.4.4. Results using base case forecast strategy

Fig. 3.4 shows 14-day net demand results for 20 % of solar DG penetration. Although day-14 forecast does not seem very accurate, the overall error metrics are still low. Table 3.2 shows MAPE for LR, GAM, LSTM, and RNN under different solar DG penetration levels. This metric has been computed as the average percent error over 4032 forecasts (14 days in advance with 5-minute

Cuadro 3.1: Model parameters

Model	Parameters						
LR	Polynomial degree of meteorological variables						
	5						
GAM	n splines			spline order			
	5			3			
LSTM	layers	neurons	activ f	lr	drop	epochs	batch
	2	[100,50]	relu	0.001	0.01	17	1000
RNN	layers	neurons	activ f	lr	drop	epochs	batch
	2	[100,50]	relu	0.001	0.01	17	1000




Figura 3.4: Demand forecast using base case forecast strategy.

periods). In general, forecast results show MAPEs between 1.65 % and 3.5 %. Accuracy of LR and GAM slightly increases with the solar DG penetration level. However, MAPEs of LSTM and RNN do not exhibit any relationship with solar DG level.

Cuadro 3.2: Forecast performance using base case forecast strategy: MAPE (%)

Model	Solar DG penetration level		
	10 %	20 %	30 %
LR	1.707	1.749	1.870
GAM	1.651	1.738	1.924
LSTM	2.536	1.473	1.567
RNN	2.713	2.703	3.494

3.4.5. Results using solar DG as regressor variable

Table 3.3 also shows MAPE results for LR, GAM, LSTM, and RNN under different solar DG penetration levels. In general, forecast results show MAPEs between 1.58 % and 3.8 %. Once the solar DG penetration level increases, MAPE of both LR and GAM remains small and do not show significant variability as opposed to LSTM.

Fig. 3.5 presents the forecast under 20 % of DG level. GAM outperforms the rest of models. Indeed, peak demand values are properly captured by this model.

Cuadro 3.3: Forecast performance using solar DG as regressor variable: MAPE (%)

Model	Solar DF penetration level		
	10 %	20 %	30 %
LR	1.681	1.717	1.851
GAM	1.582	1.677	1.900
LSTM	2.848	2.921	3.801
RNN	3.235	2.978	3.193

Cuadro 3.4: Forecast performance using Mean DG ex-post correction: MAPE (%)

Model	Solar DG penetration level		
	10 %	20 %	30 %
LR	1.695	1.771	1.962
GAM	1.656	1.760	1.957
LSTM	1.291	1.487	1.778
RNN	1.413	1.531	1.567

3.4.6. Results using Mean DG ex-post correction

Table 3.4 shows MAPE of different models when Mean DG ex-post correction is employed. It can be observed that as long as GD level increases, performance slightly decreases. However, under this approach, minimum and maximum MAPE is 1.291 % and 1.962 % respectively.

Fig. 3.6 displays the forecast of demand forecast considering Mean DG ex-post correction error as explained in 3.3.3. In this case, LSTM and RNN models have improved performance (see Table 3.4) and their corresponding forecast is close to the observed demand even in the very last days.

3.4.7. Strategy comparison

This section presents an analysis of the performance of the approaches implemented in this work. Table 3.5 collects MAPE results and highlights best results in terms of models and strategies employed in this work for different DG levels.

LR and GAM models exhibit robustness in the sense that their performance is similar under different DG penetration levels.

According to our results, the approach of solar Mean DG ex-post correction error has shown to provide the most accurate net demand forecasts since it achieves the minimum MAPE as presented in Table 3.5.

Despite base case forecast strategy does not consider any DG correction in the models, MAPE results have demonstrated that net demand is properly forecasted. In fact, MAPEs below 3.8 % in a "14-day horizon and 5-minute periods" forecast is remarkable.

Fig. 3.7 shows the instantaneous error during the two-week out-of-sample period. In most of the days, both LR and GAM models achieve instantaneous errors below 6 %. However, as long as




Figura 3.5: Demand forecast using Solar DG as explanatory variable.

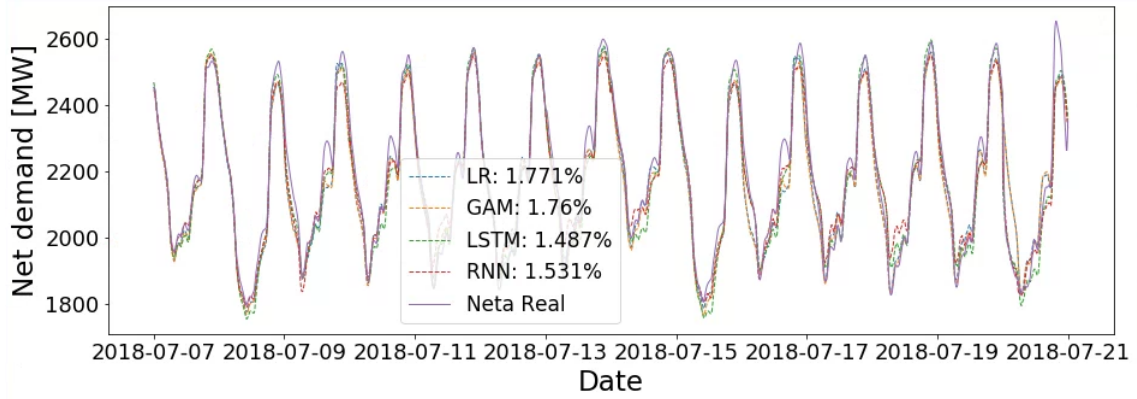


Figura 3.6: Demand forecast using strategy Mean DG ex-post correction error.




Figura 3.7: Instantaneous forecast error

the forecast gets close to the horizon (period $t + 4032$), such errors tend to increase even above 10 % in some specific periods. This behavior is expected in those periods since lags required by our models are generated by the models themselves. Thus, forecast errors are fed back to the model, which in turn cause an additional error.

Table 3.6 shows standar deviations of MAPE for each model and strategy. The mean DG ex-post correction is the approach with the smallest standard deviation; and it remains small even for different DG levels. These results suggest that the error correction approach performs satisfactorily even if the model is changed.

3.5. Conclusions

This paper focused on the adaptation and implementation of three different strategies in order to forecast net demand under hypothetical presence of solar DG. Traditional demand forecasting approaches need to be revised when it comes to net demand forecasting to accomodate the effects of potential solar DG penetration levels. Although the mean DG ex-post correction strategy performs the best, the base case strategy achieves satisfactory results. The mean DG ex-post

Cuadro 3.5: MAPE (%)

Model	10 % DG level		
	Base case	Mean DG ex-post correction	Solar DG as regressor variable
LR	1.707	1.695	1.681
GAM	1.651	1.656	1.582
LSTM	2.536	1.291	2.848
RNN	2.713	1.413	3.235
Average	2.152	1.514	2.337
20 % DG level			
LR	1.749	1.771	1.717
GAM	1.738	1.760	1.677
LSTM	1.473	1.487	2.921
RNN	2.703	1.531	2.978
Average	1.916	1.637	2.332
30 % DG level			
LR	1.870	1.962	1.851
GAM	1.924	1.957	1.900
LSTM	1.567	1.778	3.801
RNN	3.494	1.567	3.193
Average	2.214	1.816	2.686

correction approach has shown positive results. Although it was not necessarily the one with the lowest MAPE in all of our experiments, it proved to be the best approach on average. Additionally, the MAPE standard deviation of such a strategy was the smallest among the three approaches implemented, which indicates that its results are reliable and do not heavily depend on the forecast model. In general, the forecasting performance metrics achieved with the presented strategies are promising. MAPEs for 14-day forecast, using 5-minute data, were below 3.801 %.

Cuadro 3.6: *MAPE standard deviation.*

	Base case	Mean DG ex-post correction	Solar DG as regressor variable
10 %	0.477	0.168	0.719
20 %	0.468	0.129	0.627
30 %	0.759	0.162	0.839

Conclusiones

Este documento realiza un estudio empírico sobre los efectos de la penetración de la GD y la corrupción de los datos en el pronóstico de demanda. Para cumplir con el objetivo de robustecer el pronóstico ante alta penetración de GD, se implementaron 2 metodologías. La primera incluye la GD como variable regresora y la segunda realiza un corrección del pronóstico con la GD media. La metodología que mejores resultados, en promedio presenta, es la que realiza un ajuste al pronóstico. Para cumplir el objetivo de mayor robustez del pronóstico ante corrupción en los datos, se implementaron 3 estrategias enfocadas en modelos de optimización. La función objetivo, las restricciones y la arquitectura del modelo, fueron los enfoques para abordar este segundo objetivo. Siendo destacables los resultados cuando se utilizaba una arquitectura horaria combinada con la función huber y la restricción que no permitir cambios atípicos en la pendiente de la demanda. Para mayor detalle de las conclusiones sobre las metodologías de este documento, se pide al lector que se dirija a las secciones 3.5 y 2.3, ya que estas son las conclusiones de los artículos escritos.

Se resalta la importancia de trabajar con nuevas metodologías que se ajusten a el crecimiento global de los recursos energéticos renovables, como la generación distribuida. Estas nuevas metodologías permitirán una transición energética eficiente y con menor impacto de los efectos secundarios que se pueden tener al cambiar los procesos que llevan años utilizándose en la industria mundial. Estas nuevas metodologías también pueden extrapolarse a otros contextos, donde sea necesario hacer pronósticos robustos ya que pocas veces se utilizan modelos de optimización con restricciones en los pronósticos de series de tiempo. Como trabajos futuros, en el desarrollo de modelos robusto ante penetración de GD, se pueden combinar los dos enfoques que se implementaron en este documento. Esto debido a que la GD puede causar el mismo efecto, de subestimación en los pronósticos, que causan los datos corruptos. También se espera implementar una librería en Python para que las personas externas a esta investigación, puedan hacer uso de las metodologías implementadas y realizar pronósticos robustos.

Apéndice

Apéndice **A**

Otras publicaciones

Durante el desarrollo de la tesis de maestría se presentaron otras publicaciones y se participó en varios eventos de divulgación de conocimiento. El primero fue la participación en una jornada de investigación de posgrados, en la facultad de ingeniería de la Universidad de Antioquia, donde se presentaron resultados preliminares de un caso de estudio desarrollado con las metodologías propuestas en esta tesis. El segundo es la participación, con un resumen y una presentación en el *congreso 2022 IISE Región 16, Bogotá, Colombia*.

A continuación, se presentan los certificados de participación en los eventos mencionados.

Agradecimientos

Quisiera dar un agradecimiento a todas las personas que de alguna u otra forma me ayudaron a cumplir este objetivo.

A mis padres, José de Diós Casadiegos y Yenny del Rosario Osorio, por estar siempre presentes apoyándome y aconsejándome en todas las decisiones de mi vida. A mis dos hermanos, Yenny María Casadiegos y Sebastian Casadiegos porque desde pequeño me han acompañado en todos los retos que he asumido. A mi novia, Yajaira Arias por su acompañamiento permanente, su paciencia y su amor. A mis amigos de Casa de Máquinas, por la amistad brindada durante mi carrera de pregrado. Especialmente a Juan Camilo Camargo Berrueco, por ayudarme a resolver los problemas que se me presentaron durante este proceso. A mi asesor Diego Mejía Giraldo, que siempre será un ejemplo a seguir, un agradecimiento especial, porque durante cerca de ocho años no solo me ha brindado sus enseñanzas de manera desinteresada, sino que afortunadamente también he recibido sus consejos que me acompañarán durante toda mi vida profesional y personal. A la Universidad de Antioquia, por presentarme un mundo de conocimiento donde me he enriquecido con saberes y donde he podido compartir con personas que me han enseñado a valorar los pequeños y grandes detalles de la vida.

Medellín, 2022

*Aarón José
Casadiegos Osorio*

Bibliografía

- [1] T. Hong and S. Fan, “Probabilistic electric load forecasting: A tutorial review,” *International Journal of Forecasting*, vol. 32, no. 3, pp. 914–938, Jul. 2016. [Online]. Available: <http://www.sciencedirect.com/science/article/pii/S0169207015001508>
- [2] R. Flórez, “Control de frecuencia en sistemas de energía eléctrica,” Ph.D. dissertation, Universidad Nacional, Bogotá, DC, 2017.
- [3] H. He, Z. Luo, Q. Wang, M. Chen, H. He, L. Gao, and H. Zhang, “Joint operation mechanism of distributed photovoltaic power generation market and carbon market based on cross-chain trading technology,” *IEEE Access*, vol. 8, pp. 66 116–66 130, 2020.
- [4] J. Foster, X. Liu, and S. McLoone, “Short-term load forecasting with high levels of distributed renewable generation,” in *2017 52nd International Universities Power Engineering Conference (UPEC)*. IEEE, 2017, pp. 1–6.
- [5] S. Boyd and L. Vandenberghe, *Introduction to Applied Linear Algebra: Vectors, Matrices, and Least Squares*. Cambridge: Cambridge University Press, 2018.
- [6] J. Luo, T. Hong, and S.-C. Fang, “Benchmarking robustness of load forecasting models under data integrity attacks,” *International Journal of Forecasting*, vol. 34, no. 1, pp. 89–104, 2018. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S0169207017300900>
- [7] —, “Robust regression models for load forecasting,” *IEEE Transactions on Smart Grid*, vol. 10, no. 5, pp. 5397–5404, 2019.
- [8] T. Hong, J. Xie, and J. Black, “Global energy forecasting competition 2017: Hierarchical probabilistic load forecasting,” *International Journal of Forecasting*, vol. 35, no. 4, pp. 1389–1399, 2019. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S016920701930024X>
- [9] S.-J. Kim, K. Koh, M. Lustig, S. Boyd, and D. Gorinevsky, “An interior-point method for large-scale ℓ_1 -regularized least squares,” *IEEE Journal of Selected Topics in Signal Processing*, vol. 1, no. 4, pp. 606–617, 2007.
- [10] H. Zou and T. Hastie, “Zou h, hastie t. regularization and variable selection via the elastic net. j r statist soc b. 2005;67(2):301-20,” *Journal of the Royal Statistical Society: Series B (Statistical Methodology)*, vol. 67, pp. 301 – 320, 04 2005.
- [11] S. Taylor and B. Letham, “Forecasting at scale,” *PeerJ Preprints 5:e3190v*, vol. 2, 09 2017.

- [12] A. J. Smola and B. Schölkopf, “A tutorial on support vector regression,” *Statistics and Computing*, vol. 14, no. 3, pp. 199–222, 2004.
- [13] XM, “Informe Operacion del SIN y Administraci3n del Mercado 2013,” XM filial ISA, Medell3n, Antioquia, Tech. Rep., 2013. [Online]. Available: <http://informesanuales.xm.com.co/SitePages/Default.aspx>
- [14] —, “Reporte Integral de Sostenibilidad Operacion y Mercado 2020,” XM filial ISA, Medell3n, Antioquia, Tech. Rep., 2020. [Online]. Available: <https://informeanual.xm.com.co/informe/pages/xm/24-capacidad-efectiva-neta.html>
- [15] UPME, “Guia practica para la aplicacion de los incentivos tributarios de la ley 1715 de 2014,” https://www1.upme.gov.co/Documents/Cartilla_IGE_Incentivos_Tributarios_Ley1715.pdf, 2014, accessed: 2021-05-15.
- [16] L. Garc3a, M. Parikh, and R. Manghani, “Evoluci3n futura de costos de las energ3as renovables y almacenamiento en am3rica latina,” https://publications.iadb.org/publications/spanish/document/Evoluci3n_futura_de_costos_de_las_energ3as_renovables_y_almacenamiento_en_Am3rica_Latina_es.pdf, Dec. 2019, accessed: 2021-05-17.
- [17] S. E. Razavi, A. Arefi, G. Ledwich, G. Nourbakhsh, D. B. Smith, and M. Minakshi, “From load to net energy forecasting: Short-term residential forecasting for the blend of load and PV behind the meter,” *IEEE Access*, vol. 8, no. 99, pp. 224 343–224 353, Dec. 2020. [Online]. Available: <https://ieeexplore.ieee.org/document/9292948/>
- [18] D. W. van der Meer, J. Wid3n, and J. Munkhammar, “Review on probabilistic forecasting of photovoltaic power production and electricity consumption,” *Renewable and Sustainable Energy Reviews*, vol. 81, pp. 1484–1512, 2018. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S1364032117308523>
- [19] CAISO, “USING RENEWABLES TO OPERATE A LOW-CARBON GRID: Demonstration of advanced reliability services from a utility-scale solar PV plant.” <http://www.caiso.com/Documents/UsingRenewablesToOperateLow-CarbonGrid.pdf>, 2017, accessed: 2021-05-07.
- [20] C. Deb, F. Zhang, J. Yang, S. E. Lee, and K. W. Shah, “A review on time series forecasting techniques for building energy consumption,” *Renewable and Sustainable Energy Reviews*, vol. 74, pp. 902–924, Jul. 2017. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S1364032117303155>
- [21] T. Hong, “Short term electric load forecasting,” phdthesis, North Carolina State University, Raleigh, NC, Jan. 2010.
- [22] B. Liu, J. Nowotarski, T. Hong, and R. Weron, “Probabilistic load forecasting via quantile regression averaging on sister forecasts,” *IEEE Transactions on Smart Grid*, vol. 8, no. 2, pp. 730–737, Mar. 2017.
- [23] A. Y. Saber and A. K. M. R. Alam, “Short term load forecasting using multiple linear regression for big data,” in *2017 IEEE Symposium Series on Computational Intelligence (SSCI)*. Honolulu, HI, USA: IEEE, Sep. 2017, pp. 1–6.

- [24] A. Kaur, H. T. C. Pedro, and C. F. M. Coimbra, “Impact of onsite solar generation on system load demand forecast,” *Energy Conversion and Management*, vol. 75, pp. 701–709, Nov. 2013. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S0196890413004858>
- [25] M. Mordjaoui, S. Haddad, A. Medoued, and A. Laouafi, “Electric load forecasting by using dynamic neural network,” *International Journal of Hydrogen Energy*, vol. 42, no. 28, pp. 17 655–17 663, Jul. 2017. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S0360319917310455>
- [26] A. Rahman, V. Srikumar, and A. D. Smith, “Predicting electricity consumption for commercial and residential buildings using deep recurrent neural networks,” *Applied Energy*, vol. 212, pp. 372–385, Feb. 2018. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S0306261917317658>
- [27] F. Ziel and B. Liu, “Lasso estimation for GEFCom2014 probabilistic electric load forecasting,” *International Journal of Forecasting*, vol. 32, no. 3, pp. 1029–1037, Jul. 2016. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S0169207016000091>
- [28] D. Simons, “The mile-high 2019 ISO forecasting summit,” <https://blogs.itron.com/the-mile-high-2019-iso-forecasting-summit/>, May 2019, accessed: 2021-05-07.
- [29] F. A. Monforte, C. Fordham, J. Blanco, S. Barsun, A. Kankiewicz, and B. Norris, “Improving short-term load forecasts by incorporating solar PV generation,” Itron and CAISO, San Diego, California, Tech. Rep. TBD, 2016. [Online]. Available: <https://www.itron.com/-/media/feature/products/documents/white-paper/101525wp01-forecast-simulations.pdf>
- [30] F. A. Monforte, “Developing net load uncertainty forecasts to support system operations,” <https://blogs.itron.com/developing-net-load-uncertainty-forecasts-to-support-system-operations/>, Mar. 2019, accessed: 2021-05-06.
- [31] C. Yu and W. Yao, “Robust linear regression: A review and comparison,” *Communications in Statistics - Simulation and Computation*, vol. 46, no. 8, pp. 6261–6282, 2017. [Online]. Available: <https://www.tandfonline.com/doi/full/10.1080/03610918.2016.1202271>
- [32] Y. Wang, N. Zhang, Q. Chen, D. S. Kirschen, P. Li, and Q. Xia, “Data-driven probabilistic net load forecasting with high penetration of behind-the-meter PV,” *IEEE Transactions on Power Systems*, vol. 33, no. 3, pp. 3255–3264, 2018, conference Name: IEEE Transactions on Power Systems.
- [33] M. Pierro, R. Perez, M. Perez, D. Moser, and C. Cornaro, “Italian protocol for massive solar integration: Imbalance mitigation strategies,” *Renewable Energy*, vol. 153, pp. 725–739, Jun. 2020. [Online]. Available: <https://aplicacionesbiblioteca.udea.edu.co:2062/science/article/pii/S0960148120301671>
- [34] M. Pierro, F. Bucci, M. De Felice, E. Maggioni, A. Perotto, F. Spada, D. Moser, and C. Cornaro, “Deterministic and stochastic approaches for day-ahead solar power forecasting,” *Journal of Solar Energy Engineering*, vol. 139, no. 2, Nov. 2016. [Online]. Available: <https://doi.org/10.1115/1.4034823>

-
- [35] M. Pierro, M. De Felice, E. Maggioni, D. Moser, A. Perotto, F. Spada, and C. Cornaro, “Data-driven upscaling methods for regional photovoltaic power estimation and forecast using satellite and numerical weather prediction data,” *Solar Energy*, vol. 158, pp. 1026–1038, Dec. 2017. [Online]. Available: <https://aplicacionesbiblioteca.udea.edu.co:2062/science/article/pii/S0038092X17308617>
- [36] D. Tobon Orozco and S. Flórez, “Optimización de herramientas multiobjetivo para la toma de decisiones de inversión en sistemas aislados sostenibles de energía,” Universidad de Antioquia, ISA and COLCIENCIAS, Medellin, Colombia, Tech. Rep., Jan. 2008. [Online]. Available: https://www.researchgate.net/publication/254427979_Optimizacion_de_herramientas_multiobjetivo_para_la_toma_de_decisiones_de_inversion_en_sistemas_aislados_sostenibles_de_energia
- [37] UPME, MINMINAS, BID, and FMAM, “Integración de las energías renovables no convencionales en colombia,” UPME, Bogota, Colombia, Tech. Rep. ISBN No. 978-958-8363-26-4, 2015. [Online]. Available: http://www1.upme.gov.co/DemandaEnergetica/INTEGRACION_ENERGIAS_RENOVANLES_WEB.pdf
- [38] A. Martínez-Porras and L. Luengo, “Central solar fotovoltaica de 5 MW con sistema de posicionamiento autónomo.” Ph.D. dissertation, Universidad Politecnica de Cataluña., Barcelona, España, Jun. 2010. [Online]. Available: <https://upcommons.upc.edu/bitstream/handle/2099.1/10199/Mem%20ria.pdf?sequence=1>

Abreviaciones

GD	Generación Distribuida
UPME	Unidad de Planeación Minero Energética
MW	Mega Vatios
PV	Foto Voltaico
RNN	Redes Neuronales Recurrentes
LSTM	Redes Neuronales de Largo-Corto Plazo
RL	Regresión Lineal
ED	Restricción de Energía típica Diaria
EH	Restricción de Energía típica Horaria
PT	Restricción de Pendientes rípicas de la demanda
GEFCom	Competencia Global de Pronostico de Energía
ISONE	Operador Independiente del sistema de New England
MCO	Mínimos Cuadrados Ordinarios
SVR	Regresión de Soporte Vectorial
MAPE	Error Porcentual Absoluto Medio

