



**Universidad
de Medellín**
Ciencia y Libertad

Diseño de un modelo de pronóstico para la mejora de las ofertas comerciales en el Mercado Eléctrico Mayorista de México: Caso MVM

Agustín José Mazzeo

Universidad de Medellín
Facultad de Ingenierías, Maestría en Ingeniería de Software
Medellín, Colombia
2019

Diseño de un modelo de pronóstico para la mejora de las ofertas comerciales en el Mercado Eléctrico Mayorista de México: Caso MVM

Agustín José Mazzeo

Trabajo de grado presentado como requisito parcial para optar al título de:
Magister en Ingeniería de Software

Directora:

PhD. Lina María Sepúlveda Cano

Co-director:

MSc. Ricardo Alonso Gallego Burgos

Línea Temática:

Analítica de negocios aplicada al sector de energía

Universidad de Medellín

Facultad de Ingenierías, Maestría en Ingeniería de Software

Medellín, Colombia

2019

Agradecimientos

Este trabajo de investigación no habría sido posible sin la ayuda y la guía de muchos. Agradezco a mi directora de proyecto la PhD. Lina María Sepúlveda Cano por su colaboración, permanente predisposición y dedicación que resultaron indispensable para la concreción de este trabajo; a mi co-director de proyecto el MSc. Ricardo Alonso Gallego Burgos por su apoyo y tiempo para discutir y perfeccionar este trabajo; a la PhD. Luisa Fernanda Villa Montoya del Programa Ingeniería de Sistemas de la Facultad de Ingeniería de la Universidad de Medellín por sus valiosas sugerencias y comentarios que permitieron refinar varias ideas para el desarrollo del artículo de revisión sistemática de literatura. Agradezco a la Universidad de Medellín y a MVM Ingeniería de Software SAS que me otorgaron el apoyo y los recursos necesarios para poder dedicarle tiempo a la investigación. Finalmente, y no menos importante, destaco que no hubiera sido posible llevar a cabo la realización de la maestría y de este trabajo de investigación sin el apoyo y comprensión de mi esposa Adriana, mis hijas Melanie y Luciana y mi madre.

Resumen

El presente trabajo de investigación revisa los modelos desarrollados para el pronóstico de consumos y precios de energía eléctrica, las variables utilizadas y las métricas de error para medir la precisión de dichos modelos. Tiene como objetivo proponer un nuevo modelo de pronóstico que tenga el menor error posible en su predicción para la variable eléctrica precio marginal local para el mercado eléctrico mexicano. Este modelo se utilizará como base para que, en un futuro cercano, MVM Ingeniería de Software S.A.S. desarrolle el módulo o producto a incorporar en plataforma *Energy Suite* que le permita adquirir capacidades analíticas.

Palabras clave: Modelos de Previsión, Precio Marginal Local, Corto plazo, Mercado Eléctrico Mayorista, México.

Abstract

The following research work analyses the models developed for the forecast of consumption and prices of electric power, the variables used and the error measures that are used to calculate the accuracy of these models in order to elaborate a new forecast model with the smallest possible error in its prediction for the local marginal price electrical variable for the Mexican power market. This model will become the foundation over where “MVM Ingeniería de Software S.A.S.”, in the near future, will develop the module or product to be incorporated in the *Energy Suite* platform allowing it to acquire analytical capabilities.

Keywords: Forecast models, Local Marginal Price, Short-Term, Wholesale Energy Market, Mexico.

Contenido

Agradecimientos	III
Resumen	IV
Lista de acrónimos	VII
1. Introducción	1
2. Contextualización	3
2.1. Introducción	3
2.2. Contextualización del problema	3
2.3. Planteamiento del problema	4
2.4. Pregunta de investigación	4
2.5. Hipótesis	5
2.6. Alcance	5
2.7. Justificación	5
2.8. Objetivos	6
2.8.1. Objetivo general	6
2.8.2. Objetivos específicos	6
3. Fundamentación teórica	7
3.1. Introducción	7
3.2. Pronósticos de series de tiempo	7
3.3. Mercado eléctrico de energía	9
3.4. Estado del arte	11
3.4.1. Metodología para el desarrollo de la RSL	11
3.4.2. Hallazgos y resultados de la RSL desarrollada	28
3.4.3. Discusión de la RSL desarrollada	32
3.4.4. Artículos de la RSL: A review on time series forecasting techniques for building energy consumption	34
3.4.5. Hallazgos y resultados de la RSL analizada	44
3.4.6. Discusión de la RSL analizada	57
3.4.7. Conclusiones sobre el capítulo 4 de Modeling and forecasting electricity loads and prices: a statistical approach	59

4. Marco Metodológico	61
4.1. Introducción	61
4.2. Descripción del área de estudio	61
4.3. Metodología de investigación	61
4.4. Desarrollo de marco metodológico	62
5. Resultados	82
5.1. Introducción	82
5.2. Resultados	82
6. Conclusiones y recomendaciones	89
6.1. Introducción	89
6.2. Conclusiones	89
6.3. Recomendaciones	90
6.4. Trabajos futuros	91
A. Anexo: Necesidades del negocio	92
B. Anexo: Historias de usuario	95
C. Anexo: Diagrama relacional base de datos ESCentralRepo	100
D. Anexo: Consultas SQL Exploración Fuente de Información	102
E. Anexo: Resultados script R de muestreo	114
F. Anexo: Mejor calibración por modelo y técnica	116
Bibliografía	125

Lista de acrónimos

Tabla 0-1.: Lista de acrónimos

Acrónimo		Acrónimo	
ANFIS	Adaptive Neuro-Fuzzy Inference System	HIS	Heavy Industry Share
ANN	Artificial Neural Networks	IMP	Energy Imported
APE	Absolute Percentage Error	IPSO	Improved Particle Swarm Optimization
AR	Auto Regression	LSSVR	Least Squares Support Vector Regression
ARIMA	Autoregressive Integrated Moving Average	MAE	Mean Absolute Error
ARMAX	Autoregressive Moving Average with Exogenous Variable	MAED	Model for Analysis of Energy Demand
BP	Back Propagation	MAPE	Mean Absolute Percentage Error
CEE	Consumo de Energía Eléctrica	MaxAPE	Maximal Absolute Percentage Error
CV	Coefficient Variation	MdAPE	Median Absolute Percentage Error
DE	Differential Evolution	ME	Mean Error
Dstat	Directional Statistic	MLP	Multilayer Perceptron
DWT	Discrete Wavelet Transform	MSE	Mean squared error
EEMD	Ensemble Empirical Mode Decomposition	NAR	Nonlinear autoregressive
EIS	Efficient Improvement	NARX	nonlinear autoregressive exogenous
ENN	Elman Neural Network	NRMSE	Normalized Root Mean Square Error
ESN	Echo State Network	POP	Population
EXP	Energy Exported	PSO	Particle Swarm Optimization
FF	Feed Forward	R	Coefficient of Determination
FH	Factor Humedad	RBF	Radial Basis Function
FWNN	Fuzzy Wavelet Neural Network	RM	Regression Model
GA	Genetic Algorithm	RMSE	Root Mean Square Error
GD	Gradient Descent	RS	Radiación Solar
GDP	Gross Domestic Product	SVD	Singular Value Decomposition
GFS	Genetic Fuzzy System	SVM	Support Vector Machine
GM	Grey Model	T	Temperatura
GMARE	Geometric Mean Relative Absolute Error	TI	Total Imports
GP	Genetic Programming	WS	Wind Speed
H	Híbrido		

1. Introducción

El presente proyecto de investigación tiene como principal objetivo proponer un nuevo modelo de pronóstico para las variables eléctricas, como el consumo de energía o el precio de energía del sector eléctrico, que obtenga la mayor precisión posible. Puntualmente, pretende responder a la necesidad de contar con un modelo de pronóstico para la plataforma *Energy Suite* de MVM Ingeniería de Software S.A.S. que permita a los suministradores calificados del Mercado Eléctrico Mayorista (MEM) de México mejorar su posición competitiva en las operaciones de compra y venta de energía.

Por lo tanto, el planteamiento y desarrollo de este trabajo de investigación se fundamentó en la siguiente pregunta de investigación: ¿Qué modelos o técnicas de pronóstico pueden ser empleados para pronosticar las variables eléctricas que permitan establecer una adecuada oferta por parte de un participante del MEM de México y que a su vez permitan ampliar la línea base tecnológica de la plataforma *Energy Suite* de MVM?

Para el desarrollo de este trabajo, se plantearon dos hipótesis de investigación:

- La descomposición de la serie de tiempo a pronosticar por tipo de día y hora mejora la precisión del modelo de pronóstico.
- La utilización de modelos híbridos mejora la precisión con respecto a los que no lo son.

Para lograr el objetivo general se planteó una metodología con cuatro fases, donde en cada fase se respondió un objetivo específico. La primera fase tuvo como objetivo determinar qué modelos o técnicas de pronóstico y qué características se han utilizado, con el fin de tener una base de conocimiento para apoyar la fase de diseño del modelo de pronóstico del proyecto. En la siguiente fase se identificaron los requisitos funcionales y no funcionales que deben ser incorporados en la plataforma *Energy Suite* de MVM, con el fin de tener los insumos necesarios para el diseño del modelo de pronóstico. El diseño del modelo de pronóstico, con el cual los suministradores calificados del MEM de México puedan contar con la información pronosticada con el fin de lograr un mejor desempeño económico en la compra y venta de energía, constituyó la tercera fase. Y en la cuarta y última fase se buscó validar, con especialistas del MEM de México de MVM, la pertinencia del modelo de pronóstico elaborado a fin de poder determinar y cuantificar los resultados obtenidos.

Para la gestión y desarrollo del proyecto de investigación se utilizó una adaptación de la metodología SCRUM ¹. Para las fases 2, 3 y 4, se hizo uso de la metodología *Cross Industry*

¹Marco de trabajo para desarrollo ágil de software

Standard Process for Data Mining (CRISP-DM ²), con excepción de la fase de Despliegue.

Finalmente, el presente documento de investigación se estructuró en cinco capítulos que se resumen a continuación:

El Capítulo 2 describe el planteamiento del problema, su contextualización y la propuesta para resolverlo. Asimismo, se enuncian la pregunta de investigación, las hipótesis planteadas, el alcance, la justificación de la realización, el objetivo general y los objetivos específicos.

El Capítulo 3 detalla la fundamentación teórica de este trabajo de investigación, la cual se desarrolló en la fase 1 de la metodología con la realización de una revisión sistemática de literatura (RSL).

El Capítulo 4 describe el marco metodológico en el cual se llevaron a cabo las fases 2, 3 y 4 del proyecto de investigación con base en CRISP-DM. Así, en la fase 2, se realizaron las actividades de la fase de **entendimiento del negocio**, a través de talleres para definir los escenarios y necesidades del modelo de pronósticos que se requieren para el mercado eléctrico mexicano. A partir de esta definición, el encargado de la plataforma de *Energy Suite* de MVM determinó al precio marginal local como variable eléctrica a trabajar en los pronósticos. Posteriormente se dio comienzo a la fase 3, que incluye las fases de **entendimiento de los datos**, **preparación de los datos** y **modelado**. Finalmente, en la fase 4 se ejecutó la fase **evaluación del modelo**, en forma conjunta con los especialistas de MVM, a partir de la presentación y evaluación de los resultados finales de los modelos de pronóstico desarrollados.

El Capítulo 5 expone los resultados del desarrollo del proyecto de investigación en donde se muestra la precisión de la medición a través de las métricas de error MAE, MAPE y RMSE para todos los modelos y su desempeño en cuanto a la duración o tiempo de ejecución de cada modelo.

Para terminar, el Capítulo 6 presenta las conclusiones, recomendaciones y trabajos futuros producto de la realización del trabajo de investigación.

²Modelo estándar abierto del proceso que describe los enfoques comunes que utilizan los expertos en minería de datos

2. Contextualización

2.1. Introducción

El presente capítulo tiene como objetivo contextualizar al lector en el problema de investigación del trabajo de grado, desde lo global a lo particular, definiendo los aspectos a resolver, la justificación, la pregunta de investigación, las hipótesis y los objetivos.

2.2. Contextualización del problema

En la actualidad, uno de los factores clave para el desarrollo de cualquier sector de la economía de un país es contar con información en el momento oportuno y con nivel de calidad adecuado que permita un análisis consistente para la toma de decisiones [1]. El caso del Sector Eléctrico no es la excepción y en particular en el MEM donde los participantes o agentes, según el país, desempeñan diferentes roles en la cadena productiva. Para todos ellos, es igualmente importante validar la información de las transacciones, ya que supone riesgos asociados a sus actividades operativas y comerciales de compra y venta de energía [2].

El desempeño empresarial de un suministrador calificado depende de la eficiencia que tenga en el momento de realizar compras y/o ventas de energía tanto a través de contratos como en el mercado *spot* o bolsa de energía (ofertas de compra-venta) y para esto es necesario contar con información de pronósticos de ciertas variables del mercado entre las cuales se encuentran el consumo de energía eléctrica y el precio marginal local para cada nodo. Debido a lo anterior, para el suministrador calificado, resulta vital realizar pronósticos de tal forma que pueda mejorar su posición competitiva en el MEM. Sin embargo, en la actualidad se le presentan las siguientes dificultades: ausencia de conocimientos y mecanismos tecnológicos que permitan gestionar la gran cantidad de información propia, la del operador del mercado eléctrico y proveniente de otras fuentes como reguladores, entidades financieras, entre otras, y la falta de modelos de pronósticos confiables y precisos [2, 3, 4, 5].

Esto se debe a diferentes causas. Entre ellas, es muy compleja la consolidación y consistencia de los datos por el alto volumen de uso de hojas de cálculo para gestionar la información de las variables eléctricas. Además, existe desconocimiento por parte del personal técnico de las empresas suministradoras calificadas de modelos y técnicas de pronóstico que les permi-

tan crear modelos precisos y confiables [6]. A la vez, no se cuenta con procesos que verifiquen la calidad de los datos ni con esquemas de seguridad adecuados para su gestión, ya que el procesamiento de la información se hace por medio de herramientas ofimáticas, donde el nivel de seguridad es muy bajo. Conjuntamente, la no existencia de esquemas estructurados de almacenamiento de la información hace que exista un alto riesgo de pérdida de información o modificaciones involuntarias y por lo tanto no se puede realizar una trazabilidad adecuada, limitando severamente la posibilidad de gestionar apropiadamente la redundancia e integración de dicha información.

Los efectos de esta situación para los suministradores calificados son diversos. Entre ellos pueden señalarse, gestión ineficiente de la energía eléctrica y los recursos de la empresa; penalizaciones económicas por parte del regulador del mercado por no cumplir con los requerimientos de suministro de información de pronóstico oportuna y con la calidad requerida; pérdidas económicas debido a los sobre-costos y pérdidas en las compras y ventas de energía eléctrica que permitan cumplir los contratos establecidos con sus agentes consumidores. En síntesis, se ve afectado el desempeño financiero de la empresa debido a una mala negociación en la compra y venta de energía, de manera tal que hasta puede llevarla a la quiebra [7].

2.3. Planteamiento del problema

Lo descrito en las líneas de arriba y un MEM naciente como el de México (a través de la Ley de Industria Eléctrica DOF 2014 08 11 ¹ han generado oportunidades para que la empresa MVM Ingeniería de Software S.A.S. (MVM) haya comenzado a incursionar en el desarrollo de productos y servicios especializados que superen todos los desafíos de gestión y procesamiento de información que dicho mercado requiere. Por tal motivo, el propósito de este proyecto de investigación, a través de un estudio de caso, es diseñar el modelo de pronóstico que tome información de diversas fuentes para que los suministradores calificados del MEM de México cuenten con información para decidir cómo comprar y vender energía de la forma más óptima tanto en sus contratos como en la bolsa de energía, de manera que se amplíe la línea base tecnológica con capacidades de analítica para los productos que componen la plataforma *Energy Suite* de MVM.

2.4. Pregunta de investigación

Con base al problema planteado, este proyecto de investigación buscar dar respuesta a la siguiente pregunta de investigación:

¹<http://www.cenace.gob.mx/Docs/MarcoRegulatorio/Leyes/Ley de la Industria Eléctrica DOF 2014 08 11.pdf> - Consultado el 05/05/2018

¿Qué modelos o técnicas de pronóstico pueden ser empleados para pronosticar las variables eléctricas que permitan establecer una adecuada oferta por parte de un participante del MEM de México y que a su vez permitan ampliar la línea base tecnológica de la plataforma *Energy Suite* de MVM?

2.5. Hipótesis

Para el trabajo de investigación se plantearon las siguientes hipótesis:

- H1:** la descomposición de la serie de tiempo mejora la precisión de los pronósticos de las variables eléctricas, consumos de energía o precio marginal local, para la compra y venta de energía eléctrica en el mercado eléctrico mexicano.
- H2:** los modelos híbridos permiten obtener mejores resultados sobre aquellos que no lo son en los pronósticos de las variables eléctricas, consumos de energía o precio marginal, para la compra y venta de energía eléctrica en el mercado eléctrico mexicano.

2.6. Alcance

El alcance del proyecto es proponer y validar un modelo de pronósticos para que los participantes del mercado eléctrico puedan contar con información predictiva para la toma de decisiones y sirva de base para desarrollar las capacidades analíticas de la plataforma *Energy Suite* de MVM. Dicha validación será realizada con los especialistas del negocio del MEM de MVM.

Cabe señalar que queda por fuera desarrollar una implementación a nivel comercial y/o módulo que se integre a la plataforma *Energy Suite* de MVM por el tiempo que esto implicaría. Asimismo, no está contemplado realizar una validación con una empresa del sector eléctrico ya que, como se especificó anteriormente el trabajo que se llevará a cabo con los expertos de MVM. Finalmente, se utilizarán sólo técnicas que cuenten con algoritmos disponibles en los paquetes del lenguaje R ² sin profundizar en el desarrollo de algoritmos nuevos.

2.7. Justificación

MVM ha desarrollado la plataforma *Energy Suite* con el propósito de generar valor para las empresas del sector eléctrico, apoyando sus procesos de negocio. Debido a la experiencia y conocimiento que tiene MVM del MEM y al naciente MEM de México, se ha identificado una

²R es un entorno y lenguaje de programación con un enfoque al análisis estadístico

oportunidad para ampliar las capacidades tecnológicas de la plataforma *Energy Suite*. Por ello, se propone este proyecto de investigación con el fin de ampliar la línea base tecnológica de la plataforma que permita a los suministradores calificados contar con información de pronósticos de variables eléctricas, como consumos de energía eléctrica o precio marginal local, que los habilite para realizar mejores ofertas de compra y venta de energía en dicho país, y mejorar su desempeño empresarial al optimizar el uso de sus recursos y evitar sanciones por el ente regulador por no proveer la información de pronósticos de acuerdo con lo estipulado por la ley. Finalmente, la incorporación de estas capacidades analíticas a través del modelo de pronóstico que utilizará la información disponible en la plataforma *Energy Suite* generará valor tanto para los participantes del MEM de México como para la empresa MVM ya que permitirá contar con información pronosticada para mejorar sus compras y ventas de energía y contar con las bases para desarrollar un nuevo módulo o producto, respectivamente.

2.8. Objetivos

2.8.1. Objetivo general

Proponer un modelo de pronóstico para la plataforma *Energy Suite* de MVM, que permita a los suministradores calificados del MEM de México mejorar su posición competitiva en las operaciones de compra y venta de energía.

2.8.2. Objetivos específicos

1. Determinar qué modelos o técnicas de pronóstico y qué características se han utilizado con el fin de tener una base de conocimiento para apoyar la fase de diseño del modelo de pronóstico del proyecto.
2. Identificar los requisitos funcionales y no funcionales que deben ser incorporados en la plataforma *Energy Suite* de MVM con el fin de tener los insumos necesarios para el diseño del modelo de pronóstico.
3. Diseñar el modelo de pronóstico de variables eléctricas para ampliar la línea base tecnológica de la plataforma *Energy Suite* de MVM, con el cual los suministradores calificados del MEM de México, puedan contar con la información pronosticada con el fin de lograr un mejor desempeño económico en la compra y venta de energía.
4. Validar con especialistas del MEM de México de MVM la pertinencia del modelo de pronóstico elaborado con el fin de poder determinar y cuantificar los resultados obtenidos.

3. Fundamentación teórica

3.1. Introducción

En el presente capítulo se detalla la fundamentación teórica de la investigación, acorde a los objetivos descritos en el Capítulo 2, se describen temas fundamentales para el desarrollo del trabajo como son el marco teórico y el estado del arte.

3.2. Pronósticos de series de tiempo

De acuerdo con Hyndman & Athanasopoulos [8], los pronósticos son necesarios en muchas situaciones: decidir la construcción de otra planta de generación de energía en los próximos cinco años requiere de pronósticos de la demanda futura; programar el personal en un centro de llamadas para la próxima semana requiere de pronósticos de volúmenes de llamadas o almacenar un inventario requiere de pronósticos de los requisitos de *stock*.

Pronósticos precisos requieren además poder determinar adecuadamente cuándo deben iniciarse. Así, por ejemplo, las inversiones de capital puede demandar varios años de anticipación pero el enrutamiento de telecomunicaciones, sólo unos minutos previos. De todos modos, cualesquiera que sean las circunstancias o los horizontes temporales involucrados, el pronóstico es una ayuda importante para una planificación eficaz y eficiente.

Resulta necesario considerar que algunas cosas son más fáciles de predecir que otras. La hora del amanecer de mañana se puede pronosticar con mucha precisión, pero no así los números de lotería de mañana. La previsibilidad de un evento o cantidad depende de varios factores, que incluyen:

1. Qué tan bien entendemos los factores que contribuyen a ello.
2. La cantidad de datos disponibles.
3. Si los pronósticos pueden afectar lo que estamos tratando de pronosticar.

En general, los pronósticos de la demanda de electricidad pueden ser muy precisos porque las tres condiciones normalmente se cumplen. Con relación a la primera de ellas se tiene una buena idea de los factores intervinientes. Así, por ejemplo, la demanda de la electricidad es impulsada principalmente por las temperaturas, con efectos más pequeños para la variación

del calendario, como las vacaciones y las condiciones económicas. Puede decirse entonces, que siempre que haya un historial suficiente de datos sobre la demanda de electricidad y las condiciones climáticas y que se tengan las habilidades para desarrollar un buen modelo que vincule la demanda de electricidad y las variables clave del conductor, las previsiones pueden ser notablemente precisas.

Conjuntamente con lo anterior, se debe tener en cuenta que los métodos de pronósticos pueden ser muy simples, como usar la observación más reciente como un pronóstico (que use el método *naive*) o muy complejos, como redes neuronales y sistemas econométricos de ecuaciones simultáneas.

Si bien el pronóstico es una tarea estadística común en los negocios, que ayuda a tomar las decisiones sobre la programación de la producción, el transporte y el personal, y proporciona una guía para la planificación estratégica a largo plazo, a menudo la previsión empresarial se realiza deficientemente desconociendo estas estrategias y con frecuencia se confunde con la planificación y las metas, las cuales no lo reemplazan, sino que lo complementan. A continuación, se describe brevemente cada uno de estos términos para dar mayor claridad al concepto de pronóstico.

Pronóstico: se trata de predecir el futuro con la mayor precisión posible, dada toda la información disponible, incluidos los datos históricos y el conocimiento de cualquier evento futuro que pueda afectar las previsiones. Pueden distinguirse pronósticos a corto, mediano y largo plazo, dependiendo de la aplicación específica.

Pronósticos a corto plazo: son necesarios para la programación del personal, la producción y el transporte. Como parte del proceso de programación, a menudo también se requieren pronósticos de demanda.

Pronósticos a mediano plazo: son necesarios para determinar los requisitos de recursos futuros, con el fin de comprar materias primas, contratar personal o comprar maquinaria y equipo.

Pronósticos a largo plazo: se utilizan en la planificación estratégica. Dichas decisiones deben tener en cuenta las oportunidades de mercado, los factores ambientales y los recursos internos.

Metas: es lo que se desea que suceda. Las metas deben estar vinculadas a los pronósticos y la planificación, pero esto no siempre ocurre. Con demasiada frecuencia, las metas se establecen sin ningún plan sobre cómo lograrlos, y no hay pronósticos sobre su posibilidad real de concretarse.

Planificación: es una respuesta a pronósticos y metas. La planificación implica determinar las acciones apropiadas que se requieren para que sus pronósticos coincidan con sus objetivos.

En síntesis, una organización necesita desarrollar un sistema de pronóstico que involucre varios enfoques para predecir eventos inciertos. Dichos sistemas de pronóstico requieren el

desarrollo de experiencia en la identificación de problemas de pronóstico, la aplicación de una variedad de métodos de pronóstico, la selección de métodos apropiados para cada problema y la evaluación y el perfeccionamiento de los métodos de pronóstico a lo largo del tiempo. Complementariamente, cabe señalarse la necesidad de contar con un fuerte apoyo organizacional para que se haga efectivo el empleo de los métodos de pronósticos desarrollados y así continuar avanzando en su optimización.

3.3. Mercado eléctrico de energía

En el 2014, el gobierno mexicano a través de la Ley de la Industria Eléctrica (LIE) y la Ley de la Comisión Federal de Electricidad (CFE), junto con el resto de la regulación derivada de la reforma de los artículos 25, 27 y 28 de la Constitución Política de los Estados Unidos Mexicanos, realizó una transformación radical del sector eléctrico [9]. La misma consiste en desregular el mercado eléctrico con el fin de lograr una mayor eficiencia en la prestación del servicio, mantener un adecuado nivel de inversiones y de calidad con costos eficientes y tratando de no perjudicar el mantenimiento del servicio universal. Al mismo tiempo, intenta ampliar el alcance y mejorar la calidad del servicio prestado a tarifas razonables. Por esta razón, el mercado mayorista de energía busca la justa competencia e igualdad de condiciones entre los participantes del mercado para que puedan contratar libremente sus compras y ventas de energía a través de subastas por medio de contratos de largo plazo y mediante el mercado *spot* de compra y venta de corto plazo. Los usuarios básicos no forman parte de este mercado y, por lo tanto, pagan el consumo de la energía eléctrica a un precio fijo como se indica en la Figura 3-1.

A continuación, se resumen los conceptos más relevantes:

Consumo Energético [10]: potencia eléctrica utilizada por toda o por una parte de una instalación de utilización durante un período determinado.

Precio Marginal Local (PML) [11]: precio de la energía eléctrica en un nodo determinado del sistema eléctrico nacional para un periodo definido, calculado de conformidad con las reglas del mercado y aplicable a las transacciones de energía eléctrica realizadas en el Mercado Eléctrico Mayorista.

CFE: Comisión Federal de Electricidad.

CENACE: Centro Nacional de Control de Energía.

SENER: Secretaría Nacional de Energía.

CRE: Comisión Reguladora de Energía.

PIE: Productores Independientes de Energía.

Mercado Eléctrico Mayorista [11]: mercado operado por el CENACE en el que los participantes del mercado podrán realizar las transacciones señaladas en el artículo 96 de




Figura 3-1.: Mercado Eléctrico Mexicano [9]

esta Ley.

Participante del mercado [11]: persona que celebra el contrato respectivo con el CENACE en modalidad de generador, comercializador, suministrador, comercializador no suministrador o usuario calificado.

Generador [11]: titular de uno o varios permisos para generar electricidad en centrales eléctricas, o bien, titular de un contrato de participante del mercado que representa en el Mercado Eléctrico Mayorista a dichas centrales o, con la autorización de la CRE, a las centrales eléctricas ubicadas en el extranjero.

Comercializador [11]: titular de un contrato de participante del mercado que tiene por objeto realizar las actividades de comercialización.

Distribuidor [11]: organismos o empresas productivas del Estado o sus empresas productivas subsidiarias, que presten el servicio público de distribución de energía eléctrica.

Nodo [12]: un nodoP o nodo de fijación de precios corresponde a uno o varios nodos de conectividad de la red, donde se modela la inyección o retiro físicos de energía y para el cual un precio marginal local se determina para las liquidaciones financieras en el Mercado Eléctrico Mayorista.

Transportista [11]: organismos o empresas productivas del Estado, o sus empresas productivas subsidiarias, que presten el servicio público de transmisión de energía eléctrica.

Suministrador [11]: comercializador titular de un permiso para ofrecer el suministro eléctri-

co en la modalidad de suministrador de servicios básicos, suministrador de servicios calificados o suministrador de último recurso y que puede representar en el Mercado Eléctrico Mayorista a los generadores exentos.

Usuario calificado [11]: usuario final que cuenta con registro ante la CRE para adquirir el suministro eléctrico como participante del mercado o mediante un suministrador de servicios calificados.

Usuario final [11]: persona física o moral que adquiere, para su propio consumo o para el consumo dentro de sus instalaciones, el suministro eléctrico en sus centros de carga, como participante del mercado o a través de un suministrador.

3.4. Estado del arte

La primera actividad de la fase 1 que se realizó dentro de este tópico fue una revisión sistemática de lectura (RSL). Como segunda actividad se planteó analizar la RSL del 2017 de los autores Chirag Deb *et al*, *A review on time series forecasting techniques for building energy consumption* [13]. A partir de ésta, se realizó la lectura de los artículos en los cuales se aplican técnicas para construir modelos de pronóstico con el objetivo de identificarlas, así también como a las variables y métricas de error empleadas para el corto y largo plazo. Finalmente, se completo la fase 1 con la lectura del capítulo 4 de *Modeling and forecasting electricity loads and prices - A statistical approach* [14] escrito por Rafael Weron con el fin de obtener información de modelos de pronósticos sobre precios de energía.

A continuación, se presentan la metodología empleada para la RSL, los hallazgos y la discusión sobre los mismos; los artículos analizados, los hallazgos y la discusión de la RSL analizada; y las conclusiones del libro arriba mencionado.

3.4.1. Metodología para el desarrollo de la RSL

La metodología que se siguió para la RSL fue originalmente desarrollada para el ámbito de investigación médica y luego ampliada al campo de estudios de gestión y administración [15]. La misma está compuesta por tres etapas: *i*) Planeación de la revisión, *ii*) Desarrollo de la revisión, y *iii*) Desarrollo de reportes y diseminación. Para la primera etapa se tienen las siguientes fases: identificación de la necesidad de una RSL, preparación de una propuesta para la revisión y desarrollo de un protocolo de RSL. En la segunda etapa se consideran la identificación de la investigación, selección de los estudios, evaluación de la calidad del estudio, extracción de los datos, monitoreo del progreso, y síntesis de la información. Finalmente, para la última etapa, se contemplan el reporte, las recomendaciones y el paso de la evidencia a la práctica.

El objetivo de esta metodología es localizar los estudios relevantes relacionados con las

preguntas de la investigación a desarrollar, así como evaluar y sintetizar sus respectivas contribuciones e informar de manera clara los resultados y las conclusiones obtenidas a partir de ellos, con el fin de plantear sus campos de aplicación y nuevas investigaciones [16].

Asimismo, esta metodología se adoptó en aras de reducir el riesgo de sesgado en la selección de la bibliografía por preferencias subjetivas, adoptando para ello estrategias de búsqueda, cadenas de búsquedas predefinidas, criterios de exclusión/inclusión y, al mismo tiempo, ampliar el espectro de la búsqueda más allá del horizonte de la propia experiencia.

Planeación de la revisión

Las principales investigaciones en esta área son impulsadas por la utilización de distintas técnicas y modelos, la selección de variables de entrada y la cantidad de historia a utilizar, así como por técnicas para medir la precisión de los resultados, entre otros. Por tal motivo, es necesario comprender todos los aspectos que involucran desarrollar un modelo de pronósticos de CEE, con el fin de entender las evidencias y desafíos actuales en el pronóstico del consumo de energía. Para ello, se pretende responder las siguientes preguntas de investigación:

PI1: ¿Qué técnicas/modelos se utilizan para la predicción/pronóstico de consumo de energía?

PI2: ¿Qué variables de entrada usan estas técnicas/modelos?

PI3: ¿Qué técnicas se utilizan para evaluar la precisión de las técnicas/modelos? ¿Cuál es la más usada?

Desarrollo de la revisión

El primer paso de la RSL fue definir las cadenas de búsqueda usando palabras clave que estuvieran relacionadas con la definición del problema de investigación, con la intención de garantizar los resultados buscados. Para esto se utilizó la combinación de las palabras *Energy*, *Consumption* y *Forecasting* formando la frase *Energy Consumption Forecasting*. A continuación, se determinaron las bases de datos científicas de donde se obtuvieron los artículos a partir de dicha cadena de búsqueda. Inicialmente se buscó con ella con un ámbito de búsqueda que comprendió el título (*title*), el resumen (*abstract*) y las palabras claves (*keywords*) pero debido al gran número de artículos que se obtuvieron, alrededor de 2900, se decidió restringir el ámbito de búsqueda de la cadena formada sólo al título de los artículos.

La Tabla **3-1** muestra las cadenas de búsqueda utilizadas según la sintaxis propia de cada base de datos.

Tabla 3-1.: Cadenas de búsqueda utilizadas en cada base de datos científicas

#	Scopus	Science Direct	Web of Science (WOS)	IEEE
1	TITLE-ABS-KEY ("energy consumption forecasting")	Title, abstract, keywords: "energy consumption forecasting"	TS=(energy AND consumption AND forecasting)	((("Document Title": energy consumption forecasting) OR "Abstract": energy consumption forecasting) OR "Author Keywords": energy consumption forecasting)
2	TITLE ("Energy consumption forecasting")	TITLE ("energy consumption forecasting")	TÍTULO=(energy AND consumption AND forecasting)	("Document Title": "energy consumption forecasting")

En total se obtuvieron 218 artículos combinando los resultados de las bases de datos. A partir de estos resultados se realizó el proceso de selección de los artículos evidenciado y descrito en la Figura **3-2**. Además, para la eliminación de los artículos, se tuvieron en cuenta los criterios de selección que están definidos en la Tabla **3-2**.

Tabla 3-2.: Criterios considerados para la selección de artículos

Criterios de inclusión	Criterios de exclusión
- Estudios en idioma inglés	- Fuentes secundarias
- Estudios con modelos / técnicas para pronosticar consumos de energía eléctrica medidos en vatios.(kWh, MWh, GWh, TWh)	- Estudios duplicados
	- Estudios de dominio distinto al sector de energía

Como resultado final del proceso de selección se obtuvieron 47 artículos listados en la Tabla **3-3**, los cuales fueron ordenados de acuerdo con el *ranking* de citación.

Tabla 3-3.: Artículos utilizados para el análisis después de la selección

#-Ref	Artículo	Autores	Año	Citaciones
1-[17]	<i>Comparison between detailed model simulation and artificial neural network for forecasting building energy consumption</i>	Hernandez Neto, A. and Sanzovo Fiorelli, F.	2008	196
2-[18]	<i>Time series models (Grey-Markov, Grey Model with rolling mechanism and singular spectrum analysis) to forecast energy consumption in India</i>	Kumar, U. and Jain, V. K.	2010	142
3-[19]	<i>Annual electricity consumption forecasting by neural network in high energy consuming industrial sectors</i>	Azadeh, A. and Ghaderi, S. F. and Sohrabkhani, S.	2008	112

#-Ref	Artículo	Autores	Año	Citaciones
4-[20]	<i>Forecasting energy consumption of multi-family residential buildings using support vector regression: Investigating the impact of temporal and spatial monitoring granularity on performance accuracy</i>	Jain, R. K. and Smith, K. M. and Culligan, P. J. and Taylor, J. E.	2014	108
5-[21]	<i>Forecasting of Turkey's net electricity energy consumption on sectoral bases</i>	Hamzacebi, C.	2007	106
6-[22]	<i>Forecasting energy consumption using a grey model improved by incorporating genetic programming</i>	Lee, Y.-S. and Tong, L.-I.	2011	103
7-[23]	<i>Univariate modeling and forecasting of energy consumption: the case of electricity in Lebanon</i>	Saab, S. and Badr, E. and Nasr, G.	2001	101
8-[24]	<i>A simulated-based neural network algorithm for forecasting electrical energy consumption in Iran</i>	Azadeh, A. and Ghaderi, S. F. and Sohrabkhani, S.	2008	91
9-[25]	<i>Forecasting building energy consumption using neural networks and hybrid neuro-fuzzy system: A comparative study</i>	Li, K. and Su, H. and Chu, J.	2011	76
10-[26]	<i>A novel hybrid ensemble learning paradigm for nuclear energy consumption forecasting</i>	Tang, L. and Yu, L. and Wang, S. and Li, J. and Wang, S.	69	
11-[27]	<i>Integration of genetic algorithm, computer simulation and design of experiments for forecasting electrical energy consumption</i>	Azadeh, A. and Tarverdian, S.	2007	62
12-[28]	<i>A regression model for electric-energy-consumption forecasting in Eastern Saudi Arabia</i>	Al-Garni, A. Z. and Zubair, S. M. and Nizami, J. S.	1994	44
13-[1]	<i>Long-term electrical energy consumption forecasting for developing and developed economies based on different optimized models and historical data types</i>	Ardakani, F. J. and Ardehali, M. M.	2014	44
14-[29]	<i>Modeling and forecasting energy consumption for heterogeneous buildings using a physical-statistical approach</i>	Lü, X. and Lu, T. and Kibert, C. J. and Viljanen, M.	2015	40
15-[30]	<i>Forecasting net energy consumption using artificial neural network</i>	Sözen, A. and Akçayol, M. A. and Arcaklioğlu, E.	2006	32
16-[31]	<i>A novel data-characteristic-driven modeling methodology for nuclear energy consumption forecasting</i>	Tang, L. and Yu, L. and He, K.	2014	31
17-[32]	<i>Neural networks in forecasting electrical energy consumption: univariate and multivariate approaches</i>	Nasr, G. E. and Badr, E. A. and Younes, M. R.	2002	29
18-[33]	<i>Forecasting building energy consumption with hybrid genetic algorithm-hierarchical adaptive network-based fuzzy inference system</i>	Li, K. and Su, H.	2010	25

#-Ref	Artículo	Autores	Año	Citaciones
19-[34]	<i>Time series forecasting for building energy consumption using weighted Support Vector Regression with differential evolution optimization technique</i>	Zhang, F. and Deb, C. and Lee, S. E. and Yang, J. and Shah, K. W.	2016	25
20-[35]	<i>Long term energy consumption forecasting using genetic programming</i>	Karabulut, K. and Alkan, A. and Yilmaz, A.	2008	24
21-[36]	<i>Conditional dynamic forecast of electrical energy consumption requirements in Ghana by 2020: A comparison of ARDL and PAM</i>	Adom, P. K. and Bekoe, W.	2012	20
22-[37]	<i>Influence of artificial neural network structure on quality of short-term electric energy consumption forecast</i>	Baczynski, D. and Parol, M.	2004	20
23-[38]	<i>Forecasting energy consumption using ensemble ARIMA-ANFIS hybrid algorithm</i>	Barak, S. and Sadegh, S. S.	2016	19
24-[39]	<i>Forecasting Monthly Electric Energy Consumption Using Feature Extraction</i>	Meng, M. and Niu, D. and Sun, W.	2011	19
25-[40]	<i>Application of ARIMA for forecasting energy consumption and GHG emission: A case study of an Indian pig iron manufacturing organization</i>	Sen, P. and Roy, M. and Pal, P.	2016	16
26-[41]	<i>Multifactor-influenced energy consumption forecasting using enhanced back-propagation neural network</i>	Zeng, Y. R. and Zeng, Y. and Choi, B. and Wang, L.	2017	14
27-[42]	<i>A novel mode-characteristic-based decomposition ensemble model for nuclear energy consumption forecasting</i>	Tang, L. and Wang, S. and He, K. and Wang, S.	2015	13
28-[43]	<i>Using connectionist systems for electric energy consumption forecasting in shopping centers</i>	Kamaev, V. A. and Shcherbakov, M. V. and Panchenko, D. P. and Shcherbakova, N. L. and Brebels, A.	2012	13
29-[44]	<i>Fuzzy Wavelet Neural Networks for City Electric Energy Consumption Forecasting</i>	Zhang, P. and Wang, H.	2012	12
30-[45]	<i>Energy Consumption Forecasting Using Semantic-Based Genetic Programming with Local Search Optimizer</i>	Castelli, M. and Trujillo, L. and Vanneschi, L.	2015	8
31-[46]	<i>Forecasting Electrical Energy Consumption of Equipment Maintenance Using Neural Network and Particle Swarm Optimization</i>	Jiang, X. and Ling, H. and Yan, J. and Li, B. and Li, Z.	2013	7
32-[47]	<i>Load Forecast Model Switching Scheme for Improved Robustness to Changes in Building Energy Consumption Patterns</i>	Yoo, J. and Hur, K.	2013	7
33-[48]	<i>Electrical energy consumption forecasting based on cointegration and a support vector machine in China</i>	Zhang, X. P. and Rui, G.	2007	5

#-Ref	Artículo	Autores	Año	Citaciones
34-[49]	<i>Energy consumption forecasting based on Elman neural networks with evolutive optimization</i>	Ruiz, L. G. B. and Rueda, R. and Cuéllar, M. P. and Pegalajar, M. C.	2018	4
35-[50]	<i>Energy consumption forecasting for university sector buildings</i>	Amber, K. P. and Aslam, M. W. and Mahmood, A. and Kousar, A. and Younis, M. Y. and Akbar, B. and Chaudhary, G. Q. and Hussain, S. K.	2017	4
36-[51]	<i>Big Data Mining of Energy Time Series for Behavioral Analytics and Energy Consumption Forecasting</i>	Singh, S. and Yassine, A.	2018	2
37-[52]	<i>Cloud computing and extreme learning machine for a distributed energy consumption forecasting in equipment-manufacturing enterprises</i>	Wang, R. D. and Sun, X.S. and Yang, X. and Hu, H.	2016	2
38-[53]	<i>Consumption Behavior Analytics-Aided Energy Forecasting and Dispatch</i>	Zhang, Y. and Yang, R. and Zhang, K. and Jiang, H. and Zhang, J. J.	2017	2
39-[54]	<i>Electrical energy consumption forecasting in oil refining industry using support vector machines and particle swarm optimization</i>	Petkovic, M. and Rapaić, M. R. and Jakovljević, B.	2009	2
40-[55]	<i>Incorporating the effects of hike in energy prices into energy consumption forecasting: A fuzzy expert system</i>	Majazi Dalfard, V. and Nazari Asli, M. and Nazari-Shirkouhi, S. and Sajadi, S. M. and Asadzadeh, S. M.	2013	2
41-[56]	<i>Monthly electric energy consumption forecasting using multiwindow moving average and hybrid growth models</i>	Meng, M. and Shang, W. and Niu, D.	2014	2
42-[57]	<i>An Electrical Energy Consumption Monitoring and Forecasting System</i>	Rojas-Renteria, J. L. and Espinoza-Huerta, T. D. and Tovar-Pacheco, F. S. and Gonzalez-Perez, J. L. and Lozano-Dorantes, R.	2016	1
43-[58]	<i>Effective electricity energy consumption forecasting using echo state network improved by differential evolution algorithm</i>	Wang, L. and Hu, H. and Ai, X. Y. and Liu, H.	2018	1
44-[59]	<i>Forecasting mid-long term electric energy consumption through bagging ARIMA and exponential smoothing methods</i>	Meira de Oliveira, E. and Cyrino Oliveira, F. L.	2018	1
45-[60]	<i>Robust ensemble learning framework for day-ahead forecasting of household based energy consumption</i>	Alobaidi, M. H. and Chebana, F. and Meguid, M. A.	2018	1
46-[61]	<i>Monthly Energy Consumption Forecasting Based on Windowed Momentum Neural Network</i>	Mishra, S. and Singh, V. K.	2015	0

#-Ref	Artículo	Autores	Año	Citaciones
47-[62]	<i>Universal energy consumption forecasting system based on neural network ensemble</i>	Staroverov, B. A. and Gnatyuk, B. A.	2016	0

Reporte y diseminación

Como parte de esta etapa, se realizó una agrupación de los artículos seleccionados por tipo de método/modelo de pronóstico y luego, de acuerdo con el alcance establecido para el pronóstico, en corto y largo plazo. Dentro de cada uno de los grupos, se resumen las características y las ventajas más relevantes de los modelos propuestos.

A. Artificial neural network (ANN)

Corto plazo

En el 2004, Bacznski & Parol [37] entrenaron varios modelos de ANN de tipo MLP y concluyeron que el número de peso en la red neuronal debería ser de un orden de magnitud menor que el número de datos de aprendizaje. También observaron que la proporción de número de neuronas en las capas ocultas tiene una influencia considerable en la habilidad de la red neuronal para aprender y generalizar, siendo las mejores las de estructuras balanceadas. Los resultados obtenidos muestran que la estructura ANN tiene una influencia esencial en la calidad de los pronósticos de consumo de energía eléctrica.

Posteriormente, en el 2016, Rojas-Rentería *et al.* [57] investigaron un sistema de pronóstico y monitoreo basado en una red neuronal de tipo MLP aplicada en un edificio real. Propusieron un modelo con tres capas. En la capa de entrada, utilizaron tres entradas (CEE, hora y día) y en la capa de salida, el CEE con granularidad horaria. Evaluaron el modelo propuesto con distintas configuraciones encontrando que el mejor resultado fue el de configuración 3-1-1 con un nivel de confianza del 95 % en la predicción.

En el 2008, Hernandez Neto & Sanzovo Fiorelli [17] compararon su modelo propuesto de ANN de tipo FF con un software de simulación que pronostica la demanda de energía para la Administración del Edificio de la Universidad de Sao Paulo. El modelo fue entrenado con 3 *datasets* organizados de diferentes formas: una para todos los días de la semana sin discriminar días laborables de fines de semana, otra para los días laborables y la tercera, sólo para los fines de semana. La primera presentó mayor error entre la predicción y los datos reales en comparación con las otras dos independientemente de la cantidad de capas ocultas y números de neuronas en cada capa oculta. A continuación, incrementaron la complejidad del modelo agregando como variables de entrada la temperatura exterior, la humedad relativa, la radiación solar global y la radiación solar difusa. Concluyeron que se acercaron más a los datos reales cuando discriminaron los *datasets* por fines de semana y días laborables, aunque la inclusión de parámetros climáticos adicionales mejoró levemente los resultados. Finalmente, los resultados mostraron que el modelo de ANN de tipo FF no es el más adecuado para la predicción en este contexto de estudio.




Figura 3-2.: Resumen proceso selección de literatura científica (búsqueda con fecha 02/08/2018)

Alobaidiam, Chebanab & Meguid [60] en el 2018 presentaron un marco de referencia (*framework*) para predecir el promedio de consumo diario de energía de casas individuales a partir del uso de un modelo ensamblado que emplea diversidad de información. La propuesta se aplicó en un caso de estudio en Francia. Este modelo supera la generalización de la habilidad y la atenuación de varios problemas de predicción inestables de otros modelos al tiempo que mejora el desempeño de predicción con datos limitados. Construyeron un *framework* con siete submodelos, uno para cada día de la semana, con parámetros determinados a través de estudios de validación cruzada. La validación *Jackknife* fue usada para determinar los valores óptimos de me y mc del modelo propuesto de cada configuración de ensamble. El proceso fue repetido hasta obtener las estimaciones de ensambles para todas las observaciones disponibles. En la comparación con una red neuronal normal y otra de tipo *Bagging* quedó demostrado que su desempeño era superior.

Ante la situación planteada por Wang *et al.* [52] en el 2016, donde los pronósticos en la industria de facturación de equipos requieren de un constante entrenamiento debido a que nueva información se genera en forma continua, propusieron una solución utilizando *Hadoop*. Contrastaron tres modelos: el MR-OSELM-WA, el *Functional Networks* y SVM. Los resultados obtenidos les permitieron demostrar que el mejor modelo era MR-OSELM-WA, el cual evidenció que las tecnologías de procesamiento *Big Data* son efectivas para resolver este tipo de problemas dado que acortan los tiempos de entrenamiento, reducen los recursos computacionales y mejoran la precisión del pronóstico.

En el escrito presentado en el 2016, Stareverov & Gnatyuk [62], para resolver los problemas de pronóstico independientemente de la naturaleza de los datos ingresados, plantearon construir un conjunto de ANN con el fin de crear un sistema de pronóstico de carácter universal, capaz de promediar las salidas de las distintas redes neuronales individuales. Los estudios permitieron determinar el conjunto mínimo de factores relevantes y la profundidad y dimensión del vector de entrenamiento de entrada. Finalmente pudieron comprobar que una estructura de tres niveles de conjuntos de redes neuronales tiene un poder predictivo de alto dominio y su uso resulta ser prometedor para tareas relacionadas con información y análisis estadístico.

El estudio de Ruiz *et al.* [49] del 2018 derivó de investigaciones previas donde se utilizaron modelos de pronóstico NAR y NARX. Por su parte, propusieron utilizar un modelo de red neuronal denominado ENN entrenado con un GA. Puede señalarse que GA resultó ser un factor clave para optimizar las ANN y mejorar los modelos NAR y NARX, mientras que el modelo ENN aportaba mayor exactitud, pero resultaba más complejo por el incremento de componentes de la red neuronal que involucraba. Finalmente, la combinación de ENN + GA, considerando como variables de entrada el consumo de energía eléctrica y la temperatura, resultó ser el mejor modelo.

Largo plazo

En el estudio presentado en el 2007, Hamzaçebi [21], propuso un modelo ANN de tipo MLP

basado en valores de observación de un año. Realizó pronósticos de consumo de electricidad en los sectores básicos hasta 2020 comparándolos con los realizados por el MAED utilizado por el gobierno y demostró que eran más exactos. Sin embargo, el objetivo del estudio no pretendía reclamar la constante superioridad del modelo ANN sino indicar a los funcionarios políticos la importancia del uso alternativo de formas de pronóstico.

En el 2008, Azadeh, Ghaderi & Sohrabkhani [19], presentaron un modelo ANN de tipo MLP para el consumo anual de electricidad en sectores industriales de alto consumo de energía si bien tradicionalmente las ANNs habían sido utilizadas en pronósticos de corto plazo. Probaron varios modelos de ANN variando el número de neuronas en las dos capas ocultas y el método de entrenamiento. Concluyeron que, a partir de datos reales de consumo en Irán en el período 1979-2003, el modelo con la configuración 5-3-2-1 era el que pronosticaba con mejor precisión.

Ese mismo año, los mismos autores Azadeh, Ghaderi & Sohrabkhani [24] presentaron otro estudio en el que proponían un algoritmo integrado para el pronóstico mensual de consumos de energía eléctrica basado en ANN, una simulación de computadora y el diseño de experimentos usando procedimientos estocásticos. Para ello, construyeron tres modelos: algoritmo integrado basado en ANN, ANN de tipo times series y ANN simulado. Para demostrar la aplicabilidad y superioridad de éstos usaron datos reales de consumo de energía de Irán por 130 meses. Aplicaron la red MLP con tres variables de input y pudieron demostrar que la ANN de tipo MLP con configuración 3-2-1 y con algoritmo de BP tuvo el mejor resultado con un error relativo igual a 0.012. Además, el modelo ANN era superior con relación al modelo ANN de tipo Time Series y el modelo ANN simulado. Sin embargo, argumentaron que el uso de los tres modelos asegura el mejor resultado para datos reales minimizando el sesgo de utilizar un solo enfoque.

En el estudio de Jiang *et al.* [46], del año 2013, presentaron un modelo de pronóstico de consumo de energía eléctrica basado en ANN de tipo FF entrenado por PSO. El modelo utilizaba como datos de entrada los consumos eléctricos de energía del equipo, los parámetros del equipo y los parámetros de mantenimiento del equipo. Resultados experimentales les permitieron demostrar la capacidad del modelo para mejorar la precisión de los pronósticos y avanzar en el entendimiento de la relación entre el consumo de energía eléctrica y las variables de entrada.

Mishra & Singh [61] presentaron en el 2015 un modelo de red neuronal de tipo FF, que tiene el algoritmo *Windowed Momentum*. La inclusión de este componente permitió a los operadores superar los problemas por sobrepasar la mínima en iteraciones pequeñas que suelen tener lugar en este tipo de propagación. Además, observaron que, si bien días diferentes de la semana presentaban consumos diferentes de energía, las curvas de consumo para los mismos días dentro del mes en cada año eran casi iguales. Finalmente, determinaron que el uso del algoritmo *Windowed Momentum* resultaba ser más eficiente que el *Standard Momentum*.

Nasr, Badr & Younes [32] en el 2002 construyeron cuatro modelos de ANN de tipo BP

para pronosticar el consumo de energía eléctrica: uno de tipo univariado con tres parámetros de entrada de EEC y otros tres de tipo multivariado con distintas variables de entrada, donde el primero de éstos combinaba las variables EEC y la T, el segundo, empleaba TI y EEC, y el tercero, EEC, TI y la T. Los modelos fueron entrenados, probados y evaluados con información real del Líbano del periodo 1995-1999. Los resultados mostraron que los modelos multivariados resultaron superiores y, dentro de ellos, el que usaba la temperatura y EEC logro el mejor desempeño en el pronóstico.

En el 2006, Sözen, Akçayol & Arcaklioglu [30] pronosticaron el consumo anual de energía eléctrica de Turquía usando una técnica de red neuronal de tipo BP. Los resultados experimentales les permitieron demostrar que el modelo propuesto lograba predecir dentro de los errores aceptables utilizando como variables de entrada el año, la población del país, la capacidad instalada de generación y la generación bruta total del país.

En el estudio presentado en el 2017, Zeng *et al.* [41] plantearon mejorar el modelo de pronóstico basado en ANN de tipo BP incluyendo el algoritmo inteligente llamado DE. Este modelo fue comparado con otros modelos planteando dos escenarios, el primero utilizaba las variables GDP, POP, IMP y EXP y el segundo, sólo la variable CEE. Finalmente, pudieron confirmar que el modelo propuesto era el más preciso y de fácil implementación.

Meng *et al.* en 2014 [56] presentaron un modelo *Hybrid Grow*, que incluye un término constante, uno lineal y otro exponencial, combinado con un algoritmo *Multiwindow Moving Average*, que descompone los consumos mensuales en varias series periódicas. Este modelo fue contrastado con otros modelos, como el ARIMA y ANN, y concluyeron que el modelo propuesto daba mejores resultados para el pronóstico de consumos de energía anual de China.

En el 2018, Wang *et al.* [58] propusieron un nuevo modelo de ANN de tipo ESN que usaba el algoritmo DE, para determinar sus parámetros de configuración, con el fin de pronosticar consumos mensuales y anuales de energía eléctrica para una ciudad de China. Este modelo resultó tener características de fácil implementación y estabilidad que además hacían a su superioridad por sobre otros modelos en cuanto a la precisión del pronóstico tales como el ARIMA, BBPN, basic ESN y ESN-GA.

B. Autoregressive Integrated Moving Average (ARIMA)

Corto plazo

Kamaev *et al.* [43], en el 2012, propusieron un modelo ARIMA con 4 *lags* de entrada de consumos de energía. Construyeron además dos modelos de regresión lineal: uno con 4 *lags* de consumos de energía eléctrica de entrada al modelo y el otro con más entradas adicionales como la temperatura y los parámetros del edificio. Finalmente, implementaron otro modelo de ANN el cual tenía como parámetros de entrada los 4 *lags* de consumo de energía eléctrica, la temperatura y los parámetros del edificio. Como resultados finales obtuvieron que el modelo ARIMA era el de ejecución más rápida, pero con menor precisión en el pronóstico de acuerdo con la métrica de error MAPE y que el modelo de ANN, el de mejor pronóstico.

En el 2013, Yoo & Hur [47] emplearon un modelo denominado ARMAX usando el filtro *Kalman* para estimar los parámetros del modelo para pronosticar los consumos de energía eléctrica con una granularidad horaria en función de su historia y la variable exógena de temperatura. Además, la serie de tiempo fue dividida en dos series, una con los días de semana y la otra con los días del fin de semana. Finalmente, las simulaciones efectuadas demostraron la efectividad del modelo propuesto.

Zhang *et al.* [53], en el 2017, presentaron un marco de referencia (*Framework*) con el objetivo de mejorar el pronóstico de consumos eléctricos fotovoltaicos (PV) para plazos de tiempos muy cortos usando el comportamiento histórico del consumo de electricidad y la información climática como la temperatura, la *solar global horizontal irradiance*, la humedad relativa, la velocidad del viento y las precipitaciones. La propuesta incluía varios modelos de pronóstico, entre ellos un modelo ARIMA, un modelo de SVM y varios modelos ANN. Como conclusión dejaron abierta la posibilidad de una investigación futura orientada a incorporar en el *framework* la selección automática del modelo atenta a establecer el óptimo para cada contexto específico.

Largo plazo

En el 2001, Saab, Badr & Nasr [23] estudiaron diferentes técnicas de modelado univariado para pronosticar los consumos mensuales de energía eléctrica del Líbano usando modelos ARIMA. Definieron tres modelos: el ARIMA simple, el AR(1) simple y una configuración nueva combinando el modelo AR (1) con un *highpass*, siendo éste último el que obtuvo mejores resultados con respecto a los otros.

En el artículo publicado por Tang, Yu & He en 2014 [31], con el fin de mejorar la precisión del pronóstico del consumo de energía nuclear se presentó una metodología para formular un modelo ARIMA de pronóstico basado en las características propias de los datos de muestra. Para esto, los autores construyeron dos modelos adicionales, ANN y SVM, con el fin de validar el modelo formulado. Demostraron que el método propuesto mejoraba los desempeños de pronóstico en comparación con los otros modelos que ignoran las características de los datos.

En el 2016, Sen, Roy & Pal [40] desarrollaron y evaluaron modelos de pronóstico de consumo de energía mensuales en el sector industrial de producción de hierro y acero de India. Probaron varias configuraciones de modelos ARIMA y finalmente determinaron que el modelo ARIMA (1,0,0) x (0,1,1) era el de mejores resultados para la predicción de CEE.

Meira de Oliveira & Cyrino Oliveira [59], en el 2018, propusieron evaluar varios modelos para pronosticar el consumo mensual de energía eléctrica utilizando *Bagging* ARIMA y un suavizado exponencial como *Holt-Winters*. La serie de tiempo de consumos de energía eléctrica fue descompuesta en componentes más simples utilizando la técnica *Seasonal-Trend Decomposition using Loess (STL Decomposition)*, la cual permitió obtener las series de tendencia, la estacional y la de componentes remanentes. El modelo propuesto fue probado

utilizando distintas parametrizaciones para Canadá, Francia, Italia, Japón, Brasil, México y Turquía encontrándose su superioridad con respecto a otros modelos como SVM y ANN con los cuales fue comparado.

C. Genetic Fuzzy System (GFS)

Largo plazo

Majazi Dalfard *et al.* [55] en el 2013 propusieron un modelo GFS que incorporaba el efecto del aumento de los precios de energía con el fin de pronosticar el consumo anual de energía eléctrica de Irán. Como variables de entrada utilizaron la información histórica de trece años desde 1997 hasta 2009, el precio de la energía en todos los sectores económicos, el precio de gas natural en todos los sectores económicos, el GDP, la población del país, la electricidad generada por fuentes renovables y la eficiencia promedio de la generación de electricidad por medio del gas natural. Como resultado del estudio, demostraron que el modelo propuesto podría adoptarse en situaciones donde los precios de la energía aumentasen repentinamente y además se podrían extraer reglas de experto para formar una base de reglas difusa.

D. Grey Model (GM)

Largo plazo

Kumar & Jain [18] en el 2010 evaluaron el uso de un modelo *Grey-Model with Rolling Mechanism* denominado GMRM para el pronóstico del consumo anual de energía eléctrica de India. Para su entrenamiento, utilizaron una matriz de consumos de energía eléctrica con 5 *lags*. El error de entrenamiento medido con la métrica MAPE fue de 3,4%. Finalmente, para su evaluación hicieron dos predicciones: una para los años 2004-2005 y otra para los años 2005-2006 obteniéndose una precisión del 96,9% y 95,1% respectivamente y demostrando que el modelo propuesto tenía aplicación para dichos pronósticos.

En el 2011, Lee & Tong [22] propusieron mejorar el modelo GM utilizando el método *Residual Sign Estimation* a través de la programación genética. Como datos de entrenamiento, utilizaron el consumo histórico de energía eléctrica de China desde 1990 hasta el 2003 y construyeron un *dataset* con 2 *lags* de consumo eléctrico. Finalmente, compararon el modelo propuesto con otros tres modelos: GM (1,1), el propuesto por Hsu y Chen y un modelo de regresión lineal, a través de la métrica de error MAPE. Pudieron así verificar que el modelo propuesto era igual de preciso que el modelo de Hsu y Chen y mejor que los modelos GM (1,1) y el de regresión lineal.

E. Genetic Programming (GP)

Largo plazo

Azadeh & Tarverdian [27] en el 2007, propusieron un modelo utilizando GP para pronosticar los consumos de energía mensual al que entrenaron con información histórica de consumos de energía de marzo de 1994 a febrero del 2005. A través de la métrica de error MAPE, lo compararon con otros modelos de ANN demostrando su superioridad en la precisión de la predicción.

Un año después, Karabulut, Alkan & Yilmaz [35], plantearon el uso de un modelo de GP para pronosticar el consumo anual de energía eléctrica de un área del sur de Turquía. Para su validación, construyeron dos modelos de regresión adicionales: el modelo *Polynomial* y el modelo *Power Equation*, donde a través de la métrica MSE determinaron que el modelo propuesto era superior.

Castelli *et al.* en el 2015 [45] propusieron cuatro modelos utilizando GP con muestras pasadas de CEE y de información climática, con el objetivo de superar las falencias que en función a su investigación previa detectaron en algunos modelos ya sea porque se detenían en un local óptimo al momento de entrenarlos o porque no manejaban la no linealidad de los datos. Como resultado, obtuvieron que el uso de un modelo híbrido en lugar de un modelo con operadores estándares aceleraba la convergencia del proceso de búsqueda sin sobreentrenar el modelo y con resultados aceptables.

F. Regression Model (RM)

Corto plazo

En el 2017, Amber *et al.* [50] presentaron un modelo de RM para pronosticar el consumo diario de energía eléctrica de un edificio del sector universitario. Durante el desarrollo de éste, consideraron las siguientes variables: ECC, temperatura ambiente, radiación solar, humedad relativa, velocidad del viento, tipo de día y tipo de edificio. Para la validación del modelo, usaron dos *datasets*, uno con la información de un edificio académico y el otro, con la de un edificio administrativo. Midieron la precisión con la métrica NRMSE. Los resultados obtenidos les permitieron demostrar que realmente las variables que aportaban mayor precisión eran la temperatura, el tipo de día y el tipo de edificio, ya que la velocidad del viento no aportaba diferencia en la precisión del pronóstico y en cuanto a la humedad y la radiación solar, como estaban correlacionadas con la temperatura, no era necesario incluirlas.

Largo plazo

Al-Garni, Zubair & Nizami [28] en 1994 investigaron y desarrollaron un modelo de pronóstico de tipo RM para pronosticar los consumos mensuales de energía eléctrica de Arabia Saudita del Este. Como *dataset* de entrenamiento, utilizaron 5 años de historia con las siguientes variables: humedad relativa, radiación solar, temperatura, población. Para la validación del modelo propuesto realizaron un análisis residual.

En el 2012, Adom & Bekoe [36] propusieron dos modelos de pronóstico de tipo RM que denominaron *Partial Adjustment Model* (PAM) y *Autoregressive Distributed Lag Model* (ADRL) para pronosticar el consumo anual de energía eléctrica para Ghana. Como variables de entrada al modelo, consideraron las siguientes: EEC, GDP, GDP per cápita, grado de urbanización y eficiencia industrial. Los modelos fueron comparados con otros modelos de RM y concluyeron que, en cuanto a velocidad, el modelo PAM era el más rápido, pero en cuanto a precisión, el modelo ADRL era el mejor. Además, el estudio reveló que existía una relación de equilibrio a largo plazo entre las variables de consumo de electricidad, la eficiencia de la industria, la urbanización y el GDP.

En el 2014 Ardakani & Ardehali [1], desarrollaron y compararon varios modelos optimizados de regresión y ANN con el fin de determinar cómo la entrada de diferentes tipos de datos históricos afectaba los pronósticos de CEE y así poder pronosticar con ellos el consumo de energía eléctrica a largo tiempo de Irán y Estados Unidos. Los datos considerados fueron CEE y los indicadores GDP, IMP, EXP, y POP. Para optimizar las formas lineales y cuadráticas de los modelos de regresión, examinaron tres algoritmos de optimización: GD, PSO e IPSO. Finalmente, concluyeron, independientemente del tipo de economía, que los pronósticos de CEE a largo tiempo basados en el modelo IPSO-ANN que utilizaba los datos socio-económicos históricos eran más precisos.

G. Support Vector Machine (SVM)

Corto plazo

Petkovic, Rapaic & Jakovljevic [54] desarrollaron en el 2009 un modelo de SVM que utilizaba el algoritmo PSO en su entrenamiento para pronosticar el consumo de energía eléctrico en una empresa refinadora de petróleo. Como variables de entrada al modelo consideraron las siguientes: petróleo refinado diario, uso diario de las unidades industriales, tipo de petróleo refinado, consumos diarios de energía eléctrica y combustibles fósiles usados en el proceso de refinamiento y condiciones climáticas de la temporada. Para su evaluación y comparación, pronosticaron con varios modelos de SVM con distintos *kernels* con y sin el algoritmo PSO. Encontraron que los que utilizaban el algoritmo PSO mejoraba la precisión del pronóstico y, particularmente, el modelo que usaba el kernel RBF era el mejor con un error MAPE de 1,4646 %.

Jain *et al.* [20] en el 2014 propusieron pronosticar el consumo de un edificio de la ciudad de New York utilizando la información de consumos de energía eléctrica, la radiación solar y la temperatura capturada por varios sensores distribuidos por todo el edificio. Como modelo de pronóstico, optaron por utilizar el método de SVM y considerar otras variables de entrada como el tipo de día (semana o fin de semana) y el seno y el coseno de la hora. Para la validación del modelo, probaron distintas configuraciones combinando pronósticos cada 10 minutos, por hora y diario y varios escenarios espaciales. Encontraron que la mejor combinación era pronosticar por pisos completos del edificio y con una granularidad horaria.

Zhang *et al.* [34] en el 2016 presentan dos modelos de SVM, uno utilizaba el parámetro epsilon y el otro, el parámetro nu, combinados ambos con el algoritmo DE para determinar sus parámetros de configuración y los pesos de los modelos. Utilizando como variable de entrada un *dataset* con el consumo histórico de un año de energía eléctrica de un edificio de Singapur pronosticaron el consumo con una granularidad de 30 minutos y diaria. Para validar los dos modelos, los compararon contra otras tres variantes de modelos SVM y obtuvieron que los modelos propuestos los superaban. También, pudieron observar que para el pronóstico de 30 minutos su error MAPE era 3.767 % y el valor del peso del parámetro nu era alto, mientras que, para el pronóstico diario, su error MAPE era 5.843 % y el valor alto, el del peso epsilon.

Largo plazo

Los autores Zhang & Rui [48] en el 2007 compararon dos modelos SVM para pronosticar el consumo de energía eléctrica anual de China. El primer modelo fue de tipo univariado y utilizaba como variable de entrada los datos históricos de consumos de energía histórica del 1985 al 2005. Por el contrario, el segundo modelo fue de tipo multivariado y además consideró las siguientes variables de entrada: GDP per cápita, HIS y EIS. Como conclusión demostraron que el modelo que consideraba las variables socio-macroeconómicas mejoraba la precisión del pronóstico.

H. Híbridos (H)

Corto plazo

Li & Su [33] desarrollaron, en el 2010, un modelo híbrido denominado *Genetic Algorithm-Hierarchical Adaptive Network-Based Fuzzy Inference System* (GA-HANFIS), el cual utilizaba un algoritmo genético con una red jerárquica adaptativa basada en un sistema de inferencia difusa que disminuía la dimensión de las reglas base. Lo utilizaron para pronosticar el consumo diario de energía eléctrica del aire acondicionado de un hotel a partir de los datos históricos de consumo de energía eléctrica y temperatura. Para validarlo, lo compararon usando la métrica CV contra otros modelos de ANN y GFS pudiendo comprobar la superioridad de éste.

Un año más tarde, los autores Li, Su & Chu [25] plantearon un modelo híbrido que combinaba una ANN con un GFS para pronosticar el consumo mensual de energía eléctrica de un edificio y lo compararon contra un modelo tradicional de ANN de tipo FF con una sola capa oculta. Para la validación de éste, utilizaron dos *datasets* con distintas variables, para el primero, temperatura, radiación solar, humedad y velocidad del viento y para el segundo, sólo la temperatura y la cantidad de ocupantes del edificio. Después de realizar 5 ejecuciones por cada *dataset*, como resultado final obtuvieron que el modelo propuesto era superior y que además se ejecutaba prácticamente en el mismo tiempo que el modelo de ANN.

En el 2015, Lü *et al.* [29] propusieron un nuevo método basado en un enfoque físico-estadístico diseñado para tener en cuenta la heterogeneidad y complejidad de los edificios con el fin de mejorar la precisión del pronóstico. Dicho modelo híbrido estaba compuesto por un método físico, un modelo ARIMA, una SVD y un método *Convex Hull* de bases teóricas similares a las SVM. Compararon el modelo propuesto con dos modelos de SVM, uno lineal y el otro no lineal, usando para el no lineal la función RBF. Para su entrenamiento y validación, utilizaron información de cuatro edificios de Finlandia obteniendo resultados para ellos satisfactorios.

Largo plazo

Los autores Meng, Niu & Sun [39] publicaron un artículo en el 2011 con un modelo híbrido que descomponía la serie de tiempo usando la técnica DWT en series de tiempos más simples.

Como resultado de la descomposición, obtuvieron una serie de tendencia pronosticada con un modelo GM y las series de frecuencia periódicas pronosticadas con un modelo ANN de tipo RBF. Finalmente unieron resultados para obtener el pronóstico mensual de consumos de energía. Como *dataset* de entrenamiento, tomaron la información de consumos de energía de China desde enero de 1990 hasta diciembre del 2016 obtenida del sitio web *Chinese Economic and Financial Database of the China Center for Economic Research* (CCER). Finalmente, compararon el modelo propuesto con otros tres modelos utilizando las métricas de error MaxAPE, MAPE, MdAPE y GMARE, resultando ser el mejor sólo para las métricas MaxAPE y MAPE.

En el 2012, Zhang & Wang [44] propusieron para pronosticar el consumo de energía anual, un modelo híbrido denominado FWNN, que combinaba los modelos ANN y GFS y descomponía la serie de entrada de consumos de energía en *wavelets*. Este modelo tenía como características su rápida convergencia al resultado, su facilidad de implementación y su superior capacidad con respecto al modelo GM contra el cual lo compararon utilizando la métrica MAPE.

En el mismo año, Tang *et al.* [26] desarrollaron un modelo híbrido, que combinaba el EEMD y el LSSVR, con el fin de pronosticar los consumos mensuales de energía eléctrica nuclear de China. El modelo consistía en descomponer la serie de tiempo de CEE en series más simples y predecir dichos componentes por separado para luego obtener la composición del valor de pronóstico final. Como dataset de entrenamiento utilizaron la información obtenida de la Wind Database con los consumos de energía nuclear de China de marzo del 1993 a enero del 2010. Finalmente, evaluaron y compararon los modelos híbridos EEMD-LSSVR-ADD, EMD-LSSVR-LSSVR y EMD-LSSVR-ADD a través de las métricas RMSE y MAPE contra otros modelos tradicionales como SVR, LSSVR, ANN y ARIMA, obteniendo como resultado que el mejor era el modelo híbrido EMD-LSSVR-LSSVR.

Por otra parte, Tang *et al.* [42] plantearon en el 2015 combinar el método de modelado basado en las características de los datos y utilizaron la técnica *Decomposition and Ensemble* para construir los modelos de pronósticos de CEE de tipo nuclear. Para esto construyeron dos modelos, el primero usaba el conjunto de modelos ARIMA-LSSVR y el segundo, LVSSVR-LVSSVR. También construyeron y evaluaron los modelos ARIMA, FNN y LSSVR de forma individual para compararlos contra los propuestos. Como conclusión demostraron que éstos eran superiores.

Barack & Sadegh [38] propusieron un modelo híbrido para pronosticar los consumos de energía anual de Irán, el cual combinaba un modelo lineal (ARIMA) con otro no lineal (GFS) con el fin de obtener las ventajas de ambos modelos. Probaron tres patrones de configuración entre ambas técnicas e identificaron que el mejor patrón era el tercero, el cual usaba el método *AdaBoost* con la estructura ANFIS de *Genfis3* y el algoritmo de entrenamiento BP. Además, este modelo obtuvo mejores resultados, medidos con la métrica de error MSE, contra otros modelos como Single ARIMA, Single ANFIS, ANN, Zhang, Khashei & Bijari y Babu &

Reddy.

I. Otros

Corto y largo plazo

Singh & Yassine [51] 2018 propusieron en el 2018 un novedoso modelo que utilizaba minería de datos a través de análisis de patrones frecuentes en series de tiempo de energía y una técnica de *clustering* no supervisada para obtener las reglas de asociación que serían el insumo para luego pronosticar los resultados utilizando un modelo de redes bayesianas. Para el entrenamiento, crearon un *dataset* sintético a partir del *dataset* real *ISSDA-The Irish Social Science Data Archive* con series de tiempo de consumos de energía de 21 artefactos eléctricos de una casa con una resolución de un minuto. Para la evaluación de dicho modelo utilizaron, dos *datasets* reales, el *dataset UK-DALE* con la serie de tiempos de consumos de energía de 109 artefactos eléctricos recolectado de 5 casas del sur de Inglaterra con una resolución de tiempo de seis segundos y el *dataset AMPds2-Almanac of Minutely Power* con las series de tiempo de consumos de electricidad, agua y gas natural con una resolución de un minuto de un hogar residencial de Canadá desde el 2012 al 2014. Finalmente, evaluaron el modelo utilizando distintos tamaños de *datasets* de entrenamiento (25 %, 50 % y 75 % del total de éste) tanto para el corto como largo plazo y lo compararon contra otros dos modelos que utilizaban técnicas distintas, SVM y ANN con configuración MLP obteniendo como resultado la superioridad del modelo propuesto sobre éstos en todos los casos de entrenamiento.

3.4.2. Hallazgos y resultados de la RSL desarrollada

En esta sección se presentan diferentes análisis descriptivos obtenidos a partir de los artículos seleccionados. En la Figura 3-3 se visualiza la distribución de los artículos por tipo de técnica/modelo de pronóstico. Como se puede apreciar, la técnica/modelo más usada/o es la ANN seguida/o por los híbridos y ARIMA.

En la Figura 3-4 se grafica la distribución de los artículos de acuerdo con la escala de tiempo. Permite visualizar que la mayoría de ellos corresponden a pronósticos de largo plazo.

A continuación, se presentan los resúmenes de los artículos clasificados según las siguientes características: modelos, variables utilizadas y métodos de error. En la Tabla 3-4 y Tabla 3-5 se expone el resumen de las características de los artículos de pronóstico de corto plazo y largo plazo respectivamente.

Publicaciones y año de publicación

La Figura 3-5 muestra la cantidad de publicaciones de artículos y su evolución por año para las diferentes escalas de tiempo de los pronósticos y para la suma de ambos, donde claramente se puede evidenciar el auge de los trabajos de investigación sobre los modelos de pronósticos en los últimos años.




Figura 3-3.: Distribución de artículos por modelo/técnica de pronóstico




Figura 3-4.: Distribución de artículos por escala de tiempo

Referencias	[17]	[20]	[25]	[29]	[33]	[34]	[37]	[43]	[47]	[49]	[50]	[51]	[52]	[53]	[54]	[57]	[60]	[62]
Modelos																		
ANN	P		X		X		P	X		P		X	P	X		P	P	P
ARIMA								P	P					P				
H			P		P													
RM								X			P							
SVM		P		X		P						X	X	X	P			
Otros				P								P		X				
Variables																		
Día																X		X
CEE		X		X	X	X	X	X	X	X	X	X		X	X	X	X	X
FH	X		X								X			X				
Hora		X					X									X		X
RS	X	X	X					X	X	X	X			X				
T	X	X	X	X	X		X	X	X	X	X		X	X	X		X	
Tipo Día	X	X					X				X							
WS			X								X		X	X				
Otras			X	X			X	X			X	X	X	X	X			
Métodos de error																		
CV		X	X		X													
MAE						X												
MAPE	X					X	X	X			X		X		X	X	X	
ME						X			X									
MSE				X						X								
R				X				X								X		
RMSE						X		X			X			X			X	
Otros								X	X			X				X	X	X

Referencias	[18]	[19]	[21]	[22]	[23]	[24]	[26]	[27]	[28]	[1]	[30]	[31]	[32]	[35]	[36]	[38]	[39]	[40]	[41]	[42]	[44]	[45]	[46]	[48]	[55]	[56]	[58]	[59]	[61]	
Modelos																														
ANN		P	P			P	X	X		X	P	X	P			X	X		P	X				P			P	P	X	P
ARIMA					P	X	X					P				X		P							P	X	X	X	P	
GFS																X														
GM		P		P												X						X								
GP								P						P									P							
H							P									P	P				P	P								
RM		X		X					P	P					P									X						
SVM						X					X									X					P			X		
Variables																														
Año											X								X											
CEE	X	X	X	X	X	X	X	X		X	X	X	X	X	X	X	X	X		X	X	X	X	X	X	X	X	X	X	
EXP										X						X														
FH									X																				X	
GDP										X			X		X	X				X				X	X					
IMP										X			X		X	X				X										
POP									X	X	X				X				X							X				
Fuel Price		X																								X				
Energy Price		X																												
RS								X																	X					
T									X				X										X						X	
WS																							X							
Otras	X										X				X							X	X	X	X					
Métodos de error																														
APE			X														X							X		X				
Dstat							X													X										
MAE		X	X		X	X												X	X			X					X			
MAPE	X	X	X	X		X	X	X		X		X	X	X			X	X	X	X	X		X			X	X	X	X	X
MSE		X			X	X						X	X	X					X											




Figura 3-5.: Publicación de artículos por año por escala de tiempo del pronóstico

Modelos usados

En la Tabla 3-6 se observa que el modelo de ANN es el más usado para la construcción de las soluciones de pronósticos independientemente de la escala de tiempo a predecir. A éste le siguen los modelos de ARIMA e Híbridos, los cuales se usan casi al mismo porcentaje en corto y largo plazo.

Tabla 3-6.: Modelos propuestos en los artículos por escala de tiempo del pronóstico

Escala/Modelo	ANN	ARIMA	GFS	GM	H	RM	SVM	Otros
Corto plazo	7	3	0	0	3	1	3	1
Largo plazo	10	4	1	2	5	3	1	0
Total	17	7	1	2	8	4	4	1

Variables de entrada

Para los pronósticos de corto plazo como los de largo plazo, la variable más utilizada es el CEE como lo indican las Figuras 3-6 y 3-7 respectivamente.




Figura 3-6.: Ranking de variables utilizadas en pronósticos de corto plazo

Métodos/Técnicas de error

Para el cálculo de la precisión de los modelos propuestos, la técnica de error MAPE es la más utilizada (Figura 3-8) independiente de la escala de tiempo.

3.4.3. Discusión de la RSL desarrollada

Todas las soluciones propuestas en los artículos revisados de la RSL se han aplicado con éxito para la predicción del CEE en sus respectivos contextos. Cada técnica posee ciertas características ventajosas que deben aplicarse adecuadamente al caso de estudio.

Si bien, como se muestra en la Figura 3-4, el 60 % de los artículos revisados corresponde a pronósticos de largo plazo, cabe señalarse la tendencia creciente de artículos de corto plazo en los últimos años (Figura 3-5), conjuntamente la tendencia creciente de ambos, lo cual da cuenta de que este tema sigue siendo de interés para la investigación en la actualidad.

Con relación a los modelos empleados, se observa que, independientemente de la escala de tiempo considerada, el ANN es el más usado debido a que tiene más ventajas que los




Figura 3-7.: Ranking de variables utilizadas en pronósticos de largo plazo




Figura 3-8.: Ranking de métodos/técnicas para el cálculo de error en los modelos de pronóstico

modelos estadísticos por su versatilidad y capacidad de generar la relación de entrada y salida sin hacer compleja la dependencia con las variables de entrada. Por su parte, los modelos basados en ARIMA muestran una leve preeminencia en los pronósticos de largo plazo, mientras que GFS y GM no tienen aplicación en el corto plazo. Cabe mencionar que varios autores proponen la utilización de modelos híbridos o un conjunto de modelos para superar las desventajas de cada modelo, por ejemplo, la combinación de una técnica lineal con una no lineal. Otro claro ejemplo es la utilización de un modelo ANN con un algoritmo que ayuda a calcular los pesos iniciales de los nodos evitando que queden en un mínimo local y que resulten de convergencia lenta. Es importante resaltar que, aunque las ANN sean el modelo más utilizado, en los artículos revisados esto no constituye evidencia para afirmar de forma absoluta que es el mejor modelo, debido a que, en las contrastaciones, no se utiliza el mismo conjunto de datos ni se mide la precisión de los resultados utilizando la misma técnica para el cálculo del error. Otras diferencias que se evidencian es el no uso de las/os mismas/os técnicas/modelos en las distintas escalas de tiempo y que el método ARIMA sólo aplica para pronósticos de tipo univariados.

Con respecto a las variables de entrada, la más utilizada en todas las soluciones propuestas independientemente de sus características específicas es el CEE. A fin de redundar en mejores resultados, en los estudios de corto plazo la variable complementaria de mayor recurrencia es la temperatura, mientras que en los de largo plazo lo son las variables macroeconómicas como GDP y POP.

Si bien mayoritariamente el error es medido con MAPE, en un 60 % de los artículos se implementó un conjunto de otras técnicas, tales como RSME, MSE y MAE, para dar mayor fiabilidad y validación a los modelos.

Finalmente, la metodología de investigación/trabajo de los artículos se basó mayoritariamente en casos de estudio aplicados por ser la que brinda mejores posibilidades para desarrollar herramientas de pronósticos que permitan resolver los distintos problemas planteados en el mundo real.

3.4.4. Artículos de la RSL: A review on time series forecasting techniques for building energy consumption

En la Tabla **3-7** se enumeran los artículos analizados de la RSL del 2017 *A review on time series forecasting techniques for building energy consumption* [13] de los autores Chirag Deb *et al.*

Tabla 3-7.: Artículos de la RSL analizada

#-Ref	Artículo	Autores	Año	Citaciones
1-[63]	<i>Support vector machines experts for time series forecasting</i>	Cao, L.	2003	414
2-[64]	<i>Load forecasting using support vector machines: a study on EUNITE competition 2001</i>	Chen, B. J. and Chang, M. W. and Lin, C. J.	2004	335
3-[65]	<i>Applying support vector machines to predict building energy consumption in tropical region</i>	Dong, B. and Cao, C. and Lee, S.E.	2004	309
4-[66]	<i>Forecasting regional electricity load based on recurrent support vector machines with genetic algorithms</i>	Pai, P. F. and Hong, W. C.	2005	286
5-[17]	<i>Comparison between detailed model simulation and artificial neural network for forecasting building energy consumption</i>	Hernandez Neto, A. and Sanzovo Fiorelli, F.	2008	267
6-[67]	<i>Support vector machines with simulated annealing algorithms in electricity load forecasting</i>	Pai, P. F. and Hong, W. C.	2005	265
7-[68]	<i>Applications of improved grey prediction model for power demand forecasting</i>	Hsu, C. C. and Chen, C. Y.	2002	263
8-[69]	<i>A comparison of univariate methods for forecasting electricity demand up to a day ahead</i>	Taylor, J. W. and de Menezes, L. M. and McSharry, P. E.	2006	251
9-[70]	<i>Grey prediction with rolling mechanism for electricity demand forecasting of Turkey</i>	Akay, D. and Atak, M.	2006	235
10-[71]	<i>Short-term load forecasting using general exponential smoothing</i>	Christiaanse, W. R.	1971	228
11-[72]	<i>Chaotic particle swarm optimization algorithm in a support vector regression electric load forecasting model</i>	Hong, W. C.	2009	200
12-[73]	<i>Prediction of hourly energy consumption in buildings based on a feedback artificial neural network</i>	González, P. A. and Zammarreño, J. M.	2005	193
13-[74]	<i>Greek long-term energy consumption prediction using artificial neural networks</i>	Ekonomou, L.	2009	188
14-[75]	<i>Methodology for long-term prediction of time series</i>	Sorjamaa, A. and Hao, J. and Reyhani, N. and Ji, Y. and Lendasse, A.	2007	182
15-[76]	<i>Power load forecasting using support vector machine and ant colony optimization</i>	Niu, D. and Wang, Y. and Wu, D. D.	2010	177
16-[77]	<i>Applying wavelets to short-term load forecasting using PSO-based neural networks</i>	Bashir, Z. A. and El-Hawary, M. E.	2009	175
17-[78]	<i>Modeling and predicting building's energy use with artificial neural networks: methods and results</i>	Karatasou, S. and Santamouris, M. and Geros, V.	2005	172
18-[79]	<i>Integration of artificial neural networks and genetic algorithm to predict electrical energy consumption</i>	Azadeh, A. and Ghaderi, S. F. and Tarverdian, S. and Saberi, M.	2007	171

#-Ref	Artículo	Autores	Año	Citaciones
19-[80]	<i>Applying support vector machine to predict hourly cooling load in the building</i>	Li, Q. and Meng, Q. and Cai, J. and Yoshino, H. and Mochida A.	2009	170
20-[81]	<i>Electricity demand analysis using cointegration and ARIMA modelling: a case study of Turkey</i>	Erdogdu, E.	2006	152
21-[82]	<i>Electric load forecasting by support vector model</i>	Hong, W. C.	2008	151
22-[83]	<i>Triple seasonal methods for short-term electricity demand forecasting</i>	Taylor, J. W.	2010	150
23-[84]	<i>A trigonometric grey prediction approach to forecasting electricity demand</i>	Zhou, P. and Ang, B. and Poh, K.	2005	149
24-[19]	<i>Annual electricity consumption forecasting by neural network in high energy consuming industrial sectors</i>	Azadeh, A. and Ghaderi, S. F. and Sohrabkhani, S.	2008	145
25-[85]	<i>A new hybrid modified firefly algorithm and support vector regression model for accurate short term load forecasting</i>	Kavousi-Fard, A. and Samet, H. and Marzbani, F.	2014	145
26-[20]	<i>Forecasting energy consumption of multi-family residential buildings using support vector regression: Investigating the impact of temporal and spatial monitoring granularity on performance accuracy</i>	Jain, R. K. and Smith, K. M. and Culligan, P. J. and Taylor, J. E.	2014	142
27-[21]	<i>Forecasting of Turkey's net electricity energy consumption on sectoral bases</i>	Hamzacebi, C.	2006	136
28-[86]	<i>Forecasting of CO2 emissions, energy consumption and economic growth in China using an improved grey model</i>	Pao, H. T. and Fu, H. C. and Tseng, C. L.	2012	136
29-[87]	<i>A particle swarm optimization to identifying the ARMAX model for short-term load forecasting</i>	Huang, C. M. and Huang, C. J. and Wang, M. L.	2005	136
30-[22]	<i>Forecasting energy consumption using a grey model improved by incorporating genetic programming</i>	Lee, Y.-S. and Tong, L.-I.	2011	134
31-[88]	<i>Predicting hourly cooling load in the building: a comparison of support vector machine and different artificial neural networks</i>	Li, Q. and Meng, Q. and Cai, J. and Yoshino, H. and Mochida A.	2008	129
32-[89]	<i>An improved grey-based approach for electricity demand forecasting</i>	Yao, A. W. L. and Chi, S. C. and Chen, J. H.	2003	125
33-[90]	<i>Electric load forecasting by seasonal recurrent SVR (support vector regression) with chaotic artificial bee colony algorithm</i>	Hong, W. C.	2011	120
34-[91]	<i>An evaluation of methods for very short-term load forecasting using minute-by-minute British data</i>	Taylor, J. W.	2008	118

#-Ref	Artículo	Autores	Año	Citaciones
35-[92]	<i>Time series prediction using RBF neural networks with a nonlinear time-varying evolution PSO algorithm</i>	Lee, C.-M. and Ko, C.-N.	2009	117
36-[93]	<i>Short-term load forecasting with exponentially weighted methods</i>	Taylor, J. W.	2012	104
37-[94]	<i>Predicting future hourly residential electrical consumption: a machine learning case study</i>	Edwards, R. E. and New, J. and Parker, L. E.	2012	101
38-[95]	<i>Short term electric load forecasting by wavelet transform and grey model improved by PSO (particle swarm optimization) algorithm</i>	Bahrami, S. and Hooshmand, R.-A. and Parastegari, M.	2014	97
39-[96]	<i>Forecasting electricity consumption: a comparison of regression analysis, neural networks and least squares support vector machines</i>	Kaytez, F. and Taplamacioglu, M. C. and Cam, E. and Hardalac, F.	2014	94
40-[97]	<i>Forecasting the annual electricity consumption of Turkey using an optimized grey model</i>	Hamzacebi, C. and Es, H. A.	2014	90
41-[98]	<i>A simple method of forecasting based on fuzzy time series</i>	Singh, S. R.	2013	88
42-[99]	<i>Cyclic electric load forecasting by seasonal SVR with chaotic genetic algorithm</i>	Hong W.-C. and Dong, Y. and Zhang, W. Y. and Chen, L.-Y. and Panigrahi, B. K.	2007	85
43-[100]	<i>Forecasting monthly electric energy consumption in eastern Saudi Arabia using univariate time-series analysis</i>	Abdel-Aal, R. E. and Al-Garni, A. Z.	1997	84
44-[101]	<i>Monthly electricity demand forecasting based on a weighted evolving fuzzy neural network approach</i>	Chang, P.-C. and Fan C.-Y. and Lin, J.-J.	2011	83
45-[102]	<i>Improved estimation of electricity demand function by integration of fuzzy system and data mining approach</i>	Azadeh, A. and Saberi M. and Ghaderi, S. F. and Gitiforouz, A. and Ebrahimi-pour, V.	2008	80
46-[103]	<i>Prediction of energy demands using neural network with model identification by global optimization</i>	Yokoyama, R. and Wakui, T. and Satake, R.	2008	78
47-[104]	<i>Short and mid-term load forecasting using a bilevel optimization model</i>	Mao, H. and Zeng, X.-J. and Leng, G. and Zhai, Y. and Keane, J. A.	2017	78
48-[105]	<i>A strategy for short-term load forecasting by support vector regression machines</i>	Ceperic, E. and Ceperic, V. and Member, S. and Baric, A.	2013	77
49-[106]	<i>A new short-term load forecasting approach using self-organizing fuzzy armax models</i>	Yang, H.-T. and Huang, C.-M.	1998	77
50-[107]	<i>Application of residual modification approach in seasonal ARIMA for electricity demand forecasting: a case study of China</i>	Wang, Y. and Wang, J. and Zhao, G. and Dong, Y.	2012	71
51-[108]	<i>Hybrid evolutionary algorithms in a SVR-based electric load forecasting model</i>	Hong, W.-C.	2007	71

#-Ref	Artículo	Autores	Año	Citaciones
52-[109]	<i>An integrated fuzzy regression algorithm for energy consumption estimation with non-stationary data: a case study of Iran</i>	Azadeh, A. and Saberi, M. and Seraj, O.	2010	70
53-[110]	<i>A methodology for electric power load forecasting</i>	Almashaiei, E. and Soltan, H.	2011	69
54-[111]	<i>Analysis and forecasting of nonresidential electricity consumption in Romania</i>	Bianco, V. and Manca, O. and Nardini, S. and Minea A. A.	2010	68
55-[112]	<i>Analysis and design of a Taguchi–Grey based electricity demand predictor for energy management systems</i>	Yao, A. W. L. and Chi, S. C.	2004	66
56-[113]	<i>A hybrid intelligent algorithm based short-term load forecasting approach</i>	Hooshmand, R.-A. and Amooshahi, H. and Parastegari, M.	2013	65
57-[114]	<i>Comparing linear and nonlinear forecasts for Taiwan’s electricity consumption</i>	Pao, H.-T.	2004	63
58-[115]	<i>An adaptive fuzzy combination model based on self-organizing map and support vector regression for electric load forecasting</i>	Che, J. and Wang, J. and Wang, G.	2012	61
59-[116]	<i>Hourly cooling load prediction by a combined forecasting model based on Analytic Hierarchy Process</i>	Yao, Y. and Lian, Z. and Liu, S. and Hou, Z.	2004	59
60-[117]	<i>A new ARMAX model based on evolutionary algorithm and particle swarm optimization for short-term load forecasting</i>	Wang, B. and Tai, N. and Zhai, H. and Ye J. and Zhu, J. and Qi, L.	2008	58
61-[29]	<i>Modeling and forecasting energy consumption for heterogeneous buildings using a physical–statistical approach</i>	Lü, X. and Lu, T. and Kibert, C. J. and Viljanen, M.	2015	56
62-[118]	<i>Artificial neural network model for forecasting sub-hourly electricity usage in commercial buildings</i>	Chae, Y. T. and Horesh, R. and Hwang, Y. and Lee, Y. M.	2015	53
63-[119]	<i>Time series forecasting by evolving artificial neural networks with genetic algorithms, differential evolution and estimation of distribution algorithm</i>	Donate, J.P. and Li, X. and Gutiérrez Sánchez, G. and Sanchis de Miguel, A.	2013	53
64-[120]	<i>Hybrid of ARIMA and SVMs for short-term load forecasting</i>	Nie, H. and Liu, G. and Liu, X. and Wang, Y.	2012	53
65-[121]	<i>Forecasting diurnal cooling energy load for institutional buildings using Artificial Neural Networks</i>	Deb, C. and Eang, L. S. and Yang, J. and Santamouris, M.	2015	50
66-[122]	<i>Applying grey forecasting to predicting the operating energy performance of air cooled water chillers</i>	Jiang, Y. and Yao, Y. and Deng, S. and Ma, Z.	2004	50
67-[123]	<i>Day-ahead electricity price forecasting via the application of artificial neural network based models</i>	Panapakidis, I. P. and Dagoumas, A. S.	2016	48

#-Ref	Artículo	Autores	Año	Citaciones
68-[124]	<i>A predictive demand of the maximum electric power using chaos-fuzzy</i>	Lim, Y.-D. and Kim, S.-C. and Park, J.-O. and Choo, Y.-G.	2001	48
69-[125]	<i>Application of a hybrid quantized Elman neural network in short-term load forecasting</i>	Li, P. and Li, Y. and Xiong, Q. and Chai, Y. and Zhang, Y.	2014	48
70-[126]	<i>Short term load forecast using fuzzy logic and wavelet transform integrated generalized neural network</i>	Chaturvedi, D. K. and Sinha, A. P. and Malik, O. P.	2015	48
71-[127]	<i>A grey-box model of next-day building thermal load prediction for energy-efficient control</i>	Zhou, Q. and Wang, S. and Xu, X. and Xiao, F.	2008	47
72-[128]	<i>Forecasting electricity demand in Thailand with an artificial neural network approach</i>	Kandananond, K.	2011	46
73-[129]	<i>A research on short term load forecasting problem applying improved grey dynamic model</i>	Li, G.-D. and Wang, C.-H. and Masuda, S. and Nagai, M.	2011	46
74-[130]	<i>Electric load forecasting by the SVR model with differential empirical mode decomposition and auto regression</i>	Fan, G.-F. and Peng, L.-L. and Hong, W.-C. and Sun, F.	2016	46
75-[131]	<i>A hybrid simulation-adaptive network based fuzzy inference system for improvement of electricity consumption estimation</i>	Azadeh, A. and Saberi, M. and Gitiforouz, A. and Saberi, Z.	2009	46
76-[132]	<i>Building's electricity consumption prediction using optimized artificial neural networks and principal component analysis</i>	Li, K. and Hu, C. and Liu, G. and Xue, W.	2015	44
77-[133]	<i>A hybrid dynamic and fuzzy time series model for mid-term power load forecasting</i>	Lee, W.-J. and Hong, J.	2015	43
78-[134]	<i>Short-term electricity load forecasting of buildings in microgrids</i>	Chitsaz, H. and Shaker, H. and Zareipour, H. and Wood, D. and Amjady, N.	2015	42
79-[135]	<i>Short-term power load forecasting using grey correlation context modeling</i>	Jin, M. and Zhou, X. and Zhang, Z. M. and Tentzeris, M. M.	2012	42
80-[136]	<i>Imperialist competitive algorithm combined with refined high-order weighted fuzzy time series (RHWFTS-ICA) for short term load forecasting</i>	Enayatifar, R. and Sadaei, H. J. and Abdullah, A. H. and Gani, A.	2013	42
81-[137]	<i>Short term load forecasting using wavelet transform combined with Holt-Winters and weighted nearest neighbor models</i>	Sudheer, G. and Suseelatha, A.	2015	41
82-[138]	<i>Application of SVR with chaotic GASA algorithm in cyclic electric load forecasting</i>	Zhang, W. Y. and Hong, W.-C. and Dong, Y. and Tsai, G. and Sung, J.-T. and Fan, G.	2012	40
83-[139]	<i>Application of seasonal SVR with chaotic gravitational search algorithm in electricity forecasting</i>	Ju, F.-Y. and Hong, W.-C.	2013	39

#-Ref	Artículo	Autores	Año	Citaciones
84-[140]	<i>Long-term load forecasting by a collaborative fuzzy-neural approach</i>	Chen, T. and Wang, Y.	2012	36
85-[141]	<i>A new cascade NN based method to short-term load forecast in deregulated electricity market</i>	Kouhi, S. and Keynia, F.	2013	36
86-[142]	<i>Short term load forecasting technique based on the seasonal exponential adjustment method and the regression model</i>	Wu, J. and Wang, J. and Lu, H. and Dong, Y. and Lu, X.	2013	35
87-[143]	<i>A hybrid short-term load forecasting with a new input selection framework</i>	Ghofrani, M. and Ghayekhloo, M. and Arabali, A. and Ghayekhloo, A.	2015	35
88-[144]	<i>A new short-term load forecast method based on neuro-evolutionary algorithm and chaotic feature selection</i>	Kouhi, S. and Keynia, F. and Najafi Ravadanegh, S.	2014	34
89-[145]	<i>Forecasting electric energy consumption using neural networks</i>	Nizami, J. and Ai-Garni, A. Z.	1995	33
90-[146]	<i>Techniques of applying wavelet transform into combined model for short-term load forecasting</i>	Nengling, T. and Stenzel, J. and Hongxiao, W.	2006	33
91-[147]	<i>Short-term load forecasting using a hybrid model with a refined exponentially weighted fuzzy time series and an improved harmony search</i>	Sadaei, H. J. and Enayatifar, R. and Abdullah, A. H. and Gani, A.	2014	32
92-[148]	<i>A new hybrid day-ahead peak load forecasting method for Iran's National grid</i>	Moazzami, M. and Khodabakhshian, A. and Hooshmand, R.	2013	32
93-[149]	<i>A weighted LS-SVM based learning system for time series forecasting</i>	Chen, T.-T. and Lee, S.-J.	2015	31
94-[150]	<i>Long-term load forecasting based on adaptive neural fuzzy inference system using real energy data</i>	Akdemir, B. and Çetinkay, N.	2012	30
95-[151]	<i>A hybrid application algorithm based on the support vector machine and artificial intelligence: an example of electric load forecasting</i>	Chen, Y. and Yang, Y. and Liu, C. and Li, C. and Li, L.	2015	30
96-[152]	<i>A new linguistic out-sample approach of fuzzy time series for daily forecasting of Malaysian electricity load demand</i>	Efendi, R. and Ismail, Z. and Mat, M.	2014	29
97-[153]	<i>Time series analysis of household electric consumption with ARIMA and ARMA models</i>	Chujai, P. and Kerdprasop, N. and Kerdprasop, K.	2013	28
98-[154]	<i>Forecasting residential electricity consumption in Greece using monthly and quarterly data</i>	Dikaïos, T. E.	1992	27
99-[155]	<i>Fuzzy based time series forecasting of electric load</i>	Otto, P. and Schunk, T.	1999	27
100-[156]	<i>A wavelet Elman neural network for short-term electrical load prediction under the influence of temperature</i>	Kelo, S. and Dudul, S.	2012	23
101-[39]	<i>Forecasting Monthly Electric Energy Consumption Using Feature Extraction</i>	Meng, M. and Niu, D. and Sun, W.	2011	22

#-Ref	Artículo	Autores	Año	Citaciones
102-[157]	<i>Algorithm, optimal filter estimator and least error squares technique: comparative study</i>	El-naggar, K. M. and Al-rumaih, K. A.	2006	21
103-[158]	<i>Kernel regression for real-time building energy analysis</i>	Brown, M. and Barrington-Leigh, C. and Brown, Z.	2011	20
104-[159]	<i>Fuzzy based time series forecasting of electric load</i>	Fernandez, I. and Borges, C. E. and Peña, Y. K.	2011	16
105-[160]	<i>Development of an energy prediction tool for commercial buildings using case-based reasoning</i>	Monfet, D. and Corsi, M. and Choinière, D. and Arkhipova, E.	2014	16
106-[161]	<i>Hourly air temperature driven using multi-layer perceptron and radial basis function networks in arid and semi-arid regions</i>	Rezaeian-Zadeh, M. and Zand-Parsa, S. and Abghari, H. and Zolghadr, M. and Singh, V. P.	2012	15
107-[162]	<i>A hybrid neural network and ARIMA model for energy consumption forecasting</i>	Wang, X. and Meng, M.	2012	15
108-[163]	<i>Using support vector machine to predict next day electricity load of public buildings with sub-metering devices</i>	Fu, Y. and Li, Z. and Zhang, H. and Xu, P.	2015	14
109-[164]	<i>Forecasting monthly peak demand of electricity in India—a critique</i>	Rallapalli, S. R. and Ghosh, S.	2012	13
110-[165]	<i>Forecasting short-term electricity demand in residential sector based on support vector regression and fuzzy-rough feature selection with particle swarm optimization</i>	Son, H. and Kim, C.	2015	12
111-[166]	<i>Multivariate k-nearest neighbour regression for time series data — a novel algorithm for forecasting UK electricity demand</i>	Al-Qahtani, F. H. and Crone, S. F.	2013	11
112-[167]	<i>Building cooling load B21forecasting model based on LS-SVM</i>	Xuemei, L. X. L. and Jinhui, L. J. L. and Lixing, D. L. D. and Gang, X. G. X. and Jibin, L. J. L.	2009	10
113-[168]	<i>Forecasting energy consumption of institutional buildings in Singapore</i>	Deb, C. and Eang, L. S. and Yang, J. and Santamouris, M.	2015	9
114-[169]	<i>Short-term electric load forecasting using least square support vector machines</i>	Božić, M. and Stojanovi, M. and Stajic, Z.	2010	9
115-[170]	<i>Modelling and forecasting the residential electricity consumption in Brazil with pegels exponential smoothing techniques</i>	Maçaira, P. M. and Souza, R. C. and Oliveira, F. L. C.	2015	9
116-[171]	<i>Building-level occupancy data to improve ARIMA-based electricity use forecasts</i>	Newsham, G. R. and Birt, B. J.	2010	8
117-[172]	<i>Electricity consumption forecasting using fuzzy time series</i>	Bolturk, E. and Oztaysi, B. and Sari, I.U.	2012	8
118-[173]	<i>Electricity load demand forecasting using exponential smoothing methods</i>	Abd Jalil, N. A. and Ahmad, M. and Mohamed, N.	2013	8

#-Ref	Artículo	Autores	Año	Citaciones
119-[174]	<i>Optimizing of SVM with hybrid PSO and genetic algorithm in power load forecasting</i>	Wang, Y. and Niu, D. and Ma, X.	2010	8
120-[175]	<i>Fuzzy modeling to forecast an electric load time series</i>	Machado Pereira, C. and Nunes de Almeida, N. and Velloso, M. L. F.	2015	7
121-[176]	<i>A total fuzzy regression algorithm for energy consumption estimation</i>	Azadeh, A. and Seraj, O. and Saberi, M. A.	2008	6
122-[177]	<i>Predictability of energy use in homes</i>	Lachut, D. and Banerjee, N. and Rollins, S.	2014	6
123-[178]	<i>Short-term load forecasting using random forests</i>	Dudek, G.	2015	6
124-[179]	<i>Neural networks in forecasting electrical energy consumption</i>	Nasr, G. E. and Badr, E. A. and Younes, M. R.	2001	5
125-[180]	<i>Forecasting electricity consumption for Pakistan</i>	Yasmeen, F. and Sharif, M.	2014	5
126-[181]	<i>Fuzzy logic approach for forecasting half-hourly Malaysia electricity load demand</i>	Ismail, Z. and Mansor, R.	2011	5
127-[182]	<i>Application of improved grey model in long-term load forecasting of power engineering</i>	Kang, J. and Zhao, H.	2012	5
128-[183]	<i>Time-series prediction: application to the short-term electric energy demand</i>	Troncoso Lora, A. and Riquelme Santos, J. M. and Riquelme, J.C and Exposito A. G. and Martínez Ramos J. L.	2004	5
129-[184]	<i>Identification of ARMAX model for short term load forecasting: an evolutionary programming approach</i>	Hong-Tzer, Y. and Chao-Ming, H. and Ching-Lien, H.	1995	5
130-[185]	<i>Fuzzy time-series model of electric power consumption</i>	Ozawa, K. and Niimura, T. and Nakashima, T.	1999	4
131-[186]	<i>Electricity load forecasting in UTP using moving averages and exponential smoothing techniques</i>	Abdul Karim, S. A. and Alwi, S. A.	2013	4
132-[187]	<i>Building cooling load prediction based on time series method and neural networks</i>	Zhuang J. and Chen, Y. and Shi, X. and Wei, D.	2015	3
133-[188]	<i>Time series forecasting method of building energy consumption using support vector regression</i>	Liu, D. and Chen, Q. and Mori, K.	2015	3
134-[189]	<i>Electrical load time series data forecasting using interval type-2 fuzzy logic system</i>	Thiang, Y. K.	2010	3
135-[187]	<i>Building cooling load prediction based on time series method and neural networks</i>	Zhuang J. and Chen, Y. and Shi, X. and Wei, D.	2005	3
136-[190]	<i>The research of local linear model of short term electrical load on multivariate time series</i>	Lei, S. and Sun, C. and Zhou, Q. and Zhang, X.	2015	3
137-[191]	<i>A novel building cooling load prediction based on SVR and SAPSO</i>	Xuemei, L. and Lixing, D. and Lanlan, L.	2010	3

#-Ref	Artículo	Autores	Año	Citaciones
138-[192]	<i>Improving short term load forecasting using double seasonal arima model</i>	Mohamed, N. and Ahmad, M. H. and Ismail, Z.	2011	2
139-[193]	<i>Improved electric power demand forecasting by adapting the weighted average to the MISMO strategy</i>	Roger, T. and Oumarou, H. and Gérard, M. and Moses, T.	2014	2
140-[194]	<i>k-NN based neuro-fuzzy system for time series prediction</i>	Wei, C.-C. and Chen, T.-T. and Lee, S.-J.	2013	2
141-[195]	<i>Short term load forecasting using a hybrid model based on support vector regression</i>	Baziar, A. and Kavousifard, A.	2015	2
142-[196]	<i>Time series models for forecasting monthly electricity peak-load for Dubai</i>	Rashid, M. and Roken	2018	1
143-[197]	<i>Time-variant slide fuzzy time-series method for short-term load forecasting</i>	Liu, X. and Bai, E. and Fang, J. and Luo, L.	2010	1
144-[198]	<i>Maximum length weighted nearest neighbor approach for electricity load forecasting</i>	Colombo, T. and Koprinska, I. and Panella, M.	2015	1
145-[199]	<i>Demand for electricity in Lebanon</i>	Abosedra, S. and Campus, B.	2009	0
146-[200]	<i>Load forecasting in a smart grid oriented building</i>	Twanabasu, S. R. and Bremdal, B. A.	2013	0
147-[201]	<i>A time series analysis of electricity demand in Tamale</i>	Katara, S. and Faisal, A. and Engmann, G. M.	2014	0
148-[202]	<i>Modeling and forecasting energy consumption in Ghana</i>	Abledu, G. K.	2013	0
149-[203]	<i>Forecasting electricity consumption with neural networks and support vector regression</i>	Ogcu, G. and Demirel, O. F. and Zaim, S.	2012	0
150-[204]	<i>The application of support vector machine in load forecasting</i>	Zhao, W. and Wang, F. and Niu, D.	2012	0
151-[205]	<i>Evaluation of a case-based reasoning energy prediction tool for commercial buildings</i>	Monfet, D. and Arkhipova, E. and Choiniere, D.	2013	0
152-[206]	<i>Load forecasting based on fuzzy time series</i>	Pei, A.	2015	0
153-[207]	<i>Application of improved grey prediction model to short term load forecasting</i>	Li, G. and Yamaguchi, D. and Nagai, M.	2008	0
154-[208]	<i>Day-ahead load forecasting using exponential smoothing, 6</i>	Bindiu, R, Chindris, M. and Pop, G. V.	2009	0
155-[209]	<i>Very short-term load forecasting using exponential smoothing and Arima models</i>	Kotillová, A.	2011	0
156-[210]	<i>Building an integrated hybrid model for short-term and mid-term load forecasting with genetic optimization</i>	Xue, J. and Xu, Z. and Watada, J.	2012	0
157-[211]	<i>Short-term load forecasting by artificial neural networks specified by genetic algorithms – a simulation study over a Brazilian dataset</i>	Defilippo, S. B. and Neto, G. G. and Hippert H. S.	2015	0
158-[212]	<i>Short-term load forecasting using a kernel-based support vector regression combination model</i>	Che, J. and Wang, J.	2014	0
159-[213]	<i>Forecasting energy consumption in Taiwan using hybrid nonlinear models</i>	Pao, H. T.	2009	0

#-Ref	Artículo	Autores	Año	Citaciones
160-[214]	<i>The application of genetic algorithm in power short-term load forecasting</i>	Li, F. and Zhao, X.	2012	0
161-[215]	<i>Application of gray-fuzzy-markov chain method for day-ahead electric load forecasting</i>	Asrari, A. and Javan, D.S. and Javidi, M. H. and Monfared, M.	2012	0

3.4.5. Hallazgos y resultados de la RSL analizada

En esta sección se presentan diferentes análisis descriptivos obtenidos a partir de los artículos analizados de la RSL. En la Figura 3-9 se visualiza la distribución de los artículos por tipo de técnica/modelo de pronóstico. Como se puede apreciar, la técnica/modelo más usada/o es el híbrido seguida/o por los ARIMA, ANN y SVM.




Figura 3-9.: Distribución de artículos por modelo/técnica de pronóstico

En la Figura 3-10 se grafica la distribución de los artículos de acuerdo con la escala de tiempo. Permite visualizar que la mayoría de ellos corresponden a pronósticos de corto plazo y en sólo 4 artículos se proponen modelos tanto para el corto como para el largo plazo.

A continuación, se presentan los resúmenes de los artículos clasificados según las siguientes características: modelos, variables utilizadas y métodos de error. En la Tablas 3-8, 3-9 y 3-10 se expone el resumen de las características de los artículos de pronóstico de corto plazo y en las Tablas 3-11, 3-12 y 3-13, los de largo plazo.

[illegible]

Referencias	ANN	ARIMA	GFS	ES	GM	GP	KNN	H	Otros	RM	SVM
[166]							P				
[167]	X										P
[168]	P							X			
[169]											P
[171]		P									
[173]				P							
[174]	X							P			X
[175]		X	P								
[177]		X					P				X
[178]	X	X						P	X		
[181]			P								
[183]							P				
[184]								P			
[186]		X		P							
[187]		P						X			
[190]							P				
[187]								P	X		
[191]								P			
[192]		P									
[194]	X	X						P			
[195]	X	X						P			X
[197]			P								
[198]							P				
[200]	X	P									X
[205]									P		
[206]			P								
[207]					P						
[208]				P							
[209]	X	X		P							
[210]								P			X
[211]	X							P	X		
[212]								P			
[214]					X			P			
[215]	X	X				X		P			

Tabla 3-9.: Resumen artículos pronósticos corto plazo por variables utilizadas

Referencias	Año	CEE	Día	Energy Price	FH	Hora	Otras	RS	T	Tipo Día	WS
[63]		X					X				
[64]		X							X		
[17]		X			X			X	X		
[69]		X									
[71]		X									
[73]		X	X			X			X		
[75]		X									
[76]		X									
[77]		X			X				X	X	X

[illegible]

Tabla 3-10.: Resumen artículos pronósticos corto plazo por métricas de error

Referencia	APE	CV	MAE	MAPE	ME	MSE	Otros	R	RMSE
[63]		X					X		X
[64]				X					
[17]					X				
[69]	X			X					
[71]							X		
[73]				X					
[75]						X			
[76]				X					X
[77]	X			X					
[78]		X		X			X		X
[80]							X		X
[83]				X					
[85]				X			X		X
[20]		X							
[87]							X		
[88]							X		X
[89]							X		
[91]	X			X					
[92]	X			X			X		
[93]				X					
[94]		X		X			X		
[95]	X		X			X	X		
[103]							X		X
[104]			X	X					
[105]				X					
[106]							X		
[110]				X					
[112]							X		
[113]	X		X	X					
[115]			X	X					X
[116]							X		
[117]				X					
[29]								X	X
[118]	X					X	X		X
[119]							X		X
[120]				X					X
[121]								X	
[122]							X		
[123]	X		X	X			X		
[124]					X				
[125]	X			X					
[126]									X
[127]				X			X	X	X
[129]				X			X		X
[130]			X	X					X

Referencia	APE	CV	MAE	MAPE	ME	MSE	Otros	R	RMSE
[132]		X		X					
[134]							X		
[135]					X		X		
[136]	X			X		X			
[137]				X					
[141]			X	X					
[142]				X			X		
[143]				X					
[144]				X					
[146]				X					
[147]	X			X		X			X
[148]			X	X			X		X
[149]			X	X		X			X
[151]			X	X					X
[152]				X					
[153]							X		X
[155]							X		
[156]				X		X	X		
[158]							X		X
[159]				X					
[160]							X		X
[161]			X					X	X
[163]							X		
[166]				X			X		
[167]							X		
[168]								X	
[169]	X			X					
[171]			X	X			X	X	X
[173]				X					
[174]							X		X
[175]				X			X		
[177]							X		
[178]				X			X		
[181]						X			
[183]			X			X	X		
[184]							X		
[186]				X					
[187]							X		
[190]					X				
[187]							X		
[191]				X					X
[192]				X					X
[194]			X			X			X
[195]			X	X			X		X
[197]				X					
[198]				X					
[200]				X					X

Referencia	APE	CV	MAE	MAPE	ME	MSE	Otros	R	RMSE
[205]							X		X
[206]				X					
[207]				X					
[208]				X	X	X	X		
[209]				X					
[210]				X					X
[211]				X					
[212]			X	X					
[214]				X					
[215]							X		

Tabla 3-11.: Resumen artículos pronósticos largo plazo por modelo. P: Modelo Propuesto – X: Modelo Comparación

Referencia	ANN	ARIMA	GFS	ES	GM	GP	KNN	H	Otros	RM	SVM
[65]											P
[66]	X							P		X	X
[67]	X	X									P
[68]		X			P						
[70]					P						
[72]	X	X				X		P		X	
[74]	P									X	X
[79]	X							P		X	
[81]		P									
[82]	X									X	P
[84]		X			P						
[19]	P									X	
[21]	P								X		
[86]		X			P						
[22]					P					X	
[90]		X						P			
[96]	X									X	P
[97]					P						
[98]		X						P			
[99]			P								
[100]		P								X	
[101]								P			
[102]								P			
[107]		P									
[108]	X							P		X	
[109]	X		P			X					
[111]				X	P						
[114]	P	X								X	
[119]								P			
[128]	X	P								X	
[131]	X					X		P			
[133]		X						P			

Referencia	ANN	ARIMA	GFS	ES	GM	GP	KNN	H	Otros	RM	SVM
[138]		X						P			
[139]		X						P			
[140]	X	X						P	X		
[145]	P									X	
[150]								P			
[153]		P									
[154]		P									
[39]								P			
[157]						X					
[162]	X	P						X			
[164]		P							X		
[165]	X	X						P		X	
[170]				P							
[172]			P								
[176]		X	P								
[177]		X					P				X
[179]	P										
[180]		P								X	
[182]					P						
[185]			P								
[188]											P
[189]			P								
[193]							P				
[196]		P							X		
[199]		P		X					X		
[201]		P									
[202]		P									
[203]	X										P
[204]											P
[210]								P			X
[213]								P			

Tabla 3-12.: Resumen artículos pronósticos largo plazo por variables utilizadas

Referencia	Año	CEE	Energy Price	EXP	FH	GDP	IMP	Otras	POP	RS	T	Tipo Día	WS
[65]		X			X					X	X		
[66]		X											
[67]		X											
[68]		X											
[70]		X											
[72]		X											
[74]		X				X		X			X		
[79]		X	X					X					
[81]		X	X			X							
[82]		X											
[84]		X											
[19]		X						X					
[21]		X											
[86]		X				X		X					
[22]		X											
[90]		X											
[96]		X						X	X				
[97]		X											
[98]		X											
[99]		X											
[100]		X			X	X		X	X		X		
[101]		X			X			X			X		X

Referencia	Año	CEE	Energy Price	EXP	FH	GDP	IMP	Otras	POP	RS	T	Tipo Dfa	WS
[102]		X											
[107]		X											
[108]		X											
[109]		X											
[111]		X	X			X			X				
[114]		X				X		X	X		X		
[119]								X					
[128]		X		X		X		X	X				
[131]		X											
[133]		X									X		
[138]		X											
[139]		X											
[140]		X											
[145]		X			X				X	X	X		
[150]		X						X	X				
[153]		X											
[154]		X	X								X		
[39]		X											
[157]		X											
[162]		X											
[164]		X											
[165]		X	X					X	X		X		X
[170]		X											
[172]		X											
[176]		X											
[177]		X						X					
[179]		X									X		
[180]		X											
[182]		X											
[185]		X											
[188]		X											
[189]		X											
[193]		X											
[196]		X											
[199]		X			X		X				X		
[201]		X											
[202]		X											
[203]		X											
[204]		X											
[210]	X	X						X			X	X	
[213]		X						X					

Tabla 3-13.: Resumen artículos pronósticos largo plazo por métricas de error

Referencia	APE	CV	MAE	MAPE	ME	MSE	Otros	R	RMSE
[65]		X				X			
[66]				X					
[67]				X			X		
[68]				X					
[70]				X					
[72]				X					
[74]							X		
[79]				X			X		
[81]							X		
[82]				X					
[84]				X		X	X		
[19]			X	X		X			
[21]	X		X	X					X
[86]			X	X					X
[22]				X			X		
[90]				X					
[96]				X		X	X		X
[97]			X	X					
[98]				X					

Referencia	APE	CV	MAE	MAPE	ME	MSE	Otros	R	RMSE
[99]						X			
[100]			X			X	X		
[101]				X					
[102]				X					
[107]				X			X		X
[108]				X					
[109]				X					
[111]				X		X	X		
[114]			X	X					X
[119]							X		X
[128]				X					
[131]			X	X		X			X
[133]				X					
[138]				X					
[139]				X					
[140]			X	X					X
[145]						X		X	
[150]			X	X					
[153]							X		X
[154]			X		X		X		X
[39]				X			X		
[157]				X			X		
[162]			X	X					X
[164]			X	X					X
[165]			X	X			X		X
[170]				X	X				
[172]							X		
[176]				X					
[177]							X		
[179]				X		X	X		
[180]			X	X		X			X
[182]							X		
[185]							X		
[188]						X		X	
[189]									X
[193]				X			X		
[196]								X	
[199]				X		X			X
[201]			X	X			X		X
[202]	X			X			X		X
[203]				X					
[204]				X					
[210]				X					X
[213]				X		X			X

Publicaciones y año de publicación

La Figura 3-11 muestra la cantidad de publicaciones de artículos y su evolución por año para las diferentes escalas de tiempo de los pronósticos y para la suma de ambos, donde claramente se puede evidenciar que año tras año se incrementa la cantidad de investigaciones sobre el tema de pronósticos.




Figura 3-11.: Publicación de artículos por año por escala de tiempo del pronóstico

Modelos usados

En la Tabla 3-14 se observa que el modelo de técnicas híbridas es el más usado para la construcción de las soluciones de pronósticos de corto plazo seguido de las ANN y ARIMA. Para los de largo plazo, el más utilizado es ARIMA seguido de las ANN y los híbridos. En general, sin importar la escala, los más usados son los híbridos seguidos de los modelos que usan ANN y ARIMA.

Tabla 3-14.: Modelos propuestos en los artículos por escala de tiempo del pronóstico

Escala/Modelo	ANN	ARIMA	GFS	GM	GP	ES	KNN	H	Otros	RM	SVM
Corto Plazo	40	27	7	10	1	9	6	47	10	7	23
Corto Plazo	20	28	6	8	4	3	2	20	5	15	11
Total	60	55	13	18	5	12	8	67	15	22	34

Variables de entrada

Para los pronósticos de corto plazo como los de largo plazo, la variable más utilizada es el CEE como lo indican las Figuras 3-12 y 3-13 respectivamente. Para el corto plazo, le sigue la variable T y para el largo plazo, Otras.




Figura 3-12.: Ranking de variables utilizadas en pronósticos de corto plazo.

Métodos/Técnicas de error

Para el cálculo de la precisión de los modelos propuestos, la técnica de error MAPE es la más utilizada (Figura 3-14) independiente de la escala de tiempo, seguida de RMSE y MAE.

3.4.6. Discusión de la RSL analizada

Todas las soluciones propuestas en los artículos revisados se han aplicado con éxito para la predicción, en su mayoría en CEE, en sus respectivos contextos. Cada técnica posee ciertas características ventajosas que deben aplicarse adecuadamente al caso de estudio.

Si bien, como se muestra en la Figura 3-10, un poco más del 60 % de los artículos revisados corresponde a pronósticos de corto plazo, cabe señalarse la tendencia creciente de artículos de corto plazo en los últimos años a diferencia de los de largo plazo que tienen una tendencia




Figura 3-13.: Ranking de variables utilizadas en pronósticos de largo plazo




Figura 3-14.: Ranking de métodos/técnicas para el cálculo de error en los modelos de pronóstico

decreciente (Figura 3-11), conjuntamente con la tendencia creciente de ambos, lo cual da cuenta de que este tema sigue siendo de interés para la investigación en la actualidad.

Con relación a los modelos empleados, se observa que, independientemente de la escala de tiempo considerada, el modelo híbrido es el más usado debido a que se busca mejorar la precisión de los modelos y superar sus desventajas, por ejemplo, realizando la combinación de un modelo con una técnica lineal con un modelo con una no lineal. A éstos le siguen los modelos de ANN debido a que tienen más ventajas que los modelos estadísticos por su versatilidad y capacidad de generar la relación de entrada y salida sin hacer compleja la dependencia con las variables de entrada. Como tercera opción más usada, se tienen los modelos ARIMA ya que son modelos estocásticos fáciles de implementar y son los preferidos para pronósticos univariados. Es importante resaltar que, aunque los híbridos sean el modelo más utilizado, en los artículos revisados esto no es suficiente evidencia para afirmar de forma absoluta que es el mejor modelo, debido a que, en las contrastaciones, debería utilizarse el mismo conjunto de datos y al mismo tiempo, medirse la precisión de los resultados utilizando la misma técnica para el cálculo del error.

Con respecto a las variables de entrada, la más utilizada en todas las soluciones propuestas independientemente de sus características específicas, es el CEE. A fin de redundar en mejores resultados, en los estudios de corto plazo la variable complementaria de mayor recurrencia es la temperatura, mientras que en los de largo plazo lo son las variables macroeconómicas como GDP y POP.

Si bien mayoritariamente el error es medido con MAPE, en un 66 % de los artículos se implementó un conjunto de otras técnicas, tales como RSME, MSE y MAE, para dar mayor fiabilidad y validación a los modelos.

Finalmente, la metodología de investigación/trabajo de los artículos estaba basada mayoritariamente en casos de aplicación real preponderando entonces sobre los realizados con datos de simulación.

3.4.7. Conclusiones sobre el capítulo 4 de Modeling and forecasting electricity loads and prices: a statistical approach

La lectura del capítulo 4 del libro [14] permite evidenciar que el problema planteado en el trabajo de investigación es de vital importancia para el sector eléctrico debido a que, en la última década, con la des-regulación del mercado eléctrico y la introducción de la competencia han emergido nuevos desafíos para los participantes del mercado eléctrico mayorista. La volatilidad extrema de los precios, que puede ser incluso dos órdenes de magnitud mayor que para otros activos, ha obligado a los productores y consumidores mayoristas a protegerse no solo contra el riesgo de volumen sino también contra los movimientos de precios. Los pronósticos de precios se han convertido en un aporte fundamental para la toma de decisiones

y el desarrollo de la estrategia de una empresa de energía. Esto, a su vez, ha impulsado la investigación en el modelado y pronóstico de los precios de la electricidad.

Weron señala que la extrema volatilidad de los precios de energía del mercado eléctrico, que puede ser incluso dos órdenes de magnitud mayor que para otros activos, ha obligado a los productores y consumidores mayoristas a protegerse no solo contra el riesgo de volumen sino también contra los movimientos de precios. Esto es debido a que, en la última década, con la desregulación del mercado eléctrico y la introducción de la competencia han emergido nuevos desafíos para los participantes del mercado eléctrico mayorista. En consecuencia, los pronósticos de precios se han convertido en un aporte fundamental para la toma de decisiones y el desarrollo de la estrategia de una empresa de energía, impulsando, entonces, la investigación en el modelado y pronóstico de los precios de la electricidad.

Además, el autor remarca la importancia fundamental de los 3 aspectos que se deben considerar para el desarrollo de un modelo de pronósticos que son el impacto de la selección de las variables exógenas para el caso de que se decida incluirlas en el modelo, la influencia de los picos de precios pasados en el proceso de calibración del modelo y las métricas utilizadas para determinar la precisión de pronóstico. Para este último se recomienda utilizar principalmente las métricas de error MAE y MAPE para los pronósticos con granularidad horaria.

Otro aspecto que resalta es la importancia de la calidad de los datos con los cuales se trabaje ya que afectan de forma directa los resultados de los modelos de pronóstico.

Finalmente, el autor expone varios casos de estudio aplicados donde se analizan varios modelos, tanto univariantes como multivariantes, para la predicción del precio de la energía, entre ellos, los modelos tipo ARMA, GARCH, Naive y híbridos.

Lo arriba reseñado pone en evidencia que el problema planteado en el trabajo de investigación es de vital importancia para el sector eléctrico, en general y particularmente para los participantes del mercado eléctrico mayorista a la hora de tomar decisiones que redunden en negocios con mayor rentabilidad y con menor riesgo.

4. Marco Metodológico

4.1. Introducción

En el presente capítulo se describe la ruta metodológica empleada para efectos de esta investigación, se describe el área de estudio y cómo se desarrolló el trabajo teniendo en cuenta el método de investigación y validación utilizados para alcanzar los objetivos propuestos.

4.2. Descripción del área de estudio

En este proyecto, la unidad de análisis, determinada teniendo en cuenta los requerimientos de la empresa MVM con su plataforma tecnológica *Energy Suite* actualmente utilizada por algunos participantes del MEM de México, es el pronóstico de precios marginales locales del mercado eléctrico mexicano.

4.3. Metodología de investigación

Para el desarrollo de este proyecto de investigación, la metodología empleada se basó en el método de estudio de caso [216]. Esta elección se fundamenta en [217], quien sostiene que su uso en las investigaciones cualitativas permite examinar o indagar sobre un fenómeno contemporáneo en su entorno real donde la frontera entre éste y su contexto no son claramente evidentes, utilizando diversas fuentes de datos y permitiendo estudiar un caso único o múltiple. Además, para [218], el método de estudio de caso es adecuado para investigar y dar respuesta al cómo y por qué ocurren los fenómenos, permite estudiarlos desde múltiples perspectivas y no desde la influencia de una variable y permite explorar de forma más profunda y obtener un conocimiento más amplio sobre cada fenómeno.

4.4. Desarrollo de marco metodológico

La gestión integral del proyecto se realizó, mayormente, tomando una adaptación de las prácticas definidas en la metodología SCRUM¹ donde se definen los alcances de cada sprint que, por lo general, tuvieron una duración entre una y dos semanas, para luego proceder con la ejecución misma y posteriormente, con la revisión de resultados de cada uno de ellos para definir el siguiente.

Las actividades para el desarrollo de este proyecto de investigación se organizaron en 4 fases (Figura 4-1) con el objetivo de dar respuesta a cada objetivo específico planteado y fueron las siguientes:



Figura 4-1.: Desarrollo del proyecto de investigación.

- **Fase 1 - Revisión de la literatura como apoyo teórico y conceptual al proyecto de investigación en la línea de profundización:** tuvo como propósito la elaboración de un marco conceptual que sirvió de apoyo en la referenciación y apropiación de fundamentos relacionados con el objeto de estudio. Esta fase permitió dar cumplimiento al objetivo específico: *determinar qué modelos o técnicas de pronóstico y qué características se han utilizado con el fin de tener una base de conocimiento para apoyar la fase de diseño del modelo de pronóstico del proyecto.*
- **Fase 2 - Validación de la problemática y establecimiento de requisitos funcionales y no funcionales del proyecto:** tuvo como propósito validar la problemática

¹Método ágil de desarrollo de Software que adopta una estrategia de desarrollo incremental, en lugar de la planificación y ejecución completa del producto permitiendo obtener rápidamente un producto mínimo viable.

que tienen los suministradores calificados con la gestión de la información para poder pronosticar el precio marginal local, que fue la variable definida por los especialistas de MVM para la compra y venta de energía. Esta fase permitió dar cumplimiento al objetivo específico: *identificar los requisitos funcionales y no funcionales que deben ser incorporados en la plataforma Energy Suite de MVM con el fin de tener los insumos necesarios para el diseño del modelo de pronóstico.*

- **Fase 3 - Diseñar el modelo de pronósticos del proyecto:** tuvo como propósito diseñar el modelo de pronósticos que permitió pronosticar el precio marginal local, con mayor precisión y confiabilidad buscando cubrir los hallazgos identificados en la fase 2. Esta fase dio cumplimiento al objetivo específico: *diseñar el modelo de pronóstico de variables eléctricas para ampliar la línea base tecnológica de la plataforma Energy Suite de MVM, con el cual los suministradores calificados del MEM de México, puedan contar con la información pronosticada con el fin de lograr un mejor desempeño económico en la compra y venta de energía.*
- **Fase 4 - Realizar pruebas de validación del modelo del proyecto:** tuvo como propósito realizar las pruebas del modelo de pronóstico del precio marginal local con los datos con los cuales actualmente opera la plataforma *Energy Suite* con el fin de evaluar la precisión y confiabilidad del modelo desarrollado en la Fase 3. Esta fase dio cumplimiento al objetivo específico: *validar con especialistas del MEM de México de MVM la pertinencia del modelo de pronóstico elaborado con el fin de poder determinar y cuantificar los resultados obtenidos.*

Para llevar a cabo el diseño del modelo propuesto, se utilizó de forma transversal en las fases 2 a 4 la metodología *CRISP-DM*² sin contemplar su última fase de **despliegue** por no estar dentro del alcance de este proyecto de investigación. Es decir, se ejecutaron las fases de **entendimiento del negocio**, **entendimiento de los datos**, **preparación de los datos**, **modelado** y **evaluación del modelo**.

A continuación, se describen las actividades que se realizaron y su relación con las fases de la metodología. Es importante resaltar que la disposición de las fases es orientativa, pero en la práctica no hay división estricta o taxativa entre ellas.

Fase - Entendimiento del negocio

En esta fase, se trabajó de forma estrecha con los especialistas del mercado eléctrico de MVM con el fin de identificar, a través de un proceso de ingeniería de requisitos, las necesidades y las características funcionales y no funcionales necesarias para los pronósticos de variables eléctricas para el mercado eléctrico mayorista mexicano. Para esto, primero se

²Metodología utilizada en proyectos de minería de datos y consta de las siguientes fases: **comprensión del negocio**, **comprensión de los datos**, **preparación de los datos**, **modelado** y **evaluación** para el desarrollo de una solución.

preparó un inventario de preguntas iniciales (Tabla 4-1) con el fin de poder guiar y sacar el máximo provecho en los talleres que se realizaron con ellos. Como producto del desarrollo de estos talleres se obtuvieron los siguientes escenarios de negocio: ***Pronóstico de demanda (suma de la generación)***, ***Pronóstico de consumos de energía***, ***Pronóstico de los precios de compra y venta de energía*** y ***Pronóstico de generación***. (ver Anexo A)

Tabla 4-1.: Preguntas utilizadas en talleres con especialistas de MVM

#	Pregunta
1	¿Existen necesidades de información pronosticada para la toma de decisiones en el sector eléctrico?
2	¿Quiénes utilizan dicha información pronosticada?
3	¿Para qué la necesitan?
4	¿Qué decisiones se toman a partir de ella?
5	¿Son pronósticos de corto, mediano o largo plazo?
6	¿Qué variables eléctricas se necesita pronosticar?
7	¿Con qué información histórica se cuenta?
8	¿Qué otros participantes del mercado pueden utilizar estos pronósticos?

A continuación, dichos escenarios de negocio de pronósticos se presentaron a la persona encargada del desarrollo de la plataforma *Energy Suite*, quien en conjunto con los especialistas determinaron el ***Pronóstico de los precios de compra y venta de energía*** como el caso de negocio a trabajar en la investigación.

Concluida esta actividad, se procedió a realizar los talleres de co-creación con los especialistas de MVM con el objetivo de definir las historias de usuario asociadas al escenario y obtener al mismo tiempo los requisitos de requerimientos de cada historia. Para ello, se utilizó el formato plantilla existente en MVM para historias de usuario. Como resultado, se obtuvieron dos historias de usuario (ver Anexo B), las cuales nuevamente se presentaron en otra reunión a la persona encargada del desarrollo de la plataforma *Energy Suite* y éste definió que la historia a trabajar para el proyecto de investigación sería ***0001 - Pronóstico de precios marginales***.

Finalmente, teniendo definidos de forma clara el alcance y los requerimientos de la necesidad de pronóstico y de acuerdo con el escenario e historia de usuario seleccionado, se procedió a realizar una última reunión con los especialistas de MVM y el encargado del desarrollo de la plataforma suite para definir la fuente de información a utilizar. Esta última se tomó del modelo relacional de la base de datos *ESCentralRepo* de la plataforma *Energy Suite* de MVM, que fue presentado por el arquitecto del producto y la analista a cargo de la información.

Fase - Entendimiento de los datos

Cabe destacar que la información que se tomó de la base de datos *ESCentralRepo* de la plataforma *Energy Suite* es información de carácter público y es publicada por el Centro Nacional de Control de Energía (CENACE) de México de forma diaria al terminar el día

en su sitio oficial³. Esta información es procesada, también de forma diaria, por un *Robotic Process Automation* (RPA) creado por MVM y se consolida en una base de datos de la plataforma de *Energy Suite*. Para el proyecto se tomó la información de dicha fuente ya que simplificaba el proceso de consolidación y posterior obtención. Así se pudo contar con la información de precios marginales locales para todos los nodos que reportaron información desde enero de 2016 hasta agosto del 2018 para la construcción de las series de tiempo por nodo utilizadas en el desarrollo de la investigación.

Como actividad inicial de esta fase, se definieron las consultas con las sentencias SQL a partir del diagrama relacional de las tablas disponibles en la base de datos *ESCentralRepo* de la plataforma *Energy Suite* de MVM (ver Anexo C) con el fin de conocer tanto la información transaccional de los precios marginales locales como los datos maestros asociados a fin de obtener una idea preliminar de la calidad de datos de éstos. (ver Anexo D – Q1 al Q16)

Como segunda actividad, teniendo en cuenta que se contaba con más de 2400 nodos a procesar, se construyeron las consultas con las sentencias SQL (ver Anexo E – Q17 al Q28) para clasificarlos/segmentarlos inicialmente por ciudad, estado, nivel de tensión y zona de carga de forma individual por cada uno.

En la tercera actividad se ejecutaron las consultas SQL y los resultados se exportaron a hojas dentro un archivo de tipo Excel, que se nombró como *Analisis_Datos_Maestros_Nodos.xlsx*, donde se analizó la información obtenida, y se revisó la distribución de cantidad de nodos por ciudades, estados, niveles de tensión y zonas de carga. Además, se observó la cantidad y representación porcentual de nulos y la completitud de la información histórica de los nodos.

Finalmente, se decidió descartar la clasificación/segmentación por ciudades y niveles de tensión, ya que para el primer caso quedaba una distribución baja de nodos, es decir, muy desagregado, y para el segundo, no se visualizaba una distribución balanceada debido a que la mayoría de los nodos se encontraban en un nivel de tensión específico y muy pocos nodos, en los demás niveles de tensión.

Fase - Preparación de los datos

Se comenzó escribiendo un script en R, el cual se nombró *Muestreo_Nodos_Reg_MesoReg_Final.R*, para calcular la cantidad de nodos a muestrear por cada caso (estado, zona de carga). Para el cálculo del tamaño de la muestra se utilizó la siguiente fórmula 4-1:

$$n = \frac{Z^2 pq N}{NE^2 + Z^2 pq} \quad (4-1)$$

donde:

- n: tamaño de la muestra.

³<http://www.cenace.gob.mx/SIM/VISTA/REPORTES/PreEnergiaSisMEM.aspx> - Página oficial del CE-NACE para descargar la información de los nodos con relación al precio marginal local del mercado del día en adelante.

- Z: nivel de confianza.
- p: variabilidad positiva.
- q: variabilidad negativa.
- E: precisión o error.
- N: tamaño de la población.

y se tomaron los siguientes valores para los parámetros de la Tabla 4-2 y Tabla 4-3.

Tabla 4-2.: Parámetros confiabilidad para el muestreo

Confiabilidad	Z
99 %	2,575
95 %	1,96
90 %	1,645

Tabla 4-3.: Parámetros error para el muestreo

Error	E
10 %	0,1
5 %	0,05

Dado que no existen antecedentes a esta investigación, los valores de p y q deben ser iguales a 0,5.

Los resultados obtenidos evidenciaron que el muestreo poblacional por estado y zona de carga continuaban dando un numero de más de 1000 de nodos a procesar. Por lo tanto, se decidió incluir la clasificación por la región y la mesoregión. Para ello, se construyó una nueva sentencia SQL (ver Anexo 4 - Q29) y se organizó un archivo de tipo CSV, que se nombró como *Regiones_MesoRegiones_Estados.csv*, para relacionar el estado con la región y la mesoregión respectivamente. Luego, se procedió a modificar el script de R, para implementar el nuevo alcance y se ejecutó nuevamente para obtener los nuevos resultados. (ver Anexo E)

Como última actividad de esta fase, se creó una consulta SQL (ver Anexo D – Q30) seleccionando un nodo aleatorio con el fin de tener un archivo de tipo CSV, el *PML_dataset.csv*, para usarlo en el prototipo.

Fase - Modelado

El último archivo obtenido en la fase anterior se usó como *dataset* de prueba para construir el script de R, el cual se nombró como *Prueba_Ajuste_Modelos_1_v1.R*, para construir los modelos de pronósticos seleccionados, de acuerdo con la revisión del estado del arte que se realizó en la fase 1, y para calibrarlos midiéndose además el tiempo de ejecución. En total se construyeron así 5 modelos de acuerdo con la Tabla 4-4.

Tabla 4-4. Modelos de pronósticos contruidos

Modelo	Descripción
Forecast_All	Se utilizó la serie de datos de los precios de los nodos de forma completa, es decir, sin descomponer. A dicha serie se le aplicaron varias técnicas de pronóstico para pronosticar las siguientes 48 horas y se midió su error global a través de las métricas RMSE, MAE y MAPE.
Forecast_Day1	Se utilizó la serie de datos de los precios de nodo descomponiendo la serie por tipo de día (e.g. una serie para los lunes, otra para martes, etc) obteniéndose a partir de la serie original 2 series. A partir de estas series se aplicaron varias técnicas de pronóstico para pronosticar las siguientes 48 horas y se midió su error global a través de las métricas RMSE, MAE y MAPE.
Forecast_Day2	Se utilizó la serie de datos de los precios de nodo descomponiendo la serie por tipo de día, obteniéndose a partir de la serie original 2 series. A partir de estas series se propuso un modelo híbrido que para cada tipo de día determinaba la mejor técnica a través de las métricas de error RMSE, MAE y MAPE, es decir, que a diferencia del modelo Forecast_Day1 que trabaja con una sola técnica global aquí se combina la mejor técnica de cada serie individual.
Forecast_DayHour1	Se utilizó la serie de datos de los precios de nodo descomponiendo la serie por tipo de día y por hora (e.g. una serie para la hora 1 de los lunes, para la hora 2 de los martes, etc) obteniéndose a partir de la serie original 48 series. A partir de estas series se aplicaron varias técnicas de pronóstico para pronosticar las siguientes 48 horas y se midió su error global a través de las métricas RMSE, MAE y MAPE.
Forecast_DayHour2	Se utilizó la serie de datos de los precios de nodo descomponiendo la serie por tipo de día obteniéndose a partir de la serie original 2 series. A partir de estas series se propuso un modelo híbrido que para cada tipo de día y hora determinaba la mejor técnica a través de las métricas de error RMSE, MAE y MAPE, es decir, que a diferencia del modelo Forecast_DayHour1 que trabaja con una sola técnica global aquí se combina la mejor técnica de cada serie individual.

Para el cálculo de los errores RMSE, MAE y MAPE se utilizaron fórmulas 4-2, 4-3 y 4-4:

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (x_{ipro} - x_{ireal})^2}{N}} \quad (4-2)$$

$$MAE = \frac{\sum_{i=1}^N |x_{ipro} - x_{ireal}|}{N} \quad (4-3)$$

$$MAPE = \frac{\sum_{i=1}^N \frac{|x_{ipro} - x_{ireal}|}{x_{ireal}}}{N} 100 \quad (4-4)$$

donde para todas las fórmulas:

- N: cantidad de nodos de la muestra población.

- x_{ireal} : precio marginal local real.
- x_{ipro} : precio marginal local pronosticado.

Durante el proceso de calibración los resultados se almacenaron en archivos de tipo Rdata que fueron utilizados para crear otros 3 scripts de R de tipo Rmarkdown, que se nombraron *AnalisisModelos_1.v2.Rmd*, que contiene el análisis para los modelos sin descomposición de la serie de datos (Forecast_All); *AnalisisModelos_2.v2.Rmd*, que incluye el análisis para los modelos de descomposición de la serie de forma diaria (Forecast_Day1 y Forecast_Day2); y *AnalisisModelos_3.v2.Rmd*, con el análisis para los de modelos de descomposición de la serie de forma diaria y horaria (Forecast_DayHour1 y Forecast_DayHour2). Esto permitió presentar con claridad los resultados comparativos para cada técnica y así seleccionar la calibración más adecuada para el diseño de los modelos.

A continuación, en las tablas 4-5, 4-6 y 4-7 se describen las técnicas de forecast seleccionadas a partir de la revisión del estado del arte y se especifica la mejor calibración para cada modelo desarrollado. Las variantes de configuración de los parámetros de cada técnica evaluadas en el proceso de calibración de los modelos se detallan en el Anexo F.

Tabla 4-5.: Modelo Forecast_All - Mejor calibración

# Técnica	Técnica	Calibración
1	Mean_3	No aplica.
2	Mean_6	No aplica.
3	Mean_9	No aplica.
4	Mean_12	No aplica.
5	LM	Modelo calibrado fórmula con trend + season.
6	ARIMA	Parámetros automáticos definidos por la función auto.arima.
7	NNETAR	Parámetro P = 0 y resto de parámetros automáticos.
8	NNET	Parámetro Lag = 2 (2x24).
9	ETS	Parámetros automáticos.
10	KNN	Parámetro k = 15, lag = 2 (2 x 24).
11	SVM_1	Parámetro kernel = radial, c = 100, g = 100.
12	SVM_2	Parámetro kernel = linear, c = 1 y g= 0.01 y lag =4.
13	FUZZY_1	Parámetro n = 10, w = 2, C = 0.01.
14	FUZZY_2	Parámetro = 10, w = 2, C = 0.01, Lags = 30 (30 x 24)
15	HW	Calibración por fuerza bruta de los 3 parámetros.

Tabla 4-6.: Modelos Forecast_Day1 y Forecast_Day2 - Mejor calibración

# Técnica	Técnica	Calibración
1	Mean_3	No aplica.
2	Mean_6	No aplica.
3	Mean_9	No aplica.
4	Mean_12	No aplica.
5	LM	Modelo calibrado fórmula con trend + season.

# Técnica	Técnica	Calibración
6	ARIMA	Parámetros automáticos definidos por la función auto.arima.
7	NNETAR	Parámetro P = 0 y resto de parámetros automáticos.
8	NNET	Parámetro Lag = 6 (6x24). Nota: Se decidió con la métrica de error MAE.
9	ETS	Parámetros automáticos.
10	KNN	Configuración Automática y parámetro lags = 52 (52x24)
11	SVM_1	Parámetro kernel = radial, c = 1, g = 100.
12	SVM_2	Parámetro kernel = linear, c = 1 y g = 0.01 y lag = 4.
13	FUZZY_1	Parámetro n = 10, w = 2, C = 0.01.
14	FUZZY_2	Parámetro n = 10, w = 2, C = 0.01, Lags = 52 (52x24)
15	HW	Calibración por fuerza bruta de los 3 parámetros.

Tabla 4-7.: Modelos Forecast_DayHour1 y Forecast_DayHour2 - Mejor calibración

# Técnica	Técnica	Calibración
1	Mean_3	No aplica.
2	Mean_6	No aplica.
3	Mean_9	No aplica.
4	Mean_12	No aplica.
5	LM	Modelo calibrado fórmula con trend + season.
6	ARIMA	Parámetros automáticos definidos por la función auto.arima.
7	NNETAR	Parámetro P = 0 y resto de parámetros automáticos.
8	NNET	Parámetro Lag = 2 (2x24). Nota: Se decidió con la métrica de error MAE.
9	ETS	Parámetros automáticos.
10	KNN	Configuración automática y parámetro lags = 52 (52x24)
11	SVM_1	Parámetro kernel = radial, c = 100, g = 10. Nota: Se decidió con la métrica de error MAE.
12	SVM_2	Parámetro kernel = radial, c = 1, g = 1, Lags = 4.
13	FUZZY_1	Parámetro n = 6, w = 2, C = 0.01.
14	FUZZY_2	Parámetro n = 10, w = 2, C = 0.01, Lags = 52 (52x24). Nota: Se decidió con la métrica de error MAE.
15	HW	Calibración por fuerza bruta de los 3 parámetros.

A partir de los resultados de las actividades realizadas hasta ese momento, se decidió que el muestreo a utilizarse sería por clasificación/segmentación de los nodos por mesoregión usando una confiabilidad del 90 % y un error del 10 % debido a que los cálculos estimados para procesar toda la muestra sería de un mes completo de procesamiento máquina (ver Anexo E). Por lo tanto, se procedió a preparar la consulta SQL (ver Anexo D – Q31) para generar el archivo de tipo CSV, que se nombró *2-Datos.Maestros.Muestreo.Depurados.Final.csv*, de datos maes-

tros de los nodos donde se descartaron aquellos nodos que tenían información incompleta a partir de análisis que se realizó con el archivo *1-Analisis_Datos_Maestros_Nodos_Agosto_Muestreo.xlsx* que tomaba como fuente de información el listado completo de los nodos del archivo *0-Datos_Maestros_Nodos_Agosto_Muestreo.csv*.

Como siguiente paso, se modificó el script de R, *Muestreo_Nodos_Reg_MesoReg_Final.R*, agregando la funcionalidad para generar, en función de los parámetros elegidos, el archivo de tipo CSV, el cual se nombró *Nodos_Muestreo_MesoRegion_90_10.csv*. Éste contenía la selección aleatoria de los nodos por mesoregión que se procesarían posteriormente con todos los modelos y poder, a continuación, analizar los resultados y obtener las conclusiones del trabajo de investigación. Luego, se generaron las consultas SQL (ver Anexo D – Q32) para generar los archivos CSV por cada nodo seleccionado con el script de muestreo.

Finalmente, se generaron los siguientes scripts de R que se utilizaron en el procesamiento de los modelos (Tabla 4-8).

Tabla 4-8.: Scripts para procesar los modelos

Nombre	Tipo	Objetivo
1-Procesar_Estadisticas.Rmd	Rmarkdown	Plantilla para visualizar la información estadística del nodo y con la cual se genera un archivo HTML con los resultados.
2-Procesar_Forecast_All.Rmd	Rmarkdown	Plantilla que registra los resultados del nodo con los técnicas aplicadas en el modelo Forecast_All y y con la cual se genera un archivo HTML con los resultados.
2-Procesar_Forecast_Day1.Rmd	Rmarkdown	Plantilla que registra los resultados del nodo con los técnicas aplicadas en el modelo Forecast_Day1 y y con la cual se genera un archivo HTML con los resultados.
2-Procesar_Forecast_Day2.Rmd	Rmarkdown	Plantilla que registra los resultados del nodo con los técnicas aplicadas en el modelo Forecast_Day2 y con la cual se genera un archivo HTML con los resultados.
2-Procesar_Forecast_DayHour1.Rmd	Rmarkdown	Plantilla que registra los resultados del nodo con los técnicas aplicadas en el modelo Forecast_DayHour1 y con la cual se genera un archivo HTML con los resultados.
2-Procesar_Forecast_DayHour2.Rmd	Rmarkdown	Plantilla que registra los resultados del nodo con los técnicas aplicadas en el modelo Forecast_DayHour2 y con la cual se genera un archivo HTML con los resultados.
Control_Proceso_Estadisticas.R	Script R	Script de control para procesar todos los nodos muestreados con la plantilla 1-Procesar_Estadisticas.Rmd.

Nombre	Tipo	Objetivo
Control_Proceso_Forecast_ALL.R	Script R	Script de control para procesar todos los nodos muestreados con la plantilla 2-Procesar_Forecast_All.Rmd.
Control_Proceso_Forecast_Day1.R	Script R	Script de control para procesar todos los nodos muestreados con la plantilla 2-Procesar_Forecast_Day1.Rmd.
Control_Proceso_Forecast_Day2.R	Script R	Script de control para procesar todos los nodos muestreados con la plantilla 2-Procesar_Forecast_Day2.Rmd.
Control_Proceso_Forecast_DayHour1.R	Script R	Script de control para procesar todos los nodos muestreados con la plantilla 2-Procesar_Forecast_DayHour1.Rmd.
Control_Proceso_Forecast_DayHour2.R	Script R	Script de control para procesar todos los nodos muestreados con la plantilla 2-Procesar_Forecast_DayHour2.Rmd.

La plantilla *1-Procesar_Estadisticas.Rmd* se utilizó para procesar la siguiente información de cada nodo (Tabla 4-9).

Tabla 4-9.: Detalle plantilla 1-Procesar_Estadisticas.Rmd

#	Sección	Descripción
		Para los campos fecha , año , mes , día , período , día semana y precio del <i>dataset</i> histórico de precios de cada nodo calcula los siguientes valores:
1	Información de estadísticas básicas	– Valor mínimo. – Valor del primer cuartil. – Valor de la mediana. – Valor del promedio. – Valor del tercer cuartil. – Valor máximo.
		Los resultados se presentan en formato tabla.

#	Sección	Descripción
		Calcula por cada período las siguientes métricas:
		– Cantidad de registros. – Valor mínimo del precio. – Valor máximo del precio. – Valor promedio del precio. – Valor de la mediana del precio. – Valor de la desviación estándar del precio. – Valor del coeficiente de variación del precio.
2	Información de estadísticas detalladas (antes de la limpieza del <i>dataset</i>)	Los resultados se presentan en formato tabla. Con esta información se procede a hacer la limpieza del <i>dataset</i> con las siguientes consideraciones: – Los registros de los años bisiestos serán eliminados. – Los registros de las horas 25 de los solsticios de veranos serán eliminados. – Los registros de las horas 24 de los solsticios de invierno serán creados. Este registro se calcula a partir del promedio de la hora 23 de ese día y la hora 1 del día siguiente. En caso, que no existe registro de la hora 1 del siguiente día, el algoritmo repite el valor de la hora 23 de ese día. – Se entiende por registros incompletos o con error aquellos que tengan menos o mas de 24 horas por día.
3	Análisis del <i>dataset</i> que detecta los registros relacionados con el año bisiesto, el solsticio de invierno, el solsticio de verano y registros incompletos.	Los hallazgos se presentan en formato tabla. Calcula por cada período las siguientes métricas: – Cantidad de registros. – Valor mínimo del precio. – Valor máximo del precio. – Valor promedio del precio. – Valor de la mediana del precio. – Valor de la desviación estándar del precio. – Valor del coeficiente de variación del precio.
4	Información de estadísticas detalladas (después de la limpieza del <i>dataset</i>)	Se resultados se presentan en formato tabla.

#	Sección	Descripción
		Se grafican los siguientes gráficos con el objetivo de revisar la calidad de datos del campo año :
5	Análisis del campo año	– Gráfico de barras de la cantidad registros por año. – Gráfico de barras de la cantidad de horas por años.
		Se grafican los siguientes gráficos con el objetivo de revisar la calidad de datos del campo mes :
6	Análisis del campo mes	– Gráfico de barras de la cantidad de registros por mes y por año. – Gráfico de barras de la cantidad de días por mes y por año. – Gráfico de barras de cantidad de horas por mes y por año.
		Se grafican los siguientes gráficos con el objetivo de revisar la calidad de datos del campo día :
7	Análisis del campo día	– Gráfico de barras de la cantidad de registros por día por año. – Gráfico de barras de la cantidad de horas por día en el mes. Se hace un gráfico por mes.
		Se grafican los siguientes gráficos con el objetivo de revisar la calidad de datos del campo día de la semana :
8	Análisis del campo día de la semana	– Gráfico de barras de la cantidad de registros por día de la semana por año.
		Se grafican los siguientes gráficos con el objetivo de revisar la calidad de datos del campo precio :
9	Análisis del campo precio	– Gráfico histograma. – Gráfico histograma con curva distribución normal.
10	Valores atípicos	Se grafica el gráfico boxplot y se determina si hay valores atípicos.
11	Test de <i>Augmented Dickey Fuller</i>	Se realiza el test de <i>Augmented Dickey Fuller</i> .
12	Test de normalidad	Se valida si los datos del precio siguen una distribución normal, para ello se utiliza el test de <i>Anderson Darling Normality Test</i> .
13	Visualización serie de tiempo	Se grafica la serie de tiempo utilizando los valores del precio.

La plantilla *2-Procesar_Forecast_All.Rmd* se utilizó para pronosticar con todas las técnicas seleccionadas y tomando la serie de datos de precios del nodo sin descomponer. Los resultados que presenta son los siguientes:

- Tabla resultados de entrenamiento: muestra los valores pronosticados de precio para las 48 hs. por cada técnica al momento de entrenar cada modelo.
- Tabla de errores de entrenamiento: muestra los valores de las matrices de error RMSE, MAE y MAPE por cada técnica que se obtuvo producto del entrenamiento de los modelos.
- Gráfico comparación historia vs pronosticado: muestra la serie de tiempo del precio del nodo según valores históricos vs los precios pronosticados por todas técnicas durante el entrenamiento.
- Tabla de pronósticos: muestra los 48 valores pronosticados a partir de toda la historia utilizando sólo la técnica que menor error tuvo en el entrenamiento.
- Gráfico comparación historia vs el mejor pronóstico: muestra la serie de tiempo del precio histórico del nodo vs el precio pronosticado por la mejor técnica de acuerdo al menor error de entrenamiento.
- Tabla mejor pronóstico: muestra cuál fue la mejor técnica para cada métrica de error.

La plantilla *2-Procesar_Forecast_Day1.Rmd* se utilizó para pronosticar con todas las técnicas seleccionadas y descomponiendo la serie de datos de precios en tipo de día. Los resultados que presenta son los siguientes:

- Tabla resultados de entrenamiento: muestra los valores pronosticados de precio para las 48 hs por cada técnicas al momento de entrenar cada modelo.
- Tabla de errores de entrenamiento: muestra los valores de las matrices de error RMSE, MAE y MAPE por cada técnicas que se obtuvo producto del entrenamiento de los modelos.
- Gráfico comparación historia vs pronosticado: muestra la serie de tiempo del precio del nodo según valores históricos vs los precios pronosticados por todas técnicas durante el entrenamiento.
- Tabla de pronósticos: muestra los 48 valores pronosticados a partir de toda la historia utilizando solo la técnica que menor error tuvo en el entrenamiento.
- Gráfico comparación historia vs el mejor pronóstico: muestra la serie de tiempo del precio histórico del nodo vs el precio pronosticado por la mejor técnica de acuerdo al menor error de entrenamiento.
- Tabla mejor pronóstico: muestra cual fue la mejor técnica para cada métrica de error.

La plantilla *2-Procesar_Forecast_Day2.Rmd* se utilizó para pronosticar con el modelo híbrido propuesto y descomponiendo la serie de datos de precios en tipo de día. Los resultados que presenta son los siguientes:

- Tabla resultados de entrenamiento: muestra los valores pronosticados de precio para las 48 hs. por cada técnica al momento de entrenar cada modelo.

- Tabla de errores de entrenamiento: muestra los valores de las matrices de error RMSE, MAE y MAPE por cada técnica que se obtuvo producto del entrenamiento de los modelos.
- Gráfico comparación historia vs pronosticado: muestra la serie de tiempo del precio del nodo según valores históricos vs los precios pronosticados por todas técnicas durante el entrenamiento.
- Tabla de pronósticos: muestra los 48 valores pronosticados a partir de toda la historia utilizando sólo la técnica que menor error tuvo en el entrenamiento.
- Gráfico comparación historia vs el mejor pronóstico: muestra la serie de tiempo del precio histórico del nodo vs el precio pronosticado por la mejor técnica de acuerdo al menor error de entrenamiento.
- Tabla mejor pronóstico: muestra cual fue la mejor técnica para cada día para cada métrica de error.

La plantilla *2-Procesar_Forecast_DayHour1.Rmd* se utilizó para pronosticar con todas las técnicas seleccionadas y descomponiendo la serie de datos de precios en tipo de día y hora. Los resultados que presenta son los siguientes:

- Tabla resultados de entrenamiento: muestra los valores pronosticados de precio para las 48 hs por cada técnica al momento de entrenar cada modelo.
- Tabla de errores de entrenamiento: muestra los valores de las matrices de error RMSE, MAE y MAPE por cada técnica que se obtuvo producto del entrenamiento de los modelos.
- Gráfico comparación historia vs pronosticado: muestra la serie de tiempo del precio del nodo según valores históricos vs los precios pronosticados por todas técnicas durante el entrenamiento.
- Tabla de pronósticos: muestra los 48 valores pronosticados a partir de toda la historia utilizando sólo la técnica que menor error tuvo en el entrenamiento.
- Gráfico comparación historia vs el mejor pronóstico: muestra la serie de tiempo del precio histórico del nodo vs el precio pronosticado por la mejor técnica de acuerdo al menor error de entrenamiento.
- Tabla mejor pronóstico: muestra cual fue la mejor técnica para cada métrica de error.

La plantilla *2-Procesar_Forecast_DayHour2.Rmd* se utilizó para pronosticar con el modelo híbrido propuesto y descomponiendo la serie de datos de precios en tipo día y hora. Los resultados que presenta son los siguientes:

- Tabla resultados de entrenamiento: muestra los valores pronosticados de precio para las 48 hs por cada técnicas al momento de entrenar cada modelo.
- Tabla de errores de entrenamiento: muestra los valores de las métricas de error RMSE,

MAE y MAPE por cada técnicas que se obtuvo producto del entrenamiento de los modelos.

- Gráfico comparación historia vs pronosticado: muestra la serie de tiempo del precio del nodo según valores históricos vs los precios pronosticados por todas técnicas durante el entrenamiento.
- Tabla de pronósticos: muestra los 48 valores pronosticados a partir de toda la historia utilizando solo la técnica que menor error tuvo en el entrenamiento.
- Gráfico comparación historia vs el mejor pronóstico: muestra la serie de tiempo del precio histórico del nodo vs el precio pronosticado por la mejor técnica de acuerdo al menor error de entrenamiento.
- Tabla mejor pronóstico: muestra cual fue la mejor técnica para cada hora de día para cada métrica de error.

Fase - Evaluación del modelo

Culminado el procesamiento de los modelos, se procesaron y analizaron los resultados obtenidos en la actividad anterior. Para ello se desarrollaron los siguientes scripts (Tabla 4-10).

Tabla 4-10.: Scripts de procesamientos de resultados de los modelos

Nombre	Tipo	Objetivo
Control_Proceso_Result_Forecast_ALL.R	Script R	Script que procesó todos los resultados individuales obtenidos por el script <i>Control_Proceso_Forecast_ALL.R</i> y los consolidó en un archivo tipo Rdata.
Control_Proceso_Result_Forecast_Day1.R	Script R	Script que procesó todos los resultados individuales obtenidos por el script <i>Control_Proceso_Forecast_Day1.R</i> y los consolidó en un archivo tipo Rdata.
Control_Proceso_Result_Forecast_Day2.R	Script R	Script que procesó todos los resultados individuales obtenidos por el script <i>Control_Proceso_Forecast_Day2.R</i> y los consolidó en un archivo tipo Rdata.
Control_Proceso_Result_Forecast_DayHour1.R	Script R	Script que procesó todos los resultados individuales obtenidos por el script <i>Control_Proceso_Forecast_DayHour1.R</i> y los consolidó en un archivo tipo Rdata.
Control_Proceso_Result_Forecast_DayHour2.R	Script R	Script que procesó todos los resultados individuales obtenidos por el script <i>Control_Proceso_Forecast_DayHour2.R</i> y los consolidó en un archivo tipo Rdata.
Control_Proceso_Result_Forecast_All_Model.R	Script R	Script que consolidó todos archivos de tipo Rdata de todos los resultados de todos los modelos y generó los archivos de tipo CSV.

Nombre	Tipo	Objetivo
Procesar_Resultados_Finales_v1.Rmd	Rmarkdown	Script que procesó información y presentó los resultados finales con los cuales se realizó el análisis final de los modelos y los presenta en formato HTML.
Resultados_Finales_v1.xlsx	Excel	Archivo que contiene las métricas calculadas y utilizadas para sacar las conclusiones del trabajo de investigación.

La plantilla *Procesar_Resultados_Finales_v1.Rmd* se utilizó para consolidar, procesar y presentar todos los resultados obtenidos en los 5 modelos de la siguiente forma:

Primero se presenta los resultados por modelo, por mesoregión y por técnica:

- Gráfico de distribución de la métrica de error RMSE.
- Gráfico boxplot de la métrica de error RMSE.
- Gráfico de distribución de la métrica de error MAE.
- Gráfico boxplot de la métrica de error MAE.
- Gráfico de distribución de la métrica de error MAPE.
- Gráfico boxplot de la métrica de error MAPE.
- Gráfico de distribución de la métrica de tiempo de ejecución del modelo.
- Tabla resumen con las siguientes métricas estadísticas:
 - Cantidad de nodos.
 - Cantidad de valores atípicos de la métrica (RMSE, MAE, MAPE y Duración).
 - Valor mínimo de la métrica (RMSE, MAE, MAPE y Duración).
 - Valor máximo de la métrica (RMSE, MAE, MAPE y Duración).
 - Valor promedio de la métrica (RMSE, MAE, MAPE y Duración).
 - Valor de la mediana de la métrica (RMSE, MAE, MAPE y Duración).
 - Valor de la varianza de la métrica (RMSE, MAE, MAPE y Duración).
 - Valor de la desviación estándar de la métrica (RMSE, MAE, MAPE y Duración).
 - Valor del coeficiente de la variación porcentual de la métrica (RMSE, MAE, MAPE y Duración).
 - Valor del error estándar de la de la métrica (RMSE, MAE, MAPE y Duración).

Por último se presenta los resultados por modelo y por técnicas:

- Gráfico de distribución de la métrica de error RMSE.
- Gráfico boxplot de la métrica de error RMSE.
- Gráfico de distribución de la métrica de error MAE.

- Gráfico boxplot de la métrica de error MAE.
- Gráfico de distribución de la métrica de error MAPE.
- Gráfico boxplot de la métrica de error MAPE.
- Gráfico de distribución de la métrica de tiempo de ejecución del modelo.
- Tabla resumen con las siguientes métricas estadísticas:
 - Cantidad de nodos.
 - Cantidad de valores atípicos de la métrica (RMSE, MAE, MAPE y Duración).
 - Valor mínimo de la métrica (RMSE, MAE, MAPE y Duración).
 - Valor máximo de la métrica (RMSE, MAE, MAPE y Duración).
 - Valor promedio de la métrica (RMSE, MAE, MAPE y Duración).
 - Valor de la mediana de la métrica (RMSE, MAE, MAPE y Duración).
 - Valor de la varianza de la métrica (RMSE, MAE, MAPE y Duración).
 - Valor de la desviación estándar de la métrica (RMSE, MAE, MAPE y Duración).
 - Valor del coeficiente de la variación porcentual de la métrica (RMSE, MAE, MAPE y Duración).
 - Valor del error estándar de la de la métrica (RMSE, MAE, MAPE y Duración).

Con los resultados obtenidos se procedió construir el Excel *Resultados_Finales.v1.xlsx*, extrayendo la siguiente información:

- Modelo, donde se usaron los valores:
 - Forecast_All.
 - Forecast_Day1.
 - Forecast_Day2.
 - Forecast_DayHour1.
 - Forecast_DayHour2.
- Mesoregión, donde se usaron los valores:
 - 0.
 - Centro Occidente.
 - Centro País.
 - Noreste.
 - Noroeste.
 - Sur Sureste.
 - No aplica.

- Técnica, donde se usaron los valores:
 - ARIMA.
 - ETS.
 - FUZZY_1.
 - FUZZY_2.
 - HW.
 - Hybrid.
 - KNN.
 - LM.
 - MEAN_3.
 - MEAN_6.
 - MEAN_9.
 - MEAN_12.
 - NNET.
 - NNETAR.
 - SVM_1.
 - SVM_2.
- Métrica, donde se usaron los valores:
 - RMSE.
 - MAE.
 - MAPE.
 - Duración.
- Cantidad total de nodos: valor determinado a través de la cantidad de nodos por el valor del campo mesoregión.
- Valores atípicos: valor obtenido a través de las gráficas de boxplot de cada métrica.
- Cantidad de nodos métrica: se diligenció sumando la cantidad de nodos de las 2 barras más altas más cercanas al eje izquierdo de la gráfica utilizando el histograma según la métrica. (ver Figura 4-2 como referencia)
- Rango métrica: se diligenció usando el valor mínimo y máximo de las 2 barras más altas mas cercanas al eje izquierdo de la gráfica de distribución según la métrica y se usa el patrón: Min-Max. (ver 4-2 como referencia)
- Inferior: valor inferior derivado del campo rango métrica.
- Superior: valor superior derivado del campo rango métrica.

- Rango: valor calculado a partir de la siguiente fórmula: Superior - Inferior.
- % Representación: valor calculado a partir de la siguiente fórmula: Cantidad de nodos métrica / Cantidad total de nodos * 100.
- % Representación atípicos: valor calculado a partir de la siguiente fórmula: Valores atípicos / Cantidad total de nodos * 100.
- Valor mínimo: valor mínimo de la métrica.
- Valor máximo: valor máximo de la métrica.
- Diferencia: valor calculado a partir de la fórmula: Valor máximo – Valor mínimo.
- Promedio: valor promedio de la métrica.
- Mediana: valor de la mediana de la métrica.
- Varianza: valor de la varianza de la métrica.
- Desviación estándar, valor de la desviación estándar de la métrica.
- Coeficiente de variación: valor del coeficiente de variación de la métrica.
- Error estándar: error estándar de la métrica.




Figura 4-2.: Gráfico histograma de referencia

Como siguiente actividad, se procedió a analizar el archivo *Resultados.Finales_v1.xlsx* con el objetivo de obtener los resultados de la investigación. Los mismos fueron registrados en el archivo Excel *Analisis.Resultados_v1.xlsx* donde para la comparación y elección de la mejor técnica se compararon principalmente la mejor combinación de las métricas: inferior, superior, rango, % representación, mínimo, máximo, diferencia, mediana, promedio y la desviación

estándar.

Finalmente, se realizó una reunión con los especialistas de MVM, quienes expresaron que tanto los resultados como los hallazgos y conclusiones del trabajo cumplían y aun superaban sus expectativas y objetivos iniciales.

5. Resultados

5.1. Introducción

En el presente capítulo se presentan los resultados obtenidos como producto del desarrollo de trabajo de investigación.

5.2. Resultados

A continuación, se detallan los resultados obtenidos, que constó de 42 análisis con el fin de poder concluir cuál resulta ser el mejor modelo final en general.

Primero se analizaron los resultados por modelo, para los modelos Forecast_All, Forecast_Day1 y Forecast_DayHour1, y por mesoregión para todas las técnicas empleadas con el fin de determinar cuáles fueron las 2 mejores técnicas por métrica de error RMSE, MAE y MAPE. El 1 que acompaña a la métrica de error indica la técnica con el menor error para cada una de ellas y el 2, la que le sigue. Posteriormente, se determinaron la primera (Best1) y segunda (Best2) técnicas reconociendo entre todas ellas (RMSE1, RMSE2, MAE1, MAE2, MAPE1 y MAPE2) las técnicas más recurrente de acuerdo a su ranking. Para la comparación y elección de la mejor técnica se compararon principalmente la mejor combinación de las métricas: inferior, superior, rango, % representación, mínimo, máximo, diferencia, mediana, promedio y la desviación estándar. Estos criterios se aplicaron en todos los análisis realizados para obtener los resultados expuestos en este capítulo.

La Tabla **5-1** presenta los 6 análisis para el modelo Forecast_All, donde se puede confirmar que la técnica HW es la mejor opción para todas las mesoregiones y como segunda opción, se tiene la técnica ARIMA para la mayoría de las mesoregiones.

Tabla 5-1.: Resultados modelo Forecast_All por mesoregión

#	Mesoregión	RMSE1	RMSE2	MAE1	MAE2	MAPE1	MAPE2	Best1	Best2
1	0	NNETAR	ARIMA	HW	SVM.2	HW	ARIMA	HW	ARIMA
2	Centro Occidente	HW	ARIMA	HW	SVM.2	HW	ARIMA	HW	ARIMA
3	Centro País	HW	NNET	HW	SVM.2	HW	LM	HW	NNET SVM.2 LM

#	Mesoregión	RMSE1	RMSE2	MAE1	MAE2	MAPE1	MAPE2	Best1	Best2
4	Noreste	HW	ARIMA	HW	SVM_2	HW	NNETAR	HW	ARIMA SVM_2 NNETAR
5	Noroeste	HW	ARIMA	HW	ARIMA	NNETAR	HW	HW	ARIMA
6	Sur Sureste	HW	NNET	HW	NNET	HW	LM	HW	NNET

Además, se analizó la métrica de performance de la técnica (duración) para las mejores técnicas del modelo Forecast_All como muestra la Tabla 5-2.

Tabla 5-2.: Tiempos ejecución de las mejores técnicas del modelo Forecast_All por mesoregion

#	Técnica	Duración (Segundos)
1	ARIMA	4,49
	HW	12,60
2	ARIMA	4,04
	HW	48,25
	HW	53,05
3	NNET	61,14
	SVM_2	1479,37
	LM	2917,09
	ARIMA	5,17
4	HW	49,87
	NNETAR	688,67
	SVM_2	1330,96
5	ARIMA	4,62
	HW	46,61
6	HW	41,81
	NNET	46,88

Del análisis de los tiempos se puede ver que el menor tiempo de duración corresponde al modelo de la técnica ARIMA, seguido de HW.

La Tabla 5-3 presenta los 6 análisis para el modelo Forecast_Day1, donde se puede confirmar que la técnica LM es la mejor opción para la mayoría de las mesoregiones y como segunda opción se tiene la técnica HW para la mayoría de las mesoregiones.

Tabla 5-3.: Resultados modelo Forecast_Day1 por mesoregión

#	Mesoregión	RMSE1	RMSE2	MAE1	MAE2	MAPE1	MAPE2	Best1	Best2
7	0	HW	NNET	NNETAR	HW	NNETAR	HW	NNETAR	HW
8	Centro Occidente	LM	HW	LM	HW	LM	HW	LM	HW
9	Centro País	LM	NNET	LM	NNET	LM	NNET	LM	NNET
10	Noreste	LM	HW	LM	HW	LM	HW	LM	HW
11	Noroeste	SVM_2	HW	SVM_2	HW	SVM_2	HW	SVM_2	HW
12	Sur Sureste	LM	NNET	LM	HW	LM	HW	LM	HW

Además, se analizó la métrica de performance de la técnica (duración) para las mejores técnicas del modelo Forecast_Day1 como muestra la Tabla 5-4.

Tabla 5-4.: Tiempos ejecución de las mejores técnicas del modelo Forecast_Day1 por mesoregión

#	Técnica	Duración (Segundos)
7	HW	9,29
	NNETAR	26,31
8	HW	14,73
	LM	18,13
9	LM	18,30
	NNET	45,79
10	HW	15,14
	LM	18,30
11	HW	11,98
	SVM.2	22,24
12	HW	9,54
	LM	14,72

Del análisis de los tiempos se puede ver que el menor tiempo de duración corresponde al modelo de la técnica HW, seguido de LM.

La Tabla 5-5 presenta los 6 análisis para el modelo Forecast_DayHour1, donde se puede confirmar que la técnica HW es la mejor opción para todas las mesoregiones y como segunda opción se tiene la técnica Mean_6 para la mayoría de las mesoregiones.

Tabla 5-5.: Resultados modelo Forecast_DayHour1 por mesoregión

#	Mesoregión	RMSE1	RMSE2	MAE1	MAE2	MAPE1	MAPE2	Best1	Best2
13	0	HW	ARIMA	HW	ARIMA	HW	ETS	HW	ARIMA
14	Centro Occidente	HW	Mean_6	HW	Mean_6	HW	Mean_6	HW	Mean_6
15	Centro País	HW	LM	HW	Mean_6	HW	Mean_6	HW	Mean_6
16	Noreste	HW	LM	HW	LM	HW	LM	HW	LM
17	Noroeste	HW	Mean_6	HW	Mean_6	HW	Mean_6	HW	Mean_6
18	Sur Sureste	HW	Mean_6	HW	Mean_6	HW	Mean_6	HW	Mean_6

Además, se analizó la métrica de performance de la técnica (duración) para las mejores técnicas del modelo Forecast_Day1 como muestra la Tabla 5-6.

Tabla 5-6.: Tiempos ejecución de las mejores técnicas del modelo Forecast_DayHour1 por mesoregión

#	Técnica	Duración (Segundos)
13	ARIMA	2,77
	HW	37,76
14	Mean_6	0,19
	HW	51,62
15	Mean_6	0,19

#	Técnica	Duración (Segundos)
16	HW	53,82
	LM	0,40
	HW	52,50
17	Mean_6	0,19
	HW	53,78
18	Mean_6	0,21
	HW	54,22

Del análisis de los tiempos se puede ver que el menor tiempo de duración corresponde al modelo de la técnica Mean_6, seguido de ARIMA.

Como segunda actividad, se compararon las 2 mejores técnicas para los modelos Forecast_Day1 y Forecast_DayHour1 contra los resultados de la técnica híbrida de los modelos Forecast_Day2 y Forecast_DayHour2 y se encontró en ambos casos que el modelo híbrido fue superior para todas las mesoregiones como lo muestran las Tablas 5-7 y 5-8.

Tabla 5-7.: Resultados modelo Forecast_Day1 vs Forecast_Day2 por mesoregión

#	Mesoregión	RMSE1	RMSE2	MAE1	MAE2	MAPE1	MAPE2	Best1	Best2
19	0	Hybrid	HW	Hybrid	NNETAR	Hybrid	NNETAR	Hybrid	NNETAR
20	Centro Occidente	Hybrid	LM	Hybrid	LM	Hybrid	LM	Hybrid	LM
21	Centro País	Hybrid	LM	Hybrid	LM	Hybrid	LM	Hybrid	LM
22	Noreste	Hybrid	LM	Hybrid	LM	Hybrid	LM	Hybrid	LM
23	Noroeste	Hybrid	SVM.2	Hybrid	SVM.2	Hybrid	SVM.2	Hybrid	SVM.2
24	Sur Sureste	Hybrid	LM	Hybrid	LM	Hybrid	LM	Hybrid	LM

Tabla 5-8.: Resultados modelo Forecast_DayHour1 vs Forecast_DayHour2 por mesoregión

#	Mesoregión	RMSE1	RMSE2	MAE1	MAE2	MAPE1	MAPE2	Best1	Best2
25	0	Hybrid	HW	Hybrid	HW	Hybrid	HW	Hybrid	HW
26	Centro Occidente	Hybrid	HW	Hybrid	HW	Hybrid	HW	Hybrid	HW
27	Centro País	Hybrid	HW	Hybrid	HW	Hybrid	HW	Hybrid	HW
28	Noreste	Hybrid	HW	Hybrid	HW	Hybrid	HW	Hybrid	HW
29	Noroeste	Hybrid	HW	Hybrid	HW	Hybrid	HW	Hybrid	HW
30	Sur Sureste	Hybrid	HW	Hybrid	HW	Hybrid	HW	Hybrid	HW

También, se analizó la métrica de performance de la técnica (duración) para ambas comparaciones de modelos como indican las Tablas 5-9 y 5-10.

Tabla 5-9.: Tiempos ejecución de las mejores técnicas del modelo Forecast_Day1 vs Forecast_Day2 por mesoregión

#	Técnica	Duración (Segundos)
19	NNETAR	21,22
	HW	8,89

#	Técnica	Duración (Segundos)
20	Hybrid RMSE	8,64
	Hybrid MAE	8,73
	Hybrid MAPE	10,44
	LM	18,13
	HW	14,73
	Hybrid RMSE	16,48
	Hybrid MAE	16,9
	Hybrid MAPE	17,01
	LM	18,3
	NNET	45,79
	Hybrid RMSE	9,95
	Hybrid MAE	10,79
21	Hybrid MAPE	10,79
	LM	18,3
	HW	15,14
	Hybrid RMSE	12,39
	Hybrid MAE	13,57
	Hybrid MAPE	13,99
22	SVM.2	22,24
	HW	11,98
	Hybrid RMSE	32,47
	Hybrid MAE	17,86
	Hybrid MAPE	13,86
	LM	14,72
23	NNET	26,97
	HW	9,54
	Hybrid RMSE	13,36
	Hybrid MAE	14,68
	Hybrid MAPE	15,44
	LM	18,3

Del análisis de los tiempos se puede ver que el menor tiempo de duración corresponde al modelo de la técnica híbrido, seguido de HW.

Tabla 5-10.: Tiempos ejecución de las mejores técnicas del modelo Forecast_DayHour1 vs Forecast_DayHour2 por mesoregión

#	Técnica	Duración (Segundos)
25	ARIMA	2,77
	ETS	0,64
	HW	37,76
	Hybrid RMSE	24,28
	Hybrid MAE	24,28
	Hybrid MAPE	24,28
	Mean_6	0,19
	HW	51,62
26	Hybrid RMSE	13,65
	Hybrid MAE	13,65

#	Técnica	Duración (Segundos)
27	Hybrid MAPE	13,65
	Mean_6	0,19
	LM	0,43
	HW	53,82
	Hybrid RMSE	10,29
	Hybrid MAE	10,29
	Hybrid MAPE	10,29
28	LM	0,40
	HW	52,50
	Hybrid RMSE	18,27
	Hybrid MAE	18,27
	Hybrid MAPE	18,27
29	Mean_6	0,19
	HW	53,78
	Hybrid RMSE	19,68
	Hybrid MAE	19,68
	Hybrid MAPE	19,68
30	Mean_6	0,21
	HW	54,22
	Hybrid RMSE	11,64
	Hybrid MAE	11,64
	Hybrid MAPE	11,64

Del análisis de los tiempos se puede ver que el menor tiempo de duración corresponde al modelo de la técnica Mean_6, seguido de LM.

En la tercera actividad se analizaron de forma global los modelos Forecast_ALL, Forecast_Day1 y Forecast_DayHour1 para obtener las 2 mejores técnicas y su performance como muestran las Tablas 5-11 y 5-12.

Tabla 5-11.: Resultados globales modelo Forecast_All, Forecast_Day1 y Forecast_DayHour1

#	Mesoregión	RMSE1	RMSE2	MAE1	MAE2	MAPE1	MAPE2	Best1	Best2
31	Forecast_All	HW	NNET	HW	SVM_2	HW	LM	HW	NNET SVM_2 LM
32	Forecast_Day1	HW	LM	HW	Mean_6	HW	LM	HW	LM
33	Forecast_DayHour1	HW	Mean_6	HW	Mean_6	HW	Mean_6	HW	Mean_6

Tabla 5-12.: Tiempos ejecución global de las mejores técnicas de los modelos Forecast_All, Forecast_Day1 y Forecast_DayHour1

#	Técnica	Duración (Segundos)
31	LM	2975,11
	NNET	327,79
	SVM_2	1955,74

#	Técnica	Duración (Segundos)
32	HW	49,10
	LM	16,02
	HW	13,10
33	Mean_6	0,19
	HW	52,14

Del análisis de los tiempos se puede ver que el menor tiempo de duración corresponde al modelo de la técnica Mean_6, seguido de HW.

Como cuarta actividad, teniendo los resultados de la actividad 2 se compararon las mejores técnicas de los modelos Forecast_Day1 y Forecast_DayHour1 contra Forecast_Day2 y Forecast_DayHour2 respectivamente, tanto en resultados como en performance, como se muestra en la Tablas 5-13 y 5-14.

Tabla 5-13.: Resultados globales modelos

#	Modelo	RMSE1	RMSE2	MAE1	MAE2	MAPE1	MAPE2	Best1	Best2
34	Forecast_Day1								
	Vs	Hybrid	HW	Hybrid	HW	Hybrid	HW	Hybrid	HW
	Forecast_Day2								
35	Forecast_DayHour1								
	Vs	Hybrid	HW	Hybrid	HW	Hybrid	HW	Hybrid	HW
	Forecast_DayHour2								

Tabla 5-14.: Tiempos ejecución global de las mejores técnicas de los modelo

#	Técnica	Duración (Segundos)
34	HW	13,1
	Hybrid RMSE	16,87
	Hybrid MAE	14,99
	Hybrid MAPE	14,53
35	HW	52,14
	Hybrid RMSE	15,31
	Hybrid MAE	15,31
	Hybrid MAPE	15,31

Del análisis de los tiempos se puede ver que el menor tiempo de duración corresponde al modelo de la técnica HW, seguido de híbrido.

Como última actividad se procedió a determinar cual resulta ser el mejor modelo de todos, clasificados por mesoregión y de forma global. Se encontró de forma contundente que el modelo híbrido Forecast_DayHour2 ocupó el primer lugar y el modelo híbrido Forecast_Day2, el segundo, para todas las métricas de error. En cuanto a los tiempos de ejecución promedio se encontró que eran cercanos, 15,46 segundos y 15,31 segundos respectivamente, es decir, sin superioridad significativa de uno sobre otro.

6. Conclusiones y recomendaciones

6.1. Introducción

En este capítulo final se exponen las conclusiones, recomendaciones y trabajos futuros producto de la realización del trabajo de investigación.

6.2. Conclusiones

A través del desarrollo de la fase 1 donde se revisa el estado del arte se pudo determinar que los modelos o técnicas de pronóstico más utilizados hasta el momento son híbridos, ANN y ARIMA independientemente de si es pronóstico del corto o largo plazo. Dentro de sus características se observa que la mayoría de ellos usan principalmente la variable de consumo de energía eléctrica y, particularmente para el caso del corto plazo cuando se consideran otras variables es la variable temperatura la que se adiciona. En cambio, para largo plazo, las variables incorporadas, por lo general, son las macroeconómicas (GDP, IMP, EXP, POP). Las técnicas de error más usadas para la medición de la precisión de los modelos, en orden creciente, son MAE, RMSE y MAPE. Establecer esta base de conocimiento permitió contar con un punto de partida para el desarrollo de la fase de diseño del modelo de pronóstico del proyecto. La síntesis de esta fase fue expuesta en el artículo de RSL *Revisión sistemática de literatura sobre modelos de pronósticos de consumo de energía eléctrica* fue presentado de forma oral en el *Seminario Internacional de Ciencias de la Computación (SICC 2018)* y seleccionado para su publicación en la Revista Ingenierías Universidad de Medellín.

En su desarrollo, el presente trabajo permitió, a través de sesiones de trabajo con los especialistas de energía y del producto de MVM, identificar los requisitos funcionales y no funcionales requeridos para incluirse en la plataforma de *Energy Suite* y servir de línea base para el desarrollo del diseño del modelo pronósticos.

Posteriormente, se diseñaron 5 modelos de pronósticos para la variable eléctrica, precio marginal local, del mercado eléctrico mexicano para pronosticar las 48 horas siguientes. El modelo Forecast_ALL no descompone la serie de tiempo pero evalúa la mejor de las técnicas analizadas, entre ellas HW, ARIMA, LM, entre otras. Los modelos Forecast_Day1 y Forecast_Day2 descomponen la serie por tipo de día. La diferencia entre ellos es que el primero mide el error global para determinar una técnica mientras que el segundo modelo mide el

error por serie para determinar la mejor técnica. Finalmente, se construyeron los modelos *Forescat_DayHour1* y *Forecast_DayHour2* los cuales descomponen la serie de tiempo por tipo de día y por hora. Estos 2 últimos presentan entre sí las mismas diferencias que los 2 modelos anteriores. Cabe destacar que los modelos *Forecast_Day2* y *Forecast_DayHour2* son los propuestos en el presente trabajo como modelos híbridos porque son capaces tanto de descomponer la serie de datos como de combinar técnicas. Es decir, cuentan con la capacidad de determinar en el momento de entrenamiento, por medio de una métrica de error como MAE, MAPE o RSME, la mejor técnica individual para cada serie y en consecuencia mejorar sustancialmente la precisión de los pronósticos. Los otros 3 son menos precisos por tener determinada la técnica por defecto sin contar como los híbridos con la posibilidad de adaptar su configuración en función de los datos propios de cada nodo. En consecuencia, esta desventaja hace que se vuelvan menos dinámicos frente a los modelos propuestos.

Como paso final de la construcción de los modelos se procedió a ejecutarlos y evaluar los resultados con el fin de determinar el modelo con mejor precisión en su pronóstico y la relación rendimiento/tiempo de ejecución clasificados por mesoregión y de forma global. Donde se encontró de forma contundente que el modelo híbrido *Forecast_DayHour2* ocupó el primer lugar y el modelo híbrido *Forecast_Day2*, el segundo, para todas las métricas de error. En cuanto a los tiempos de ejecución promedio, se encontró que eran cercanos, 15,46 segundos y 15,31 segundos respectivamente, es decir, sin superioridad significativa de uno sobre otro.

Los resultados de los 5 modelos de pronósticos desarrollados fueron presentados a los especialistas de energía y del producto de MVM quienes se mostraron ampliamente satisfechos con los resultados, tanto de precisión como de tiempos de ejecución, del modelo híbrido *Forecast_DayHour2* dada su superioridad con respecto a los demás modelos desarrollados. Por lo tanto, este diseño final quedó aceptado como base para el desarrollo del módulo de pronósticos de la plataforma de *Energy Suite* de MVM.

Adicionalmente, superando los objetivos planteados al inicio de este trabajo de investigación, se pudo establecer una metodología y sus respectivos artefactos para la evaluación de distintos modelos de pronósticos bajo el mismo *set* de datos.

Finalmente, puede concluirse que el objetivo general se ve logrado al haber podido proponer un modelo de pronóstico que puede ser incorporado a futuro a la plataforma de *Energy Suite* de MVM y que permite a los suministradores calificados del MEM de México mejorar su posición competitiva en las operaciones de compra y venta de energía.

6.3. Recomendaciones

Para el desarrollo del módulo/producto de pronósticos que permita incluir las capacidades analíticas a la plataforma *Energy Suite* de MVM se recomienda utilizar el modelo híbrido de descomposición por día y hora (*Forecast_DayHour2*). Con respecto a las técnicas a utilizar

en el modelo híbrido se sugiere tomar solo las 3 mejores de las 15 técnicas con el fin de disminuir el tiempo de procesamiento de pronóstico por nodo. Además, se debe realizar el seguimiento a su efectividad utilizando las métricas MAE, MAPE y RMSE con el fin de ir validando la precisión del modelo. Finalmente, se recomienda que cada 6 meses se ejecute nuevamente la metodología resultante del proyecto de investigación con el objetivo de validar si las técnicas utilizadas en los modelos siguen teniendo los mismos resultados de efectividad o si cambiaron con el fin de proceder a ajustar el modelo de la plataforma *Energy Suite* de MVM.

6.4. Trabajos futuros

Producto del desarrollo del trabajo de investigación se pueden proponer los siguientes trabajos futuros, utilizando la metodología resultante del proyecto. En primer lugar, por ejemplo, validar con otras técnicas o modelos híbridos existentes con el fin encontrar un modelo con mayor precisión. En segundo lugar, se podrían explorar los modelos multivariados. Otras líneas de investigación podrían ser profundizar la calibración de las mejores técnicas halladas o incluso proponer otros modelos descomposición o híbridos y comprobar si las mejores técnicas halladas aplican para los demás días de la semana y sus respectivas horas. Finalmente, se podría realizar el mismo proceso de investigación cambiando la variable de precios marginales locales por otras variables eléctricas como, por ejemplo, consumos de energía con el objeto de contar con otros modelos de pronóstico para la plataforma *Energy Suite* de MVM.

A. Anexo: Necesidades del negocio

Pronóstico de demanda (Suma de la generación)

Es el proceso que se realiza para predecir en el tiempo el valor de la carga total de energía eléctrica, consumos totales incluyendo pérdidas de energía, con el propósito de realizar la planificación óptima de los recursos de generación de distintas tecnologías, requerimientos en redes de transmisión y distribución con el objetivo de buscar el abastecimiento de la energía con el costo óptimo. Este tipo de pronóstico es de interés para todos los participantes del mercado eléctrico y las instituciones que lo involucran.

Para el largo plazo, generalmente se realiza con un horizonte de cinco a diez años y con una granularidad mensual. Esta información se utiliza principalmente para definir los planes de expansión de transmisión, distribución y generación, decisiones de inversión y para la firma de contratos relacionado con el suministro de energía. Para el mediano plazo, se utiliza un horizonte de dos o tres años con una granularidad mensual, esta información también se utiliza para definir y validar la pertinencia de los planes de expansión, planificar la operación del sistema interconectado buscando el mínimo costo de operación de las centrales térmicas, costos de racionamiento y costos de embalses, y para estimar los rangos de los precios de compra y venta de energía.

Para el corto plazo se tienen dos tipos de pronóstico: uno con el horizonte de un año y granularidad semanal y el otro con el horizonte de una semana y con una granularidad horaria. Se usa para determinar la programación de las centrales de generación. Adicionalmente, este pronóstico sirve para dar respuesta a un requerimiento regulatorio que a su vez sirve para estimar los pagos por cargo de potencia en el mercado eléctrico.

Pronóstico de consumos de energía

Es el proceso de predecir el valor de los consumos de energía futuros que contemplan las cargas residenciales, industriales y comerciales con el propósito de planificar la operación óptima de la red y poder determinar los precios de compra y venta de energía. Este tipo de pronóstico es principalmente de interés para los comercializadores, distribuidores de energía, generadores y el operador de red. Para el largo plazo, se utiliza un horizonte de cinco años con una granularidad mensual, generalmente esta información se requiere para planificar la expansión de la red de distribución.

Para el mediano plazo, contempla un horizonte mensual con granularidad diaria, esta información es vital para poder planificar la operación integrada del sistema de interconec-

tado y la operación regional. Además, también sirve como insumo para ayudar a definir la planificación de las compras y ventas de energía en el mercado mayorista.

Para el corto plazo, se realiza con un horizonte diario con una granularidad diaria, esta información se requiere para planificar la operación horaria del sistema interconectado y la operación regional de la red distribución. Por otra parte, también se usa para realizar la planificación de las compras y ventas de energía en el mercado mayorista.

Pronóstico de los precios de compra y venta de energía

Es el proceso de predecir el precio de compra y venta de la energía con el fin de maximizar los beneficios de la organización que utilizará dicha información. Esto es vital principalmente para los comercializadores, generadores y el operador del sistema y del mercado. Dependiendo del país los precios a pronosticar puede ser el precio de energía nacional o precios nodales o precios regionales.

Para el largo y mediano plazo la información pronosticada se utiliza con el propósito de definir las estrategias comerciales e identificar el portafolio y riesgos financieros de las empresas generadoras y comercializadoras.

Para el corto plazo se suelen requerir dos tipos de pronósticos, uno con horizonte mensual y granularidad diaria y el otro con horizonte diario y granularidad horaria con el fin de contar con información para poder negociar la compra y venta de energía, optimizar el portafolio de comercialización y gestionar los riesgos financieros asociados.

Pronóstico de generación

Es el proceso para predecir el comportamiento de las fuentes de energía primaria para poder calcular la producción de energía futura por tipo de tecnología con el fin de disminuir la incertidumbre en la operación de los sistemas eléctricos y en los precios de la energía. Esto aplica para todo tipo de planta de generación, es decir, eólica, solar, hidráulica, térmica y mareomotrices.

Para el largo plazo, con un horizonte de cinco años y mensual. Aplica para todos los participantes del mercado eléctrico y las instituciones que lo involucran para estimar el precio de la energía futura.

Para el mediano plazo, se suele usar un horizonte de dos años y una granularidad mensual, esta información de pronósticos es principalmente por los generadores, comercializados, el estado e inversionistas con el fin de poder estimar la producción de energía, el precio de compra y venta de energía, los ingresos totales entre otros. Para el corto plazo, con un horizonte diario y una granularidad horaria, principalmente los generadores, el operador del sistema, los comercializadores y los distribuidores lo utilizan para determinar la disponibilidad esperada de producción de energía con el fin realizar el cálculo del despacho económico óptimo de los recursos de generación integrados.

Observación: estos horizontes y granularidades pueden variar ligeramente acorde a las leyes

del país.

B. Anexo: Historias de usuario

Tabla B-1.: Historia de Usuario 1


ID HISTORIA DE USUARIO	0001
Historia	Historia de usuario – Pronóstico de precios marginales
Rol	Como empresa comercializadora de energía requiero:
Descripción	poder pronosticar los precios marginales locales en el corto plazo
Resultado	con la finalidad de: contar con información para poder negociar la compra y ventas de energía.
Criterio de aceptación	1. Para el Comercializador crear la consulta en el producto Transaction / Generación Pronósticos. 2. Filtros: ■ Concepto: Precio Marginal Local. ■ Criterio: Nodo Individual, Zona de Carga, Sistema. ■ Elemento. 3. La fuente de datos será tomada de la base de datos del producto que se carga con la información que publica el CENACE. 4. Se pronosticarán 2 días en granularidad horaria. 5. Debe usar varios modelos/técnicas de pronóstico y decidir pronosticar con la mejor en función del menor error. 6. Debe mostrar la matriz de entrenamiento. 7. Debe mostrar la matriz de error por cada técnica. 8. Debe mostrar la matriz con el pronóstico de los nuevos individuos utilizando la mejor técnica. 9. Como salida se tendrán varias pestañas: ■ Debe mostrar la gráfica de la serie de tiempo de los datos históricos. ■ Debe mostrar el entrenamiento por cada técnica utilizar. ■ Debe mostrar la gráfica de la serie de tiempo del pronóstico de los nuevos individuos.
Prioridad	Alta

Prototipo Asociado	
Estado	No iniciado
Estimación (esfuerzo)	3 semanas
Sprint	(Por definir – Fuera del alcance)


Tabla B-2.: Historia de Usuario 2

ID HISTORIA DE USUARIO	0002
Historia	Historia de usuario – Consulta Ventas – Enlace Internacional
Rol	Como empresa generadora de energía requiero:
Descripción	poder consultar el informe de venta enlace internacional
Resultado	con la finalidad de: contar con información generar la oferta de energía.
Criterio de aceptación	1. Para el Generador, crear la consulta en Transaction / Generación documentos / Venta - Enlace internacional. 2. Filtros: ■ Fecha. ■ Enlace Internacional. ■ Flujo. 3. Debe mostrar un dato de referencia que es Spread Base. Es un dato de entrada almacenado en ConceptElements por enlace internacional. Se toma siempre el último disponible para el enlace. Este dato en la consulta es modificable y debe refrescar los valores de la columna que lo utilice. 4. Las columnas del reporte son las siguientes: ■ Período. ■ Capacidad del Enlace: dato de entrada almacenado en ConceptElements con el concepto CAPAENLA. Se toma siempre el último disponible para el enlace internacional. Este último se encuentra marcado en la tabla LoadCenters. ■ Pronóstico Precio Externo: dato de entrada almacenado en ConceptElements con el concepto FOREPRICE. Se toma siempre el último disponible para el enlace. ■ Pronóstico Precio Interno: dato de entrada almacenado en Forecast con el concepto. Se toma siempre el último disponible para el nodo del enlace internacional. Este dato debe salir de la herramienta de pronóstico. ■ Spread: dato calculado como Pronóstico del precio interno menos FOREPRICE. Se señalan con color las celdas correspondientes a los períodos donde la diferencia es mayor o igual al Spread Base. ■ Oferta internacional Energía - Energía: se toman los valores cargados en la tabla ConceptElements para el concepto CANTIDAD para el enlace internacional. Estos valores son horarios para la fecha.

Criterio de aceptación	■ Oferta internacional Energía - Precio: se toman los valores cargados en la tabla ConceptElements para el concepto PRECOFER para el enlace internacional. Estos son horarios para la fecha. ■ Oferta internacional Potencia - Potencia: se toman los valores cargados en la tabla ConceptElements con el concepto CANTPOTE para el enlace internacional. Este es un dato para el día que va en el período 0. ■ Oferta internacional Potencia - Precio: se toma el valor cargado en la tabla ConceptElements con el concepto PRECPOTE para el enlace internacional. Este es un dato para el día que va en el período 0. Se debe calcular para todas las horas con la siguiente fórmula: (Oferta CENACE – Energía / Sumatoria de Oferta CENACE - Energía) * Oferta internacional Potencia – Precio para el día-hora 0. ■ Oferta CENACE - Energía: se toma como base la cantidad de la Oferta Internacional Energía, concepto CANTIDAD, pero puede ser modificado por el usuario. Se debe almacenar con el concepto CANOFEMER. Si se modifica debe recalcular el Precio horario de la potencia y el Precio Energía + potencia. ■ Oferta CENACE - Precio: se toma como base el precio de la Oferta Internacional Energía, concepto PRECOFER, pero puede ser modificado por el usuario. Se debe almacenar con el concepto PREOFEMER. Si se modifica debe recalcular el Precio Energía + Potencia. ■ Oferta CENACE - Precio Energía + potencia: se calcula sumando Precio de Oferta CENACE y Precio oferta Internacional Potencia. Se recalcula con los cambios en los valores que lo integran.
Prioridad	Alta

Prototipo Asociado		
	Estado	No iniciado
	Estimación (esfuerzo)	3 semanas
	Sprint	(Por definir – Fuera del alcance)

C. Anexo: Diagrama relacional base de datos ESCentralRepo



D. Anexo: Consultas SQL Exploración Fuente de Información

Tabla D-1.: Consulta SQL 1

# Query	1	Tiempo Ejecución	00:00:00	# Registros	2604
Objetivo	Consulta la cantidad de elementos de sistema que están cargados en la tabla de datos maestros.				
Consulta	SELECT [ElementId] FROM [Master].[SystemElements];				
Resultado	Se identifica que al momento de ejecutar la consulta se cuentan con 2604 elementos de sistema que están cargados en la tabla de datos maestros.				

Tabla D-2.: Consulta SQL 2

# Query	2	Tiempo Ejecución	00:01:26	# Registros	2600
Objetivo	Consulta la cantidad de elementos de sistema para el tipo de mercado del día en adelante que actualmente tienen registros en la tabla de datos maestros y transaccional de precios. Además, se calcula la cantidad de registros, su fecha inicial y su fecha final de precios que están cargados por elemento de sistema.				
Consulta	SELECT DISTINCT MPL.[ElementId], TV.[Name], TV.[Order], TV.[Description], TY.[Name], TY.[Description], COUNT(MPL.[ElementId]) AS [Cantidad], MIN(MPL.[Date]) AS [FechaInicio], MAX(MPL.[Date]) AS [FechaFin] FROM [Transaction].[MarginalLocalPrice] MPL INNER JOIN [Master].[SystemElements] AS Sy ON MPL.[ElementId] = Sy.[ElementId] INNER JOIN [Master].[TypeValues] AS TV ON Sy.[Type] = TV.[Id] INNER JOIN [Master].[Types] AS TY ON TV.[TypeId] = TY.[Id] WHERE MPL.[MarketType] = 'TMerDiaA'; GROUP BY MPL.[ElementId], TV.[Name], TV.[Order], TV.[Description], TY.[Name], TY.[Description];				
Resultado	Se identifica que al momento de ejecutar la consulta se cuentan con 2600 elementos de sistema que están cargados en las tablas de datos maestros y transaccional de precios para el tipo de mercado del día en adelante.				

Tabla D-3.: Consulta SQL 3

# Query	3	Tiempo Ejecución	00:00:00	# Registros	108
Objetivo	Consulta la cantidad de elementos de sistema de tipo Zona de Carga para el tipo de mercado del día en adelante que están cargados en la tabla de datos maestros y transaccional de precios.				
Consulta	SELECT DISTINCT MPL.[ElementId], TV.[Name], TV.[Order], TV.[Description], TY.[Name], TY.[Description] FROM [Transaction].[MarginalLocalPrice] MPL INNER JOIN [Master].[SystemElements] AS Sy ON MPL.[ElementId] = Sy.[ElementId] INNER JOIN [Master].[TypeValues] AS TV ON Sy.[Type] = TV.[Id] INNER JOIN [Master].[Types] AS TY ON TV.[TypeId] = TY.[Id] WHERE tv.[Id] = 'LoadZon' AND MPL.[MarketType] = 'TMerDiaA';				
Resultado	Se identifica que al momento de ejecutar la consulta se cuentan con 108 elementos de sistema de tipo Zona de Carga que están cargados en las tablas de datos maestros y transaccional de precios para el tipo de mercado del día en adelante.				

Tabla D-4.: Consulta SQL 4

# Query	4	Tiempo Ejecución	00:01:54	# Registros	2492
Objetivo	Consulta la cantidad de elementos de sistema de tipo Nodo para el tipo de mercado del día en adelante que están cargados en la tabla de datos maestros y transaccional de precios.				
Consulta	SELECT DISTINCT MPL.[ElementId], TV.[Name], TV.[Order], TV.[Description], TY.[Name], TY.[Description] FROM [Transaction].[MarginalLocalPrice] MPL INNER JOIN [Master].[SystemElements] AS Sy ON MPL.[ElementId] = Sy.[ElementId] INNER JOIN [Master].[TypeValues] AS TV ON Sy.[Type] = TV.[Id] INNER JOIN [Master].[Types] AS TY ON TV.[TypeId] = TY.[Id] WHERE tv.[Id] = 'ENodoSis' AND MPL.[MarketType] = 'TMerDiaA';				
Resultado	Se identifica que al momento de ejecutar la consulta se cuentan con 2492 elementos de sistema de tipo Nodo que están cargados en las tablas de datos maestros y transaccional de precios para el tipo de mercado del día en adelante.				

Tabla D-5.: Consulta SQL 5

# Query	5	Tiempo Ejecución	00:01:22	# Registros	2600
Objetivo	Consulta la cantidad de elementos del sistema para el tipo de mercado del día en adelante que tienen datos en la tabla transaccional de precios.				
Consulta	SELECT DISTINCT [ElementId] FROM [Transaction].[MarginalLocalPrice] AS MPL WHERE MPL.[MarketType] = 'TMerDiaA';				
Resultado	Se identifica que al momento de ejecutar la consulta se cuentan con 2600 elementos del sistema que están cargados en la tabla transaccional de precios para el tipo de mercado del día en adelante.				

Tabla D-6.: Consulta SQL 6

# Query	6	Tiempo Ejecución	00:00:00	# Registros	2496
Objetivo	Consulta la cantidad de nodos que están cargados en la tabla de datos maestros.				
Consulta	SELECT [NodeId] FROM [Master].[Nodes];				
Resultado	Se identifica que al momento de ejecutar la consulta se cuentan con 2496 nodos que están cargados en la tabla de datos maestros.				

Tabla D-7.: Consulta SQL 7

# Query	7	Tiempo Ejecución	00:00:01	# Registros	2493
Objetivo	Consulta la cantidad de nodos cargados en la tabla de datos maestros y transaccional de precios para el tipo de mercado del día en adelante.				
Consulta	SELECT DISTINCT [NodeId] FROM [Master].[Nodes] AS N INNER JOIN [Transaction].[MarginalLocalPrice] AS M ON N.[NodeId] = M.[ElementId] WHERE M.[MarketType] = 'TMerDiaA';				
Resultado	Se identifica que al momento de ejecutar la consulta se cuentan con 2493 nodos que están cargados en las tablas de datos maestros y transaccional de precios para el tipo de mercado del día en adelante.				

Tabla D-8.: Consulta SQL 8

# Query	8	Tiempo Ejecución	00:01:18	# Registros	2493
Objetivo	Consulta la cantidad de elementos de tipo nodo cargados en la tabla de datos maestros y transaccional de precios para el tipo de mercado del día en adelante.				
Consulta	SELECT DISTINCT [ElementId] FROM [Transaction].[MarginalLocalPrice] AS M INNER JOIN [Master].[Nodes] AS N ON N.[NodeId] = M.[ElementId] WHERE M.[MarketType] = 'TMerDiaA';				
Resultado	Se identifica que al momento de ejecutar la consulta se cuentan con 2493 elementos de sistema de tipo nodo que están cargados en la tabla de datos maestros y transaccional de precios para el tipo de mercado del día en adelante.				

Tabla D-9.: Consulta SQL 9

# Query	9	Tiempo Ejecución	00:00:00	# Registros	2496
Objetivo	Consulta para conocer los datos maestros básicos de los nodos disponibles.				
Consulta	SELECT [NodeId], [Name], [PlaceID], [City], [State], [TransmissionRegion] FROM [Master].[Nodes];				
Resultado	Se obtienen los datos maestros básicos de los 2496 nodos.				

Tabla D-10.: Consulta SQL 10

# Query	10	Tiempo Ejecución	00:00:00	# Registros	2496
Objetivo	Consulta para conocer los datos maestros básicos de los nodos y los de su zona de carga disponibles.				
Consulta	SELECT N.[NodeId], N.[Name], N.[PlaceID], N.[City], N.[State], N.[TransmissionRegion] FROM [Master].[Nodes] AS N INNER JOIN [Master].[LoadZones] AS L ON N.[LZId] = L.[LZId];				
Resultado	Se obtienen los datos maestros básicos y de su zona de carga de los 2496 nodos.				

Tabla D-11.: Consulta SQL 11

# Query	11	Tiempo Ejecución	00:00:00	# Registros	2496
Objetivo	Consulta para conocer los datos maestros básicos de los nodos y los de su zona de carga disponibles.				
Consulta	SELECT N.[NodeId], N.[Name], N.[PlaceID], N.[City], N.[State], N.[TransmissionRegion], L.[Name], L.[StartDate], L.[EndDate] FROM [Master].[Nodes] AS N INNER JOIN [Master].[LoadZones] AS L ON N.[LZId] = L.[LZId] INNER JOIN [Master].[OperationTransmissionZones] AS O ON N.[OTZId] = O.[OTZId];				
Resultado	Se obtienen los datos maestros básicos y de su zona de carga de los 2496 nodos.				

Tabla D-12.: Consulta SQL 12

# Query	12	Tiempo Ejecución	00:00:00	# Registros	2496
Objetivo	Consulta para conocer los datos maestros básicos de los nodos, los de su zona de carga y los de su zona de operación de transmisión disponibles.				
Consulta	SELECT N.[NodeId], N.[Name], N.[PlaceID], N.[City], N.[State], N.[TransmissionRegion], L.[Name], L.[StartDate], L.[EndDate], O.[Name], O.[StartDate], O.[EndDate] FROM [Master].[Nodes] AS N INNER JOIN [Master].[LoadZones] AS L ON N.[LZId] = L.[LZId] INNER JOIN [Master].[OperationTransmissionZones] AS O ON N.[OTZId] = O.[OTZId] INNER JOIN [Master].[DistributionZones] AS D ON N.[DZId] = D.[DZId];				
Resultado	Se obtienen los datos maestros básicos, de su zona de carga y los de su zona de operación de transmisión de los 2496 nodos.				

Tabla D-13.: Consulta SQL 13

# Query	13	Tiempo Ejecución	00:00:00	# Registros	2496
Objetivo	Consulta para conocer los datos maestros básicos de los nodos, los de su zona de carga y los de su zona de operación de transmisión disponibles.				
Consulta	SELECT N.[NodeId], N.[Name], N.[PlaceID], N.[City], N.[State], N.[TransmissionRegion], L.[Name], L.[StartDate], L.[EndDate], O.[Name], O.[StartDate], O.[EndDate], D.[Name], D.[StartDate], D.[EndDate] FROM [Master].[Nodes] AS N INNER JOIN [Master].[LoadZones] AS L ON N.[LZId] = L.[LZId] INNER JOIN [Master].[OperationTransmissionZones] AS O ON N.[OTZId] = O.[OTZId] INNER JOIN [Master].[DistributionZones] AS D ON N.[DZId] = D.[DZId] INNER JOIN [Master].[SystemElements] AS S ON N.[NodeId] = S.[ElementId];				
Resultado	Se obtienen los datos maestros básicos, de su zona de carga y los de su zona de operación de transmisión de los 2496 nodos.				

Tabla D-14.: Consulta SQL 14

# Query	14	Tiempo Ejecución	00:00:00	# Registros	2392
Objetivo	Consulta para conocer los datos maestros básicos de los nodos, los de su zona de carga, los de su zona de operación de transmisión, los de sus zonas de distribución, los de su sistema, los de su centro de control regional, los de su administración de distribución y los de su administración de distribución regional disponibles.				
Consulta	SELECT N.[NodeId], N.[Name], N.[PlaceID], N.[City], N.[State], N.[TransmissionRegion], N.[LoadType], N.[TensionLevelType], L.[Name], L.[StartDate], L.[EndDate], O.[Name], O.[StartDate], O.[EndDate], D.[Name], D.[StartDate], D.[EndDate], S.[ElementName], R.[Name], R.[StartDate], R.[EndDate], Sy.[Name], Sy.[TimeZone], Sy.[StartDate], R.[EndDate], DM.[Name], DM.[StartDate], DM.[EndDate], RT.[Name], RT.[StartDate], RT.[EndDate] FROM [Master].[Nodes] AS N INNER JOIN [Master].[LoadZones] AS L ON N.[LZId] = L.[LZId] INNER JOIN [Mas- ter].[OperationTransmissionZones] AS O ON N.[OTZId] = O.[OTZId] INNER JOIN [Master].[DistributionZones] AS D ON N.[DZId] = D.[DZId] INNER JOIN [Master].[SystemElements] AS S ON N.[NodeId] = S.[ElementId] INNER JOIN [Master].[RegionalControlCenters] AS R ON L.[RCCId] = R.[RCCId] INNER JOIN [Master].[Systems] AS Sy ON R.[SystemId] = Sy.[SystemId] INNER JOIN [Master].[DistributionManagements] AS DM ON D.[DMId] = DM.[DMId] INNER JOIN [Master].[RegionalTransmissionManagements] AS RT ON O.[RTMId] = RT.[RTMId];				
Resultado	Se obtienen los datos maestros básicos, de su zona de carga y los de su zona de operación de transmisión, los de sus zonas de distribución, los de su sistema, los de su centro de control regional, los de su administración de distribución y los de su administración de distribución regional de los 2392 nodos.				

Tabla D-15.: Consulta SQL 15

# Query	15	Tiempo Ejecución	00:00:00	# Registros	111
Objetivo	Consulta la cantidad zona de carga que están cargados en la tabla de datos maestros.				
Consulta	SELECT L.[LZId], L.[Name], L.[StartDate], L.[EndDate] FROM [Mas- ter].[LoadZones] AS L;				
Resultado	Se identifica que al momento de ejecutar la consulta se cuentan con con 111 zonas de carga que están cargados en la tabla de datos maestros.				

Tabla D-16.: Consulta SQL 16

# Query	16	Tiempo Ejecución	00:00:00	# Registros	109
Objetivo	Consulta para conocer los datos maestros básicos de las zonas de carga con su centro de control regional y de su sistema.				
Consulta	SELECT L.[LZId], L.[Name], L.[StartDate], L.[EndDate], S.[ElementName], R.[Name], R.[StartDate], R.[EndDate], Sy.[Name], Sy.[TimeZone], Sy.[StartDate], R.[EndDate] FROM [Master].[LoadZones] AS L INNER JOIN [Master].[SystemElements] AS S ON L.[LZId] = S.[ElementId] INNER JOIN [Master].[RegionalControlCenters] AS R ON L.[RCCId] = R.[RCCId] INNER JOIN [Master].[Systems] AS Sy ON R.[SystemId] = Sy.[SystemId];				
Resultado	Se obtienen los datos maestros básicos, de su centro de control regional y de su sistema de las 109 zonas de carga.				

Tabla D-17.: Consulta SQL 17

# Query	17	Tiempo Ejecución	00:00:00	# Registros	821
Objetivo	Consulta la cantidad de ciudades que están cargadas en la tabla de datos maestros relacionadas con nodos.				
Consulta	SELECT DISTINCT [City] FROM [Master].[Nodes];				
Resultado	Se identifica que al momento de ejecutar la consulta se cuentan con 821 ciudades que tienen nodos.				

Tabla D-18.: Consulta SQL 18

# Query	18	Tiempo Ejecución	00:00:00	# Registros	821
Objetivo	Consulta la cantidad de nodos por ciudades que están cargados en la tabla de datos maestros.				
Consulta	SELECT DISTINCT [City], COUNT([NodeId]) AS [Cantidad_Nodos] FROM [Master].[Nodes] GROUP BY [City] ORDER BY [City];				
Resultado	Se identifican la cantidad de nodos por ciudad.				

Tabla D-19.: Consulta SQL 19

# Query	19	Tiempo Ejecución	00:00:00	# Registros	34
Objetivo	Consulta la cantidad de estados que están cargados en la tabla de datos maestros relacionadas con nodos.				
Consulta	SELECT DISTINCT [State] FROM [Master].[Nodes];				
Resultado	Se identifica que al momento de ejecutar la consulta se cuentan con 34 estados que tienen nodos.				

Tabla D-20.: Consulta SQL 20

# Query	20	Tiempo Ejecución	00:00:00	# Registros	34
Objetivo	Consulta la cantidad de nodos por estados que están cargados en la tabla de datos maestros.				
Consulta	SELECT DISTINCT [State], COUNT([NodeId]) AS [Cantidad_Nodos] FROM [Master].[Nodes] GROUP BY [State] ORDER BY [State];				
Resultado	Se identifican la cantidad de nodos por estado.				

Tabla D-21.: Consulta SQL 21

# Query	21	Tiempo Ejecución	00:00:00	# Registros	9
Objetivo	Consulta la cantidad de niveles de tensión que están cargados en la tabla de datos maestros relacionadas con nodos.				
Consulta	SELECT DISTINCT [TensionLevelType] FROM [Master].[Nodes];				
Resultado	Se identifica que al momento de ejecutar la consulta se cuentan con 9 niveles de tensión que tienen nodos.				

Tabla D-22.: Consulta SQL 22

# Query	22	Tiempo Ejecución	00:00:00	# Registros	9
Objetivo	Consulta la cantidad de nodos por nivel de tensión que están cargados en la tabla de datos maestros.				
Consulta	SELECT DISTINCT [TensionLevelType], COUNT([NodeId]) AS [Cantidad_Nodos] FROM [Master].[Nodes] GROUP BY [TensionLevelType] ORDER BY [TensionLevelType];				
Resultado	Se identifican la cantidad de nodos por nivel de tensión.				

Tabla D-23.: Consulta SQL 23

# Query	23	Tiempo Ejecución	00:00:00	# Registros	110
Objetivo	Consulta la cantidad de zonas de carga que están cargados en la tabla de datos maestros relacionadas con nodos.				
Consulta	SELECT DISTINCT [LZId] FROM [Master].[Nodes];				
Resultado	Se identifica que al momento de ejecutar la consulta se cuentan con 110 zonas de carga que tienen nodos.				

Tabla D-24.: Consulta SQL 24

# Query	24	Tiempo Ejecución	00:00:00	# Registros	110
Objetivo	Consulta la cantidad de nodos por zona de carga que están cargados en la tabla de datos maestros.				
Consulta	SELECT DISTINCT N.[LZId], L.[Name], COUNT([NodeId]) AS [Cantidad_Nodos] FROM [Master].[Nodes] AS N INNER JOIN [Master].[LoadZones] AS L ON N.[LZId] = L.[LZId] GROUP BY N.[LZId], L.[Name] ORDER BY N.[LZId];				
Resultado	Se identifican la cantidad de nodos por zona.				

Tabla D-25.: Consulta SQL 25

# Query	25	Tiempo Ejecución	00:00:00	# Registros	821
Objetivo	Consulta las estadísticas básicas para mirar la calidad de la información de los nodos por ciudad.				
Consulta	SELECT DISTINCT [City], [NodeId], COUNT([Id]) AS [Cantidad_Registros], MIN([Date]) AS [FechaInicio], MAX([Date]) AS [FechaFin] FROM [Master].[Nodes] AS N INNER JOIN [Transaction].[MarginalLocalPrice] AS MPL ON N.[NodeId] = MPL.[ElementId] WHERE [MarketType] = 'TMerDiaA' GROUP BY [City], [NodeId] ORDER BY [City];				
Resultado	Se identifican las estadísticas básicas de los registros de los nodos por ciudad.				

Tabla D-26.: Consulta SQL 26

# Query	26	Tiempo Ejecución	00:00:00	# Registros	34
Objetivo	Consulta las estadísticas básicas para mirar la calidad de la información de los nodos por estados.				
Consulta	SELECT DISTINCT [State], [NodeId], COUNT([Id]) AS [Cantidad_Registros], MIN([Date]) AS [FechaInicio], MAX([Date]) AS [FechaFin] FROM [Master].[Nodes] AS N INNER JOIN [Transaction].[MarginalLocalPrice] AS MPL ON N.[NodeId] = MPL.[ElementId] WHERE [MarketType] = 'TMerDiaA' GROUP BY [State], [NodeId] ORDER BY [State];				
Resultado	Se identifican las estadísticas básicas de los registros de los nodos por estado.				

Tabla D-27.: Consulta SQL 27

# Query	27	Tiempo Ejecución	00:00:00	# Registros	9
Objetivo	Consulta las estadísticas básicas para mirar la calidad de la información de los nodos por nivel de tensión.				
Consulta	SELECT DISTINCT [TensionLevelType], [NodeId], COUNT([Id]) AS [Cantidad_Registros], MIN([Date]) AS [FechaInicio], MAX([Date]) AS [FechaFin] FROM [Master].[Nodes] AS N INNER JOIN [Transaction].[MarginalLocalPrice] AS MPL ON N.[NodeId] = MPL.[ElementId] WHERE [MarketType] = 'TMerDiaA' GROUP BY [TensionLevelType], [NodeId] ORDER BY [TensionLevelType];				
Resultado	Se identifican las estadísticas básicas de los registros de los nodos por nivel de tensión.				

Tabla D-28.: Consulta SQL 28

# Query	28	Tiempo Ejecución	00:00:00	# Registros	110
Objetivo	Consulta las estadísticas básicas para mirar la calidad de la información de los nodos por zonas de carga.				
Consulta	SELECT DISTINCT N.[LZId], L.[Name], [NodeId], COUNT([Id]) AS [Cantidad_Registros], MIN([Date]) AS [FechaInicio], MAX([Date]) AS [FechaFin] FROM [Master].[Nodes] AS N INNER JOIN [Transaction].[MarginalLocalPrice] AS MPL ON N.[NodeId] = MPL.[ElementId] INNER JOIN [Master].[LoadZones] AS L ON N.[LZId] = L.[LZId] WHERE [MarketType] = 'TMerDiaA' GROUP BY N.[LZId], L.[Name], [NodeId] ORDER BY N.[LZId];				
Resultado	Se identifican las estadísticas básicas de los registros de los nodos por zona de carga.				

Tabla D-29.: Consulta SQL 29

# Query	29	Tiempo Ejecución	00:00:00	# Registros	34
Objetivo	Consulta las estadísticas básicas para mirar la calidad de la información de los nodos por estados con el objetivo de completarlo con la región y mesoregión.				
Consulta	SELECT N.[NodeId], N.[State], COUNT(MPL.[Id]) AS [Cantidad_Registros], MIN(MPL.[Date]) AS [FechaInicio], MAX(MPL.[Date]) AS [FechaFin] FROM [Master].[Nodes] AS N INNER JOIN [Transaction].[MarginalLocalPrice] AS MPL ON N.[NodeId] = MPL.[ElementId] WHERE [MarketType] = 'TMerDiaA' GROUP BY N.[NodeId], N.[State] ORDER BY N.[State], N.[NodeId];				
Resultado	Se identifican las estadísticas básicas de los registros de los nodos por estado.				

Tabla D-30.: Consulta SQL 30

# Query	30	Tiempo Ejecución	00:00:18	# Registros	19439
Objetivo	Consulta para obtener el dataset para la calibración de los modelos de pronósticos.				
Consulta	SELECT Year(T.[Date]) AS [Year], Month(T.[Date]) AS [Month], Day(T.[Date]) AS [Day], T.[Period], DATEPART(WEEKDAY,T.[Date]) AS [WeekDay], T.[ElementId] AS [Element], CAST(T.Value AS FLOAT) AS [Value] FROM [Transaction].[MarginalLocalPrice] AS T WHERE T.[ElementId] = '01AAP-85' AND T.[MarketType] = 'TMerDiaA' AND T.[Version] = 0 AND T.[Date] <= '20180417';				
Resultado	Se obtienen los datos históricos del precio marginal local del nodo '01AAP-85'.				

Tabla D-31.: Consulta SQL 31

# Query	31	Tiempo Ejecución	00:02:15	# Registros	2473
Objetivo	Consulta final con todos los nodos con los cuales se procederá a realizar el muestreo aleatorio por mesoregión.				
Consulta	SELECT DISTINCT N.[NodeId], N.[State], N.[LZId], COUNT([Id]) AS [Cantidad_Registros], MIN([Date]) AS [FechaInicio], MAX([Date]) AS [FechaFin] FROM [Master].[Nodes] AS N INNER JOIN [Transaction].[MarginalLocalPrice] AS MPL ON N.[NodeId] = MPL.[ElementId] INNER JOIN [Master].[LoadZones] AS L ON N.[LZId] = L.[LZId] WHERE [MarketType] = 'TMerDiaA' AND [NodeId] NOT IN ('05POE-115', '06CDU-115', '06EAP-138', '06LAA-138', '06RRD-138', '06TNM-400', '08BEL-115', '07EDA-115', '07ACU-115', '07SAZ-115', '04GYC-230', '04TCG-115', '05CMF-115', '05PH2-115', '01PMX-115', '01ATG-69', '07ELP-230', '07ASJ-115', '07WIS-230', '02DIN-69', '03VRT1115', '03BCD-115', '02VMN-230', '03VRT2115', '07TJD-69', '07TJI-69', '07FLO-69', '07RSI-69', '02BPP-115') GROUP BY N.[NodeId], N.[State], N.[LZId] ORDER BY N.[State], N.[NodeId];				
Resultado	Se obtiene el listado de nodos depurados a muestrear.				

Tabla D-32.: Consulta SQL 32

# Query	32	Tiempo Ejecución	00:00:00	# Registros	Variable
Objetivo	Consulta la información histórica de cada nodo muestreado, a través del parámetro VariableNodo, con el objetivo de generar el archivo de tipo CSV que se utilizará para procesar con los modelos propuestos.				
Consulta	SELECT Year(T.[Date]) AS [Year], Month(T.[Date]) AS [Month], Day(T.[Date]) AS [Day], T.[Period], DATEPART(WEEKDAY,T.[Date]) AS [WeekDay], T.[ElementId] AS [Element], CAST(T.Value AS FLOAT) AS [Value] FROM [Transaction].[MarginalLocalPrice] AS T WHERE T.[ElementId] = VariableNodo AND T.[MarketType] = 'TMerDiaA' AND T.[Version] = 0 AND T.[Date] != '20180814';				
Resultado	Generación de archivos de tipo CSV con la información histórica de cada cado seleccionado en el muestreo de forma aleatoria.				

E. Anexo: Resultados script R de muestreo

Tabla E-1.: Tabla muestreo - Cantidad nodos a procesar

Concepto	N	n_99_5	n_99_10	n_95_5	n_95_10	n_90_5	n_90_10
Estado	2473	2155	1582	1972	1276	1827	1073
Zona de Carga	2473	2348	2052	2265	1839	2191	1672
Región	2473	1654	860	1345	593	1137	456
Mesoregión	2473	1410	637	1084	421	883	316

Donde,

- N: tamaño de la población de nodos depurados.
- n_99_5: tamaño de la muestra poblacional con una confiabilidad del 99 % y un error del 5 %.
- n_99_10: tamaño de la muestra poblacional con una confiabilidad del 99 % y un error del 10 %.
- n_95_5: tamaño de la muestra poblacional con una confiabilidad del 95 % y un error del 5 %.
- n_95_10: tamaño de la muestra poblacional con una confiabilidad del 95 % y un error del 10 %.
- n_90_5: tamaño de la muestra poblacional con una confiabilidad del 90 % y un error del 5 %.
- n_90_10: tamaño de la muestra poblacional con una confiabilidad del 90 % y un error del 10 %.

Tabla E-2.: Tabla muestreo - Estimación tiempo procesamiento (días)

Concepto	t_99_5	t_99_10	t_95_5	t_95_10	t_90_5	t_90_10
Estado	179,58	131,83	164,33	106,33	152,25	89,41
Zona de Carga	195,67	171,00	188,75	153,25	182,58	139,33
Región	137,83	71,66	112,08	49,41	94,75	38,00
Mesoregión	117,50	53,08	90,33	35,08	73,58	26,33

Donde,

- N: tamaño de la población de nodos depurados.
- t_{99_5}: tiempo requerido en días para procesar el tamaño de la muestra poblacional con una confiabilidad del 99 % y un error del 5 %.
- tiempo requerido en días para procesar el tamaño de la muestra poblacional con una confiabilidad del 99 % y un error del 10 %.
- t_{95_5}: tiempo requerido en días para procesar el tamaño de la muestra poblacional con una confiabilidad del 95 % y un error del 5 %.
- t_{95_10}: tiempo requerido en días para procesar el tamaño de la muestra poblacional con una confiabilidad del 95 % y un error del 10 %.
- t_{90_5}: tiempo requerido en días para procesar el tamaño de la muestra poblacional con una confiabilidad del 90 % y un error del 5 %.
- t_{90_10}: tiempo requerido en días para procesar el tamaño de la muestra poblacional con una confiabilidad del 90 % y un error del 10 %.

F. Anexo: Mejor calibración por modelo y técnica

Tabla F-1.: Parámetros de calibración de las técnicas utilizadas en los modelos

#	Técnica	Descripción Técnica	Calibración
1	Mean_3	Promedio de los últimos 3 meses.	No se calibró.
2	Mean_6	Promedio de los últimos 6 meses.	No se calibró.
3	Mean_9	Promedio de los últimos 9 meses.	No se calibró.
4	Mean_12	Promedio de los últimos 12 meses.	No se calibró.
5	LM	Modelo de regresión lineal que utilizó la parametrización de ecuación trend + season.	No se calibró.
6	ARIMA	Modelo arima (Box-Jenkins).	Se calibró utilizando la función <i>auto.arima</i> para obtener determinar sus parámetros de forma automática.
7	NNETAR	Modelo de red neuronal de tipo <i>feed-forward</i> con una sola capa oculta.	Se probaron las siguientes 6 calibraciones para los parámetros p (<i>Number of non-seasonal lags used as inputs</i>) y P (<i>Number of seasonal lags</i>) 1. Parámetro p y P automáticos. 2. Parámetro p automático y P = 2. 3. Parámetro p automático y P = 4. 4. Parámetro p automático y P = 6. 5. Parámetro p = 2 y P = 0. 6. Parámetro p = 4 y P = 0.
8	ETS	Modelo de espacio de estado de suavizado exponencial.	Se calibró de forma automática.

#	Técnica	Descripción Técnica	Calibración
9	NNET	Modelo de red neuronal (de tipo regresión) con una sola capa oculta y capas salto.	Se probaron las siguientes 5 calibraciones modificando la cantidad de entradas <i>lags</i> y el resto de los parámetros se configuraron así: <i>size</i> = 3 (<i>number of units in the hidden layer</i>), <i>skipt</i> = T (<i>switch to add skip-layer connections from input to output</i>), <i>maxit</i> = 10^4 (<i>maximum number of iterations</i>), <i>decay</i> = 10^{-2} (<i>parameter for weight decay</i>), <i>trace</i> = F (<i>switch for tracing optimization</i>) y <i>linout</i> = T (<i>switch for linear output units</i>) 1. Parámetro entradas <i>lags</i>: 10. 2. Parámetro entradas <i>lags</i>: 2. 3. Parámetro entradas <i>lags</i>: 4. 4. Parámetro entradas <i>lags</i>: 6. 5. Parámetro entradas <i>lags</i>: 8.
10	KNN	Modelo de KNN de tipo regresión.	Se probaron las siguientes 67 calibraciones modificando los parámetros <i>k</i> (<i>The k parameter in KNN regression</i>) y <i>lags</i> (<i>the lags used as autoregressive variables</i>) y dejando el parámetro <i>msas</i> (<i>A string indicating the Multiple Step Ahead Strategy used when more than one value is predicted</i>) con el valor <i>recursive</i>. 1. Parámetro <i>k</i> y <i>lags</i> automáticos. 2. Parámetro <i>k</i> = 1 y <i>lags</i> = 2. 3. Parámetro <i>k</i> = 1 y <i>lags</i> = 4. 4. Parámetro <i>k</i> = 1 y <i>lags</i> = 6. 5. Parámetro <i>k</i> = 1 y <i>lags</i> = 8. 6. Parámetro <i>k</i> = 1 y <i>lags</i> = 10. 7. Parámetro <i>k</i> = 1 y <i>lags</i> = 12. 8. Parámetro <i>k</i> = 3 y <i>lags</i> = 2. 9. Parámetro <i>k</i> = 3 y <i>lags</i> = 4. 10. Parámetro <i>k</i> = 3 y <i>lags</i> = 6. 11. Parámetro <i>k</i> = 3 y <i>lags</i> = 8. 12. Parámetro <i>k</i> = 3 y <i>lags</i> = 10. 13. Parámetro <i>k</i> = 3 y <i>lags</i> = 12. 14. Parámetro <i>k</i> = 5 y <i>lags</i> = 2.

#	Técnica	Descripción Técnica	Calibración
10	KNN	Modelo de KNN de tipo regresión.	15. Parámetro $k = 5$ y lags = 4.
			16. Parámetro $k = 5$ y lags = 6.
			17. Parámetro $k = 5$ y lags = 8.
			18. Parámetro $k = 5$ y lags = 10.
			19. Parámetro $k = 5$ y lags = 12.
			20. Parámetro $k = 7$ y lags = 2.
			21. Parámetro $k = 7$ y lags = 4.
			22. Parámetro $k = 7$ y lags = 6.
			23. Parámetro $k = 7$ y lags = 8.
			24. Parámetro $k = 7$ y lags = 10.
			25. Parámetro $k = 7$ y lags = 12.
			26. Parámetro $k = 9$ y lags = 2.
			27. Parámetro $k = 9$ y lags = 4.
			28. Parámetro $k = 9$ y lags = 6.
			29. Parámetro $k = 9$ y lags = 8.
			30. Parámetro $k = 9$ y lags = 10.
			31. Parámetro $k = 9$ y lags = 12.
			32. Parámetro $k = 11$ y lags = 2.
			33. Parámetro $k = 11$ y lags = 4.
			34. Parámetro $k = 11$ y lags = 6.
			35. Parámetro $k = 11$ y lags = 8.
			36. Parámetro $k = 11$ y lags = 10.
			37. Parámetro $k = 11$ y lags = 12.
			38. Parámetro $k = 13$ y lags = 2.
			39. Parámetro $k = 13$ y lags = 4.
			40. Parámetro $k = 13$ y lags = 6.
			41. Parámetro $k = 13$ y lags = 8.
			42. Parámetro $k = 13$ y lags = 10.
			43. Parámetro $k = 13$ y lags = 12.
			44. Parámetro $k = 15$ y lags = 2.
			45. Parámetro $k = 15$ y lags = 4.
			46. Parámetro $k = 15$ y lags = 6.

#	Técnica	Descripción Técnica	Calibración
10	KNN	Modelo de KNN de tipo regresión.	47. Parámetro k = 15 y lags = 8.
			48. Parámetro k = 15 y lags = 10.
			49. Parámetro k = 15 y lags = 12.
			50. Parámetro k = 17 y lags = 2.
			51. Parámetro k = 17 y lags = 4.
			52. Parámetro k = 17 y lags = 6.
			53. Parámetro k = 17 y lags = 8.
			54. Parámetro k = 17 y lags = 10.
			55. Parámetro k = 17 y lags = 12.
			56. Parámetro k = 19 y lags = 2.
			57. Parámetro k = 19 y lags = 4.
			58. Parámetro k = 19 y lags = 6.
			59. Parámetro k = 19 y lags = 8.
			60. Parámetro k = 19 y lags = 10.
			61. Parámetro k = 19 y lags = 12.
			62. Parámetro k = 21 y lags = 2.
			63. Parámetro k = 21 y lags = 4.
			64. Parámetro k = 21 y lags = 6.
			65. Parámetro k = 21 y lags = 8.
			66. Parámetro k = 21 y lags = 10.
			67. Parámetro k = 21 y lags = 12.
11	SVM_1	Modelo de SVM de tipo regresión.	Se probaron las siguientes 32 calibraciones modificando los parámetros kernel (<i>the kernel used in training and predicting</i>), cost (<i>cost of constraints violation</i>), gamma (<i>parameter needed for all kernels except linear</i>) y degree (<i>parameter needed for kernel of type polynomial</i>) y dejando el parámetro type = eps-regression (<i>svm can be used as a classification machine, as a regression machine, or for novelty detection</i>)

#	Técnica	Descripción Técnica	Calibración
11	SVM_1	Modelo de SVM de tipo regresión.	1. Parámetro: kernel = radial, cost = 1 y gamma = 0.01.
			2. Parámetro: kernel = radial, cost = 1 y gamma = 0.1.
			3. Parámetro: kernel = radial, cost = 1 y gamma = 1.
			4. Parámetro: kernel = radial, cost = 1 y gamma = 10.
			5. Parámetro: kernel = radial, cost = 1 y gamma 100.
			6. Parámetro: kernel = radial, cost = 100 y gamma = 0.01.
			7. Parámetro: kernel = radial, cost = 100 y gamma = 0.1.
			8. Parámetro: kernel = radial, cost = 100 y gamma = 1.
			9. Parámetro: kernel = radial, cost = 100 y gamma = 10.
			10. Parámetro: kernel = radial, cost = 100 y gamma = 100.
			11. Parámetro: kernel = radial, cost = 500 y gamma = 0.01.
			12. Parámetro: kernel = radial, cost = 500 y gamma = 0.1.
			13. Parámetro: kernel = radial, cost = 500 y gamma = 1.
			14. Parámetro: kernel = radial, cost = 500 y gamma = 10.
			15. Parámetro: kernel = radial, cost = 500 y gamma = 100.
			16. Parámetro: kernel = radial, cost = 1000 y gamma = 0.01.
			17. Parámetro: kernel = radial, cost = 1000 y gamma = 0.1.
			18. Parámetro: kernel = radial, cost = 1000 y gamma = 1.

#	Técnica	Descripción Técnica	Calibración
11	SVM_1	Modelo de SVM de tipo regresión.	19. Parámetro: kernel = radial, cost = 1000 y gamma = 10.
			20. Parámetro: kernel = radial, cost = 1000 y gamma = 100.
			21. Parámetro: kernel = radial, cost = 5000 y gamma = 0.01.
			22. Parámetro: kernel = radial, cost = 5000 y gamma = 0.1.
			23. Parámetro: kernel = radial, cost = 5000 y gamma = 1.
			24. Parámetro: kernel = radial, cost = 5000 y gamma = 10.
			25. Parámetro: kernel = radial, cost = 5000 y gamma = 100.
			26. Parámetro: kernel = radial, cost = 10000 y gamma = 0.01.
			27. Parámetro: kernel = radial, cost = 10000 y gamma = 0.1.
			28. Parámetro: kernel = radial, cost = 10000 y gamma = 1.
			29. Parámetro: kernel = radial, cost = 10000 y gamma = 10.
			30. Parámetro: kernel = radial, cost = 10000 y gamma = 100.
			31. Parámetro: kernel = linear, cost = 100 y gamma = 100.
			32. Parámetro: kernel = polynomial, cost = 100 y gamma = 100 y degree = 2.
12	SVM_2	Modelo de SVM de tipo regresión usando de entrada una matriz de <i>lags</i> .	Se probaron las siguientes 33 calibraciones modificando los parámetros kernel (<i>the kernel used in training and predicting</i>), cost (<i>cost of constraints violation</i>), gamma (<i>parameter needed for all kernels except linear</i>) y degree (<i>parameter needed for kernel of type polynomial</i>) y la cantidad de <i>lags</i> de entrada y dejando el parámetro type = eps-regression (<i>svm can be used as a classification machine, as a regression machine, or for novelty detection</i>)

#	Técnica	Descripción Técnica	Calibración
12	SVM_2	Modelo de SVM de tipo regresión usando de entrada una matriz de <i>lags</i> .	1. Parámetro: kernel = radial, cost = 10000 y gamma = 10 y todos los lags.
			2. Parámetro: kernel = radial, cost = 1 y gamma = 0.01 y lags = 4.
			3. Parámetro: kernel = radial, cost = 1 y gamma = 0.1 y lags = 4.
			4. Parámetro: kernel = radial, cost = 1 y gamma = 1 y lags = 4.
			5. Parámetro: kernel = radial, cost = 1 y gamma 10 y lags = 4.
			6. Parámetro: kernel = radial, cost = 1 y gamma 100 y lags = 4.
			7. Parámetro: kernel = radial, cost = 100 y gamma = 0.01 y lags = 4.
			8. Parámetro: kernel = radial, cost = 100 y gamma = 0.1 y lags = 4.
			9. Parámetro: kernel = radial, cost = 100 y gamma = 1 y lags = 4.
			10. Parámetro: kernel = radial, cost = 100 y gamma 10 y lags = 4.
			11. Parámetro: kernel = radial, cost = 100 y gamma 100 y lags = 4.
			12. Parámetro: kernel = radial, cost = 500 y gamma = 0.01 y lags = 4.
			13. Parámetro: kernel = radial, cost = 500 y gamma = 0.1 y lags = 4.
			14. Parámetro: kernel = radial, cost = 500 y gamma = 1 y lags = 4.
			15. Parámetro: kernel = radial, cost = 500 y gamma 10 y lags = 4.
			16. Parámetro: kernel = radial, cost = 500 y gamma 100 y lags = 4.
			17. Parámetro: kernel = radial, cost = 1000 y gamma = 0.01 y lags = 4.
			18. Parámetro: kernel = radial, cost = 1000 y gamma = 0.1 y lags = 4.
			19. Parámetro: kernel = radial, cost = 1000 y gamma = 1 y lags = 4.

#	Técnica	Descripción Técnica	Calibración
12	SVM_2	Modelo de SVM de tipo regresión usando de entrada una matriz de <i>lags</i> .	20. Parámetro: kernel = radial, cost = 1000 y gamma 10 y lags = 4.
			21. Parámetro: kernel = radial, cost = 1000 y gamma 100 y lags = 4.
			22. Parámetro: kernel = radial, cost = 5000 y gamma = 0.01 y lags = 4.
			23. Parámetro: kernel = radial, cost = 5000 y gamma = 0.1 y lags = 4.
			24. Parámetro: kernel = radial, cost = 5000 y gamma = 1 y lags = 4.
			25. Parámetro: kernel = radial, cost = 5000 y gamma 10 y lags = 4.
			26. Parámetro: kernel = radial, cost = 5000 y gamma 100 y lags = 4.
			27. Parámetro: kernel = radial, cost = 10000 y gamma = 0.01 y lags = 4.
			28. Parámetro: kernel = radial, cost = 10000 y gamma = 0.1 y lags = 4.
			29. Parámetro: kernel = radial, cost = 10000 y gamma = 1 y lags = 4.
			30. Parámetro: kernel = radial, cost = 10000 y gamma 10 y lags = 4.
			31. Parámetro: kernel = radial, cost = 10000 y gamma 100 y lags = 4.
			32. Parámetro: kernel = linear, cost = 1 y gamma 0.01 y lags = 4.
			33. Parámetro: kernel = polynomial, cost = 1 y gamma 0.01, lags = 4 y degree = 2.
13	FUZZY_1	Modelo de lógica difusa acorde al método Abbasov y Mamedova.	Se probaron las siguientes 7 calibraciones modificando los parámetros <i>n</i> (<i>Number of fuzzy set</i>), <i>w</i> (<i>The w parameter</i>) y dejando fijo los parámetros <i>C</i> = 0.01 (<i>A optional constant</i>) y <i>type</i> = Abbasov-Mamedova (<i>Model is choosed to predicts time series by fuzziness</i>).

#	Técnica	Descripción Técnica	Calibración
13	FUZZY_1	Modelo de lógica difusa acorde al método Abbasov y Manedova.	1. Parámetro: $n = 5$ y $w = 5$. 2. Parámetro: $n = 2$ y $w = 2$. 3. Parámetro: $n = 4$ y $w = 2$. 4. Parámetro: $n = 6$ y $w = 2$. 5. Parámetro: $n = 8$ y $w = 2$. 6. Parámetro: $n = 10$ y $w = 2$. 7. Parámetro: $n = \text{length}(\text{serie_datos}) - 5$ y $w = 2$. Nota: En el artículo [219] se recomienda que el mejor valor para w es 2.
14	FUZZY_2	Modelo de lógica difusa acorde al método NTFS.	Se probaron las siguientes 7 calibraciones modificando los parámetros n (<i>Number of fuzzy set</i>), w (<i>The w parameter</i>) y dejando fijo los parámetros $C = 0.01$ (<i>A optional constant</i>) y $\text{type} = \text{NTFS}$ (<i>Model is choosed to predicts time series by fuzziness</i>). 1. Parámetro: $n = 5$ y $w = 5$. 2. Parámetro: $n = 2$ y $w = 2$. 3. Parámetro: $n = 4$ y $w = 2$. 4. Parámetro: $n = 6$ y $w = 2$. 5. Parámetro: $n = 8$ y $w = 2$. 6. Parámetro: $n = 10$ y $w = 2$. 7. Parámetro: $n = \text{length}(\text{serie_datos}) - 5$ y $w = 2$. Nota: En el artículo [219] se recomienda que el mejor valor para w es 2.
15	HW	Modelo Holt-Winters.	La calibración se realizó con un algoritmo de fuerza bruta que busca la mejor combinación de los 3 parámetros α , β y γ del modelo.

Bibliografía

- [1] F. J. Ardakani and M. M. Ardehali, “Long-term electrical energy consumption forecasting for developing and developed economies based on different optimized models and historical data types,” *Energy*, vol. 65, pp. 452–461, 2014.
- [2] R. Weron, “Electricity price forecasting: A review of the state-of-the-art with a look into the future,” *International Journal of Forecasting*, vol. 30(4), p. 1030–1081, 2014.
- [3] G. R. T. Esteves, B. Q. Bastos, F. L. Cyrino, R. F. Calili, and R. C. Souza, “Long term electricity forecast: A systematic review,” *Procedia Computer Science*, vol. 55, p. 549–558, 2015.
- [4] T. Hong and S. Fan, “Probabilistic electric load forecasting: A tutorial review,” *International Journal of Forecasting*, vol. 32(3), p. 914–938, 2016.
- [5] J. Nowotarski and R. Weron, “Recent advances in electricity price forecasting: A review of probabilistic forecasting,” *Renewable and Sustainable Energy Reviews*, vol. 81(Part 1), p. 1548–1568, 2018.
- [6] C. Kuster, Y. Rezgui, and M. Mourshed, “Electrical load forecasting models: A critical systematic review,” *Sustainable Cities and Society*, vol. 35, p. 257–270, 2017.
- [7] P. L. Joskow, “Introduction to electricity sector liberalization: Lessons learned from cross-country studies,” *Electricity Market Reform*, pp. 1–32, 2006.
- [8] R. J. Hyndman and G. Athanasopoulos, *Forecasting: principles and practice*. OTexts, 2013.
- [9] J. Esquivel Zubiri, “Archivo:Mercado eléctrico reforma energética.” https://es.wikipedia.org/wiki/Archivo:Mercado_el%C3%A9ctrico_reforma_energ%C3%A9tica.jpg, 2014. [Consultado el 05/05/2018].
- [10] SIE, “Glosario de términos de electricidad.” http://sie.energia.gob.mx/docs/glosario_elec_es.pdf. [Consultado el 05/05/2018].
- [11] J. Esquivel Zubiri, “Ley de la industria eléctrica.” http://www.diputados.gob.mx/LeyesBiblio/pdf/LIElec_110814.pdf, 2014. [Consultado el 14/02/2019].
- [12] CENACE, “Catálogo de NodosP.” <https://www.cenace.gob.mx/Paginas/Publicas/MercadoOperacion/NodosP.aspx>. [Consultado el 05/05/2018].
- [13] 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, 2017.
- [14] R. Weron, *Modeling and forecasting electricity loads and prices: a statistical approach*. Chichester: Wiley, 2006.
- [15] D. Tranfield, D. Denyer, and P. Smart, “Towards a methodology for developing evidence-informed management knowledge by means of systematic review,” *British Journal of Management*, vol. 14, pp. 207–222, 2003.
- [16] D. Denyer and D. Tranfield, *Producing a systematic review*. Sage Publications, 2009.
- [17] A. Hernandez Neto and F. Sanzovo Fiorelli, “Comparison between detailed model simulation and artificial neural network for forecasting building energy consumption,” *Energy and Buildings*, vol. 40(12), pp. 2169–2176, 2008.
- [18] U. Kumar and V. K. Jain, “Time series models (grey-markov, grey model with rolling mechanism and singular spectrum analysis) to forecast energy consumption in india,” *Energy*, vol. 35(4), pp. 1709–1716, 2010.
- [19] A. Azadeh, S. F. Ghaderi, and S. Sohrabkhani, “Annual electricity consumption forecasting by neural network in high energy consuming industrial sectors,” *Energy Conversion and Management*, vol. 49, pp. 0196–8904, 2008.
- [20] R. K. Jain, K. M. Smith, P. J. Culligan, and J. E. Taylor, “Forecasting energy consumption of multi-family residential buildings using support vector regression: Investigating the impact of temporal and spatial monitoring granularity on performance accuracy,” *Applied Energy*, vol. 123, pp. 168–178, 2014.
- [21] C. Hamzacebi, “Forecasting of turkey’s net electricity energy consumption on sectoral bases,” *Energy Policy*, vol. 35(3), pp. 2009–2016, 2007.
- [22] Y.-S. Lee and L.-I. Tong, “Forecasting energy consumption using a grey model improved by incorporating genetic programming,” *Energy Conversion and Management*, vol. 52(1), pp. 147–152, 2011.
- [23] S. Saab, E. Badr, and G. Nasr, “Univariate modeling and forecasting of energy consumption: the case of electricity in lebanon,” *Energy*, vol. 26(1), pp. 1–14, 2001.
- [24] A. Azadeh, S. F. Ghaderi, and S. Sohrabkhani, “A simulated-based neural network algorithm for forecasting electrical energy consumption in iran,” *Energy Policy*, vol. 36(7), pp. 2637–2644, 2008.
- [25] K. Li, H. Su, and J. Chu, “Forecasting building energy consumption using neural networks and hybrid neuro-fuzzy system: A comparative study,” *Energy and Buildings*, vol. 43(10), pp. 2893–2899, 2011.
- [26] L. Tang, L. Yu, S. Wang, J. Li, and S. Wang, “A novel hybrid ensemble learning paradigm for nuclear energy consumption forecasting,” *Applied Energy*, vol. 93, pp. 432–443, 2012.

- [27] A. Azadeh and S. Tarverdian, "Integration of genetic algorithm, computer simulation and design of experiments for forecasting electrical energy consumption," *Energy Policy*, vol. 35(10), pp. 5229–5241, 2007.
- [28] A. Z. Al-Garni, S. M. Zubair, and J. S. Nizami, "A regression model for electric-energy-consumption forecasting in eastern saudi arabia," *Energy*, vol. 19(10), pp. 1043–1049, 1994.
- [29] X. Lü, T. Lu, C. J. Kibert, and M. Viljanen, "Modeling and forecasting energy consumption for heterogeneous buildings using a physical–statistical approach," *Applied Energy*, vol. 144, pp. 261–275, 2015.
- [30] A. Sözen, M. A. Akçayol, and E. Arcaklioğlu, "Forecasting net energy consumption using artificial neural network," *Energy Sources*, vol. 1(2), pp. 147–155, 2006.
- [31] L. Tang, L. Yu, and K. He, "A novel data-characteristic-driven modeling methodology for nuclear energy consumption forecasting," *Applied Energy*, vol. 128, pp. 1–14, 2014.
- [32] G. E. Nasr, E. A. Badr, and M. R. Younes, "Neural networks in forecasting electrical energy consumption: univariate and multivariate approaches," *Energy Research*, vol. 26(1), pp. 67–78, 2002.
- [33] K. Li and H. Su, "Forecasting building energy consumption with hybrid genetic algorithm-hierarchical adaptive network-based fuzzy inference system," *Energy and Buildings*, vol. 42(11), pp. 2070–2076, 2010.
- [34] F. Zhang, C. Deb, S. E. Lee, J. Yang, and K. W. Shah, "Time series forecasting for building energy consumption using weighted support vector regression with differential evolution optimization technique," *Energy and Buildings*, vol. 126, pp. 94–103, 2016.
- [35] K. Karabulut, A. Alkan, and A. Yilmaz, "Long term energy consumption forecasting using genetic programming," *Association for Scientific Research*, vol. 13, pp. 71–80, 2008.
- [36] P. K. Adom and W. Bekoe, "Conditional dynamic forecast of electrical energy consumption requirements in ghana by 2020: A comparison of ardl and pam," *Energy*, vol. 44(1), pp. 367–380, 2012.
- [37] D. Baczynski and M. Parol, "Influence of artificial neural network structure on quality of short-term electric energy consumption forecast," *Generation, Transmission and Distribution, IEE Proceedings*, vol. 151, pp. 241–245, 2004.
- [38] S. Barak and S. S. Sadegh, "Forecasting energy consumption using ensemble arima–anfis hybrid algorithm," *International Journal of Electrical Power & Energy Systems*, vol. 82, pp. 92–104, 2016.
- [39] M. Meng, D. Niu, and W. Sun, "Forecasting monthly electric energy consumption using feature extraction," *Energies*, vol. 4(10), pp. 1495–1507, 2011.
- [40] P. Sen, M. Roy, and P. Pal, "Application of arima for forecasting energy consumption

- and ghg emission: A case study of an indian pig iron manufacturing organization,” *Energy*, vol. 116(Part 1), pp. 1031–1038, 2016.
- [41] Y. R. Zeng, Y. Zeng, B. Choi, and L. Wang, “Multifactor-influenced energy consumption forecasting using enhanced back-propagation neural network,” *Energy*, vol. 127, pp. 381–396, 2017.
 - [42] L. Tang, S. Wang, K. He, and S. Wang, “A novel mode-characteristic-based decomposition ensemble model for nuclear energy consumption forecasting,” *Annals of Operations Research*, vol. 234, pp. 111–132, 2015.
 - [43] V. A. Kamaev, M. V. Shcherbakov, D. P. Panchenko, N. L. Shcherbakova, and A. Brebels, “Using connectionist systems for electric energy consumption forecasting in shopping centers,” *Automation and Remote Control*, vol. 73(6), pp. 1075–1084, 2012.
 - [44] P. Zhang and H. Wang, “Fuzzy wavelet neural networks for city electric energy consumption forecasting,” *Energy Procedia*, vol. 17(B), pp. 1332–1338, 2012.
 - [45] M. Castelli, L. Trujillo, and L. Vanneschi, “Energy consumption forecasting using semantic-based genetic programming with local search optimizer,” *Computational Intelligence and Neuroscience*, vol. 2015, p. 8, 2015.
 - [46] X. Jiang, H. Ling, J. Yan, B. Li, and Z. Li, “Forecasting electrical energy consumption of equipment maintenance using neural network and particle swarm optimization,” *Mathematical Problems in Engineering*, vol. 2013, p. 8, 2013.
 - [47] J. Yoo and K. Hur, “Load forecast model switching scheme for improved robustness to changes in building energy consumption patterns,” *Energies*, vol. 6, pp. 1329–1343, 2013.
 - [48] X. P. Zhang and G. Rui, “Electrical energy consumption forecasting based on cointegration and a support vector machine in china,” *WSEAS Transactions on Mathematics*, vol. 6(6), pp. 878–883, 2007.
 - [49] L. G. B. Ruiz, R. Rueda, M. P. Cuéllar, and M. C. Pegalajar, “Energy consumption forecasting based on elman neural networks with evolutive optimization,” *Expert Systems with Applications*, vol. 92, pp. 380–389, 2018.
 - [50] K. P. Amber, M. W. Aslam, A. Mahmood, A. Kousar, M. Y. Younis, B. Akbar, G. Q. Chaudhary, and S. K. Hussain, “Energy consumption forecasting for university sector buildings,” *Energies*, vol. 10(10), p. 1579, 2017.
 - [51] S. Singh and A. Yassine, “Big data mining of energy time series for behavioral analytics and energy consumption forecasting,” *Energies*, vol. 11(2), p. 452, 2018.
 - [52] R. D. Wang, X. Sun, X. Yang, and H. Hu, “Cloud computing and extreme learning machine for a distributed energy consumption forecasting in equipment-manufacturing enterprises,” *Cybernetics and Information Technologies*, vol. 16(6), pp. 83–97, 2016.
 - [53] Y. Zhang, R. Yang, K. Zhang, H. Jiang, and J. J. Zhang, “Consumption beha-

- viator analytics-aided energy forecasting and dispatch,” *In IEEE Intelligent Systems*, vol. 32(4), pp. 59–63, 2017.
- [54] M. Petkovic, M. R. Rapaić, and B. Jakovljević, “Electrical energy consumption forecasting in oil refining industry using support vector machines and particle swarm optimization,” *WSEAS Transactions on Information Science and Applications*, vol. 6(11), pp. 1761–1770, 2009.
- [55] V. Majazi Dalfard, M. Nazari Asli, S. Nazari-Shirkouhi, S. M. Sajadi, and S. M. Asadzadeh, “Incorporating the effects of hike in energy prices into energy consumption forecasting: a fuzzy expert system,” *Neural Computing and Applications*, vol. 23(1), pp. 153–169, 2013.
- [56] M. Meng, W. Shang, and D. Niu, “Monthly electric energy consumption forecasting using multiwindow moving average and hybrid growth models,” *Journal of Applied Mathematics*, vol. 2014, pp. 1–7, 2014.
- [57] J. L. Rojas-Renteria, T. D. Espinoza-Huerta, F. S. Tovar-Pacheco, J. L. Gonzalez-Perez, and R. Lozano-Dorantes, “An electrical energy consumption monitoring and forecasting system,” *Engineering, Technology & Applied Science Research*, vol. 6(5), pp. 1130–1132, 2016.
- [58] L. Wang, H. Hu, X. Y. Ai, and H. Liu, “Effective electricity energy consumption forecasting using echo state network improved by differential evolution algorithm,” *Energy*, vol. 153, pp. 801–815, 2018.
- [59] E. Meira de Oliveira and F. L. Cyrino Oliveira, “Forecasting mid-long term electric energy consumption through bagging arima and exponential smoothing methods,” *Energy*, vol. 144, pp. 776–788, 2018.
- [60] M. H. Alobaidi, F. Chebana, and M. A. Meguid, “Robust ensemble learning framework for day-ahead forecasting of household based energy consumption,” *Applied Energy*, vol. 212, pp. 997–1012, 2018.
- [61] S. Mishra and V. K. Singh, “Monthly energy consumption forecasting based on windowed momentum neural network,” *IFAC-PapersOnLine*, vol. 48(30), pp. 433–438, 2015.
- [62] B. A. Staroverov and B. A. Gnatyuk, “Universal energy consumption forecasting system based on neural network ensemble,” *Optical Memory and Neural Networks*, vol. 25(3), pp. 198–202, 2016.
- [63] L. Cao, “Support vector machines experts for time series forecasting,” *Neurocomputing*, vol. 51, pp. 321–339, 2003.
- [64] B. J. Chen, M. W. Chang, and C. J. Lin, “Load forecasting using support vector machines: a study on eunite competition 2001,” *IEEE Transactions on Power Systems*, vol. 19(4), pp. 1821–1830, 2004.

- [65] B. Dong, C. Cao, and S. Lee, "Applying support vector machines to predict building energy consumption in tropical region," *Energy and Buildings*, vol. 37(5), pp. 545–553, 2004.
- [66] P. F. Pai and W. C. Hong, "Forecasting regional electricity load based on recurrent support vector machines with genetic algorithms," *Electric Power Systems Research*, vol. 74(3), pp. 417–425, 2005.
- [67] P. F. Pai and W. C. Hong, "Support vector machines with simulated annealing algorithms in electricity load forecasting," *Energy Conversion and Management*, vol. 46(17), pp. 2669–2688, 2005.
- [68] C. C. Hsu and C. Y. Chen, "Applications of improved grey prediction model for power demand forecasting," *Energy Conversion and Management*, vol. 44(14), pp. 2241–2249, 2002.
- [69] J. W. Taylor, L. M. de Menezes, and P. E. McSharry, "A comparison of univariate methods for forecasting electricity demand up to a day ahead," *International Journal of Forecasting*, vol. 22(1), pp. 1–16, 2006.
- [70] D. Akay and M. Atak, "Grey prediction with rolling mechanism for electricity demand forecasting of turkey," *Energy*, vol. 32(9), pp. 1670–1675, 2006.
- [71] W. R. Christiaan, "Short-term load forecasting using general exponential smoothing," *IEEE Transactions on Power Apparatus and Systems*, vol. PAS-90(2), pp. 900–911, 1971.
- [72] W. C. Hong, "Chaotic particle swarm optimization algorithm in a support vector regression electric load forecasting model," *Energy Conversion and Management*, vol. 50(1), pp. 105–117, 2009.
- [73] P. A. González and J. M. Zamarréño, "Prediction of hourly energy consumption in buildings based on a feedback artificial neural network," *Energy and Buildings*, vol. 37(6), pp. 595–601, 2005.
- [74] L. Ekonomou, "Greek long-term energy consumption prediction using artificial neural networks," *Energy*, vol. 35(2), pp. 512–517, 2009.
- [75] A. Sorjamaa, J. Hao, N. Reyhani, Y. Ji, and A. Lendasse, "Methodology for long-term prediction of time series," *Neurocomputing*, vol. 70(16-18), pp. 2861–2869, 2007.
- [76] D. Niu, Y. Wang, and D. D. Wu, "Power load forecasting using support vector machine and ant colony optimization," *Expert Systems with Applications*, vol. 37(3), pp. 2531–2539, 2010.
- [77] Z. A. Bashir and M. E. El-Hawary, "Applying wavelets to short-term load forecasting using pso-based neural networks," *IEEE Transactions on Power Systems*, vol. 24(1), pp. 20–27, 2009.
- [78] S. Karatasou, M. Santamouris, and V. Geros, "Modeling and predicting building's

- energy use with artificial neural networks: methods and results,” *Energy and Buildings*, vol. 38(8), pp. 949–958, 2005.
- [79] A. Azadeh, S. F. Ghaderi, S. Tarverdian, and M. Saberi, “Integration of artificial neural networks and genetic algorithm to predict electrical energy consumption,” *Applied Mathematics and Computation*, vol. 186(2), pp. 1731–1741, 2007.
- [80] Q. Li, Q. Meng, J. Cai, H. Yoshino, and M. A., “Applying support vector machine to predict hourly cooling load in the building,” *Applied Energy*, vol. 86(10), pp. 2249–2256, 2009.
- [81] E. Erdogdu, “Electricity demand analysis using cointegration and arima modelling: a case study of turkey,” *Energy Policy*, vol. 35(2), pp. 1129–1146, 2006.
- [82] W. C. Hong, “Electric load forecasting by support vector model,” *Applied Mathematical Modelling*, vol. 33(5), pp. 2444–2454, 2008.
- [83] J. W. Taylor, “Triple seasonal methods for short-term electricity demand forecasting,” *European Journal of Operational Research*, vol. 204(1), pp. 139–152, 2010.
- [84] P. Zhou, B. Ang, and K. Poh, “A trigonometric grey prediction approach to forecasting electricity demand,” *Energy*, vol. 31(14), pp. 2839–2847, 2005.
- [85] A. Kavousi-Fard, H. Samet, and F. Marzbani, “A new hybrid modified firefly algorithm and support vector regression model for accurate short term load forecasting,” *Expert Systems with Applications*, vol. 41(13), pp. 6047–6056, 2014.
- [86] H. T. Pao, H. C. Fu, and C. L. Tseng, “Forecasting of co2 emissions, energy consumption and economic growth in china using an improved grey model,” *Energy*, vol. 40(1), pp. 400–409, 2012.
- [87] C. M. Huang, C. J. Huang, and M. L. Wang, “A particle swarm optimization to identifying the armax model for short-term load forecasting,” *IEEE Transactions on Power Systems*, vol. 20(2), pp. 1126–1133, 2005.
- [88] Q. Li, Q. Meng, J. Cai, H. Yoshino, and M. A., “Predicting hourly cooling load in the building: a comparison of support vector machine and different artificial neural networks,” *Energy Conversion and Management*, vol. 50(1), pp. 90–96, 2008.
- [89] A. W. L. Yao, S. C. Chi, and J. H. Chen, “An improved grey-based approach for electricity demand forecasting,” *Electric Power Systems Research*, vol. 67(3), pp. 217–224, 2003.
- [90] W. C. Hong, “Electric load forecasting by seasonal recurrent svr (support vector regression) with chaotic artificial bee colony algorithm,” *Energy*, vol. 36(9), pp. 5568–5578, 2011.
- [91] J. W. Taylor, “An evaluation of methods for very short-term load forecasting using minute-by-minute british data,” *International Journal of Forecasting*, vol. 24(4), pp. 645–658, 2008.

- [92] C.-M. Lee and C.-N. Ko, "Time series prediction using rbf neural networks with a nonlinear time-varying evolution pso algorithm," *Neurocomputing*, vol. 73(1-3), pp. 449–460, 2009.
- [93] J. W. Taylor, "Short-term load forecasting with exponentially weighted methods," *IEEE Transactions on Power Systems*, vol. 27(1), pp. 458–464, 2012.
- [94] R. E. Edwards, J. New, and L. E. Parker, "Predicting future hourly residential electrical consumption: a machine learning case study," *Energy and Buildings*, vol. 49, pp. 591–603, 2012.
- [95] S. Bahrami, R.-A. Hooshmand, and M. Parastegari, "Short term electric load forecasting by wavelet transform and grey model improved by pso (particle swarm optimization) algorithm," *Energy*, vol. 72, pp. 434–442, 2014.
- [96] F. Kaytez, M. C. Taplamacioglu, E. Cam, and F. Hardalac, "Forecasting electricity consumption: a comparison of regression analysis, neural networks and least squares support vector machines," *Energy Systems*, vol. 67, pp. 431–438, 2014.
- [97] C. Hamzacebi and H. A. Es, "Forecasting the annual electricity consumption of turkey using an optimized grey model," *Energy*, vol. 70, pp. 165–171, 2014.
- [98] S. R. Singh, "A simple method of forecasting based on fuzzy time series," *Applied Mathematics and Computation*, vol. 186(1), pp. 330–339, 2007.
- [99] H. W.-C., Y. Dong, W. Y. Zhang, L.-Y. Chen, and B. K. Panigrahi, "Cyclic electric load forecasting by seasonal svr with chaotic genetic algorithm," *Energy Systems*, vol. 44(1), pp. 604–614, 2013.
- [100] R. E. Abdel-Aal and A. Z. Al-Garni, "Forecasting monthly electric energy consumption in eastern saudi arabia using univariate time-series analysis," *Energy*, vol. 22(11), pp. 1059–1069, 1997.
- [101] P.-C. Chang and J.-J. Fan C.-Y. and Lin, "Monthly electricity demand forecasting based on a weighted evolving fuzzy neural network approach," *International Journal of Electrical Power & Energy Systems*, vol. 33(1), pp. 17–27, 2011.
- [102] A. Azadeh, S. M., S. F. Ghaderi, A. Gitiforouz, and V. Ebrahimipour, "Improved estimation of electricity demand function by integration of fuzzy system and data mining approach," *Energy Conversion and Management*, vol. 49(8), pp. 2165–2177, 2008.
- [103] R. Yokoyama, T. Wakui, and R. Satake, "Prediction of energy demands using neural network with model identification by global optimization," *Energy Conversion and Management*, vol. 50(2), pp. 319–327, 2008.
- [104] H. Mao, X.-J. Zeng, G. Leng, Y. Zhai, and J. A. Keane, "Short and mid-term load forecasting using a bilevel optimization model," *IEEE Transactions on Power Systems*, vol. 24(2), pp. 1080–1090, 2009.

- [105] E. Ceperic, V. Ceperic, S. Member, and A. Baric, "A strategy for short-term load forecasting by support vector regression machines," *IEEE Transactions on Power Systems*, vol. 28(4), pp. 4356–4364, 2013.
- [106] H.-T. Yang and C.-M. Huang, "A new short-term load forecasting approach using self-organizing fuzzy armax models," *IEEE Transactions on Power Systems*, vol. 13(1), pp. 217–225, 1998.
- [107] Y. Wang, J. Wang, G. Zhao, and Y. Dong, "Application of residual modification approach in seasonal arima for electricity demand forecasting: a case study of china," *Energy Policy*, vol. 48, pp. 284–294, 2012.
- [108] W.-C. Hong, "Hybrid evolutionary algorithms in a svr-based electric load forecasting model," *International Journal of Electrical Power & Energy Systems*, vol. 31(7-8), pp. 409–417, 2007.
- [109] A. Azadeh, M. Saberi, and O. Seraj, "An integrated fuzzy regression algorithm for energy consumption estimation with non-stationary data: a case study of iran," *Energy*, vol. 35(6), pp. 2351–2366, 2010.
- [110] E. Almeshaiei and H. Soltan, "A methodology for electric power load forecasting," *Alexandria Engineering Journal*, vol. 50(2), pp. 137–144, 2011.
- [111] V. Bianco, O. Manca, S. Nardini, and M. A. A., "Analysis and forecasting of nonresidential electricity consumption in romania," *Applied Energy*, vol. 87(11), pp. 3584–3590, 2010.
- [112] A. W. L. Yao and S. C. Chi, "Analysis and design of a taguchi–grey based electricity demand predictor for energy management systems," *Energy Conversion and Management*, vol. 45(7-8), pp. 1205–1217, 2004.
- [113] R.-A. Hooshmand, H. Amooshahi, and M. Parastegari, "A hybrid intelligent algorithm based short-term load forecasting approach," *International Journal of Electrical Power & Energy Systems*, vol. 45(1), pp. 313–324, 2013.
- [114] H.-T. Pao, "Comparing linear and nonlinear forecasts for taiwan's electricity consumption," *Energy*, vol. 31(12), pp. 2129–2141, 2004.
- [115] J. Che, J. Wang, and G. Wang, "An adaptive fuzzy combination model based on self-organizing map and support vector regression for electric load forecasting," *Energy*, vol. 37(1), pp. 657–664, 2012.
- [116] Y. Yao, Z. Lian, S. Liu, and Z. Hou, "Hourly cooling load prediction by a combined forecasting model based on analytic hierarchy process," *International Journal of Thermal Sciences*, vol. 43(11), pp. 1107–1118, 2004.
- [117] B. Wang, N. Tai, H. Zhai, Y. J., J. Zhu, and L. Qi, "A new armax model based on evolutionary algorithm and particle swarm optimization for short-term load forecasting," *Electric Power Systems Research*, vol. 78(10), pp. 1679–1685, 2008.

- [118] Y. T. Chae, R. Horesh, Y. Hwang, and Y. M. Lee, "Artificial neural network model for forecasting sub-hourly electricity usage in commercial buildings," *Energy and Buildings*, vol. 111, pp. 184–194, 2015.
- [119] J. Donate, X. Li, G. Gutiérrez Sánchez, and A. Sanchis de Miguel, "Time series forecasting by evolving artificial neural networks with genetic algorithms, differential evolution and estimation of distribution algorithm," *Neural Computing and Applications*, vol. 22(1), pp. 11–20, 2011.
- [120] H. Nie, G. Liu, X. Liu, and Y. Wang, "Hybrid of arima and svms for short-term load forecasting," *Energy Procedia*, vol. 16(Part C), pp. 1455–1460, 2012.
- [121] C. Deb, L. S. Eang, J. Yang, and M. Santamouris, "Forecasting diurnal cooling energy load for institutional buildings using artificial neural networks," *Energy and Buildings*, vol. 121, pp. 284–297, 2015.
- [122] Y. Jiang, Y. Yao, S. Deng, and Z. Ma, "Applying grey forecasting to predicting the operating energy performance of air cooled water chillers," *International Journal of Refrigeration*, vol. 27(4), pp. 385–392, 2004.
- [123] I. P. Panapakidis and A. S. Dagoumas, "Day-ahead electricity price forecasting via the application of artificial neural network based models," *Applied Energy*, vol. 172, pp. 132–151, 2016.
- [124] *A predictive demand of the maximum electric power using chaos-fuzzy*, vol. 2, IEEE, 2001.
- [125] P. Li, Y. Li, Q. Xiong, Y. Chai, and Y. Zhang, "Application of a hybrid quantized elman neural network in short-term load forecasting," *International Journal of Electrical Power & Energy Systems*, vol. 55, pp. 749–759, 2014.
- [126] D. K. Chaturvedi, A. P. Sinha, and O. P. Malik, "Short term load forecast using fuzzy logic and wavelet transform integrated generalized neural network," *International Journal of Electrical Power & Energy Systems*, vol. 67, pp. 230–237, 2015.
- [127] Q. Zhou, S. Wang, X. Xu, and F. Xiao, "A grey-box model of next-day building thermal load prediction for energy-efficient control," *International Journal of Energy Research*, vol. 32(15), pp. 1418–1431, 2008.
- [128] K. Kandananond, "Forecasting electricity demand in thailand with an artificial neural network approach," *Energies*, vol. 4(8), pp. 1246–1257, 2011.
- [129] G.-D. Li, C.-H. Wang, S. Masuda, and M. Nagai, "A research on short term load forecasting problem applying improved grey dynamic model," *International Journal of Electrical Power & Energy Systems*, vol. 33(4), pp. 809–816, 2011.
- [130] G.-F. Fan, L.-L. Peng, W.-C. Hong, and F. Sun, "Electric load forecasting by the svr model with differential empirical mode decomposition and auto regression," *Neurocomputing*, vol. 173(Part 3), pp. 958–970, 2016.

- [131] A. Azadeh, M. Saberi, A. Gitiforouz, and Z. Saberi, "A hybrid simulation-adaptive network based fuzzy inference system for improvement of electricity consumption estimation," *Expert Systems with Applications*, vol. 36(8), pp. 11108–11117, 2009.
- [132] K. Li, C. Hu, G. Liu, and W. Xue, "Building's electricity consumption prediction using optimized artificial neural networks and principal component analysis," *Energy and Buildings*, vol. 108, pp. 106–113, 2015.
- [133] W.-J. Lee and J. Hong, "A hybrid dynamic and fuzzy time series model for mid-term power load forecasting," *International Journal of Electrical Power & Energy Systems*, vol. 64, pp. 1057–1062, 2015.
- [134] H. Chitsaz, H. Shaker, H. Zareipour, D. Wood, and N. Amjady, "Short-term electricity load forecasting of buildings in microgrids," *Energy and Buildings*, vol. 99, pp. 50–60, 2015.
- [135] M. Jin, X. Zhou, Z. M. Zhang, and M. M. Tentzeris, "Short-term power load forecasting using grey correlation contest modeling," *Expert Systems with Applications*, vol. 39(1), pp. 773–779, 2012.
- [136] R. Enayatifar, H. J. Sadaei, A. H. Abdullah, and A. Gani, "Imperialist competitive algorithm combined with refined high-order weighted fuzzy time series (rhwfts-ica) for short term load forecasting," *Energy Conversion and Management*, vol. 76, pp. 1104–1116, 2013.
- [137] G. Sudheer and A. Suseelatha, "Short term load forecasting using wavelet transform combined with holt-winters and weighted nearest neighbor models," *International Journal of Electrical Power & Energy Systems*, vol. 64, pp. 340–346, 2015.
- [138] W. Y. Zhang, W.-C. Hong, Y. Dong, G. Tsai, J.-T. Sung, and G. Fan, "Application of svr with chaotic gasa algorithm in cyclic electric load forecasting," *Energy*, vol. 45(1), pp. 850–858, 2012.
- [139] F.-Y. Ju and W.-C. Hong, "Application of seasonal svr with chaotic gravitational search algorithm in electricity forecasting," *Applied Mathematical Modelling*, vol. 37(23), pp. 9643–9651, 2013.
- [140] T. Chen and Y. Wang, "Long-term load forecasting by a collaborative fuzzy-neural approach," *International Journal of Electrical Power & Energy Systems*, vol. 43(1), pp. 454–464, 2012.
- [141] S. Kouhi and F. Keynia, "A new cascade nn based method to short-term load forecast in deregulated electricity market," *Energy Conversion and Management*, vol. 71, pp. 76–83, 2013.
- [142] J. Wu, J. Wang, H. Lu, Y. Dong, and X. Lu, "Short term load forecasting technique based on the seasonal exponential adjustment method and the regression model," *Energy Conversion and Management*, vol. 70, pp. 1–9, 2013.

- [143] M. Ghofrani, M. Ghayekhloo, A. Arabali, and A. Ghayekhloo, "A hybrid short-term load forecasting with a new input selection framework," *Energy*, vol. 81, pp. 777–786, 2015.
- [144] S. Kouhi, F. Keynia, and S. Najafi Ravadanegh, "A new short-term load forecast method based on neuro-evolutionary algorithm and chaotic feature selection," *International Journal of Electrical Power & Energy Systems*, vol. 62, pp. 862–867, 2014.
- [145] J. Nizami and A. Z. Ai-Garni, "Forecasting electric energy consumption using neural networks," *Energy Policy*, vol. 23(12), pp. 1097–1104, 1995.
- [146] T. Nengling, J. Stenzel, and W. Hongxiao, "Techniques of applying wavelet transform into combined model for short-term load forecasting," *Electric Power Systems Research*, vol. 76(6-7), pp. 525–533, 2006.
- [147] H. J. Sadaei, R. Enayatifar, A. H. Abdullah, and A. Gani, "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*, vol. 62, pp. 118–129, 2014.
- [148] M. Moazzami, A. Khodabakhshian, and R. Hooshmand, "A new hybrid day-ahead peak load forecasting method for iran's national grid," *Applied Energy*, vol. 101, pp. 489–501, 2013.
- [149] T.-T. Chen and S.-J. Lee, "A weighted ls-svm based learning system for time series forecasting," *Information Sciences*, vol. 299, pp. 99–116, 2015.
- [150] B. Akdemir and N. Çetinkay, "Long-term load forecasting based on adaptive neural fuzzy inference system using real energy data," *Energy Procedia*, vol. 14, pp. 794–799, 2012.
- [151] Y. Chen, Y. Yang, C. Liu, C. Li, and L. Li, "A hybrid application algorithm based on the support vector machine and artificial intelligence: an example of electric load forecasting," *Applied Mathematical Modelling*, vol. 39(9), pp. 2617–2632, 2015.
- [152] R. Efendi, Z. Ismail, and M. Mat, "A new linguistic out-sample approach of fuzzy time series for daily forecasting of malaysian electricity load demand," *Applied Soft Computing*, vol. 28, pp. 422–430, 2014.
- [153] *Time series analysis of household electric consumption with ARIMA and ARMA models*, 2013.
- [154] T. E. Dikaaios, "Forecasting residential electricity consumption in greece using monthly and quarterly data," *Energy Economics*, vol. 14(3), pp. 226–232, 1992.
- [155] *Fuzzy based time series forecasting of electric load*, IEEE, 1999.
- [156] S. Kelo and S. Dudul, "A wavelet elman neural network for short-term electrical load prediction under the influence of temperature," *International Journal of Electrical Power & Energy Systems*, vol. 43(1), pp. 1063–1071, 2012.

- [157] K. M. El-naggar and K. A. Al-rumaih, "Algorithm, optimal filter estimator and least error squares technique: comparative study," *Int'l J Electr Robot Electron Commun Eng*, vol. 1, pp. 941–945, 2006.
- [158] M. Brown, C. Barrington-Leigh, and Z. Brown, "Kernel regression for real-time building energy analysis," *Journal of Building Performance Simulation*, vol. 5(4), pp. 263–276, 2011.
- [159] *Fuzzy based time series forecasting of electric load*, IEEE, 2011.
- [160] D. Monfet, M. Corsi, D. Choinière, and A. E., "Development of an energy prediction tool for commercial buildings using case-based reasoning," *Energy and Buildings*, vol. 81, pp. 152–160, 2014.
- [161] M. Rezaeian-Zadeh, S. Zand-Parsa, H. Abghari, M. Zolghadr, and V. P. Singh, "Hourly air temperature driven using multi-layer perceptron and radial basis function networks in arid and semi-arid regions," *Theoretical and Applied Climatology*, vol. 109(3-4), pp. 519–528, 2012.
- [162] X. Wang and M. Meng, "A hybrid neural network and arima model for energy consumption forecasting," *Journal of Computers*, vol. 7(5), pp. 1184–1190, 2012.
- [163] Y. Fu, Z. Li, H. Zhang, and P. Xu, "Using support vector machine to predict next day electricity load of public buildings with sub-metering devices," *Procedia Engineering*, vol. 121, pp. 1016–1022, 2015.
- [164] S. R. Rallapalli and S. Ghosh, "Forecasting monthly peak demand of electricity in india—a critique," *Energy Policy*, vol. 45, pp. 516–520, 2012.
- [165] H. Son and C. Kim, "Forecasting short-term electricity demand in residential sector based on support vector regression and fuzzy-rough feature selection with particle swarm optimization," *Procedia Engineering*, vol. 118, pp. 1162–1168, 2015.
- [166] *Multivariate k-nearest neighbour regression for time series data — a novel algorithm for forecasting UK electricity demand*, IEEE, 2013.
- [167] *Building cooling load B21forecasting model based on LS-SVM*, vol. 1, IEEE, 2009.
- [168] C. Deb, L. S. Eang, J. Yang, and M. Santamouris, "Forecasting energy consumption of institutional buildings in singapore," *Procedia Engineering*, vol. 121, pp. 1734–1740, 2015.
- [169] M. Božić, M. Stojanovi, and Z. Stajic, "Short-term electric load forecasting using least square support vector machines," *Automatic Control and Robotics*, vol. 9, pp. 141–150, 2010.
- [170] P. M. Maçaira, R. C. Souza, and F. L. C. Oliveira, "Modelling and forecasting the residential electricity consumption in brazil with pegels exponential smoothing techniques," *Procedia Computer Science*, vol. 55, pp. 328–335, 2015.

- [171] *Building-level occupancy data to improve ARIMA-based electricity use forecasts*, BuildSys '10, (New York, NY, USA), ACM, 2010.
- [172] *Electricity consumption forecasting using fuzzy time series*, In Computational Intelligence and Informatics (CINTI), (New York, NY, USA), IEEE, 2010.
- [173] N. A. Abd Jalil, M. Ahmad, and N. Mohamed, "Electricity load demand forecasting using exponential smoothing methods," *World Applied Sciences Journal*, vol. 22, pp. 1540–1543, 2013.
- [174] Y. Wang, D. Niu, and X. Ma, "Optimizing of svm with hybrid pso and genetic algorithm in power load forecasting," *JNW*, vol. 5, pp. 1192–1200, 2010.
- [175] C. Machado Pereira, N. Nunes de Almeida, and M. L. F. Velloso, "Fuzzy modeling to forecast an electric load time series," *Procedia Computer Science*, vol. 55, pp. 395–404, 2015.
- [176] *A total fuzzy regression algorithm for energy consumption estimation*, (Daejeon), IEEE, 2008.
- [177] *Predictability of energy use in homes*, (Dallas, TX), IEEE, 2014.
- [178] *Short-term load forecasting using random forests*, vol. 323, Springer, Cham, 2015.
- [179] *Neural networks in forecasting electrical energy consumption*, FLAIRS-01, 2001.
- [180] F. Yasmeen and M. Sharif, "Forecasting electricity consumption for pakistan," *International Journal of Emerging Technology and Advanced Engineering*, vol. 4(4), pp. 496–503, 2014.
- [181] Z. Ismail and R. Mansor, "Fuzzy logic approach for forecasting half-hourly malaysia electricity load demand," pp. 1–17, 2011.
- [182] J. Kang and H. Zhao, "Application of improved grey model in long-term load forecasting of power engineering," *Systems Engineering Procedia*, vol. 3, pp. 85–91, 2012.
- [183] *Time-series prediction: application to the short-term electric energy demand*, vol. 3040 of *Lecture Notes in Computer Science*, (Berlin, Heidelberg), Springer, 2004.
- [184] Y. Hong-Tzer, H. Chao-Ming, and H. Ching-Lien, "Identification of armax model for short term load forecasting: an evolutionary programming approach," *IEEE Transactions on Power Systems*, vol. 11(1), pp. 403–408, 1995.
- [185] *Fuzzy time-series model of electric power consumption*, vol. 2, (Edmonton, Alberta, Canada, Canada), IEEE, 1999.
- [186] S. A. Abdul Karim and S. A. Alwi, "Electricity load forecasting in utp using moving averages and exponential smoothing techniques," *Applied Mathematical Sciences*, vol. 7(80), pp. 4003–4014, 2013.
- [187] Z. J., Y. Chen, X. Shi, and D. Wei, "Building cooling load prediction based on time series method and neural networks," *International Journal of Grid and Distributed*

- Computing*, vol. 8, pp. 105–114, 2015.
- [188] *Time series forecasting method of building energy consumption using support vector regression*, (Lijiang, China), IEEE, 2015.
- [189] *Electrical load time series data forecasting using interval type-2 fuzzy logic system*, vol. 5, (Chengdu), IEEE, 2010.
- [190] *The research of local linear model of short term electrical load on multivariate time series*, vol. 5, (St. Petersburg, Russia), IEEE, 2005.
- [191] *A novel building cooling load prediction based on SVR and SAPSO*, vol. 1, (Tainan, Taiwan), IEEE, 2010.
- [192] N. Mohamed, M. H. Ahmad, and Z. Ismail, “Improving short term load forecasting using double seasonal arima model,” *World Applied Sciences Journal*, vol. 15(2), pp. 223–231, 2011.
- [193] T. Roger, H. Oumarou, M. Gérard, and T. Moses, “Improved electric power demand forecasting by adapting the weighted average to the mismo strategy,” *International Journal on Electrical Engineering and Informatics*, vol. 6(2), pp. 237–249, 2014.
- [194] *k-NN based neuro-fuzzy system for time series prediction*, (Honolulu, HI, USA), IEEE, 2013.
- [195] *Short term load forecasting using a hybrid model based on support vector regression*, vol. 4, 2015.
- [196] M. Rashid and Roken, “Time series models for forecasting monthly electricity peak-load for dubai,” *Chancellor’s Undergrad Res Award*, pp. 1–14, 2018.
- [197] *Time-variant slide fuzzy time-series method for short-term load forecasting*, vol. 1, (Xiamen, China), IEEE, 2010.
- [198] *Maximum length weighted nearest neighbor approach for electricity load forecasting*, (Killarney, Ireland), IEEE, 2010.
- [199] S. Abosedra and B. Campus, “Demand for electricity in lebanon,” *International Business & Economics Research Journal (IBER)*, vol. 8(1), pp. 1–8, 2009.
- [200] *Load forecasting in a smart grid oriented building*, (Stockholm, Sweden), IET, 2013.
- [201] S. Katara, A. Faisal, and G. M. Engmann, “A time series analysis of electricity demand in tamale,” *International Journal of Statistics and Applications*, vol. 4(6), pp. 269–275, 2014.
- [202] G. K. Abledu, “Modeling and forecasting energy consumption in ghana,” *Journal of Energy Technologies and Policy*, vol. 3(12), pp. 1–10, 2013.
- [203] G. Ogcü, O. F. Demirel, and S. Zaim, “Forecasting electricity consumption with neural networks and support vector regression,” *Procedia - Social and Behavioral Sciences*, vol. 58, pp. 1576–1585, 2012.

- [204] W. Zhao, F. Wang, and D. Niu, “The application of support vector machine in load forecasting,” *JOURNAL OF COMPUTERS*, vol. 7(7), pp. 1615–1622, 2012.
- [205] *Evaluation of a case-based reasoning energy prediction tool for commercial buildings*, (Montreal, Quebec, Canada), 2013.
- [206] *Load forecasting based on fuzzy time series*, Advances in Engineering Research, Atlantis Press, 2015.
- [207] *Application of improved grey prediction model to short term load forecasting*, 2008.
- [208] C. M. Bindiu, R. and G. V. Pop, “Day-ahead load forecasting using exponential smoothing, 6,” *Scientific Bulletin of the Petru Maior University of Tirgu Mures*, vol. 6(23), pp. 89–93, 2009.
- [209] A. Kotillová, “Very short-term load forecasting using exponential smoothing and arima models,” *Journal of Information, Control and Management Systems*, vol. 9(2), pp. 85–92, 2011.
- [210] J. Xue, Z. Xu, and J. Watada, “Building an integrated hybrid model for short-term and mid-term load forecasting with genetic optimization,” *International Journal of Innovative Computing, Information and Control*, vol. 8(10), pp. 7381–7391, 2012.
- [211] *Short-term load forecasting by artificial neural networks specified by genetic algorithms – a simulation study over a Brazilian dataset*, (Rosario, Argentina), 2015.
- [212] J. Che and J. Wang, “Short-term load forecasting using a kernel-based support vector regression combination model,” *Applied Energy*, vol. 132, pp. 602–609, 2014.
- [213] H. T. Pao, “Forecasting energy consumption in taiwan using hybrid nonlinear models,” *Energy*, vol. 34(10), pp. 1438–1446, 2009.
- [214] *The application of genetic algorithm in power short-term load forecasting*, vol. 50, (Singapore), 2012.
- [215] A. Asrari, D. Javan, M. H. Javidi, and M. Monfared, “Application of gray-fuzzy-markov chain method for day-ahead electric load forecasting,” *Przegląd Elektrotechniczny*, p. 228–237, 2012.
- [216] *El estudio de casos en la preparación de tesis de posgrado en el ámbito de la PYME*, vol. 1, 2008.
- [217] R. K. Yin, *The abridged version of case study research: Design and method*. Thousand Oaks, CA, US: Sage Publications, Inc, 1998.
- [218] S. Chetty, “The case study method for research in small-and medium-sized firms,” *International Small Business Journal*, vol. 15(1), pp. 73–85, 1996.
- [219] *An Improved Fuzzy Time Series Forecasting Model*, vol. 760 of *Studies in Computational Intelligence*, (Cham), Springer, 2018.