



Universidad Nacional de Lanús

Departamento de Planificación y Políticas Públicas

Maestría en Gestión de la Energía

Modelado de la Demanda de Potencia Eléctrica en la República Argentina Usando la Metodología Box - Jenkins

Trabajo Final de Maestría Profesional, Presentado como Requisito Final para
Optar al Grado Académico de **Magíster en Gestión de la Energía**

Maestrando: Lic. Carlos Eduardo Mora Fresca

Director: Dr. Cristóbal Ernesto Vega González

Fecha de Entrega Online de la Primera Versión: 21 de Septiembre de 2022

Fecha de la Defensa Oral y Pública Presencial en la UNLa: 30 de Junio de 2023

Fecha de Entrega Online de la Versión Final: 15 de Julio de 2023

Modelado de la Demanda de Potencia Eléctrica en la República Argentina Usando la Metodología Box-Jenkins

Carlos Eduardo Mora Fresca¹

Maestría en Gestión de la Energía

Departamento de Planificación y Políticas Públicas

Universidad Nacional de Lanús

Resumen

El propósito de esta tesis es estimar modelos de series de tiempo que permitan obtener un pronóstico de la demanda de potencia eléctrica del Sistema Argentino de Interconexión (SADI). La metodología usada es la de Box y Jenkins. Para ello se ajustan modelos estacionales, autoregresivos, integrados y de media móvil (SARIMA). Se obtiene una familia de modelos y se selecciona el modelo que mejor se ajuste a los datos, basado en criterios estadísticos y complejidad de parámetros del mismo. Contar con este tipo de predicciones permite que la toma de decisiones operativas a corto plazo sea mucho más sencilla y con ello se garantiza la confiabilidad del sistema de potencia. La fuente de información histórica para la elaboración de este estudio fue la disponible en CAMMESA en el período Enero 2018 hasta Julio 2022. Como resultado final se obtienen modelos horarios por día de semana. Los modelos son seleccionados mediante el criterio de información Akaike. El modelo final corresponde a SARIMA (5, 1, 6) (1, 1, 1)₂₄ (0, 1, 0)₁₆₈ cuya bondad de ajuste es de 99,97 %. Los resultados del modelo final obtenido se comparan con los datos de la previsión de CAMMESA en los meses de Febrero-Marzo 2022 y Mayo 2023, obteniendo una mejora en el pronóstico del 2,23 %. Los resultados obtenidos pueden ser usados para predecir la demanda de potencia eléctrica y elaborar la programación diaria que incluye los esquemas de generación e intercambio de energía así como el almacenamiento en embalses de rebombeo.

Palabras Claves: Demanda de Potencia Eléctrica, Modelos horarios de Series de Tiempo, Predicción: Modelos SARIMA.

Clasificación MSC2020: **62M10** Series de Tiempo, Autocorrelación, Regresión; **62P30** Aplicaciones de estadística en ingeniería e industria y gráficos de control; **91B74** Modelos económicos de sistemas del mundo real (por ejemplo, mercados de electricidad, etc.); **97M40** Investigación de Operaciones y Economía.

¹carlosmorafresca@cnea.gob.ar

Modeling the Electric Power Requirement in the Argentine Republic Using the Box-Jenkins Methodology

Carlos Eduardo Mora Fresca²
Master in Energy Management
Department of Planning and Public Policies
Universidad Nacional de Lanús

Abstract

The purpose of this thesis is to estimate time series models that allow obtaining a forecast of the daily electrical power requirement of the Argentine Interconnection System (SADI). The methodology used is the one developed by Box and Jenkins. For this, seasonal, autoregressive, integrated and moving average models (SARIMA) are adjusted. A family of models is obtained and the model that best fits the data is selected, based on statistical criteria and complexity of its parameters. Having this type of prediction makes short-term operational decision-making much easier and thereby guarantees the reliability of the power system. The source of historical information for the preparation of this study was the one available in CAMMESA in the period from January 2018 to July 2022. As a final result, hourly models are obtained by typical weekday. The models are selected using the Akaike information criteria. The final model corresponds to SARIMA (5, 1, 6) (1, 1, 1)₂₄ (0, 1, 0)₁₆₈ whose goodness of fit is 99.97%. The results of the final model obtained are compared with the CAMMESA forecast data for the months of February-March 2022 and May 2023, obtaining an improvement in the forecast of 2.23%. The results obtained can be used to predict the demand for electrical power and prepare the daily schedule when preparing the generation and exchange schemes for energy as well as storage in pumping reservoirs.

Keywords: Electric Power Requirement, Time Series Hourly Models, Forecast: SARIMA Models.

Classification MSC2020: **62M10** Time series, auto-correlation, regression; **62P30** Applications of statistics in engineering and industry, control charts; **91B74** Economic models of real-world systems (e.g., electricity markets, etc.); **97M40** Operations research, economics.

²carlosmorafresca@cnea.gob.ar

Índice general

Resumen	II
Abstract	III
Índice general	IV
1. Establecimiento del Problema	2
1.1. Introducción	2
1.2. Energía y Sociedad	3
1.2.1. Dimensión Política	3
1.2.2. Dimensión Económica	4
1.2.3. Dimensión Social	4
1.2.4. Dimensión Ambiental	4
1.3. Demanda de Potencia Eléctrica	6
1.3.1. Factores que Afectan la Estimación de la Demanda de Electricidad	6
1.4. Objetivo General	8
1.5. Objetivos Específicos	8
1.6. Justificación del Estudio	8
1.6.1. Para los Generadores	8
1.6.2. Para los Distribuidores y Transportistas	9
1.6.3. Para los Comercializadores	9
1.6.4. Para el Operador del Mercado	9
1.7. Estado del Arte	11
2. Modelos de Análisis de Series de Tiempo	16

2.1. Introducción	16
2.2. Horizonte de Predicción	18
2.3. Pronóstico	20
2.4. Objetivos del Análisis de Series de Tiempo	21
2.5. Descripción de los Modelos	22
2.5.1. Modelos Lineales	23
2.5.2. Modelos No Lineales	25
3. Modelado Clásico de Series Temporales	27
3.1. Metodología Box-Jenkins: modelos ARIMA	30
3.1.1. Definición y consecuencias de la estacionariedad e invertibilidad . . .	32
3.1.2. Estacionalidad	34
3.2. Ventajas y Desventajas de modelos ARIMA	34
3.2.1. Ventajas:	34
3.2.2. Desventajas:	35
3.3. Estacionariedad de la Serie	35
3.3.1. Definición estricta	35
3.3.2. Condiciones débiles para la estacionariedad	36
3.4. Análisis del Espectro de Frecuencias	37
3.5. Pasos para identificar un modelo SARIMA	38
3.6. Selección de Variables, Modelos y Pronóstico	40
3.6.1. Pasos para Seleccionar un Modelo y Validarlo	41
4. Descripción del Sistema Eléctrico Argentino.	42
4.1. Actores del Sistema Eléctrico Argentino	42
4.2. Balance de Energía en tiempo Real	43
4.2.1. La Frecuencia como indicador de Calidad de Suministro	44
4.3. Criterios Generales de Operación	45
4.3.1. Seguridad del Abastecimiento	45
4.3.2. Calidad del Suministro	45
4.3.3. Mínimo Costo	46
4.4. Instancias de programación para cubrir la demanda	46

4.4.1. Programación Estacional	46
4.4.2. Programación Semanal	47
4.4.3. Programación Diaria	48
4.5. Boletín Informativo Semanal	49
4.6. Datos de Operación en Tiempo Real	51
4.7. Evolución de la Demanda de Energía en Argentina	52
4.7.1. Demanda de Energía Eléctrica vs Población	53
4.7.2. Demanda de Eléctrica vs. Variación del PBI	54
4.7.3. Demanda por Regiones	54
4.7.4. Demanda por Sectores de Consumo	57
4.8. Factores que afectan a la demanda	58
4.8.1. Pandemia de SARS-CoV-2	58
4.8.2. Curvas de Demanda Estacional	60
4.8.3. Demanda vs. Temperatura	61
4.8.4. Máximos de Demanda de Potencia	64
4.8.5. Bonus Track: Análisis de la influencia de la temperatura en el máximo histórico de demanda del 13 de marzo de 2023	66
5. Metodología	68
5.1. Consideraciones y supuestos sobre la Demanda	68
5.1.1. Influencia de la Temperatura sobre la Demanda	69
5.2. Aplicación de la Metodología Box-Jenkins	71
5.2.1. Paso 1: Graficar la Serie de Tiempo	72
5.2.2. Paso 2: Comportamiento Estacional de la Serie	73
5.2.3. Pasos 3 y 4: Inspección detallada de la Serie y Confirmación de Tendencia de la Serie	79
6. Resultados y Análisis de los Resultados	82
6.1. Resultados de la Serie SADI. Pasos 1 y 2.	82
6.2. Paso 3: Análisis de los Residuos	85
6.3. Comparación modelo SARIMA vs. la previsión de CAMMESA	86
6.3.1. Paso 4: Validar el Modelo	86

7. Conclusiones y Trabajos Futuros	90
A. Programas Informáticos Empleados	92
A.1. Hoja de Cálculo	92
A.2. Programa Econométrico	92
B. Cómo Descargar Datos de la Página de Cammesa	93
B.1. Datos de Demanda Horaria	93
B.2. Previsión Diaria	97
B.3. Para otras Consultas de Información Estadística Pública Oficial de Cammesa	98
C. Prueba de Raíz Unitaria	99
C.1. Introducción	99
C.1.1. Terminología y Notación	99
C.1.2. Ejemplos	99
C.2. ¿Como encontrar el orden de integración adecuado?	100
C.3. Prueba de Dickey-Fuller	100
C.3.1. Prueba de Dickey-Fuller Aumentada	101
D. Notación de Operadores	103
D.1. El operador de retardos	103
D.2. El operador diferencia	104
Bibliografía	105

Capítulo 1

Establecimiento del Problema

Este capítulo presenta una aproximación a la importancia del problema de pronóstico de demanda de potencia eléctrica, indica los objetivos propuestos para la realización de esta tesis y la justificación e importancia del estudio.

1.1. Introducción

Uno de los mayores sueños del hombre desde que tiene uso de razón ha sido poder predecir el futuro. A lo largo de la historia de la humanidad es posible encontrar diversos ejemplos de oráculos, augures y visionarios que con poco acierto, vaticinaban acerca del futuro. Ese sueño de conocer el futuro parte de la ventaja de conocer previamente las consecuencias que una acción o decisión va a tener. Los tiempos pasados no son una excepción y ese sueño continúa y se hace más importante cuando entran en juego cuestiones de índole económica. De hecho, ha sido en el campo económico donde las técnicas de predicción de los valores futuros de una serie temporal han sido más ampliamente utilizadas.

Son muchos los ejemplos en donde conocer de forma previa el valor futuro de una variables puede resultar útil. Desde un punto de vista global, la predicción de valores futuros de variables es importante para lo siguiente:

- **Planificar:** El conocimiento de las condiciones de funcionamiento de un sistema requiere poder prever el rango de valores futuros de las variables que afectan al mismo.
- **Adquirir Recursos:** Los tiempos necesarios en la adquisición y transporte de productos, la preparación de personal calificado o la puesta en marcha de nuevas unidades de producción, obliga a tomar las decisiones de su adquisición o formación de modo que tal que estén disponibles en el momento que se les requiera. Para esta toma de decisiones, una predicción ajustada es de gran importancia económica y estratégica.

- **Priorizar Acciones:** La predicción de valores futuros facilita la toma de decisiones que garanticen la seguridad y confiabilidad del sistema en el corto y mediano plazo.

Son muchas las actividades humanas, en las que la predicción juega un papel de primordial importancia. El sector vinculado a la coordinación del sector eléctrico no es ajeno a la necesidad de predicción de las variables que le afectan. Por una parte, la toma de decisiones de gran trascendencia futura (políticas de expansión e inversión) requieren conocer como evolucionará la demanda de potencia en el largo plazo. Por otra parte, el normal funcionamiento operativo diario requiere conocer los valores futuros en el corto plazo. Un echo importante a tener en cuenta es que la energía eléctrica, a diferencia de otro tipo de suministros, es que actualmente no es posible almacenar la electricidad a gran escala. Desde un punto de vista práctico, las usinas deben generar permanentemente tanta energía eléctrica como la que demanden todos los usuarios de la red, más las pérdidas asociadas a la transmisión y distribución. La oferta debe acompañar los vaivenes de la demanda manteniendo un estrecho equilibrio. Esto obliga a una planificación de la producción eléctrica día tras día, con un grado de certidumbre en la previsión de la demanda técnico y económicamente razonable, que ayude a decidir cuales centrales eléctricas, y con que participación, deben estar en funcionamiento en cada momento.

1.2. Energía y Sociedad

La energía constituye un elemento esencial para la calidad de vida del ser humano y es un insumo de alta difusión en el conjunto de todas las actividades productivas. La disponibilidad de energía ha tenido un papel central en el proceso de desarrollo de la humanidad. Es así, que las grandes revoluciones tecnológicas han estado fuertemente ligadas a la sustitución entre fuentes energéticas primarias, conocidas hoy en día como transiciones energéticas.

Es importante destacar que tanto la producción como el consumo de energía tienen interacciones importantes con el medio ambiente. El uso de los recursos fósiles conduce a un progresivo agotamiento de las reservas correspondientes.

Por otra parte existen reacciones sociales ante el i) aumento de precios de los energéticos así como en ii) las políticas de racionamiento y/o cortes de abastecimiento eléctrico, por lo que es evidente el impacto de las cuestiones energéticas en el plano de la política de un país.

Estas consideraciones ponen en evidencia los importantes vínculos de la energía con las dimensiones del desarrollo sustentable propuestas en [CEPAL et al., 1997]. A continuación se muestra como contribuye el Sistema Energético a la sustentabilidad del Desarrollo.

1.2.1. Dimensión Política

- Mantenimiento de influencia internacional.
- Seguridad y Diversificación del abastecimiento externo.

1.2.2. Dimensión Económica

- Autarquía Energética.
- Reducir la cuota energética de las importaciones.
- Captación de rentas energéticas e inversión de las mismas en otras formas de capital.
- Reducir la intensidad energética.
- Uso racional y eficiente de la energía en los sectores productivos.
- Financiamiento suficiente para el sector.
- Mayor valor agregado a las cadenas energéticas.
- Mayor calidad del suministro energético y confiabilidad del suministro.
- Reducir los costos de suministro energético.
- Diversificación del Mix Energético.

1.2.3. Dimensión Social

- Abastecimiento Suficiente y Satisfacción de necesidades Básicas.
- Acceso a Energéticos y tecnologías modernos.
- Mayor acceso a la Electricidad y abastecimiento de servicios sociales.

1.2.4. Dimensión Ambiental

- Reducción de impactos locales y globales por emisiones.
- Manejo sostenible de los recursos fósiles.
- Manejo sustentable de las cuencas hidráulicas.
- Utilización sostenible y ecocompatible de los recursos renovables a corto y largo plazo.

Debido a que el desarrollo de los pueblos está íntimamente relacionado con la productividad de los mismos, el consumo de energía eléctrica se vuelve indispensable para las máquinas y artefactos que ayudan a incrementar la productividad y a elevar el nivel de confort de sus habitantes. La importancia de la predicción de la demanda de energía eléctrica surge, de forma obvia, de la incertidumbre asociada a una magnitud futura.

En las últimas décadas, el problema de mayor atención que ha tenido el sector eléctrico en cuanto a predicción es la previsión de la demanda eléctrica en el corto plazo (entre

1 y 7 días). En las publicaciones especializadas, es posible encontrar decenas de artículos describiendo nuevos modelos de predicción de la demanda de energía eléctrica, modelos en los que el desarrollo de nuevas técnicas meta heurísticas (Próximas a la Inteligencia Artificial) van desde uso de modelos avanzados para la producción de energía intermitente en parques eólicos en [Fernández, 2007] hasta uso de Big Data y minería de datos para caracterizar el comportamiento de la demanda de una región tal como se plantea en [Fabrégas et al., 2018].

Este trabajo tiene como objetivo encontrar, mediante la metodología de series de tiempo, un modelo que permita pronosticar la demanda horaria de potencia eléctrica, para hacer predicciones que permitan tomar decisiones a corto y mediano plazo, y de esta forma servir de apoyo al momento de la asignación de recursos energéticos. Por ello, es importante conocer algunas características técnicas del sistema de potencia.

Un sistema de potencia se define como todo el recorrido que realiza la energía eléctrica desde que se produce en una central eléctrica hasta que llega a los usuarios. El objetivo fundamental de un sistema de potencia es garantizar la producción continua de potencia eléctrica las 24 horas del día, los 365 días del año, de forma confiable y segura. Por ende las compañías generadoras de este servicio deben considerar diversos factores para poder planificar de qué forma suplirán la demanda de sus usuarios. Vale destacar que un sistema de potencia confiable debe ser redundante, es decir, tener disponibilidad de equipos y diversas alternativas para satisfacer la demanda en caso de cualquier eventualidad no prevista.




Figura 1.1: Sistema de Potencia

El sector eléctrico Argentino constituye el tercer mercado energético de América Latina. De acuerdo al informe anual de [CAMMESA, 2022] durante 2021 la oferta de energía eléctrica estuvo conformada en primer lugar por la generación térmica (63,2 %), en segundo por la generación hidroeléctrica (16,9 %), en tercero por las energías renovables intermitentes (que incluyen hidráulicas de potencia < 50MW, eólica, fotovoltaica, biogás y biomasa) con un 12,2 % y en cuarto lugar la generación de origen nuclear con un (7,1 %). Finalmente se puede mencionar que para cubrir la demanda fue necesario importar 0,6 %.

1.3. Demanda de Potencia Eléctrica

La demanda de potencia eléctrica es una función no lineal del tiempo, además de ser variable en los diferentes puntos geográficos de la red. Esto se debe a los diferentes usos e intensidades que se le da a la demanda eléctrica [Herrera, 2007].

1.3.1. Factores que Afectan la Estimación de la Demanda de Electricidad

i) Factores no controlables

- **Costumbres de los Centros de Consumo:** Los distintos centros urbanos poseen distintas costumbres (ej. la siesta en el norte del país) que dan como resultado variaciones diferentes en la demanda.
- **Factor Inercial:** Sólo se puede apreciar en las primeras horas de la mañana cuando inicia la semana, y en las primeras horas después de un feriado, provocando que la demanda sea más baja que la media correspondiente.
- **Estructura Económica:** La demanda de potencia eléctrica es diferente para cada uno de los sectores de consumo, por ejemplo: el consumo de una zona industrial es diferente al de una zona agrícola o zona turística.
- **Condiciones Climáticas:** Los patrones de consumo eléctrico de una zona varían con la estación del año, temperatura, humedad, velocidad del viento, etc.
- **Factores Aislados:** La presencia de un gran número de eventos que pueden ser fortuitos o no (eventos deportivos, huelgas, programas de televisión, elecciones, fallas aleatorias en el sistema de potencia).

ii) Factores controlables

- **Tarifa:** Al conocer los patrones de consumo de grandes consumidores, se puede desfasar sus consumos en horas que no coincidan con la demanda máxima.

Una vez conocidos los factores que afectan las estimaciones en la demanda, lo que sigue es obtener una previsión de la demanda cuya consecuencia inmediata es elaborar los esquemas de generación e intercambio de potencia eléctrica, recordando lo siguiente:

- **Permisos Programados:** Se debe saber con cuales equipos (de generación y transmisión) se dispondrá al momento de elaborar los esquemas de generación e intercambio de potencia eléctrica.
- **Políticas de Consumo de Combustible:** Es importante conocer dichas políticas al momento de prever como se generará la energía necesaria calculada en la previsión de la demanda (balance o coordinación hidro-térmica y stock de combustibles).

Quienes planifican y operan en tiempo real un sistema de potencia, deben considerar que los datos de pronóstico de la demanda no son valores determinísticos sino más bien que pueden llegar a tener fluctuaciones en sus pronósticos en función de las incertidumbres propias de las variables asociadas, en consecuencia, deben estar preparados para tomar las decisiones adecuadas para modificar sus predicciones conforme se produzcan cambios no previstos. Para ello deben de manejar toda la información posible de los equipos con los que cuentan, el tiempo requerido para incorporarlos (distintas reservas rotantes), las restricciones por mantenimientos programados tanto en generación como en transmisión, a que riesgos puede estar expuesto el sistema eléctrico (tormentas, incendios, etc) y como actuar, cómo se comporta la demanda los diversos días de la semana y en los distintos meses del año. Es decir, quienes administran el sistema de potencia deben prever o adelantarse a los cambios antes de que estos tengan lugar [Martin, 2005].

Cada vez que se enciende o apaga un equipo eléctrico en casa o lugar de trabajo, se envía una orden a todo el sistema eléctrico (varias plantas generadoras, redes de transmisión y distribución) para que aumenten o disminuyan de forma instantánea la generación de potencia eléctrica a fin de satisfacer las necesidades de los usuarios. Es importante destacar que los centros de generación de energía no necesariamente se encuentran cerca de los centros de consumo. De esta forma, además de la demanda del equipo que se conecta a la red, se deben sumar las pérdidas en las redes de transmisión y distribución. La suma de la demanda y las pérdidas en la red corresponden a el suministro de energía, el cual, en todo momento, debe ser exactamente igual a la generación de potencia eléctrica. Esto último, es debido a que no es posible almacenar la electricidad en cantidades considerables y además algunas plantas generadoras requieren de cierto tiempo de arranque que puede ser de horas.

Por todo lo anterior, es necesario prever los valores futuros de la demanda lo más ajustada posible a la realidad para programar y disponer de generación necesaria que cubra tanto a la demanda de potencia eléctrica como a las pérdidas asociadas a la red. Por otro lado, se debe tener en cuenta que tanto las plantas generadoras como las redes de distribución y transmisión requieren mantenimiento, por lo que también es necesario conocer los requerimientos futuros de la demanda para poder efectuar los mantenimientos teniendo en cuenta que prevalezca la redundancia y siempre exista disponibilidad de equipos a fin de brindar un buen servicio. Finalmente, hay que conocer cómo evolucionará la demanda de potencia a lo largo de los años para poder planificar las inversiones adecuadas e incorporar nuevos equipos a los ya existentes que conforman el sistema de potencia y de esa forma seguir prestando un buen servicio a lo largo del tiempo [Moreno, 2006].

El problema en cuestión es poder efectuar una previsión a *corto plazo* de la demanda de potencia eléctrica en Argentina. En la sección Horizonte de Predicción se describen los horizontes temporales de predicción, en donde se menciona: cuál es el período de tiempo que determina el momento futuro para el cual se realizan las predicciones, la importancia de los mismos y los datos requeridos para cada estudio. A continuación se formulan los objetivos de la investigación.

1.4. Objetivo General

- Obtener un modelo estadístico de series de tiempo usando la metodología Box-Jenkins para el pronóstico horario de la demanda de potencia eléctrica.

1.5. Objetivos Específicos

1. Formular modelos de series de tiempo que permitan predecir la demanda horaria de potencia eléctrica en el Sistema Argentino de Interconexión (SADI).
2. Obtener un modelo horario de la demanda de potencia eléctrica de serie de tiempo que mejor se adapte a los datos, usando como criterios estadísticos el AKAIKE (AIC) y BAYESIANO (BIC).
3. Pronosticar la demanda horaria basada en el modelo construido anteriormente.
4. Comparar la predicción obtenida así como la previsión de demanda empleada en la programación diaria de CAMMESA con los datos reales de los meses de febrero, marzo de 2022 y mayo 2023 y cuantificar la mejora del pronóstico.

1.6. Justificación del Estudio

Dependiendo del tipo de agente del mercado, la predicción de la demanda se justifica por las razones enunciadas a continuación:

1.6.1. Para los Generadores

La predicción de demanda en el corto plazo permite definir la cantidad de energía a generar (ofertar) para el día siguiente, mediante un mix tecnológico en cada una de las horas del día, recordando que existen períodos de tiempo intrínsecos de arranque, desde el momento del encendido hasta entrar en régimen de generación diferentes para cada tecnología.

Conocer cual es la demanda a cubrir permite programar la operación de unidades y fijar el precio de oferta de la electricidad en el mercado. En el medio plazo es un elemento fundamental para la definición de planes de mercado, contratos de venta y análisis de la evolución del mercado.

En el largo plazo, permite detectar los períodos para los cuales existen excesos o carencias de capacidad de generación con el fin de planificar las inversiones en la expansión del sistema de generación y adoptar medidas de conservación de la energía; en el largo plazo, este es un

problema fundamental debido a que la construcción de una nueva planta generadora puede tardar varios años, afectando a la fiabilidad del suministro de energía eléctrica.

1.6.2. Para los Distribuidores y Transportistas

A corto plazo, permite realizar el seguimiento del comportamiento de la red con el fin de identificar puntos críticos que en el futuro pueden ocasionar problemas. [Murillo et al., 2003] emplea modelos de series de tiempo SARIMA con el objetivo de apoyar la toma de decisiones al momento de otorgar permisos para el mantenimiento de equipos críticos en el mediano plazo. Por otra parte, los pronósticos basados en picos máximos de demanda son elementos fundamentales para definir el programa de expansión del sistema de transporte a largo plazo.

1.6.3. Para los Comercializadores

En el medio y largo plazo, es un elemento fundamental para el análisis del comportamiento del mercado y la definición de los planes estratégicos y operativos para la comercialización de la energía eléctrica pudiendo gestionar la curva de demanda ofreciendo tarifas diferenciadas en las horas de valle, donde la demanda de potencia es baja.

1.6.4. Para el Operador del Mercado

En el corto plazo es un elemento fundamental para la programación y operación de las unidades de generación, minimizando los ajustes del programa de operación en tiempo real, con el fin de evitar los sobre costos en la producción de electricidad.

Dichos costos adicionales se pueden producir en un primer escenario porque el pronóstico de la demanda de potencia sea superior al valor real, tal como se observa entre las horas 10 y 14 de la Figura 1.2 correspondiente al día 14/06/2021, entonces el precio de generación de la potencia demandada será alto porque este se halla con base en el costo marginal de la última unidad generada para compensar el pronóstico de la demanda.

El segundo escenario en el cual el pronóstico de la demanda es menor o inferior a la demanda real, tal como se muestra en la Figura 1.2 entre las horas 15 y 17, así como desde la 20 a la hora 24. Esto implica costos adicionales para cubrir la demanda mediante la compra de energía más cara en el mercado spot o mediante importaciones a países limítrofes o incluso puede llevar a la disminución en la calidad de prestación del servicio manifestándose por cortes y racionamiento de energía, disminuyendo la calidad de suministro.




Figura 1.2: Demanda diaria de Potencia Eléctrica en el SADI, día 14/06/2021.

Fuente: Página Web de CAMMESA. Sección Demanda Real vs. Prevista del SADI

A continuación, en la figura 1.3 se muestra como fue la generación necesaria para cubrir la demanda en el día 14/06/2021.




Figura 1.3: Generación para cubrir la demanda del SADI, día 14/06/2021.

Fuente: Página Web de CAMMESA. Sección Demanda y Generación Real del SADI

El objetivo de esta tesis es encontrar un modelo de series de tiempo, compararlo con el empleado actualmente por el operador de mercado Argentino y cuantificar la posible mejora del pronóstico.

En el caso de Argentina, el operador de mercado es CAMMESA, quien diariamente debe despachar el SADI considerando la generación existente y su costo de generación. Es importante mencionar que actualmente no todos los equipos de generación están disponibles, lo que hace necesario una previsión ajustada a la realidad. La importancia que tiene elaborar una previsión *ajustada de la demanda*, por parte de quienes planifican las operaciones, se debe a que es necesario conocer como quedarán los perfiles de tensión, los intercambios de potencia y las reservas rodantes al instante de desincorporar momentáneamente un equipo para realizarle cualquier labor de mantenimiento preventivo o correctivo.

Al momento de defender esta tesis, el valor máximo de demanda del SADI fue de 29.105 MW ocurrido el 13 de marzo de 2023 a las 15:28, ver síntesis de marzo de [CNEA, 2023].

Una primera estimación de la demanda consiste en tener caracterizados días tipo, esta metodología se explica en la sección Pronóstico cuando se describen modelos subjetivos de predicción; en este caso es un modelo *persistente día de semana y condiciones meteorológicas tipo*. El mismo tiene la desventaja, de depender (como su nombre lo dice), del analista o personal que realiza la predicción. A pesar de que los analistas, que hacen el despacho de carga, tiene la experiencia necesaria para elaborar la previsión, muchas veces es posible que no consideren u omitan algunos detalles pues esta metodología a su vez depende de los partes meteorológicos (otro pronóstico), por lo que la incertidumbre de la predicción se propaga mucho más aún (sin tomar en cuenta posibles errores que pueda cometer el analista).

1.7. Estado del Arte

La previsión de la demanda de energía eléctrica desempeña un papel importante en la gestión de la oferta y la demanda de energía tanto para los gobiernos como para las empresas privadas. Es por ello, que el uso de modelos para pronosticar con precisión las tendencias futuras de consumo de energía, específicamente con datos no lineales, es un tema importante para los sistemas de producción y distribución de energía. En este sentido se han desarrollado varias técnicas, en las últimas décadas, alrededor del mundo, para predecir con precisión el futuro en el consumo de energía.

Resulta interesante citar el reciente trabajo recopilatorio de literatura especializada realizado por un grupo de investigadores de Ohio University [Ghalehkhondabi et al., 2016], quienes revisaron publicaciones especializadas en forma de artículos científicos en el periodo 2005-2015 sobre los modelos más utilizados a nivel mundial para la predicción eléctrica.

Este dossier ha servido como referencia para esbozar las diversas propuestas metodológicas para abarcar los objetivos planteados en esta tesis.

Se debe considerar que la precisión de cualquier pronóstico de demanda de potencia eléctrica está influenciada directamente por:

✓ Los datos disponibles, ✓ La metodología aplicada, y ✓ El horizonte a planificar.

A continuación se muestran diversos modelos, haciendo énfasis en los tres puntos planteados anteriormente y se citan trabajos de investigación y papers actuales:

- **Modelos de Energía Total Consumida:** En esta categoría se incluyen los modelos en los cuales la variable dependiente es el consumo total de energía a lo largo de un determinado período de tiempo, el cual, frecuentemente se refiere a un año, un trimestre o un mes. La mayoría de estos modelos se enfocan en una determinada unidad de consumo (demanda doméstica, comercial o industrial). Un ejemplo de este modelo puede ser el LEAP (Long-range Energy Alternatives Planning model) en donde se considera la demanda útil de diversas unidades de consumo y se puede comparar con cual tecnología y recursos puede ser cubierta. Un segundo ejemplo de aplicación de este tipo de modelos es el planteado en [Ortiz, 2015] mediante regresión adaptativa multivariante para sector residencial de Ecuador. Otro ejemplo es el propuesto por [Escobar et al., 2009] en Chile, en donde propone usar redes neuronales para el pronóstico mensual de Energía eléctrica Generada. El horizonte de predicción es de largo plazo y el error absoluto medio porcentual de $\pm 3\%$. El principal problema de este tipo de modelos es no considerar picos de demanda, parámetro de importancia, tanto para la generación como para el transporte de energía eléctrica.
- **Modelos de Pico de Demanda:** Estos modelos tienen un considerable interés para las empresas eléctricas ya que las puntas de carga o picos de demanda constituyen el fundamento de la planificación de capacidad generadora, y del calendario futuro de mantenimiento. El estudio de *pronóstico de energía y potencia eléctrica del sistema eléctrico nacional* debe contemplar escenarios bajos y altos de la demanda de potencia y consumo de energía en un período dado, tomando como referencia los valores máximos de demanda por lo que el resultado de la predicción es a largo plazo. Este tipo de análisis puede observarse en el trabajo de [Batahona, 2018] donde emplea series de tiempo pronosticar la demanda máxima de potencia en la Ciudad de Riobamba en el período 2017-2020. Por otro lado [Chen et al., 2004] en Taiwán, proponen usar *máquinas de vector de soporte* para pronosticar valores pico de demanda de potencia en un horizonte de 30 días. Otro ejemplo de este tipo de modelos es el WASP (Wien Automatic System Planning) auspiciados por el Organismo Internacional de Energía Atómica (OIEA) el cual es usado en planificación energética y tiene como input y output los valores máximos de potencia.
- **Modelos de Comportamiento de la Demanda en Múltiples Usuarios:** Este tipo de modelos requiere contar con información horaria de cada usuario dentro de la red y permite caracterizar los patrones de consumo de los mismos para definir factores como: tipo de usuario, demanda máxima coincidente, etc. Un ejemplo de aplicación de este tipo de modelos es el presentado por [Fabrégas et al., 2018] donde realizan un análisis de los consumos de energía de la región de Cataluña durante 2016. Al tratar con los datos de todos los clientes y contratos es necesario hacer uso de técnicas de minería de datos y de Big Data permitiendo conocer hábitos de consumo de los distintos tipos de clientes.

- **Modelos Econométricos:** En estos modelos la demanda futura se determina considerando la influencia de variables explicativas macroeconómicas (PIB, intercambios económicos, número de clientes, tarifas). Generalmente este tipo de modelos suelen ser los más complejos. Un ejemplo de aplicación de este tipo de modelos es el planteado en el trabajo de [Mishra et al., 2019] donde desde un enfoque ARIMA-Cópula, consideran como variables explicativas a la misma demanda de potencia eléctrica, a la generación eólica y a las tarifas. Es importante destacar que desde instituciones como el Organismo Internacional de Energía Atómica se auspician programas de planificación energética que siguen esta metodología, un ejemplo es el MAED (Model for Analysis of the Energy Demand). El MAED requiere de otros pronósticos a largo plazo, como la evolución de variables económicas, crecimiento de la población, un año base representativo, precios de los combustibles en todo el periodo de estudio, eficiencia de las tecnologías y mejoras en la intensidad energética de electrodomésticos, etc. A efectos de poder abordarlos se hace necesario realizar un análisis de sensibilidad, por lo que se deben plantear escenarios que van desde el escenario BaU (Business as Usual) hasta escenarios alternativos (optimistas y pesimistas) donde se modifiquen, de una a la vez (*Ceteris paribus*), las distintas variables que explican el modelo. Finalmente, es posible encontrar en la literatura trabajos que comparan las diversas metodologías, como se observa en el trabajo de [Şişman, 2016] donde comparan los resultados de modelos ARIMA con resultados del MAED, encontrando que el ARIMA presenta menor error en la predicción.
- **Modelos de Demanda Horaria:** Los modelos de esta categoría sirven para planificar el día a día en un despacho de carga. La meta de este trabajo especial de grado es encontrar un modelo fiable que sea útil al momento de programación diaria (y los esquema de generación). Ejemplo de este tipo de modelos es explicado en [Tabares and Hernández, 2009] para la región noroeste (Antioquia-Chocó) en Colombia. Por otra parte, [Martin, 2005] en Paraná, Brasil propone usar *máquinas de vector de soporte* para el pronóstico de la demanda de potencia eléctrica para el planeamiento y operación de sistemas eléctricos por día tipo. El horizonte de predicción que considera es de corto plazo y el error absoluto medio porcentual es de $\pm 1,63\%$ para los días de semana y $\pm 3,73\%$ para los fines de semana. Resultados similares fueron obtenidos por [Fattaheian-Dehkordi et al., 2014] quienes también usaron máquinas de vector de soporte y adicionaron la variable temperatura en una red inteligente en Teherán y mejoraron la predicción a un rango de $\pm 0,75\%$ y $\pm 1,46\%$ para días laborales y fines de semana respectivamente. Otra metodología propuesta por [Murillo et al., 2003] es hacer modelos ARIMA independientes para cada hora sin considerar otras variables explicativas. Finalmente, es importante destacar el trabajo presentado por [Mado et al., 2018] en Indonesia donde usan un modelo de series de tiempo que considera doble estacionalidad (DSARIMA) para el pronóstico de demanda de potencia eléctrica y obtuvieron pronósticos con un error de $\pm 2,06\%$, sensiblemente mejor que los resultados obtenidos por [Halepoto et al., 2014] mediante regresión lineal múltiple (condicionando temperatura) en Qasimabad, Pakistan cuyo pronóstico tuvo un error del $\pm 2,98\%$.

- **Modelos para Redespacho:** Estos modelos buscan recortar el horizonte de predicción para de esta forma llevar a cabo un despacho económico en las distintas horas del día. Un ejemplo de este tipo de modelos puede ser para considerar el redespacho de energía renovable intermitente, tal como se muestra en el trabajo de [Tarade and Katti, 2011] donde usa modelos ARIMA y redes neuronales para predecir la velocidad del viento y la generación eléctrica en parques eólicos. Por otra parte, [Herrera, 2007] en Quito, Ecuador propone usar Inteligencia Artificial (Razonamiento Inductivo Fuzzy -FIR- Y Algoritmos Evolutivos) para la reprogramación del parque hidro-térmico, con las consideraciones específicas de control de tensiones y despacho de potencia reactiva. El horizonte de predicción que usa es a muy corto plazo. Esta metodología actúa cada vez que en el redespacho se ve un error absoluto medio porcentual del $\pm 2\%$. Otro ejemplo de aplicación de estos modelos basados en inteligencia artificial es el presentado por [Blancas and Noel, 2018] donde emplean también lógica difusa para pronóstico en el corto plazo de energía eléctrica. Es importante destacar que con esta metodología los parámetros del modelo no son accesibles de forma explícita, por lo que no se sabe la influencia de cada uno de ellos en el resultado.
- **Modelos que Consideran Variables Climáticas de Forma Explícita:** Variables como la cantidad de luz solar en el día o la temperatura influyen de forma sensible en demanda, es por ello que estas variables, en caso de que se dispongan de los datos pueden y deben ser considerados, en modelos multivariantes, al momento de la previsión de demanda. Se pueden mencionar los trabajos de [Ismail et al., 2008] y [Molnar et al., 2016] quienes utilizan datos climáticos, horas de luz diaria e información industrial para hacer un modelo econométrico que permita predecir el pico diario de demanda en Malasia y la curva de carga diaria (demanda de energía eléctrica horaria) en Alemania respectivamente. Otros análisis similares pueden consultarse en [Valor et al., 2001] para el caso de España y en [Psiloglou et al., 2009] para las ciudades de Londres y Atenas. Es posible comparar este tipo de modelos con otros tal como lo hicieron [Gutiérrez, 2003] en Andalucía, España, quien propone usar modelos de series temporales multivariantes (suponer que la serie de demanda de potencia es función de la serie de temperatura) y contrastarlos con modelos econométricos. El horizonte de predicción que usa es de medio plazo, el error absoluto medio porcentual es de $\pm 23\%$. Para el caso de Argentina se pueden mencionar los documentos de trabajo del entonces Ministerio de Energía y Minería, realizados por [Zotelo, 2016] y [Mastronardi et al., 2016]. En estos últimos trabajos se proponen modelos diarios y al igual que los casos anteriores analizan una región específica y/o un tipo de usuario (generalmente residencial). Finalmente, en cuanto a modelos horarios que incorporen a la temperatura como variable explicativa se pueden mencionar [Fattaheian-Dehkordi et al., 2014] y [Halepoto et al., 2014] quienes con máquinas de vector de soporte el primero y regresión lineal múltiple el segundo, obtuvieron pronósticos con errores medios porcentuales de $\pm 1,46\%$ y $\pm 2,98\%$ respectivamente. Vale destacar que en ambos casos la región de estudio era acotada, (una smart grid y una ciudad respectivamente) por lo que una temperatura promedio, era representativa

de la región de estudio y además se disponían de datos de temperatura de forma horaria. En general es posible encontrar mucha literatura en donde se propone usar a la temperatura como variable explicativa de la demanda, pero luego el dato que se ofrece de input al modelo es un dato de promedio mensual de una estación meteorológica que no representa el lugar geográfico de la demanda[Vu et al., 2015].

Es importante destacar que muchos de los programas de planificación energética basados en optimización de la oferta bien sea para el despacho diario como el programa Juana usado por CAMMESA, así como para la planificación en el mediano/largo plazo, como el Oscar-Margo y MESSAGE, están pensados para usar datos de demanda como variable exógena, por lo que requieren como input externo la demanda de energía, así como tener previamente caracterizada la curva de demanda de potencia eléctrica, por lo que los resultados de este estudio más allá de permitir predecir la curva de demanda horaria también pueden ser usados para caracterizar la curva de demanda y usar estos resultados en programas de planificación energética que los necesiten.

Una vez establecido el problema, haber planteado los objetivos de la investigación y descrito el estado del arte lo que sigue es el desarrollo, en forma de capítulos de la metodología empleada, los resultados obtenidos y su análisis respectivo, así como las conclusiones arribadas y los eventuales trabajos futuros.

El capítulo 2 describe las distintas metodologías existentes para el estudio de series de tiempo. La metodología específica de Box - Jenkins es descrita en el capítulo 3.

De esta forma el Capítulo 4 presenta un panorama general del Sistema Argentino de Interconexión (SADI). Además, muestra de forma descriptiva como ha evolucionado la demanda de potencia eléctrica en el periodo de estudio 2001-2021 y se indica como es la estructura de los datos a procesar.

Mientras que el Capítulo 5 desarrolla la metodología descrita en el capítulo 3 para el caso específico de la demanda horaria de potencia eléctrica usando los datos de demanda del periodo enero 2018 a julio 2022.

El capítulo 6 presenta los resultados del modelo obtenido y se usa el mismo para predecir valores de demanda en 1 semana en los meses de febrero y marzo de 2022. Los valores de la predicción con el modelo de esta tesis serán usados para compararlos con los valores de la programación diaria de CAMMESA, a efecto de verificar que en los casos en que la programación diaria sobreestime la demanda, el contar con un modelo mejor ajustado a la predicción permitiría realizar un despacho de carga más ajustado y por un lado cubrir la totalidad de la demanda sin necesidad hacer racionamientos de energía y disminuir la compra de energía en mercado spot durante el redespacho; Por otra parte permitiría ahorrar en la remuneración a los generadores por concepto de potencia disponible y reserva rotante.

El Capítulo 7 presenta las conclusiones y recomendaciones para trabajos futuros.

Por último se presentan 2 secciones de anexos. El Anexo A explica con mayor detalle la prueba de raíz unitaria, que se usa para saber si una serie es integrada y en el Anexo B, se presenta la notación de operadores empleada en los capítulos 4 y 5.

Capítulo 2

Modelos de Análisis de Series de Tiempo

En este capítulo se aborda la importancia de poder predecir el valor futuro de una variable basado en un fundamento científico. Para ello se define el horizonte de tiempo a predecir, se describen los objetivos del estudio de las series temporales, y finalmente se presentan los principales métodos utilizados para el análisis de modelos lineales y no lineales.

2.1. Introducción

Desde los tiempos más remotos poder predecir eventos futuros ha fascinado al hombre. En los primeros relatos escritos, las referencias a la predicción del futuro son constantes. La predicción requiere de un estudio meticuloso de los sucesos pasados y las relaciones existentes entre ellos, para a partir de allí, intentar extrapolar un evento futuro.

Según historiadores clásicos, el primer hombre que fue capaz de realizar una predicción fundamentada sobre una base científica fue Tales de Mileto¹. Tales fue capaz de predecir un eclipse total de sol, ocurrido el 28 de mayo de 585 a.C. Es evidente, que la capacidad de predicción de Tales le venía de su estudio de las centenarias series de cronológicas de eclipses que habían registrado los astrónomos egipcios, en las que descubrió un patrón que se repetía en el tiempo.

Pero si en los tiempos de Tales de Mileto la predicción de un suceso natural fomentaba admiración general, hoy en día, con la tecnología disponible, la predicción de valores futuros de cualquier variable entra dentro de lo que podríamos catalogar como técnica cotidiana.

¹625 a.C. - 546 a.C. fue uno de los siete sabios de Grecia

El desarrollo de modelos de predicción ha sido, durante los últimos 60 años, un campo científico relativamente activo y en el que se han sucedido continuos avances. La búsqueda de la relación existente entre el valor actual de una variable y los valores pasados de la misma, o de otras variables que puedan influir sobre el valor de la primera, constituye una de las bases del desarrollo de modelos de predicción. La suposición de que entendiendo las relaciones entre los datos del pasado, se podrá extrapolar el comportamiento futuro, es la idea que subyace en todos los modelos de predicción.

La metodología con la que se estimará la demanda de potencia Eléctrica en Argentina en el corto plazo con un horizonte de 24 horas, en periodos diarios, con paso horario, es por medio de un modelo de series temporales. Este método de predicción se basa en el modelo estadístico SARIMA (Promedio móvil integrado auto regresivo y estacional). La novedad de esta metodología es que permite tener un solo modelo diario independiente de si es día de semana o fin de semana, a diferencia de modelos horarios como los presentados por [Murillo et al., 2003] donde se hace un modelo para cada hora.

Cuando hablamos de una secuencia de valores observados a lo largo del tiempo, y por tanto ordenados cronológicamente en periodos de tiempo generalmente regulares, la denominamos, en un sentido amplio, SERIE TEMPORAL. El análisis de una serie cronológica consiste en hacer uso de estos datos para elaborar un modelo que describa y reproduzca adecuadamente el comportamiento de esta variable en el pasado y permita realizar predicciones satisfactorias. Resulta difícil imaginar una rama de la ciencia en la que no aparezcan datos que puedan ser considerados como series temporales.

Los pronósticos de series temporales pueden ser utilizados en diversas aplicaciones importantes entre las que se pueden mencionar: series en economía (Índice de la bolsa de valores, intercambios económicos, evoluciones de precios de mercado); en física (temperatura, índice pluviométrico, demanda de potencia eléctrica) y en matemática (secuencia de Fibonacci, ecuaciones diferenciales e integrales). Estos datos contenidos en una serie temporal se deben etiquetar por un índice correspondiente al número de observación (número del instante en el que fue tomado el valor); así, suponiendo una serie temporal X , está vendría expresada de la siguiente forma:

$$X = \{X_1, X_2, X_3 \dots\} \quad (2.1)$$

Si, conocidos los valores pasados de la serie, no fuera posible predecir con total certeza el próximo valor de la variable, decimos que la serie es no determinista o aleatoria, y lógicamente es de éstas de las que se ocupa el cuerpo de doctrina denominado *análisis de series temporales*.

El análisis estadístico de series temporales se usa hoy día con bastante naturalidad en muchas áreas de la ciencia, fundamentalmente en economía, física e ingeniería.

La predicción de un valor futuro de una serie temporal significa determinar los valores que tomará la variable justo después del ultimo valor registrado. Dicha determinación del valor futuro de la variable puede realizarse desde dos perspectivas:

- La predicción de los valores se puede realizar por extrapolación de los valores pasados.
- Se puede establecer un modelo matemático que explique las relaciones entre los valores de la variable en el pasado y utilizar ese modelo para predecir los valores futuros de la variable.

Esta tesis se centra en la segunda perspectiva, la de extraer información del pasado. Luego se presenta el modelo que mejor explique las relaciones entre los valores pasados de la variable, para ser utilizado posteriormente en la predicción de los valores futuros.

2.2. Horizonte de Predicción

El desarrollo de cualquier modelo de predicción debe contemplar, desde el primer momento del diseño, el horizonte de predicción, esto es, el periodo de tiempo (contabilizado desde un instante determinado en que se realiza la predicción), que determina el momento futuro para el que se realizarán las predicciones. No existe unanimidad en cuanto a cuáles son las fronteras que separan una clasificación de otra; es más, la mayoría de los autores de artículos relacionados con el tema rehuyen cuantificar los términos, y los que si lo hacen, dan valores diferentes, en especial para la predicción a corto plazo. Según [Gutiérrez, 2003] básicamente, se pueden considerar tres horizontes temporales para la predicción de la demanda de energía eléctrica:

- **Predicción a corto plazo:** Se suele subdividir en muy corto plazo y corto plazo propiamente dicho.
 - *A muy corto plazo:* Se suele considerar que el primero de tales periodos abarca los próximos 30 minutos en un tiempo real a partir del momento en que se efectúa la predicción de la demanda. El principal objetivo a cubrir en este período de tiempo es la distribución, de la forma más segura posible, entre los diversos recursos de generación disponibles. Realmente se trata de realizar el seguimiento de la carga y de la predicción inmediata de ésta basándose en los datos. Si se reduce el horizonte de predicción, también disminuyen los errores de predicción.
 - *A corto plazo:* El horizonte de predicción abarca desde el límite con el muy corto plazo hasta una semana en el futuro. Esta predicción es la de mayor interés para poder actuar en el despacho de carga diario (previsión de la demanda). La empresa eléctrica en este periodo debe ocuparse principalmente del mantenimiento previamente establecido de las unidades de transmisión y sistemas de transporte de energía así como de la operación diaria de su equipo generador. Asimismo la empresa eléctrica junto con el ente centralizado debe llevar a cabo la coordinación hidrotérmica, el despacho económico, la asignación de unidades generadoras y la gestión de la carga. Los datos en los que se basa esta predicción en este periodo son la carga diaria y la información de la temperatura en la misma

época de los años recientes del pasado. La predicción de la punta de potencia diaria suele tener lugar también para la próxima semana. En este horizonte temporal de corto plazo es importante, tanto una predicción lo más exacta posible de la demanda para determinar qué generadores deberían ser puestos en funcionamiento y cuáles deberían permanecer en reserva. Es importante contar con una adecuada predicción de los factores climáticos (temperatura, humedad, etc.) y de su variabilidad para de esta forma poder considerarlos.

- **Predicción a medio plazo:** Se suele entender como el periodo de predicción que se extiende en el futuro desde un mes hasta un año a partir del momento en que se efectúa el pronóstico. Esta predicción es necesaria, generalmente, para establecer el calendario de mantenimiento de las plantas generadoras y sistemas de transmisión. Los datos básicos para realizar esta predicción son los datos mensuales de punta de carga a lo largo de varios años, así como la energía demandada y temperatura registrada en ellos. Se tienen en cuenta los indicadores socio económicos y los picos de carga. La energía demandada mensualmente se predice en el horizonte temporal de un año. En este período, las compañías eléctricas se enfrentan al problema de cubrir una estructura de la demanda cualitativa y cuantitativa potencialmente cambiante que han de satisfacer con una capacidad generadora que es esencialmente fija o determinada.
- **Predicción a largo plazo:** Es el período de predicción que abarca desde uno a diez años en el futuro. Puesto que el tiempo necesario para planificar, construir, probar y poner en funcionamiento nueva capacidad generadora puede oscilar entre tres y diez años, un modelo econométrico puede resultar muy adecuado en este horizonte temporal de largo plazo y, cuanto más exactas sean sus predicciones, mayor es la probabilidad de satisfacer los picos de carga (puntas en la demanda) y mejorar el factor de carga². Esta predicción de largo plazo se necesita, generalmente, para la planificación del sistema generador y del sistema de transmisión o transporte, ya que una modelización y predicción adecuada a largo plazo de la demanda puede anticipar la capacidad de generación óptima y la combinación o mezcla de potencia generadora más conveniente con que se debe contar (posiblemente mediante nuevas adquisiciones) el parque generador. Los datos para la elaboración de la demanda a largo plazo suelen ser, además de los mencionados anteriormente (pero con periodicidad anual), el precio de la electricidad, la evolución demográfica, así como los indicadores económicos más importantes.

Hay que recordar que cuanto mayor sea el horizonte, mayor será el rango de incerteza en la predicción.

²El factor de carga durante un periodo determinado se define como la razón de la potencia media demandada a la potencia máxima durante dicho periodo

2.3. Pronóstico

En muchas ocasiones se dispone de otras informaciones que pueden ser útiles en la determinación de valores futuros de una variable, de la que se dispone de una serie temporal. La variable que tratamos de predecir puede ser función de otras variables cuyos valores se pueden conocer, lo que las hace variables *explicativas* de la variable a predecir. En función de que se use, o no, esa información con los valores de las posibles variables explicativas, se pueden distinguir dos métodos (univariante y multivariante); Adicionalmente se añade otro método de pronóstico también válido pero menos formal que depende de la experiencia de quien realiza el pronóstico; Así, los métodos de pronóstico pueden ser clasificados en tres grupos [Martin, 2005]:

Subjetivo: Es una metodología que utiliza datos cualitativos para obtener resultados que permiten efectuar argumentos intuitivos a partir de la evolución de escenarios capaces de indicar valores futuros para las variables desconocidas del problema. Ellos se basan en la experiencia empírica y varían dependiendo de la aplicación; son simples y fáciles de usar pero no siempre muy precisos como los métodos formales. En el caso particular de este estudio se pueden mencionar algunos modelos básicos.

- **Modelo Persistente:** La potencia eléctrica demandada en las próximas 24 horas es igual a la demandada en las últimas 24 horas.
- **Modelo Persistente día de semana y condiciones meteorológicas tipo:** La potencia eléctrica demandada en las próximas 24 horas es igual a la demandada en las 24 horas del último día tipo cuyas condiciones meteorológicas coincidan con el parte meteorológico del día en cuestión. Ejemplo: la demanda del próximo martes (cuyo parte meteorológico indica que será soleado) debe ser parecida a la demanda del último martes soleado.

Univariante: también conocido como series temporales, este método pretende establecer la relación entre los propios valores del pasado de la variable a predecir. Una vez que se establece la relación, con este modelo se realizan proyecciones hacia el futuro para cumplir con el objetivo de toda predicción, obtener valores futuros. Matemáticamente, el valor de un futuro inmediato de la variable a predecir es función de sus propios valores pasados:

$$X_{t+1} = f(X_t, X_{t-1}, \dots, X_{t-d}) \quad (2.2)$$

Multivariante: también conocidos como métodos causales, es un método cuyo propósito es establecer una relación entre los valores del pasado de la variable a predecir y los valores, también pasados, de las posibles variables explicativas. Una vez establecida la relación (determinado el modelo) se puede usar para predecir valores futuros de la

variable a predecir. En el caso más general de los métodos multivariante, el valor futuro de la variable a predecir puede ser función de los valores pasados de la propia variable, de los valores pasados y futuros de las variables explicativas; matemáticamente se expresa:

$$X_{t+1} = f(X_t, X_{t-1}, \dots, X_{t-d}, u_{t+1}, u_t, u_{t-1}, \dots, u_{t-m}, v_{t+1}, v_t, v_{t-1}, \dots, v_{t-n}) \quad (2.3)$$

2.4. Objetivos del Análisis de Series de Tiempo

Los objetivos del análisis de series temporales son diversos, pudiendo destacar la predicción, el control de un proceso, la simulación de procesos, y la generación de nuevas teorías físicas o biológicas.

- Se denomina **predicción** a la estimación de valores futuros de la variable en función del comportamiento pasado de la serie. Este objetivo se emplea ampliamente en el campo de la ingeniería y de la economía. En este trabajo se empleara la predicción mediante modelos basados en la teoría de series temporales, ya que permite una buena planificación de los recursos energéticos, en función de la demanda que se espera en el futuro, prevista por el modelo. Otro de los campos en los que se aplica la predicción mediante series temporales es el de la *meteorología* o en la predicción de otros fenómenos naturales.
- En la teoría de **control de procesos**, se trata de seguir la evolución de una variable determinada con el fin de regular su resultado. Esta teoría se utiliza en este trabajo, por ejemplo en el seguimiento de la previsión en tiempo real.
- La **simulación** se emplea en investigación aplicada, cuando el proceso es muy complejo para ser estudiado de forma analítica. En el ámbito de este trabajo se emplea cuando se desea saber el impacto que genera emitir un permiso a un determinado equipo del sistema de potencia.

Evidentemente aunque el valor futuro de una serie temporal no sea predecible con total exactitud, para que tenga interés su estudio, el resultado tampoco puede ser completamente aleatorio, existiendo alguna regularidad en cuanto a su comportamiento en el tiempo, lo que hará posible su modelado y por ende, en su caso, la predicción. La búsqueda de regularidades y de patrones ha sido siempre una de las tareas básicas de la ciencia, y muchas veces se descubren simetrías que sirven de fundamento para la predicción del comportamiento de los fenómenos, incluso antes de que se entienda la razón o causa que justifica esa regularidad. Esto ocurrió, por ejemplo, con el sistema periódico de los elementos, descrito por Mendeleiev³, quien ordeno, basado en propiedades semejantes y relaciones de masa, de

³Químico ruso(1834-1907), creador de la tabla periódica de los elementos.

forma muy correcta los elementos químicos en base a las simetrías observadas entre ellos, antes de que se comprendiese la razón de esas simetrías o periodicidad, razones que luego se fundamentaron sobre todo en trabajos de Schrödinger⁴ y Pauli⁵.

Por lo tanto, si se pueden encontrar patrones de regularidad en diferentes secciones de una serie temporal, se puede también describirlas mediante modelos basados en distribuciones de probabilidad. La secuencia ordenada de variables aleatorias $X(t)$ y su distribución de probabilidad asociada, se denomina **proceso estocástico**. Un proceso estocástico es por tanto el modelo matemático para una serie temporal.

Un concepto importante que encontramos en este ámbito, es el de procesos estacionarios. Si examinamos por ejemplo la temperatura para un determinado mes a lo largo de los años en una determinada zona geográfica, y se está produciendo un cambio climático, aunque haya fluctuaciones, habrá una tendencia creciente. De una manera informal, diremos que una serie es *estacionaria* cuando se encuentra en equilibrio estadístico, en el sentido de que sus propiedades no varían a lo largo del tiempo, y por lo tanto no pueden existir tendencias. Un proceso es *no-estacionario* si sus propiedades varían con el tiempo, como el clima.

2.5. Descripción de los Modelos

Los modelos utilizados para la predicción de valores a partir de series de tiempo pueden ser clasificados en modelos lineales y no lineales.

A continuación se muestra las diferentes técnicas o modelos de análisis de series de tiempo:

- Modelos lineales
 - Regresión Lineal
 - ARIMA y sus variantes, también conocida como Box-Jenkins
 - Filtro de Kalman
- Modelos no lineales
 - Las Redes Neuronales Artificiales
 - Maquinas de Vector de Soporte
 - Los Sistemas de Interferencia Difusa

⁴Físico austríaco(1887-1961), desarrollo la ecuación que lleva su nombre.

⁵Físico austríaco (1900-1958), padre fundador de la mecánica cuántica con el principio que lleva su nombre.

2.5.1. Modelos Lineales

Un **proceso lineal** se puede clasificar como aquel donde el valor actual de la serie temporal puede ser expresado como función lineal de valores presentes y pasados de un proceso puramente aleatorio. De la misma forma un método de pronóstico lineal es aquel en donde los valores pronosticados del futuro pueden ser expresados como función lineal de valores observados, incluido el instante presente [Martin, 2005].

La definición estadística de un sistema lineal, es aquella donde se considera respuestas de tipo $y_1(t)$; $y_2(t)$, continuas en el tiempo, las cuales corresponden a las señales de entrada $x_1(t)$; $x_2(t)$. Una propiedad de los sistemas lineales es que la combinación lineal de dos valores de entrada deben reproducir la salida. Así; $\lambda_1 x_1(t) + \lambda_2 x_2(t)$ debe producir la salida $\lambda_1 y_1(t) + \lambda_2 y_2(t)$, donde λ_1 y λ_2 son cualquier constante.

Es bastante posible encontrar modelos que son localmente lineales aunque de forma global sean no lineales. La definición exacta de linealidad no es fácil de precisar, sin embargo es posible partir de un modelo *lineal* y convertirlo poco a poco en *no lineal*.

Regresión Lineal

En estadística la regresión lineal o ajuste lineal es un método matemático que modeliza la relación entre una variable dependiente y, las variables independientes x_i y un término aleatorio a . Este modelo puede ser expresado como:

$$y(t) = a_0 + a_1 x_1(t) + \dots a_n x_n(t) + a(t) \quad (2.4)$$

donde:

$y(t)$: Demanda

$x_i(t)$: Variable correlacionada (temperatura, tipo de día, etc)

a_i : Coeficientes de regresión

$a(t)$: Variable aleatoria (media cero y varianza constante)

ARIMA y sus variantes

En estadística y econometría, en particular en series temporales, un modelo autorregresivo integrado de media móvil o ARIMA (por sus nombre en inglés, autoregressive integrated moving average) es un modelo estadístico que utiliza variaciones y regresiones de datos estadísticos con el fin de encontrar patrones para una predicción hacia el futuro. Este modelo fue desarrollado a finales de los 60's. Box y Jenkins (1976) lo sistematizaron.

ARIMA puede determinar dos cosas:

- Cuánto del pasado se debe utilizar para predecir la siguiente proyección.
- Valores de las series.

ARIMA necesita identificar los coeficientes y número de regresiones que se utilizarán. Este modelo es muy sensible a la precisión con que se determinen sus coeficientes.

ARIMA es un modelo (p,d,q) en donde:

p: Autorregresión
d: Integración o Diferenciación
q: Media Móvil

Un modelo ARIMA (autoregressive integrated moving average) es un modelo dinámico de series de tiempo, es decir las estimaciones futuras vienen explicadas por los datos del pasado y no por variables independientes. Un caso particular es el modelo AR(p) = ARIMA (p,0,0) se puede representar como:

$$X_t = c + \sum_{i=1}^p \varphi_i X_{t-i} + \varepsilon_t \quad (2.5)$$

en donde $\varphi_1, \dots, \varphi_p$ representa los parámetros del modelo, c es una constante, y ε_t es el término de error (llamados también innovaciones).

Luego se define un modelo SARIMA (seasonal autoregressive integrated moving average), como un modelo Arima que además considera el efecto de la estacionalidad.

Filtro de Kalman

Es un algoritmo que sirve para poder identificar el estado oculto (no medible) de un sistema dinámico lineal incluso cuando el sistema está sometido a ruido blanco aditivo.

$$x(k+1) = \phi(k) * z(k) + W(k) \quad (2.6a)$$

$$f(t) = H(k) * x(k) + v(k) \quad (2.6b)$$

donde:

$\mathbf{x}(\mathbf{k})$: Variación del vector de estado

$\mathbf{W}(\mathbf{k})$: Ruido blanco con matriz de la varianza conocida

$\mathbf{z}(\mathbf{k})$: Variación de la medición del vector

$\phi(\mathbf{k})$: Matriz de transición

$\mathbf{H}(\mathbf{k})$: Matriz de correlación

$\mathbf{v}(\mathbf{k})$: Error

2.5.2. Modelos No Lineales

Muchas veces inicialmente es más útil simular (debido a la formulación matemática y la facilidad computacional), un proceso de forma lineal y luego convertirlo *gradualmente*⁶ en no lineal. Esto se hace debido a que muchas de las series que son de interés de análisis tienen comportamiento no lineal, por lo que se hace necesario utilizar otras técnicas fuera de las clásicas para realizar la predicción de éstas y así obtener modelos más eficientes.

Las Redes Neuronales Artificiales

Es un conjunto de procesadores elementales interconectados, no lineal ni estacionario, que realiza al menos alguna de las siguientes funciones: Aprendizaje, Memorización, Generalización o Abstracción de características esenciales, a partir de un conjunto de ejemplos [Escobar et al., 2009]. Son modelos no lineales eficientes que tienen la capacidad de aprender, identificar y aproximar. Las RNA son una rama de la inteligencia artificial que consiste en el aprendizaje y procesamiento automático, inspirado en la forma en que funciona el sistema nervioso biológico. El objetivo de la utilización de las redes neuronales, es conseguir respuestas similares a las que es capaz de conseguir el cerebro, que se caracterizan por su generalización y robustez, un ejemplo de este tipo de modelos aplicado a pronóstico de demanda de potencia puede observarse en el trabajo de [Sanjinés, 2011] donde realiza un Análisis y pronóstico de la demanda de potencia eléctrica en Bolivia combinando modelos de series de tiempo SARIMA con redes neuronales.

Maquinas de Vector de Soporte

Son modelos de aprendizaje universal en los que no es necesario determinar a priori el numero de neuronas en la primera capa de la red neural, sino que se definen a lo largo del proceso de aprendizaje. Así, la máquina depende de un subconjunto de datos de

⁶hasta donde la matemática sea sencilla

entrenamiento que sirven como vectores soporte para, presentando una característica estable en el conjunto de datos de entrenamiento. Estos modelos se basan en la teoría estadística de aprendizaje.

Los Sistemas de Interferencia Difusa

Esta metodología combina la modelación cualitativa, la cual determina el grupo de variables de entrada que mejor describen el comportamiento entrada-salida de los datos de entrenamiento mediante la identificación de máscaras de correlación (máscaras óptimas) y la simulación cualitativa que compara los datos de prueba con sus **k** vecinos más cercanos (k-NN *k Nearest Neighbors*) de la base de datos de entrenamiento e interpola entre las salidas previamente observadas. Es decir, aprende y analiza los patrones observados de las señales medidas para luego predecir el comportamiento futuro en base a su conocimiento del pasado.

Capítulo 3

Modelado Clásico de Series Temporales

En este capítulo se detallará los contenidos sobre el modelado clásico de las series temporales que se usaran en esta tesis de maestría y que definirán el marco teórico.

Siguiendo la metodología planteada por [Box et al., 1976] y [Chatfield, 2003] a continuación se describen los pasos que se deben hacer estudiar una serie de tiempo:

- El primer paso obligatorio para analizar una serie temporal es presentar un gráfico de la evolución de la variable a lo largo del tiempo.
- El siguiente paso consistirá en determinar si la secuencia de valores es completamente aleatoria o si, por el contrario, se puede encontrar algún patrón a lo largo del tiempo, pues sólo en este caso podremos seguir con el análisis.

La metodología tradicional para el estudio de series temporales es muy sencilla de comprender, y se basa en descomponer las series en varias partes: variación estacional o periódica, tendencia y otras fluctuaciones irregulares. ***El orden en que se descomponga la serie es independiente, debido a que cada parte se encontrará representada en el modelo mediante un operador matemático que es conmutativo en la multiplicación, el producto de esos operadores permite obtener el polinomio que representa al modelo Box-Jenkins de la serie de tiempo.***

- **Estacionalidad:** Corresponde a fluctuaciones periódicas de la variable, en periodos relativamente cortos de tiempo.
- **Tendencia:** Es la dirección general de la variable en el periodo de observación, es decir el cambio a largo plazo de la media de la serie.

- **Otras fluctuaciones irregulares:** Después de extraer de la serie la tendencia y variaciones cíclicas, nos quedará una serie de valores residuales, que pueden ser o no totalmente aleatorios. Volvemos a estar como en el punto de partida, pues ahora también nos interesa determinar si esa secuencia temporal de valores residuales puede o no ser considerada como aleatoria pura.

Una vez que se aplica un proceso clásico de descomposición mediante un procedimiento de análisis de: la estacionalidad y la tendencia se obtiene las siguientes series:




Figura 3.1: Descomposición de una serie temporal en sus componentes

Análisis de la estacionalidad:

Para analizar la estacionalidad de una serie introduciremos un concepto de gran interés en el análisis de series temporales: la **función de autocorrelación**.

La función de autocorrelación mide la correlación entre los valores de la serie distanciados un lapso de tiempo k .

Recordemos la fórmula del coeficiente de correlación simple, dados N pares de observaciones y , x :

$$r = \frac{\sum (y_i - \bar{y})(x_i - \bar{x})}{\sqrt{\sum (y_i - \bar{y})^2 \cdot \sum (x_i - \bar{x})^2}} \quad (3.1)$$

De igual forma, dada una secuencia temporal de N observaciones $x_1 \dots x_N$, podemos formar $N-1$ parejas de observaciones contiguas $(x_1, x_2), (x_2, x_3), \dots (x_{N-1}, x_N)$ y calcular el coeficiente de correlación de estas parejas. A este coeficiente lo denominaremos **coeficiente de autocorrelación** de orden 1 y lo denotamos como r_1 .

Análogamente se pueden formar parejas con puntos separados por una distancia 2, es decir $(x_1, x_3), (x_2, x_4)$, etc. y calcular el nuevo coeficiente de autocorrelación de orden 2. De forma general, si preparamos parejas con puntos separados una distancia k , calcularemos el coeficiente de autocorrelación de orden k .

Al igual que para el coeficiente de correlación lineal simple, se puede calcular un error estándar y por tanto un intervalo de confianza para el coeficiente de autocorrelación.

La **función de autocorrelación** es el conjunto de coeficientes de autocorrelación r_k desde 1 hasta un máximo que no puede exceder la mitad de los valores observados, y es de gran importancia para estudiar la estacionalidad de la serie, ya que si ésta existe, los valores separados entre sí por intervalos iguales al periodo estacional deben estar correlacionados de alguna forma. Es decir que el coeficiente de autocorrelación para un retardo igual al periodo estacional debe ser significativamente diferente de 0.

Relacionada con la función de autocorrelación nos encontramos con la **función de autocorrelación parcial**. En el coeficiente de autocorrelación parcial de orden k , se calcula la correlación entre parejas de valores separados esa distancia pero eliminando el efecto debido a la correlación producida por retardos anteriores a k .

Los intervalos de confianza de las funciones de autocorrelación y autocorrelación parcial vendrán dados por $\pm \frac{1.96}{\sqrt{N}}$, donde N es el número de observaciones. Los intervalos de confianza ayudan a detectar los valores significativos y su posición en el eje X nos indica la probable presencia de un factor de estacionalidad para ese valor de retardo.

Análisis de la tendencia:

Como ya se menciono hace un momento, una primera idea sobre la presencia de tendencia en la serie la obtendremos en su representación gráfica.

Los medios más utilizados para detectar y eliminar la tendencia de una serie se basan en la aplicación de **filtros** a los datos. Un filtro no es más que una función matemática que aplicada a los valores de la serie produce una nueva serie con unas características determinadas. Entre esos filtros encontramos las **medias móviles**.

Una media móvil se calcula, para cada punto, como un promedio del mismo número de valores a cada lado de ese punto. Así una media móvil de tres puntos se calcula como:

$$m(x_t) = \frac{x_{t-1} + x_t + x_{t+1}}{3} \quad (3.2)$$

Mientras que una media móvil de cuatro puntos viene dada por:

$$m(x_t) = \frac{\frac{x_{t-2}}{2} + x_{t-1} + x_t + x_{t+1} + \frac{x_{t+2}}{2}}{4} \quad (3.3)$$

Cuando la cantidad de puntos de la media móvil es par, se toma la mitad de los valores extremos.

Existen otros procedimientos para extraer la tendencia, como **ajuste de polinomios**, **alisado mediante funciones exponenciales**, etc. Una clase de filtro, que es particularmente útil para eliminar la tendencia, se basa en aplicar **diferencias** a la serie hasta convertirla en estacionaria. Una diferencia de primer orden se obtiene restando dos valores contiguos:

$$\nabla x_{t+2} = x_{t+1} - x_t \quad (3.4)$$

Si volvemos a diferenciar esa serie, restando los nuevos valores consecutivos obtenemos una nueva serie más suavizada:

$$\nabla^2 x_{t+2} = \nabla x_{t+2} - \nabla x_{t+1} \quad (3.5)$$

3.1. Metodología Box-Jenkins: modelos ARIMA

A comienzo de los años 70, G.E.P. Box, profesor de Estadística de la Universidad de Wisconsin, y G.M. Jenkins, profesor de Ingeniería de Sistemas de la Universidad de Lancaster, introdujeron una pequeña revolución en el enfoque del análisis de series temporales en sus trabajos sobre el comportamiento de la contaminación en la bahía de San Francisco, con el propósito de establecer mejores mecanismos de pronóstico y control. El libro *Time Series Analysis: Forecasting and Control* [Box et al., 1976], en el que describen la metodología, se convirtió rápidamente en un clásico, y sus procedimientos desde entonces se utilizan ampliamente en diferentes ramas de la ciencia, conociéndose como modelos ARIMA y también como *modelos Box-Jenkins*.

Para este tipo de modelos, es necesario descomponer la serie en sus componentes (estacional o cíclica, tendencia y por último variable aleatoria). No hay una única forma de iniciar el proceso de descomposición, en el trabajo original de [Box et al., 1976], al tratarse de un modelo ARIMA (en contraste en modelos SARIMA se suele iniciar eliminando la componente cíclica), el primer paso propuesto consiste en convertir la serie de observaciones en una **serie estacionaria**, que es aquella en la que ni la media, ni la varianza, ni las autocorrelaciones dependen del tiempo, (en la sección Estacionariedad de la Serie se hablara un poco más sobre estas propiedades).

Una vez *estabilizada* la serie mediante las transformaciones adecuadas, se procede a estudiar la presencia de regularidades en la serie, para identificar un posible modelo matemático. Para ello se calculan la función de autocorrelación simple y parcial, y se compara su forma *con un catálogo de patrones gráficos, que son típicos de los diferentes modelos propuestos*, seleccionando el modelo que más se adecuó a la forma de las funciones de autocorrelación que se has obtenido con los datos analizados.

Una vez elegida la forma del modelo, se estiman los coeficientes del mismo, y finalmente se procede a efectuar un análisis de los residuos (diferencia entre el valor realmente observado y el valor previsto por el modelo), con el fin de comprobar si el ajuste del modelo a nuestros datos es adecuado. Si no lo fuera repetimos el proceso buscando otros modelos.

Una vez determinado un modelo suficientemente válido, sobre la serie estacionaria, procedemos a deshacer la transformación inicialmente efectuada para estabilizar la serie, y ahora comprobamos si los pronósticos del modelo son adecuados con nuestros datos, volviendo a comenzar la búsqueda de otro modelo si no fuera el caso. Puede por tanto tratarse de un proceso iterativo de mejora del modelo.

En el modelo, cada valor tomado por la variable en un instante dado, está influido por los valores de la variable en momentos anteriores, y se expresa como una relación lineal, función de:

1. Valores recientes de la variable
2. Ruidos en valores recientes de la variable
3. Valores remotos de la variable
4. Ruidos en valores remotos de la variable

El esquema general del modelo es el siguiente:

$$Z_t = c + \phi_1 Z_{t-1} + \phi_2 Z_{t-2} + \dots + \phi_p Z_{t-p} + a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q} \quad (3.6)$$

que es la fórmula general de los modelos denominados **ARMA**. Está constituido por una combinación de p términos **AR** (proceso autorregresivo), y q términos **MA** (proceso de

medias móviles). La parte AR modela la influencia de los valores anteriores de la serie (Z_{t-1} hacia atrás), y la parte MA modela la influencia del ruido en valores anteriores de la serie (a_{t-1} hacia atrás), junto con el término a_t que corresponde al ruido esperado en el mismo momento t en el que se estima el nuevo valor de la variable X .

Escrito en notación de operadores de retardos se tiene:

$$\phi_p(B)Z_t = c + \theta_q(B)a_t \quad (3.7)$$

donde los polinomios característicos de la parte AR (3.8a) y MA (3.8b) del modelos son:

$$\phi_p(B) = 1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p \quad (3.8a)$$

$$\theta_q(B) = 1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q \quad (3.8b)$$

Una de las ventajas de estos modelos es su gran simplicidad (sumas de términos), frente a los modelos propuestos en la formulación clásica.

La letra I que aparece en el nombre del modelo completo **-ARIMA-**, corresponde al último proceso a realizar, una vez definido el tipo de modelo y estimados los coeficientes de éste, ya que entonces hay que restablecer las características originales de la serie de datos que fue transformada para inducir la estacionariedad.

A ese proceso inverso se denomina en general **I**ntegración y aporta esa letra que completa el nombre y la representación en notación de operadores es la siguiente.

$$\phi_p(B)\nabla^d Z_t = c + \theta_q(B)a_t \quad (3.9)$$

donde ∇^d es el operador diferencia (ver Apéndice D.2 El operador diferencia) y d es el orden de integración.

3.1.1. Definición y consecuencias de la estacionariedad e invertibilidad

Estacionariedad:

Se dice que un proceso estocástico es *estacionario* si todas las raíces de la ecuación característica $1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p = 0$, están fuera del círculo de radio unidad del plano complejo.

La condición de estacionariedad sólo afecta a la componente AR del proceso ARIMA, ya que la componente MA siempre es estacionaria.

Cuando el polinomio AR tiene alguna raíz igual a uno, se dice que tiene *raíces unitarias*.

Consecuencias del cumplimiento:

- El proceso tiene media y varianza incondicionales finitas y estables.
- El proceso puede escribirse en forma MA equivalente.

Consecuencias del no cumplimiento (raíces unitarias):

- La varianza incondicional diverge a infinito.
- Si tiene deriva, la media incondicional diverge a infinito.
- El factor AR puede factorizarse separando las raíces unitarias de las raíces estacionarias.

Invertibilidad

Se dice que un proceso estocástico es *invertible* si todas las raíces de la ecuación característica $1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q = 0$, están fuera del círculo de radio unidad del plano complejo.

La condición de invertibilidad solo afecta a la componente MA del proceso ARIMA, ya que la componente AR siempre es invertible.

Consecuencias del cumplimiento:

- El proceso puede escribirse en forma AR equivalente.

Consecuencias del no cumplimiento (raíces unitarias):

- El proceso podría simplificarse, bien eliminando una diferencia; o bien representando la tendencia de forma determinista.

Representaciones alternativas:

Cuando un proceso estocástico no tiene raíces AR ni MA dentro del círculo de radio unidad, puede escribirse de forma equivalente como $AR(\infty)$ o $MA(\infty)$.

3.1.2. Estacionalidad

Muchas series a menudo muestran un *comportamiento estacional*, esto es, una pauta que se repite con una periodicidad fija, a menudo diario, mensual o anual.

El período estacional (S) se define como el número de observaciones necesarias para recorrer todo el ciclo estacional. Por ejemplo, $S=12$ para datos mensuales, $S=24$ para datos horarios, etc.

Para captar este comportamiento, se define el modelo ARIMA $(p, d, q)x(P, D, Q)_S$:

$$\phi_p(B)\Phi_P(B^S)\nabla_S^D\nabla^d Z_t = c + \theta_q(B)\Theta_Q(B^S)a_t \quad (3.10)$$

que incluye 3 nuevos factores, la ec. (3.11a) muestra el polinomio AR estacional, la ec. (3.11b) el polinomio MA estacional y la ec. (3.11c) es el operador diferencia estacional:

$$\Phi_P(B) = 1 - \Phi_1 B^S - \Phi_2 B^{2 \cdot S} - \dots - \Phi_P B^{P \cdot S} \quad (3.11a)$$

$$\Theta_Q(B) = 1 - \Theta_1 B^S - \Theta_2 B^{2 \cdot S} - \dots - \Theta_Q B^{Q \cdot S} \quad (3.11b)$$

$$\nabla_S \equiv 1 - B^S \quad (3.11c)$$

Este tipo de modelos que admiten relaciones entre un dato y el de S períodos atrás se conocen como SARIMA.

3.2. Ventajas y Desventajas de modelos ARIMA

3.2.1. Ventajas:

- Proporcionan intervalos de confianza en sus predicciones con una base estadística fiable.
- Debido a que son modelos ampliamente difundidos en los ámbitos de predicción económica, es bastante fácil encontrar paquetes computacionales para su desarrollo.

3.2.2. Desventajas:

- Como son modelos lineales se hace difícil modelar suficientemente bien todos los problemas ya que la mayoría de los problemas sociales y económicos presentan características de no linealidad.
- Son modelos muy sensibles a outliers¹ lo que obliga a revisar la serie temporal para detectarlos y corregirlos antes de diseñar el modelo de predicción. En esta tesis cuando se modela la demanda de potencia por día de semana se debe tener cuidado con los días feriados o eventos fortuitos como el corte ocurrido el 16 de julio de 2019.

3.3. Estacionariedad de la Serie

3.3.1. Definición estricta

La obtención de las distribuciones de probabilidad del proceso es posible en ciertas situaciones, por ejemplo con variables climáticas, donde podemos suponer que cada año se observa una realización el mismo proceso, o técnicas, que pueden generarse en un laboratorio. Sin embargo, en muchas situaciones de interés, como ocurre con variables económicas o sociales, sólo podemos observar una realización del proceso. Por ejemplo, si observamos la serie de crecimientos anuales de la riqueza de un país no es posible volver atrás en el tiempo para generar otra realización. El proceso estocástico existe conceptualmente, pero no es posible obtener muestras sucesivas o realizaciones independientes del mismo. Para poder estimar las características *transversales* del proceso (medias, varianzas, etc.) a partir de su evolución *longitudinal* es necesario suponer que las propiedades *transversales* (distribución de las variables en cada instante) son estables a lo largo del tiempo. Esto conduce al concepto de estacionariedad, que definimos a continuación [Peña, 2005].

Se dirá que un proceso estocástico (serie temporal) es estacionario en sentido estricto si:

1. las distribuciones marginales de todas las variables son idénticas;
2. las distribuciones finito-dimensionales de cualquier conjunto de variables sólo dependen de los retardos entre ellas.

La primera condición establece que, en particular, la media y la varianza de todas las variables son las mismas. También lo son los coeficientes de asimetría y kurtosis de las distribuciones marginales, ya que estas distribuciones son las mismas para todos los retardos. La segunda condición impone que la dependencia entre las variables sólo depende de sus retardos, es decir, la misma dependencia existe entre las variables x_t, x_{t+j}, x_{t+j+h} que entre las variables $x_{t+k}, x_{t+k-j}, x_{t+k-j-h}$. Estas dos condiciones pueden resumirse estableciendo que

¹valores atípicos

la distribución conjunta de cualquier conjunto de variables no se modifica si trasladamos las variables en el tiempo, es decir:

$$F(x_i, x_j, \dots, x_k) = F(x_{i+h}, x_{j+h}, \dots, x_{k+h}) \quad (3.12)$$

3.3.2. Condiciones débiles para la estacionariedad

La estacionariedad estricta es una condición muy fuerte, ya que para contrastarla es necesario disponer de las distribuciones conjuntas para cualquier selección de variables del proceso. Una propiedad más débil, pero más fácil de contrastar en la práctica, es la *estacionariedad en sentido débil*, que implica la estabilidad de la media, la varianza y la estructura de covarianzas a lo largo del tiempo. Un proceso es estacionario en sentido débil si, para todo t ,

1. $\mu_t = \mu = cte$
2. $\sigma_t^2 = \sigma^2 = cte$
3. $\gamma(t, t - k) = E[(x_t - \mu)(x_{t-k} - \mu)] = \gamma_k$; con $k = 0, \pm 1, \pm 2$

Las dos primeras condiciones indican que la media y la varianza son constantes. La tercera que la covarianza entre dos variables depende sólo de su separación. En un proceso estacionario las autocovarianzas y autocorrelaciones sólo dependen del retardo entre las observaciones y en particular, la relación entre x_t y x_{t-k} , es siempre igual a la relación entre z_t y z_{t+k} . Podemos escribir:

$$Cov(x_t, x_{t+k}) = Cov(z_{t+j}, z_{t+j+k}) = \gamma_k; j = 0 \pm 1, \pm 2, \dots \quad (3.13)$$

y también, para las autocorrelaciones:

$$\rho(k) = \frac{\gamma_k}{\gamma_0} \quad (3.14)$$

Se verifica:

1. $\gamma_k = \gamma_{-k}$
2. $\gamma_0 = \sigma^2$
3. $\rho_k = \frac{\gamma_k}{\gamma_0} = \rho_{-k}$

Se denomina función de autocorrelación simple (fas) a la representación de los coeficientes de autocorrelación del proceso en función del retardo.

La estacionariedad débil no garantiza la estabilidad completa del proceso. Por ejemplo, la distribución de las variables x_t puede estar cambiando en el tiempo. Sin embargo, si suponemos que estas variables tienen conjuntamente una distribución normal n-dimensional, como ésta queda determinada por las medias, las varianzas y las covarianzas, todas las distribuciones marginales serán idénticas, y también lo serán las distribuciones de subconjuntos de hasta $n - 1$ variables del tipo $(x_{t_1}, x_{t_1+j}, x_{t_1+k})$ y $(x_{t_2}, x_{t_2+j}, x_{t_2+k})$ para cada t . Por tanto, para procesos con distribuciones conjuntamente normal la estacionariedad débil coincide con la estricta.

En adelante utilizaremos para simplificar la expresión proceso estacionario para referirnos a un proceso estacionario en sentido débil, indicando expresamente cuando el proceso es estacionario en sentido estricto. En resumen para la obtención de estimaciones con propiedades estadísticas adecuadas de los parámetros de un modelo ARIMA, es necesario que la serie muestral que utilizamos para la estimación sea estacionaria en media y varianza.

La serie debe ser invariable con respecto al tiempo. Cuando las características de la misma cambian con respecto al tiempo, el proceso es no estacionario. Una forma de definir la estacionariedad de una serie, es verificar que las propiedades del proceso no son afectadas por cambios de origen temporal, es decir, cuando al realizar un mismo desplazamiento en el tiempo de todas las variables de cualquier distribución conjunta finita, resulta que esta distribución no varía. En resumen la hipótesis de estacionariedad implica que la media y la varianza del proceso sean constantes y que las autocovarianzas, y las autocorrelaciones dependan solamente del retardo, y no del momento del tiempo.

3.4. Análisis del Espectro de Frecuencias

Antes de querer aplicar la metodología ARIMA es recomendable realizar un análisis del Espectro de Frecuencias a fin de garantizar que se puede aplicar la metodología. En caso de que se encuentre un pico en el espectro, no sería posible aplicar la metodología ARIMA sin antes, eliminar la componente estacional.

En todo caso se demuestra que cualquier proceso periódico se puede modelar, con la precisión deseada, mediante series de términos de funciones senoidales (seno y coseno), lo que se conoce como **series de Fourier**, y se denomina espectro a la representación de las amplitudes, en el eje de las Y, que constituyen los diferentes términos de la serie para toda la gama de frecuencias (eje de las X).

El espectro es una herramienta fundamental para detectar *estacionalidad* en una serie y determinar su periodo.

Como es de esperar, el espectro está íntimamente relacionado con la función de autocorrelación y la función de autocorrelación parcial.

Dado que $Periodo = 1/Frecuencia$, al obtener la frecuencia, o frecuencias (picos en el espectro), se puede calcular de forma sencilla el periodo de las oscilaciones en la serie.

En aquellos conjuntos de datos en los que el espectro de frecuencia permita identificar un Periodo, es recomendable hacer como primer paso una diferencia estacional para convertir la serie en una serie que cumpla las premisas de los modelos ARIMA.

Por lo general la forma de eliminar la componente cíclica es mediante una diferencia estacional. Vale destacar que cuando se hace una diferencia estacional la serie pasa de tener $N - S$ valores debido a que el primer conjunto de valores de la serie no puede restar al periodo anterior al inicio de la serie de datos. Este tipo de modelos que incluyen a la componente estacional se conocen como SARIMA, donde la S agregada corresponde a Seasonally.

3.5. Pasos para identificar un modelo SARIMA

Los pasos que se deben seguir para identificar un modelo SARIMA son siguientes:

1. Representar gráficamente la serie temporal en Rango Completo. Esto permite evidenciar outliers y tener una primera aproximación visual sobre la existencia o no de estacionalidad y tendencia de la serie. Los outlier pueden ser sustituidos por otros valores más ajustados al resto de los valores.
2. Realizar un análisis espectral para demostrar la existencia o no del periodo de la serie. En esta instancia también se pueden ver las gráficas de la función de auto-correlación (ACF) y de la función de auto-correlación parcial (PACF) en donde se evidenciará o no la estacionalidad. En caso de que la serie sea estacional, se debe aplicar una diferencia estacional. En este caso la nueva serie contendrá $N-S$ observaciones.
3. Realizar una inspección visual detallada y prestar atención a la media (altura del conjunto de datos) y varianza (ancho del conjunto de datos respecto a un valor medio).
4. Examinar las gráficas de la función de auto-correlación (ACF) y de la función de auto-correlación parcial (PACF) para confirmar si la serie es estacionaria o integrada. Se recomienda realizar una prueba de raíz unitaria para ver si la serie es integrada. En caso de que la serie no sea estacionaria, el comportamiento no estacionario en la varianza puede corregirse por una transformación (logarítmica, Box-Cox). Para el caso de la media puede corregirse aplicando un filtro de media móvil o aplicando diferenciación, en este último caso la nueva serie contendrá $N-1$ observación.
5. Una vez alcanzada la estacionariedad de la serie, observar de nuevo las gráficas ACF y PACF para determinar si queda algún patrón en la misma: si hay que considerar estacionalidad (los valores de la ACF y de la PACF para múltiplos del índice de estacionalidad son significativamente diferentes de cero). A partir de las gráficas de ACF y PACF se puede determinar también los valores de los parámetros p , q , P y Q del modelo SARIMA.

A continuación en la Figura 3.2 se presenta un diagrama de procesos en donde se describe el algoritmo para identificar los parámetros de un modelo SARIMA a partir de una serie de tiempo.

Notar que en las instancias decisivas (color verde), pueden existir series en las que el paso se deba repetir más de una vez debido a que la serie tenga más de una estacionalidad y no alcance con la aplicación de una sola diferencia estacional y/o tenga más de un grado de integración.

Por otra parte en esta instancia se usa el rango completo de la serie a fin de tener mayor robustez estadística en la identificación de los parámetros del modelo (en especial en los parámetros estacionales).




Figura 3.2: Diagrama de Proceso: Identificación de los Parámetros del Modelos SARIMA. Elaboración Propia.

3.6. Selección de Variables, Modelos y Pronóstico

Debido a que todo modelo requiere ser evaluado para juzgar la bondad o adecuación del mismo, se tienen los siguientes criterios.

- **Parsimonia:** Un modelo nunca puede ser una descripción total de la realidad, ya que para poder describir la realidad se tendría que desarrollar un modelo que considerara muchas variables y por lo tanto sería tan complejo que resultaría inútil en la práctica. El principio de Occam enuncia que un modelo se debe mantener tan simple como sea posible. Un buen modelo es aquel que explica mucho en forma resumida.
- **Identificalidad:** Significa que para un conjunto de datos determinados, los parámetros estimados deben tener valores únicos.
- **Bondad de Ajuste:** El objetivo fundamental de todos los modelos de regresión es lograr explicar la mayor cantidad posible de la variación de la variable dependiente utilizando variables explicativas incluidas en el modelo
- **Poder predictivo:** Debe ser capaz de poder predecir valores futuros con un error razonable. Esta predicción debe realizarse fuera del rango de datos en el que fueron estimados los parámetros del modelo.

Existen casos en los que es posible ajustar varios modelos, cumpliendo las condiciones de estacionariedad de la serie y cuando además las gráficas de ACF y PACF no quedan suficientemente claras (posiblemente por tener muchas muestras ya que las bandas de seguridad son inversamente proporcional al número de datos) como para determinar el orden de los parámetros p , q , P y Q (órdenes de las componentes auto-regresivas, de media móvil, auto-regresivas estacionales y de media móvil estacionales respectivamente), se puede usar un criterio que ayude a la selección del modelo, entre uno de los posibles candidatos.

El criterio que se usa en este estudio es el criterio de información Akaike (AIC) [Akaike76], que penaliza a aquellos modelos que requieren un mayor número de parámetros. Recordando el principio de parsimonia, el cual es una de las leyes básicas al momento de elaborar un modelo de predicción podemos concluir que si existen varios modelos que expliquen una serie temporal, entonces, el más simple es el mejor.

En el caso de usar el error medio cuadrático de los residuos (diferencia entre valores de la serie temporal y el valor previsto por el modelo), el valor AIC corresponde a la ecuación (3.15), donde MSE corresponde al error medio cuadrático de los residuos, n al número de observaciones y m al número de parámetros del modelo $m = p + q + P + Q$. Se selecciona aquel modelo que presente un menor valor del AIC.

$$AIC = n \ln MSE \cdot n + 2m \quad (3.15)$$

3.6.1. Pasos para Seleccionar un Modelo y Validarlo

Todo lo anterior se puede listar los siguientes pasos:

1. Estimar los parámetros de las familias de modelos SARIMA, teniendo en cuenta la identificación realizada previamente. Con el fin de optimizar las corridas de cada modelo, se considera una ventana o rango muestral de los datos de la serie menor al rango completo que generalmente suele ser un periodo completo.
2. Se comparan modelos teniendo en cuenta por una parte que las raíces de los parámetros se encuentren fuera del radio unidad a fin de que el polinomio sea invertible y por otra se selecciona el modelo usando el criterio AIC.
3. Se verifica que los residuos del modelo obtenido correspondan a un ruido blanco: se tengan distribución normal y los residuos sean uniformes, para esto último se realiza un periodograma.
4. Se pone a prueba el modelo contra datos reales fuera del rango muestral con que fue estimado el mismo.




Figura 3.3: Diagrama de Proceso: Identificación y Validación de Modelos SARIMA.

Descripción del Sistema Eléctrico Argentino.

Este capítulo muestra la descripción del sistema eléctrico Argentino. Se hace énfasis en la evolución de la demanda de potencia eléctrica en el periodo de estudio enero 2018 a diciembre 2021. Todas las tablas y gráficas presentadas fueron elaboradas con datos públicos de CAMMESA para los datos del MEM y del Banco Mundial para datos de población y PBI. Algunas figuras son tomadas de los informes anuales de CAMMESA y de la Síntesis mensual del Mercado Eléctrico Mayorista elaborada por el Departamento de Planificación Estratégica de la Comisión Nacional de Energía Atómica (CNEA). Finalmente se estudia la curva a efectos de ver que factores la han modificado en dicho período.

4.1. Actores del Sistema Eléctrico Argentino

El sector eléctrico Argentino constituye el tercer mercado energético de América Latina. De acuerdo al informe anual de [CAMMESA, 2022] durante 2022 el consumo de energía eléctrica fue de 138.760 GWh.

Este requerimiento de energía correspondió a la demanda de 9052 grandes usuarios y 616 distribuidores. El mismo fue cubierto gracias a la energía producida por 468 generadores y la importación de energía de países limítrofes. Además, es importante mencionar que existen 52 transportistas que operan las redes de transmisión de energía eléctrica. El detalle de los diferentes actores, agentes y participantes del Mercado Eléctrico Mayorista (MEM) se muestra en la Tabla 4.1, la cual es tomada del informe anual del año 2022 elaborado por [CAMMESA, 2022].

Actores	Cantidad
Grandes Usuarios Mayores (GUMA)	370
Grandes Usuarios Menores (GUME)	2163
Grandes Usuarios Particulares (GUPA)	21
Grandes Usuarios en Distribuidores Mayores a 300kW (GUDI)	6498
Total Grandes Usuarios	9052
Distribuidores de Energía	28
Cooperativas Eléctricas Agentes del MEM	48
Distribuidores Menores (DIME)	1
Coopertivas No Agentes del MEM	539
Total Distribución	616
Generadores	432
Autogeneradores	29
Cogeneradores	7
Total Generación	468
Transportista en Alta Tensión	1
Transportista en distribución Troncal	7
Transportista PAFT	44
Total Transportistas	52

Tabla 4.1: Actores, Agentes y Participantes en el MEM para diciembre 2022

Fuente: Informe anual 2022 de CAMMESA

4.2. Balance de Energía en tiempo Real

En el capítulo 1 se vio que cada vez que se enciende (o apaga) un artefacto eléctrico se envía una señal a todo el sistema para producir (o dejar hacerlo), de forma instantánea (dado que actualmente la energía no puede ser almacenada a gran escala), esta energía en las los generadores locales o a través de la importación de países vecinos.

Un primer esquema simple en el que se cumpla la igualdad de potencia generada y demandada incluiría desde el lado de la oferta a los generadores y la importación y del lado de la demanda a los agentes de mercado y las exportaciones. Sin embargo, tal como se observa en la Figura 4.1 existen otras variables a tomar en cuenta.

Considerando que los centros donde se produce la energía no necesariamente se encuentra en los lugares de consumo, la energía debe ser transmitida por redes de transmisión, asumiendo una pérdida, del lado de la demanda.

En el caso de Argentina existen dos centrales de doble embalse (centrales de rebombeo) que pueden ser usadas como generadores en momentos del día en que se necesite producir energía (generalmente en los picos diarios cuando la energía es más cara), o como motores

para *almacenar* energía (bombeando energía desde el embalse inferior al superior) en los momentos del valle de demanda, cuando la energía es más barata, este consumo va del lado de la demanda en el balance.

Finalmente, en el caso más extremo en que la oferta no alcance a cubrir la demanda y se deban hacer maniobras operativas que impliquen desmejoras en la calidad del servicio como racionamientos de tensión o cortes de suministros, estos deben contabilizarse como demanda no satisfecha. Todo lo anterior puede observarse en el siguiente esquema.




Figura 4.1: Variables a tomar en cuenta en el Balance de Energía

4.2.1. La Frecuencia como indicador de Calidad de Suministro

En la Figura 4.1 se observa que en general se trata de que todos los componentes de la demanda sean satisfechos con la oferta en cada instante. El SADI opera a 50 *Hz*, en una situación ideal se espera que todo el sistema opere de forma estable en ese valor de frecuencia; sin embargo, existen dos situaciones en las que el sistema pueda estar trabajando: i) con una sobre frecuencia o ii) con un valor de sub frecuencia.

El primer caso se da cuando la oferta es mayor a la demanda, pongamos en caso de cuando se pierde un bloque de carga (se corta una línea de transmisión por ejemplo por un incendio cerca de la red). El sistema debe tener en sus protecciones relés de bote de generación, que actúan desconectando generación ya que las máquinas se podrían llegar a desbocar (al operar con más frecuencia implica que el generador gira más rápido).

En el segundo caso se da cuando la oferta es menor a la demanda, un ejemplo de esto es cuando una máquina del sistema se desconecta por algún problema y el resto de los generadores del sistema intentan asumir esta generación haciendo que la frecuencia del sistema baje. Para evitar que el sistema colapse, existen relés de protección de Desconexión Automática de Carga (DAC), que actúan *aliviando la carga* que no es prioritaria (previamente se estudia que demanda puede desconectarse en este tipo de escenarios).

Ambas situaciones se deben tomar muy en cuenta en sistemas que tengan alta penetrabilidad de fuentes intermitentes ya que se debe contar con un respaldo o back up de potencia firme que asuma la generación cuando la fuente intermitente se interrumpa.

En general, en la operación de un sistema de potencia se pueden llegar a dejar algunas máquinas que operen con cierto margen de reserva rotante inmediata (no entregan la totalidad de su potencia) a efectos de que puedan "amortiguar" los requerimientos de demanda no previstas o alguna eventual desconexión de un generador. Es muy común que se pueda llegar a dejar una máquina, de gran potencia cuya reserva rotante sea inmediata y este preparada para generar en rampas de potencia pronunciadas. Esta máquina suele conocerse como el gobernador o regulador principal de frecuencia del sistema y en muchos casos son hidroeléctricas de embalse.

4.3. Criterios Generales de Operación

Son 3 los criterios que el operador de despacho toma en cuenta al momento de operar un sistema de Interconexión. A continuación listan en orden jerárquico.

4.3.1. Seguridad del Abastecimiento

- El despacho seguro es aquel que garantiza la resistencia de la red a una falla simple (N-1) o en algunos casos (cuando hay probabilidad de ocurrencia simultanea) falla doble (N-2), sin que se produzcan colapsos parciales o totales.
- Se permiten interrupciones momentáneas parciales, por actuación de algún automatismo de alivio de carga (desconexión por sub frecuencia).
- Se permiten interrupciones manuales momentáneas por mantenimientos programados.
- Un sistema más seguro, implica que debe ser redundante, lo que lo hace más costoso.

4.3.2. Calidad del Suministro

- Frecuencia dentro de la banda normal de operación ($50,0 \pm 0,2$ Hz).

- Tensión dentro de la banda normal de tensión ($1,00 \pm 0,03$ pu (per unit) para 500/220kV) y $1,00 \pm 0,05$ pu para tensiones inferiores).
- Sobre tensión operativa (fuera de banda) a fin de garantizar nivel de tensión en extremo de la red donde hay un nodo de carga

4.3.3. Mínimo Costo

- Se despacha de la máquina menos costosa a la más costosa (Criterio de costo marginal).
- Se consideran excepciones en cuanto a los tiempos de arranque y parada. Se consideran tiempos prolongados (en el rango de varias horas/días) para aplicar el mínimo costo.

4.4. Instancias de programación para cubrir la demanda

El operador de despacho CAMMESA, realiza una programación en distintos horizontes de tiempo. Siempre considerando que a mayor plazo menor es el grado de detalle y mayor la incertidumbre. Por el contrario, para plazos menores el grado de detalle es mayor y la incertidumbre menor. Esto se puede apreciar mejor en la siguiente Figura:




Figura 4.2: Incertidumbre y grado de detalle en diferentes horizontes de planificación

4.4.1. Programación Estacional

Esta instancia tiene como objetivo analizar la operación futura del sistema eléctrico para los próximos 3 ó 6 meses. Por una parte se emplean modelos de despacho estocásticos

para la coordinación hidrotérmica que consideran las diversas crónicas de caudales de ríos, considerando una probabilidad de ocurrencia. Entre los modelos que se emplean se tienen:

- Oscar: Toma en cuenta la Valorización del Agua usando programación dinámica.
- Margo: Se emplea para la coordinación del despacho hidrotérmico usando programación lineal.

Por otra parte, para un horizonte de 14 semanas se considera modelos determinísticos de gestión operativa global que toman en cuenta:

- Uso de Embalses
- Autonomía y Stock de Combustibles

Estos modelos se tienen en cuenta para evaluar los precios estacionales, requerimientos de combustibles así como la evaluación del impacto en la operación de futuros ingresos y los riesgos asociados. Al integrar la programación OSCAR/MARGO se puede hacer una valorización del agua que representa la esperanza matemática de los ahorros futuros en la operación y en falla para cada metro cúbico de agua marginal almacenada.

Entre los embalses de regulación estacional se tienen:

- Piedra del Águila
- El Chocón

4.4.2. Programación Semanal

Su objetivo es minimizar el costo total de operación en el mercado. Considera el costo variable de producción térmico más el costo variable de producción hidroeléctrico (mediante los valores del agua), más el costo variable de transporte, a través del factor de nodo, más la valorización de la energía no suministrada.

La metodología de cálculo es a través de un modelo de optimización lineal determinística.

Entre los resultados que se obtienen se tiene:

- Generación hidroeléctrica por central, día y bloque horario.
- Generación térmica por central, día y bloque horario.
- Intercambios regionales por día y bloque horario.
- Precios marginales regionales por día y bloque horario.
- Evolución diaria de los embalses.

4.4.3. Programación Diaria

La programación diaria sigue la misma metodología de la programación semanal y considera además restricciones operativas y de la red.

El modelo es también determinístico y a través de programación lineal se busca que el despacho diario se lleve a cabo al mínimo costo.

Sus resultados llegan a dar información de la generación horaria de cada una de las máquinas del parque y presupone el cálculo del precio de mercado.

Entre las restricciones operativas, tanto para el parque hidro como térmico que se toman en cuenta se tienen:

- Generación Máxima diaria y semanal.
- Potencia base diaria, Potencia operable mínima y máxima.
- Disponibilidad de combustibles.
- Límite de flujo entre regiones y Generación regional mínima y máxima.
- Volumen mínimo y máximo de los embalses.
- Volumen de turbinado/vertido mínimo de los embalses.
- Capacidad operativa de las centrales de rebombeo.

A continuación se presenta un esquema de las diferentes instancias de programación:




Figura 4.3: Instancias de Programación de despacho

4.5. Boletín Informativo Semanal

A continuación se muestra un ejemplo del boletín informativo semanal para operadores del SADI, el mismo es un documento público disponible en la página web de [CAMMESA, 2022]. En el mismo se presentan los diferentes input que se tienen en cuenta en la programación semanal y diaria. En las Figuras 4.4, 4.5 y 4.6 se presenta la programación semanal que corresponde a la segunda semana de septiembre de 2022.

En la Figura 4.4 se presentan los input correspondientes a Condiciones meteorológicas y energías previstas; un panorama general de la situación energética del despacho de las principales tecnologías y la forma en la que será cubierto el pico de demanda diaria.

Para esta tesis es importante destacar el ítem referido a la previsión de la demanda ya que la misma actualmente se estima (no hay un modelo como si lo hay para la oferta) en base a temperatura media del GBA (región que sumada al litoral y BAS es sensible a la temperatura por ser el lugar geográfico donde se encuentra el 80 % de la demanda residencial). El valor agregado de esta tesis es proponer un modelo estadístico que pueda ser usado en esta instancia.




Figura 4.4: Boletín Informativo Programación Semanal CAMMESA, Demanda, Despacho y Cubrimiento del Pico

En la Figura 4.5 se presenta la situación actual del sistema de transporte, un cronograma de los trabajos de mantenimiento relevantes, las áreas críticas del SADI y finalmente el suministro de gas natural para las usinas.

- **Transporte en el STAT (Sistema de Transporte en Alta Tensión):** Se prevé operar respetando las condiciones de seguridad establecidas y sin inconvenientes de control de tensiones ni sobrecargas.

- **Transporte por Distribución Troncal:** Sin novedades.

- **Trabajos de mantenimientos relevantes:**

Propietario	Equipo	Trabajo	Hora	Fecha
TRANSNEA / ANDE	Línea de 500 kV Clorinda – Guarambaré	Montaje de nueva estructura. Se prevé la finalización de los trabajos para fines del corriente año	Continuo	X
TRANSENER	Transformador N° 2 de ET Rio Grande	Indisponible por señalización Buchholz y pérdida de aceite.	Continuo	X
TRANSENER	Barra B de ET Nueva San Juan	Mantenimiento General	8 a 17	5-sep
TRANSENER	Línea de 500 kV Almafuerde - Embalse	Mantenimiento General	8 a 17	11-sep
TRANSENER	Línea de 500 kV Arroyo Cabral - Almafuerde	Reemplazo aisladores	8 a 17	10-sep
TRANSENER	Barra A de ET Esperanza	Mantenimiento general	8 a 17	Del 06 al 08/09
TRANSENER	Barra B de ET Esperanza	Mantenimiento general	8 a 17	Del 09 al 11/09
TRANSENER	Transformador N°1 de ET Santo Tomé	Cambio de TV	7 a 17	5-sep
TRANSENER	Transformador 2 de ET Resistencia	Mediciones	7 a 17	Del 09 al 11/09

- **Áreas críticas:** En general, en función de las temperaturas pronosticadas y el parque de generación previsto, no se prevén problemas de suministro en las diversas regiones del SADI.

- **Suministro de Gas a usinas:** El cupo de Gas para usinas se estima que alcanzará en promedio los 29000 dam3/día para los días hábiles y 28000 dam3/día para el fin de semana.

Figura 4.5: Boletín Informativo Programación Semanal CAMMESA, Transporte, Mantenimientos, áreas Críticas y Combustibles

Finalmente, en la Figura 4.6 los datos que se muestran son las indisponibilidades relevantes del parque térmico e hidráulico, la situación de la generación renovable, habilitaciones previstas en el periodo de estudio y por último lo referente a importaciones o exportaciones de energía eléctrica con países vecinos.

- **Indisponibilidades relevantes del parque térmico:**

- 1) **Costanera:** La TV06 se encuentra F/S indisponible por problema en bomba de lubricación y la TV04 continúa indisponible por arranque fallido, ambas sin previsión. La TV07 continúa F/S indisponible por pinchadura de caldera, sin fecha cierta de disponibilidad.
- 2) **Loma de la Lata:** La TG03 salió F/S indisponible el 01/09 para mantenimiento estacional hasta el 21/09.
- 3) **Güemes:** La TG01 continúa F/S indisponible por falla en compresor de Gas, se prevé disponible el 10/09.
- 4) **CC Agua del Cajón:** La TG05 salió F/S indisponible para mantenimiento estacional el 29/08 hasta el 26/09.
- 5) **Surenito:** La TV13 salió F/S indisponible el 02/09 luego de un arranque fallido por problemas en tratamiento de agua de caldera.
- 6) **CC Costanera:** ½ CC (TG09/TV10) quedó disponible el 04/09, se encontraba F/S indisponible para mantenimiento estacional.
- 7) **CC El Bracho:** Salió F/S indisponible el 02/09 para mantenimiento estacional hasta el 11/09.
- 8) **CC de Puerto:** ½ CC (TG12/TV10) entró E/S el 30/08, se encontraba F/S indisponible para mantenimiento estacional. La TG11 salió el 01/09 para mantenimiento estacional, continúa indisponible por problemas en álabes.
- 9) **CC Timbúes:** La TG01 salió F/S indisponible el 03/09 para mantenimiento estacional hasta el 16/10.
- 10) **San Nicolás:** La TV15 salió F/S indisponible el 04/09 por pinchadura de caldera, sin previsión de disponibilidad.

- **Indisponibilidades relevantes en Centrales hidráulicas:**

CH Yacayeta: El Grupo N°16 continúa indisponible hasta el 14/10 para mantenimiento estacional.

CH Rio Grande: El Grupo N°4 continúa indisponible por falla en excitación, sin previsión de disponibilidad. Los Grupos N°1 y 2 continúan indisponibles hasta el 16/09 para mantenimiento estacional.

El 03/09 desenganchó el Transformador N°2 de la Central marcando fallas en Buchholz y protección diferencial quedando indisponible para revisión y reparación de pérdida de aceite. Queda toda la central indisponible.

CH Salto Grande: El Grupo N°3 continúa indisponible hasta el 09/09 para mantenimiento estacional.

- **Generación Renovable:** Se prevé que la generación con fuentes renovables de energía alcance el 13 % de la energía total generada para la semana, una media horaria aproximada de 2000 MW.

- **Habilitaciones:**

El 11/08 se habilitó para la Operación Comercial en el MEM la Central Térmica a Biogás "General Villegas" (GENERAL VILLEGAS BIOGAS S.A.), con una potencia máxima de 1,22 MW. Se conecta a la Línea de 33 kV General Villegas – Banderado jurisdicción de EDEN en la provincia de Buenos Aires.

- **Importación / Exportación:**

Se prevé importación térmica de Brasil.
No se prevén realizar intercambios de energía con Chile, Uruguay ni Paraguay.

CAMMESA, 05/09/2022.
Gerencia de Operaciones

Figura 4.6: Boletín Informativo Programación Semanal CAMMESA, Indisponibilidades, Generación Renovable, Habilitaciones, Importaciones/exportaciones

4.6. Datos de Operación en Tiempo Real

Para la operación horaria en tiempo real y el re despacho, además, de los datos mencionados anteriormente, se hace especial énfasis en los siguientes datos:

- **Previsión de la Demanda.**
- Previsión del Despacho Hidrotérmico.
- Previsión de Restricciones por Mantenimientos Programados N-1.
- Previsión de Riesgos para el Sistema eléctrico (tormentas, incendios, etc)
- Partes meteorológicos de velocidad de viento, intensidad y horas de irradiancia solar, y de temperatura.

Hasta ahora se han planteado los criterios generales para operar el SADI así como las instancias que se toman en cuenta en la programación para cubrir la demanda, en esto último se mencionaron algunos programas (estocásticos en el caso de OSCAR-MARGO y deterministas en el caso Juana para la programación semanal y diaria) que en general apuntan a resolver desde el lado de la oferta como se va a cubrir la demanda en cada bloque horario. Pero en todos los casos es necesario disponer a priori de la demanda.

Al momento de realizar la simulación tanto de la programación semanal como diaria, el input de los valores de demanda se determinan considerando valores reales recientes y se consideran días tipo de acuerdo a correlaciones estadísticas y condiciones meteorológicas. En aquellos casos en que la correlación no sea alta, se debe considerar un criterio conservador (se sobre estima la demanda) y en consecuencia la oferta.

El propósito de esta tesis es encontrar un modelo basado en la metodología de series de tiempo que permita estimar con una base estadística, un modelo para pronosticar la demanda horaria que es un input en la previsión semanal y diaria.

Es por ello que es de suma importancia conocer a priori el comportamiento de la demanda. En las siguientes secciones se presenta como ha evolucionado la demanda de potencia eléctrica en Argentina en los últimos 20 años.

Históricamente la demanda de energía eléctrica ha tenido un comportamiento creciente, explicado por el aumento de la población (relación lineal) con ciertas oscilaciones en algunos años explicadas por el desarrollo económico.

4.7. Evolución de la Demanda de Energía en Argentina en el Período 2001-2021

A continuación, en la figura 4.7 se presenta la evolución de la generación neta para cubrir demanda la cual no incluye exportaciones y difiere de la demanda neta final por tipo de sector, debido a que en el primero se usan datos obtenidos de la medición en la generación y redes de transporte y en el segundo datos del consumidor final. En esta tesis la llamaremos simplemente demanda.




Figura 4.7: Demanda Anual de Energía Eléctrica 2001-2021.

Fuente: Edición Especial 20 Aniversario de la Síntesis del MEM[CNEA, 2021].

Para entender la evolución de la demanda mostrada en la Figura 4.7 es importante recordar el contexto socio económico del país. A partir de 1998, en Argentina se inició un periodo recesivo que culminó en el año 2002, dando inicio a una crisis económica, institucional y social. La salida formal de la convertibilidad se produjo a inicios del 2002, acompañada por el anuncio del cese de pagos externos. La economía argentina se encontraba en un contexto de alta desocupación laboral, una industria nacional débil con capacidad ociosa y un PBI que alcanzó la mayor caída interanual histórica.

Entre 2008 y 2009, la economía mundial fue impactada por dos acontecimientos: el descenso de los precios de los commodities y del petróleo luego de alcanzar sus máximos niveles históricos, y la crisis financiera de Estados Unidos (Subprime). En este contexto Argentina se mostró vulnerable, provocando un descenso en el PBI.

A inicios de 2016, la implementación de nuevas medidas económicas como: la salida del cepo, la quita de retenciones a las exportaciones, y la disminución de subsidios, entre otras, provocaron un descenso del PBI que se mantuvo en los años posteriores.

De la figura 4.7 se observa que el consumo de energía ha evolucionado de forma creciente en 15 años, explicados fácilmente por aumento de la población, mientras que se observa además que se ha contraído en 6 años que pueden ser explicados entre otras cosas por las crisis económicas que han ocurrido en el país. De este análisis se puede proponer que la demanda de energía eléctrica puede modelarse como una función no lineal en el tiempo en la que sus variables explicativas son: la población y el uso e intensidad de la energía (este último se puede vincular al desarrollo económico). Históricamente la demanda de energía eléctrica ha tenido un comportamiento creciente, explicado fácilmente por I) el aumento de la población (relación lineal) con ciertas oscilaciones en algunos años cuya correlación se explica por II) el desarrollo económico (comportamiento media móvil).

4.7.1. Demanda de Energía Eléctrica vs Población

En la Figura 4.8 se muestra cómo ha evolucionado el consumo de energía y la población del país en el periodo que va del 2001 al 2021 y se observa por una parte que el consumo de energía inició el periodo en 78,1 TWh evolucionando hasta los 133,9 TWh en 2021 lo que representa una variación en todo el periodo de 71,45 %. Al hacer el mismo análisis para la población se obtiene que la misma tuvo un crecimiento del 26,00 % en el mismo periodo.




Figura 4.8: Evolución de la demanda anual vs la población.

Fuente: Edición Especial 20 Aniversario de la Síntesis del MEM[CNEA, 2021].

4.7.2. Demanda de Eléctrica vs. Variación del PBI

El aumento de la población explica en parte la tendencia (creciente) de la demanda, pero no las variaciones anuales por lo que se debe analizar la variación de la demanda versus la variación del Producto Bruto Interno (PBI). En la Figura 4.9 se muestra la correlación entre la variación anual de la demanda de energía eléctrica versus la variación anual del PBI.




Figura 4.9: Variación anual demanda vs. PBI.

Fuente: Edición Especial 20 Aniversario de la Síntesis del MEM[CNEA, 2021].

4.7.3. Demanda por Regiones

El Mercado Eléctrico Mayorista (MEM) está compuesto por nueve regiones eléctricas tal como se muestra en la Figura 4.10. Estas se presentan agrupadas teniendo en cuenta como criterio las proximidades geográficas entre ellas y sus similares demandas energéticas.

Actualmente todas las regiones están interconectadas mediante el Sistema Argentino de Interconexión (SADI). Es conveniente destacar que hasta febrero de 2006 la región patagónica se encontraba aislada del resto del MEM y es a partir del 1 de marzo de 2006 que por medio de la línea Choele Choel-Puerto Madryn se interconecta el sistema patagónico al MEM y forman un único sistema. Actualmente la provincia de tierra del Fuego no se encuentra conectada al SADI.

A continuación, se muestra la agrupación de las regiones eléctricas del MEM.

REGIÓN	PROVINCIAS
Gran Buenos Aires (GBA)	C.A.B.A y Gran Buenos Aires
Buenos Aires (BAS)	Buenos Aires sin GBA
Centro (CEN)	Córdoba, San Luis
Comahue (COM)	La Pampa, Neuquén, Río Negro
Cuyo (CUY)	Mendoza, San Juan
Litoral (LIT)	Entre Ríos, Santa Fe
Noreste Argentino (NEA)	Chaco, Corrientes, Formosa, Misiones
Noroeste Argentino (NOA)	Catamarca, Jujuy, La Rioja, Salta, Santiago del Estero, Tucumán
Patagonia (PAT)	Chubut, Santa Cruz




Figura 4.10: Mapa de las regiones eléctricas del MEM.

Fuente: Edición Especial 20 Aniversario de la Síntesis del MEM[CNEA, 2021]. GeoSADI

En las Figuras 4.11 y 4.12 se muestra la evolución de la demanda por regiones en los periodos 2001 al 2010 y 2011 al 2021, respectivamente.




Figura 4.11: Demanda anual por regiones eléctricas 2001-2010.

Fuente: Edición Especial 20 Aniversario de la Síntesis del MEM[CNEA, 2021].




Figura 4.12: Demanda anual por regiones eléctricas 2011-2021.

Fuente: Edición Especial 20 Aniversario de la Síntesis del MEM[CNEA, 2021].

4.7.4. Demanda por Sectores de Consumo

De acuerdo a la aplicación de la Resolución 323/2023 de la Secretaría de Energía, se establecen las siguientes categorías por energía consumida y potencia contratada en:

Residenciales

Incluye la demanda de distribuidores clasificada como:

- Bomberos Voluntarios.
- Electrodependientes.
- Todos los segmentos residenciales: N1, N2, N3 y N3 excedente.



Comercial/Intermedios

Incluye la demanda de distribuidores clasificada como:

- Alumbrado Público.
- Usuario no Residencial con potencia contratada de 10 kW a 300 kW.



Industrial/Comercial Grande

Incluye la demanda de distribuidores clasificada como:

- TARIFA USUARIO NO RESIDENCIAL ≥ 300 kW
 - TARIFA USUARIO NO RESIDENCIAL ≥ 300 kW EDUCACIÓN/SALUD
- Mas la demanda de Gran Usuario del MEM:
- La Demanda de Grandes Usuarios Menores (GUMEs)
 - La Demanda de Grandes Usuarios Mayores (GUMAs/AUTO)




Figura 4.13: Clasificación de los Sectores de Consumo.

En la Figura 4.14 se muestra la demanda por sectores de consumo, así como la participación de la demanda en porcentaje del periodo 2011-2021. Se observa que para el sector residencial la demanda evoluciona de forma positiva salvo en tres años donde disminuye debido posiblemente a ajustes en la tarifa del servicio. Los sectores comercial e industrial presentan vaivenes producto de diversas crisis en la economía del país.




Figura 4.14: Demanda anual por sectores de consumo 2005-2021.

Fuente: Edición Especial 20 Aniversario de la Síntesis del MEM[CNEA, 2021].

4.8. Factores que afectan a la demanda

Entre los factores que pueden afectar a la demanda se tienen:

- Catástrofes no controlables sobre alguna unidad de consumo. Ejemplo: la pandemia
- Estación del año y Temperaturas Extremas Prolongadas
- Racionamientos por falta de oferta para cubrir la demanda

4.8.1. Pandemia de SARS-CoV-2 en 2020

En el caso del periodo de estudio, durante 2020, ocurrió una pandemia mundial, que terminó afectando las diferentes actividades económicas del país. Por ello resulta interesante estudiar el comportamiento de la demanda ante esta situación particular[Mora C., 2020].

Se tiene que desde marzo 2020 en adelante muchas de las actividades se vieron afectadas por la llegada del virus SARS-CoV-2 y la implementación del aislamiento social preventivo y obligatorio (ASPO) y del distanciamiento social preventivo y obligatorio (DSPO) en el país a efectos de mitigar los efectos del virus y mejorar la infraestructura de salud. El efecto de la pandemia sobre la demanda de energía eléctrica de los sectores industrial y comercial se observa en la Figura 4.15.




Figura 4.15: Demanda Diaria Grandes Usuarios marzo a diciembre 2020

Consumo Industrial y Comercial

El nivel de consumo industrial y comercial está relacionado con el nivel de producción industrial y está íntimamente relacionado con el momento económico que un país o región está atravesando. La dependencia del consumo industrial con la producción puede ser diferente para los diferentes tipos de productos, sin embargo, las unidades industriales normalmente introducen incertidumbre en los pronósticos de carga debido a las paradas ocasionadas por eventos como huelgas o planes nacionales de racionamiento, introduciendo grandes disturbios en la previsión de potencia eléctrica. En el caso de la pandemia de 2020 sobre la demanda de potencia eléctrica se observa en la Figura 4.15 un mayor impacto en los GUMAs (Grandes Usuarios Mayores) a partir del la tercera semana del mes de marzo 2020, momentos en que el ASPO se encontraba en su fase 1 en todo el país.

Luego se observa que la demanda fue en aumento, desde los últimos días de abril hasta diciembre 2020 a medida que se autorizaron nuevas actividades económicas como esenciales. La recuperación de la demanda (porcentaje respecto a valores previos a la ASPO y DISPO) en los GUMAs se puede observar en la Figura 4.16 que, para diciembre 2020, se recuperan los valores de demanda previos al comienzo del ASPO. En diciembre, se registró una baja en las últimas dos semanas del año, debido a que las actividades disminuyen por las fiestas de fin de año y los días feriados.




Figura 4.16: Evolución de la demanda media diaria GUMAs (sin Aluar) marzo-dic 2020

Consumo Residencial

En el sector residencial los factores que influyen en la demanda son más difíciles de identificar, ya que cada persona, decide que artefactos enciende a una determinada hora, así, la demanda se relaciona con la psicología del comportamiento de los individuos.

Entre los factores sociales y ambientales que pueden influenciar el consumo residencial se pueden mencionar: grandes eventos (un recital), elecciones, condiciones climatológicas, programas especiales de TV y en el caso Argentino: Juegos de fútbol.

4.8.2. Curvas de Demanda Estacional

A continuación se presentan las Figuras 4.17 y 4.18, donde se muestran las curvas del patrón de demanda característico para las estaciones de invierno y verano. Las mismas son estimadas por CAMMESA en su informe anual.




Figura 4.17: Curva Típica de demanda del SADI: Invierno.

Fuente: Informe anual [CAMMESA, 2022].




Figura 4.18: Curva Típica de demanda del SADI: Verano 2018.

Fuente: Informe anual [CAMMESA, 2022].

La principal diferencia entre las curvas de demanda entre el invierno y el verano se observa en la magnitud del pico de la tarde y el de la noche. Una explicación posible [Beyrne et al., 2015] es el uso de aire acondicionado en la tarde de verano y no uso de iluminación debido a la mayor cantidad de horas de luz en el verano respecto al invierno.

4.8.3. Demanda vs. Temperatura

Para Argentina existen diversos documentos de trabajo que analizan las características de las demandas estacionales de energía eléctrica en Verano e Invierno. Entre los trabajos que se pueden citar se tienen: [Beyrne et al., 2015], [Zotelo, 2016], [Mastronardi et al., 2016].

En [Beyrne et al., 2015] se estudió el comportamiento diario de la demanda total de energía en términos de la temperatura de un pool de ciudades, encontrando efectos intradiarios y el impacto que tiene una variación de $1\text{ }^{\circ}\text{C}$ en el consumo eléctrico en ambas estaciones, a la vez que se analiza la incidencia que tienen las olas de calor y las olas de frío en la demanda de electricidad. Entendiendo por ola de calor o frío a aquellos valores extremos de temperatura de forma prolongada durante varios días.

[Zotelo, 2016] analizó el impacto en la demanda total de energía del país en función de pronósticos climáticos a 3 meses (temperaturas y olas de frío y calor). Propuso modelos de regresión simple con paso diario.

Es importante destacar que la demanda de energía eléctrica del sector residencial se ve sensiblemente influenciada (aumenta) por la temperatura cuando ocurren valores extremos, de calor o frío, de forma prolongada por varios días seguidos, tal como ocurrió en la ola de calor del verano 2022[Mora and Iglesia, 2022].

Al consultar la literatura especializada se encuentran en [Watson et al., 2005] dos vocablos que capturan la variabilidad intradiaria de la temperatura respecto a una temperatura de *comfort*: Heating Degree Days (HDD) y Cooling Degree Days (CDD). Para el caso de Argentina [Zotelo, 2016] y el informe anual de [CAMMESA, 2022] establecen que en verano se considera un día de temperatura extrema a aquellos cuya temperatura media (medida en la región GBA), es mayor o igual a $26\text{ }^{\circ}\text{C}$, mientras que en invierno un día de temperatura extrema son aquellos cuya temperatura media es menor o igual a $10\text{ }^{\circ}\text{C}$.

De lo anterior se puede obtener como primera conclusión que existe una relación global entre demanda de potencia eléctrica y temperatura, que es no lineal y tiene un umbral de temperatura a partir del cual la demanda empieza a dar una respuesta. En Argentina la relación es positiva para los meses de verano y oscila entre 2% y 3% por cada grado centígrado adicional de temperatura. En contraste se observa que se revierte el efecto en meses fríos aumentando entre un 0.3% y un 1.4% la demanda ante la disminución de un grado adicional de temperatura[Mastronardi et al., 2016].

Este aumento en la demanda es inferido en [Beyrne et al., 2015] por el uso de acondicionadores de aire y sistemas de calefacción eléctrica, en el verano e invierno respectivamente.

En las Figuras 4.19 y 4.20 se pueden observar esta relación semielástica (con distintas pendientes) entre la demanda (principalmente residencial) y temperaturas extremas. La relación se encontró en distintas ciudades analizadas y en distintos tipos de día (laborable y no laborable para la región del AMBA en el año 2015), [Mastronardi et al., 2016].




Figura 4.19: Demanda Diaria de Energía Eléctrica en varias ciudades vs. Temperatura. Periodo 2004 a 2016. **Fuente:** Mastronardi et al, 2016




Figura 4.20: Demanda Diaria de Energía Eléctrica en AMBA por tipo de día vs. Temperatura. Año 2015. **Fuente:** Mastronardi et al, 2016

En la Figura 4.21 se pueden observar esta relación semielástica entre demanda (principalmente residencial) y temperaturas extremas. El análisis fue realizado por [Mastronardi et al., 2016] para distintos años en el AMBA en el año 2015 y se observa que la forma de U se ha ido pronunciando a lo largo del tiempo. Una posible explicación es lo inferido por [Beyrne et al., 2015] respecto al uso de acondicionadores de aire y calefacción.




Figura 4.21: Demanda Diaria de Energía Eléctrica en AMBA en años seleccionados vs. Temperatura. Año 2015. **Fuente:** Mastronardi et al, 2016

Si bien en las figuras previas se observa la semielasticidad de la demanda de energía eléctrica respecto a la temperatura para varias ciudades o regiones de estudio; esto no implica que se pueda extrapolar directamente a un caso país.

En el caso de Argentina por la gran extensión que tiene pueden existir regiones diferentes condiciones meteorológicas (no solo temperatura sino también humedad, horas de luz solar, etc), que hacen implican un desafío al momento de intentar hacer una predicción de la demanda de todo el país, considerando uno o unos pocos valores de temperatura representativa. Cammesa, en el boletín informativo para operadores del SADI informa un valor promedio diario, con horizonte de una semana tomado en la estación meteorológica del Aeropuerto Internacional Ministro Pistarini de Ezeiza en la provincia de Buenos Aires, el cual tiene cierta lógica pues el AMBA concentra una parte importante de la demanda residencial, la cual es la más sensible a temperaturas extremas.

Es importante acotar que en una sola provincia pueden haber diferentes climas en un mismo momento. Por ejemplo, en la provincia de Mendoza, que debido a su extensión puede subdividirse en subregiones, y es así que tiene al Oeste posee la alta montaña (Uspallata) y El Valle de UCO, Al Sur San Rafael, en el Centro Gran Mendoza, al Norte Lavalle y al Este San Martín. Puede darse el caso de que en el norte de la provincia y Mendoza Capital se registren altas temperaturas; en Uspallata, puede estar nevando, en San Rafael puede haber tormenta eléctrica, en el Valle de UCO pueden haber bancos de niebla y en Rivadavia (este) puede estar granizando de forma simultánea.

De todos modos, [CAMMESA, 2022] en su informe anual, presenta la figura 4.22 la cual también muestra una relación parabólica (forma de U) entre la temperatura y el consumo diario de energía eléctrica principalmente residencial (distribuidores) del país en conjunto.




Figura 4.22: Demanda Diaria de Energía Eléctrica Distribuidores vs. Temperatura.

Fuente: Informe anual 2021 de CAMMESA

4.8.4. Máximos de Demanda de Potencia

Hasta ahora se ha visto que las temperaturas extremas, sostenidas en el tiempo implican una respuesta de aumento en la demanda de potencia eléctrica, principalmente en el sector de consumo residencial, destinado al acondicionamiento del ambiente a una temperatura de confort[Beyrne et al., 2015]. De esta forma se puede pensar que los máximos de demanda ocurren en los meses de verano y/o invierno.

En la Figura 4.23 se muestra la evolución de los máximos de demanda de potencia en el periodo correspondiente a enero 2001 hasta enero de 2022.




Figura 4.23: Demanda máxima de potencia eléctrica 2001 - 2022.

Fuente: Edición Especial 20 Aniversario de la Síntesis del MEM[CNEA, 2021].

Se observa que los mismos pueden ocurrir tanto en los meses de verano como en los meses invierno donde las temperaturas son extremas. Sin embargo, desde 2013 se observa que los máximos ocurren solo en verano.

Una explicación a esta ausencia de picos máximos de demanda en invierno alternados con los del verano, es la propuesta por [Mastronardi et al., 2016] en donde explican que la diferencia de pendiente de la semielasticidad, (menor en el invierno) puede deberse al uso de un sustituto como la calefacción a gas natural debido a que la tarifa de gas es menor a la tarifa de energía eléctrica.

Por otra parte la ausencia de máximos de demanda durante 2019 y 2020 no tiene una única razón, podría llegar a explicarse en menor o mayor medida por diversos factores: I) aumento de la tarifa en años anteriores, II) programas de uso racional y eficiente de la energía (etiquetado de electrodomésticos), III) ingreso de generación distribuida, IV) crisis económica de 2019 y V) disminución de la actividad comercial e industrial producto del confinamiento por la pandemia causada por el SARS CoV-2 durante el año 2020, el impacto de este último efecto se encuentra explicado en el informe especial, Demanda eléctrica bajo efecto del Covid-19[Mora C., 2020].

Durante la semana del 10 al 16 de enero de 2022, ocurrió en Argentina un fenómeno meteorológico caracterizado por un marcado y sostenido aumento de la temperatura, denominado Ola de Calor¹.

¹Esta tesis fue entregada para revisión de jurados en septiembre de 2022. Sin embargo, antes de la defensa oral y pública de la misma ocurrió en el mes de marzo de 2023 otro fenómeno meteorológico con temperaturas extremas sostenidas implicando los siguientes récord: el mes más caluroso desde 1944 con una media mensual de 27,1 °C, dos máximos de potencia en días hábiles (10 y 13 de marzo), un máximo de potencia un día sábado (11 de marzo), máximo de energía: en día hábil el 13 de marzo con 590,7 GWh con una temperatura media en GBA de 31 °C y máximo de energía en día sábado el 11 de marzo con un consumo de 559,8 GWh y una temperatura promedio de 32,2 °C. Esta ola de calor sostenida representa el máximo de consumo de energía semanal de 3.782,1 GWh entre los días 06 al 12 de marzo de 2023.

El máximo de demanda², a la fecha de realización de esta tesis, fue de 28.231 MW, registrado el 14 de enero de 2022 a las 14 : 12 horas, día el que la temperatura promedio en la provincia de Buenos Aires fue de 33,8 °C, alcanzando a las 14:00 horas el segundo máximo histórico de temperatura en 41,5°C en varias ciudades del país[Mora and Iglesia, 2022]. En esta instancia se le exigió al SADI, responder a rampas de potencia de hasta 1500 $\frac{MW}{h}$. El consumo total de energía ese día fue de 575,9GWh.

Con el fin de mostrar los últimos picos de demanda alcanzados en el ínterin de la presentación del manuscrito (septiembre de 2022) y defensa oral (junio 2023), se presentan la siguiente figura 4.24, tomada de la síntesis mensual del MEM de marzo 2023 de[CNEA, 2023].




Figura 4.24: Picos de demanda de potencia eléctrica desde 2010 al 13 de marzo de 2023.

Fuente: Síntesis del MEM[CNEA, 2023], mes de marzo.

4.8.5. Bonus Track: Análisis de la influencia de la temperatura en el máximo histórico de demanda del 13 de marzo de 2023

El grupo de planificación energética de la CNEA, realiza una publicación periódica mensual llamada síntesis del mercado eléctrico mayorista de la [CNEA, 2023] y para la edición correspondiente al mes de marzo, analizaron la influencia de la ola de calor de

²Al momento de la defensa oral y pública de esta tesis, el máximo de demanda corresponde a 29.105 MW, ocurrido el día lunes 13/03/2023 a las 15:28, en medio de una ola de calor sostenida por varios días. Ese día la Temperatura media de Bs As (medida en el aeropuerto Ezeiza) fue de 31,0 °C

marzo 2023. En este sentido concluyeron que en días de temperaturas extremas como el del 13 de marzo, en donde la demanda del SADI alcanzó los 29.105 MW frente a los 20.200 MW del viernes 3 de febrero de 2023, día este último de temperaturas similares a las medias del verano. La diferencia de acondicionamiento térmico fue del orden de 9.000 MW (43 % superior a la media) ante un aumento promedio de $6\text{ }^{\circ}\text{C}$ ($1500\frac{\text{MW}}{^{\circ}\text{C}}$) en la región del AMBA.




Figura 4.25: Demanda de potencia eléctrica y temperatura en el AMBA del 03 de febrero y del 13 de marzo de 2023. **Fuente:** Síntesis del MEM[CNEA, 2023], mes de marzo 2023.

Es de destacar que es la primera vez en 20 años que el pico de verano ocurre en marzo ya que es habitual que se registró en los meses de enero o febrero.

Capítulo 5

Metodología

En los capítulos anteriores se han presentando, por una parte los objetivos y la justificación de esta tesis de maestría, seguido de los diferentes modelos disponibles en la literatura, haciendo énfasis en la metodología de Box-Jenkins y en el capítulo anterior se hizo una descripción completa del sistema eléctrico Argentino. A continuación, en este capítulo se presentan en primer lugar las diversas consideraciones y supuestos asumidos en la modelación y finalmente, se emplea la metodología de series temporales Box y Jenkins. La serie empleada es la correspondiente a la potencia demandada país (demanda agentes + Perdidas en la red de Alta Tensión + Centrales de Bombeo), en paso horario, en el período enero 2018 hasta julio 2022 en el SADI.

5.1. Consideraciones y supuestos sobre la Demanda

El objetivo de esta tesis es encontrar un modelo de demanda horario para todo el país, a ser usado como input en la programación diaria, se analiza la demanda agentes (Residencial, comercial e industrial) para todo el país, considerando que luego el optimizador de Cammesa tendrá en cuenta i) la oferta disponible en todas las regiones del país, ii) las perdidas asociadas en las redes, iii) la energía empleada en las centrales de rebombeo y iv) las interconexiones entre regiones.

De esta forma el pronóstico será sobre el **suministro horario de energía del país** (Demanda agentes + Pérdidas en la red de Alta Tensión + Bombeo) que es verdaderamente el dato que necesita el optimizador para resolver la oferta necesaria para cubrir la demanda. No se considera dentro de la demanda las exportaciones a países vecinos.

5.1.1. Influencia de la Temperatura sobre la Demanda

La figura 5.1 muestra el mapa de temperatura media anual de Argentina. Es posible distinguir regiones climáticas diferentes bien marcadas especialmente en el eje norte-sur. Por otra parte, el SADI se encuentra dividido en 9 regiones eléctricas en función de diferentes características operativas del mismo, ver sección 4.7.3.




Figura 5.1: Mapa de temperatura media anual de Argentina. Fuente: INTA

Cada una de las diferentes regiones eléctricas del SADI tienen asociada una temperatura promedio tomada de las distintas estaciones meteorológicas que hay en el país.

En el caso del GBA corresponde a la estación meteorológica del Aeropuerto de Ezeiza. Un valor medio diario es presentado en el boletín de la programación semanal de CAMMESA (ver sección 4.5). Este dato es importante a tener en cuenta cuando se emplean previsiones de demanda por *días tipo* y se realiza un pronóstico de pico de demanda diario [Ismail et al., 2008], [Halepoto et al., 2014] y [Hassani et al., 2014] o consumo de energía diario y curva de carga [Psiloglou et al., 2009], [Mastronardi et al., 2016], [Molnar et al., 2016] y [Zotelo, 2016].

Sin embargo, en caso de querer correlacionar la temperatura con la demanda horaria, sería necesario disponer de datos de temperatura con paso de tiempo horario y además contar con datos de temperatura en un lugar acotado en donde la temperatura promedio sea representativa tal como lo hicieron [Fattaheian-Dehkordi et al., 2014] en su estudio en una smart grid en Teherán. Sin embargo, dada la extensión del territorio argentino y teniendo en cuenta que existen diversas regiones climáticas, sumado a que la demanda esta distribuida de forma heterogénea (localizada en grandes grupos urbanos) no hay forma de asociar de forma explícita una temperatura, pesada promedio, para cada región del país como si puede ocurrir en un estudio más acotado (por ciudades o regiones) como los realizados (de forma diaria) por [Beyrne et al., 2015] y [Zotelo, 2016] respectivamente.

Para sortear este problema se toman en cuenta las conclusiones de la tesis doctoral de [Gutiérrez, 2003] quien analizó que la influencia de la temperatura esta implícita en la serie de tiempo de la demanda de potencia. Por otra parte, [Vu et al., 2015] en su estudio analizaron el impacto de diferentes variables climáticas sobre el consumo de energía (mensual) mediante un modelo robusto basado en la eliminación hacia atrás, en donde luego de un análisis pudieron concluir que existen variables que tienen una alta relación con otras, por lo que usando criterios de colinealidad, estas variables pueden ser excluidas como variables explicativas mientras que se considere un conjunto de variables independientes.

Por todo lo anterior, al tratarse de un caso país, y no local, solo se va a considerar la serie de consumo de potencia eléctrica, no considerando explícitamente la variación de la temperatura ambiental como un factor a tener en cuenta en el pronóstico de demanda. Esta suposición también fue adoptada por [Chen et al., 2004], donde se dieron cuenta que no existe una mejoría notable en los pronósticos cuando se considera la temperatura.

Se tienen en cuenta además que modelos que emplean a la temperatura como variable explicativa para estudio de casos locales y cuando se disponen de datos diarios, tal como ocurrió en el estudio de [Fattaheian-Dehkordi et al., 2014] quien obtuvo un pronóstico con un error del $\pm 2.98\%$ usando máquinas de vector de soporte, que es un buen pronóstico, pero vale destacar que en la literatura existen modelos de serie de tiempo SARIMA que dan menor error en la predicción, como por ejemplo [Pappas et al., 2008] quien para un estudio horario en Grecia obtuvo, con un modelo más simple pronósticos con un $\pm 1.02\%$ de error.

Para el caso de esta tesis de maestría, teniendo en cuenta que no es un estudio local y que no se disponen de datos horarios de demanda en cada región geográfica, se propone el uso

de un modelo de series de tiempo que considere solo los datos históricos de demanda como variable explicativa. Esto es debido a que la temperatura evoluciona de forma continua y no discreta, es por ello que al usar un modelo SARIMA, **se presupone que los datos de demanda contienen implícitamente información de como evoluciona la temperatura en la componente autorregresiva del modelo**, (algo análogo a lo planteado por [Vu et al., 2015] cuando eliminaron de su modelo variables como la humedad o cantidad de horas de luz de sol), con correlaciones en las últimas semanas, días y horas. Con esto en cuenta se tiene que una temperatura extrema durante *una sola hora o unas pocas horas* no es determinante para influir en la demanda. Esto se observa en los valores encerrados en rojo en la figura 5.2 los cuales corresponden a días de los días de *veranito* de la 3ra semana de agosto y últimos días fríos de octubre. Por el contrario, las temperaturas extremas sostenidas, si influyen, en la demanda de potencia eléctrica, sobre todo en el sector residencial tal como también lo observó [Valor et al., 2001] en su estudio de España.




Figura 5.2: Desviaciones observadas de días aislados con temperaturas extremas.

5.2. Aplicación de la Metodología Box-Jenkins

A continuación se presenta el algoritmo a seguir para obtener los parámetros de un modelo de serie de tiempo Estacional, Autoregresivo, Integrado y de Media Móvil (SARIMA por las siglas en inglés) basado en la metodología Box-Jenkins, visto en el capítulo 3 (Pasos para identificar un modelo SARIMA) y en el diagrama de procesos de la Figura 3.2.

Los datos de demanda de potencia son presentados en forma de valores reales sucesivos, en intervalos regulares de una hora. Se totalizan 24 medidas diarias, las cuales constituyen una serie temporal discreta.

5.2.1. Paso 1: Graficar la Serie de Tiempo

En la Figura 5.3 se observan los valores registrados de demanda correspondientes al período de tiempo desde 01-Enero-2018 hasta 31-Julio-2022, totalizando 1673 días, es decir, 40152 horas de estudio.

Además se observan valores outliers el domingo, día del padre, 16 de junio de 2019, no considerados en el análisis debido a que corresponden a una sucesión de fallas que dejó sin energía eléctrica a todo el país y no corresponde a un comportamiento de la demanda. Estos valores podrían ser sustituidos por los valores correspondientes a la semana anterior (en este caso no fue necesario hacerlo, debido a que para este estudio solo afectaría si se quisiera hacer un pronóstico en esa semana en particular). Por otra parte se observa el impacto de la pandemia (después del día 800) explicado en la sección 4.8.1, Pandemia de SARS-CoV-2.




Figura 5.3: Serie de tiempo de la potencia demandada del SADI: Enero 2018 - Julio 2022.

Al visualizar la serie se observan momentos bien marcados de baja y alta demanda, que podrían sugerir una componente estacional (a verificar mediante un periodograma). Si bien la serie está actualizada hasta julio 2022.

Tal como se vio en la sección 3.5, en esta instancia que tiene como objetivo estimar los parámetros del modelo se considera toda la ventana de datos, es decir, desde el 01 de enero de 2018 hasta el 31 de julio de 2022.

5.2.2. Paso 2: Comportamiento Estacional de la Serie

En las figuras 5.4, 5.5, se muestra la curva semanal para la segunda semana de abril y la tercera semana de diciembre de 2019-2020. Es fácil observar una componente periódica de los valores sobre un valor base.




Figura 5.4: Potencia demandada del SADI: 2da Semana abril 2019-2020.

De la figura 5.4 se observa que para la 2da semana de abril, debido al ASPO, los valores de demanda de 2020 son menores a los de 2019 y en algunos casos se puede observar que hay un pequeño desfase en las primeras horas del día: las actividades se inician más tarde. El comportamiento de los picos de la tarde y la noche se mantiene igual a los de las curvas típicas de invierno.




Figura 5.5: Potencia demandada del SADI: 3ra Semana diciembre 2019-2020.

Respecto a la Figura 5.5, se observa que para la 3ra semana de diciembre, cuando muchas de las actividades habían vuelto a la normalidad y gran parte del país transitaba por el DSPO, la demanda de 2020 llega a ser superior a la de 2019. El perfil de los picos de la tarde y noche se mantienen igual y corresponden a las curvas típicas de verano.

Tanto para las semanas de abril y diciembre es posible diferenciar dos días tipos: hábiles y fines de semana.

De esta forma se puede tomar un día hábil como día típico de la estación y estudiar su curva de demanda característica, tal como hace CAMMESA y fue mostrado en la sección 4.8.2. Curvas de Demanda Estacional del capítulo anterior.

Concluida la inspección visual de la serie, se observa, en las Figuras 5.4 y 5.5 un comportamiento estacional. Este comportamiento se debe verificar mediante la función de autocorrelación (correlograma) y análisis espectral (periodograma).

Primer Correlograma

En la Figura 5.6 se representa el correlograma de la serie, con los límites de confianza al 95 %. Se observa un alto grado de correlación para retardos cíclicos, lo cual implica que la media también varía en forma periódica; es decir, cada hora tiene una media distinta. Esta afirmación se confirma en el espectro de la muestra presentado en la Figura 5.7.




Figura 5.6: FAC y FACP de la potencia demandada del SADI

Primer Periodograma Muestral

En la Figura 5.7 esta representada la densidad espectral en función de la frecuencia escalada ($f_e = T/s$), T es la longitud de la muestra y s la frecuencia. Se observan dos patrones estacionales: uno de 24 horas y otro de 168 horas. Se observa que el pico de mayor densidad espectral ocurre para la frecuencia de 24 horas.




Figura 5.7: Periodograma Muestral SADI.

Paso 1Bis Serie Primera Diferencia Estacional (24 horas)

Para remover la media cíclica, se aplicó la diferenciación estacional (24 horas). La serie resultante $d_{24}SADI$ se representa en la Figura 5.8.




Figura 5.8: Serie temporal diferencia estacional (24 horas) de la potencia demandada del SADI en el periodo de estudio completo

En las Figuras 5.9 y 5.10 están el correlograma y el periodograma muestral, repectivamente, de la serie de la diferencia estacional. Se observa otro pico de mayor densidad espectral pero esta vez en el periodo 168 horas (1 semana).




Figura 5.9: FAC y FACP de la potencia demandada del $d_{24}SADI$




Figura 5.10: Periodograma muestral de la potencia demandada del $d_{24}SADI$

De las Figuras 5.9 y 5.10 se puede deducir que la serie de la diferencia estacional($d_{24}SADI$) tiene otra componente estacional pero esta vez de una semana.

Paso 1 Tris Segunda Diferencia Estacional (168 horas)

Se aplica nuevamente una diferencia estacional pero esta vez de 168 horas. La serie resultante $d_{168}d_{24}SADI$ se representa en la Figura 5.11.




Figura 5.11: Serie temporal Diferencia estacional (168 horas) de la Diferencia estacional (24 horas) de la potencia demandada del SADI desde Enero 2018 hasta Julio 2022

En la Figura 5.12 se presenta el correlograma, de la serie de la diferencia estacional (168) de la diferencia estacional (24) de la serie original.




Figura 5.12: FAC y FACP de la potencia demandada del $d_{168}d_{24}SADI$

Por la forma de la función de autocorrelación mostrada en la Figura 5.12 se intuye, que la serie $d_{168}d_{24}SADI$ puede ser integrada.

5.2.3. Pasos 3 y 4: Inspección detallada de la Serie y Confirmación de Tendencia de la Serie

Se aplica una primera diferencia para convertir la serie en estacionaria, en las figuras 5.13 y 5.14 se muestran la serie resultante $d_1d_{168}d_{24}SADI$ y su correlograma respectivamente.




Figura 5.13: Serie temporal primera diferencia de la diferencia estacional (168 horas) de la diferencia estacional (24 horas) de la potencia demandada del SADI periodo completo




Figura 5.14: FAC y FACP de la serie $d_1d_{168}d_{24}SADI$

De la Figura 5.14 se puede deducir que la serie $d_1d_{168}d_{24}SADI$ es estacionaria con orden autorregresivo no estacional menor o igual a 5, orden media móvil no estacional menor o igual a 6, orden de la diferencia no estacional 1, orden autorregresivo estacional (24) menor o igual a 1, orden media móvil estacional menor o igual a 1 y orden de la diferencia estacional 1, además fue necesario aplicar una diferencia estacional de 168 horas.

Se realiza una prueba de raíz unitaria mediante un contraste aumentado de Dickey-Fuller, encontrando $(a - 1) = -0.0277802$, rechazando H_0 , por que lo que hay raíz unitaria, la serie no es estacionaria y se confirma que la serie es $I(1)$ y tiene tendencia, ver tabla 5.1.

```
Contraste aumentado de Dickey-Fuller para d_168d_24SADI
contrastar hacia abajo desde 53 retardos, con el criterio AIC
tamaño muestral 39906
la hipótesis nula de raíz unitaria es: [a = 1]
```

```
contraste sin constante
incluyendo 53 retardos de (1-L)d_168d_24SADI
modelo: (1-L)y = (a-1)*y(-1) + ... + e
valor estimado de (a - 1): -0,0277802
estadístico de contraste: tau_nc(1) = -25,3683
valor p asintótico 5,302e-41
Coef. de autocorrelación de primer orden de e: -0,000
diferencias retardadas: F(53, 39852) = 845,295 [0,0000]
```

```
contraste con constante
incluyendo 53 retardos de (1-L)d_168d_24SADI
modelo: (1-L)y = b0 + (a-1)*y(-1) + ... + e
valor estimado de (a - 1): -0,0277804
estadístico de contraste: tau_c(1) = -25,368
valor p asintótico 2,872e-52
Coef. de autocorrelación de primer orden de e: -0,000
diferencias retardadas: F(53, 39851) = 845,274 [0,0000]
```

```
con constante y tendencia
incluyendo 53 retardos de (1-L)d_168d_24SADI
modelo: (1-L)y = b0 + b1*t + (a-1)*y(-1) + ... + e
valor estimado de (a - 1): -0,0277808
estadístico de contraste: tau_ct(1) = -25,3679
valor p asintótico 1,005e-96
Coef. de autocorrelación de primer orden de e: -0,000
diferencias retardadas: F(53, 39850) = 845,253 [0,0000]
```

Tabla 5.1: Contraste aumentado de Dickey-Fuller de la serie $d_{168}d_{24}SADI$

Afirmar que el orden de la diferencia no estacional es 1, implica que el proceso es integrado o $I(1)$. Para confirmar esta aseveración fue realizada una prueba de raíces unitarias basada en el contraste aumentado de Dickey-Fuller (ADF) para la serie $d_1d_{168}d_{24}SADI$, para un

tamaño muestral de 39905¹, con la hipótesis nula de raíz unitaria: $a = 1$, obteniendo que $(a - 1) = -0,896313$, no rechazando H_0 , por que lo que se garantiza que no existe raíz unitaria, concluyendo que la serie $d_1d_{168}d_{24}SADI$ es estacionaria $I(0)$ y no tiene tendencia. El resultado se presenta en la tabla 5.2.

```

Contraste aumentado de Dickey-Fuller para d_d_168d_24SADI
contrastar hacia abajo desde 53 retardos, con el criterio AIC
tamaño muestral 39905
la hipótesis nula de raíz unitaria es: [a = 1]

contraste sin constante más variables ficticias estacionales
incluyendo 53 retardos de (1-L)d_d_168d_24SADI
modelo: (1-L)y = (a-1)*y(-1) + ... + e
valor estimado de (a - 1): -0,896313
estadístico de contraste: tau_nc(1) = -41,8341
valor p asintótico 1,157e-05
Coef. de autocorrelación de primer orden de e: -0,000
diferencias retardadas: F(53, 39828) = 245,123 [0,0000]

contraste con constante más variables ficticias estacionales
incluyendo 53 retardos de (1-L)d_d_168d_24SADI
modelo: (1-L)y = b0 + (a-1)*y(-1) + ... + e
valor estimado de (a - 1): -0,896313
estadístico de contraste: tau_c(1) = -41,8336
valor p asintótico 2,233e-15
Coef. de autocorrelación de primer orden de e: -0,000
diferencias retardadas: F(53, 39827) = 245,117 [0,0000]

con constante y tendencia más variables ficticias estacionales
incluyendo 53 retardos de (1-L)d_d_168d_24SADI
modelo: (1-L)y = b0 + b1*t + (a-1)*y(-1) + ... + e
valor estimado de (a - 1): -0,896314
estadístico de contraste: tau_ct(1) = -41,833
valor p asintótico 1,124e-139
Coef. de autocorrelación de primer orden de e: -0,000
diferencias retardadas: F(53, 39826) = 245,111 [0,0000]

```

Tabla 5.2: Contraste aumentado de Dickey-Fuller de la serie $d_1d_{168}d_{24}SADI$

Paso 5: Identificación de Parámetros del Modelo

Del análisis anterior surge que el modelo inicial a estimar, para la serie de demanda de potencia del SADI, corresponde a la familia de modelos:

$$SARIMA(5, 1, 6)(1, 1, 1)_{24}(0, 1, 0)_{168}$$

¹El número de observaciones de la muestra de la nueva serie es menor a la original debido a que en cada proceso de diferenciación (simple o estacional) se disminuye la cantidad de datos.

Resultados y Análisis de los Resultados

En el capítulo anterior, se llegó a la estructura de las familias de modelos SARIMA. En este capítulo se estimó un primer modelo que incluye todos los parámetros luego se realizó una búsqueda exhaustiva entre los distintos modelos de las familias SARIMA, de la serie demanda de potencia SADI, tomando como criterio inicial el menor p -Valor de los coeficientes y raíces fuera del radio unidad y se selecciona el modelo cuyo AIC sea menor. Al este modelo se le realiza un análisis a los residuos a fin de observar que los mismos se distribuyan de forma normal y de manera uniforme (se garantiza que no se distribuyan de forma periódica), además se busca que no se presente fuerte correlación en los primeros rezagos. Finalmente, se hace el pronóstico de la serie fuera de los datos originales y se compara con la predicción de CAMMESA.

6.1. Resultados de la Serie SADI. Pasos 1 y 2.

Una vez estimados los parámetros iniciales que debe contener el modelo $SARIMA(5, 1, 6)(1, 1, 1)_{24}(0, 1, 0)_{168}$. Se siguen los 4 pasos indicados en la subsección 3.6.1 Pasos para Seleccionar un Modelo y Validarlo y el diagrama de procesos de la Figura 3.3. En esta instancia se usa la ventana muestral que contiene los datos del 01 de enero al 31 de diciembre de 2021 (obs. 1096 a 1460). En la tabla 6.1 se muestran los parámetros del modelo inicial el cual contiene todas las variables del modelo propuestos. Finalmente se observa que el Modelo Inicial no viable dado que la raíz de la componente media móvil estacional es igual a 1, haciendo que el proceso no sea invertible.

PASO 1: Estimación del Modelo InicialModelo 1: ARIMA, usando las observaciones 1096:01–1460:24 ($T = 8760$)Variable dependiente: $(1 - L)(1 - L^s)d_{168}Demanda$

Desviaciones típicas basadas en la matriz de productos externos

		Coefficiente	Desv. Típica	z	valor p
	ϕ_1	0,393817	0,0902222	4,374	0,0000
	ϕ_2	0,781469	0,00704261	111,2	0,0000
	ϕ_3	-0,175453	0,0721532	-2,431	0,0148
	ϕ_4	-0,989874	0,0112522	-87,97	0,0000
	ϕ_5	0,319180	0,0850572	3,754	0,0003
	Φ_1	0,230843	0,0146000	15,80	0,0000
	θ_1	0,113655	0,0907456	1,249	0,2118
	θ_2	-0,708880	0,0438702	-16,16	0,0000
	θ_3	-0,185762	0,0625133	-2,950	0,0032
	θ_4	0,856746	0,0379876	22,54	0,0000
	θ_5	0,0774534	0,0751856	1,030	0,3030
	θ_6	0,0501814	0,0328692	1,526	0,1270
	Θ_1	-0,987487	0,0287978	-34,72	0,0000
Media de la vble. dep.		0,291807	D.T. de la vble. dep.	307,2485	
Media de innovaciones		0,236814	D.T. innovaciones	228,8756	
R^2		0,986992	R^2 corregido	0,986969	
Log-verosimilitud		-34354,59	Criterio de Akaike	68731,19	
Criterio de Schwarz		68802,96	Hannan–Quinn	68756,33	
		Real	Imaginaria	Módulo	Frecuencia
AR					
	Raíz 1	0,8746	0,5193	1,0171	0,0853
	Raíz 2	0,8746	-0,5193	1,0171	-0,0853
	Raíz 3	2,1547	0,0000	2,1547	0,0000
	Raíz 4	-0,8876	-1,1570	1,4583	-0,3541
	Raíz 5	-0,8876	1,1570	1,4583	0,3541
AR (estacional)					
	Raíz 1	4,5144	0,0000	4,5144	0,0000
MA					
	Raíz 1	-6,1743	0,0000	6,1743	0,5000
	Raíz 2	0,9015	-0,5465	1,0542	-0,0867
	Raíz 3	0,9015	0,5465	1,0542	0,0867
	Raíz 4	-0,8745	-1,1395	1,4364	-0,3542
	Raíz 5	-0,8745	1,1395	1,4364	0,3542
	Raíz 6	5,2708	0,0000	5,2708	0,0000
MA (estacional)					
	Raíz 1	1,0000	0,0000	1,0000	0,0000

Tabla 6.1: Modelo Inicial de Series Temporales

Finalmente, luego de correr varios modelos que cumplan el criterio inicial de menor p – *valor* de los coeficientes así como raíces fuera del radio unidad, se muestra el modelo que mejor se adapta a los datos en la tabla 6.1, el mismo fue elegido, de entre otros modelos candidatos, tomando el menor valor del Criterio de información Akaike AIC. Con este modelo se obtiene una bondad de ajuste (variable real vs pronosticada), dentro de la ventana muestral, del 98,71 % coherente con el trabajo de [Mado et al., 2018].

PASO 2: Estimación del Modelo Mejor Adaptado a los Datos

Modelo 212: ARIMA, usando las observaciones 1096:01–1460:24 ($T = 8760$)

Variable dependiente: $(1 - L)(1 - L^s)d.168$ Demanda

Desviaciones típicas basadas en la matriz de productos externos

		Coeficiente	Desv. Típica	z	valor p
ϕ_1		1,19005	0,0738418	6,68	0,0000
ϕ_2		0,122718	0,0391515	6,30	0,0000
ϕ_4		0,219049	0,0474270	6,768	0,0000
ϕ_5		-0,710952	0,0728141	-32,897	0,0000
Φ_1		-0,421512	0,0145925	-31,18	0,0000
θ_1		0,282456	0,0742343	8,28	0,0000
θ_4		-0,266543	0,0508875	-8,179	0,0000
θ_5		0,6191859	0,0510289	22,2231	0,0000
θ_6		0,168029	0,0341071	8,0801	0,0000
Media de la vble. dep.		0,239807	D.T. de la vble. dep.	307,2485	
Media de innovaciones		0,231960	D.T. innovaciones	218,1293	
R^2		0,987080	R^2 corregido	0,987050	
Log-verosimilitud		-33337,76	Criterio de Akaike	66703,52	
Criterio de Schwarz		66794,87	Hannan–Quinn	66735,57	
		Real	Imaginaria	Módulo	Frecuencia
AR					
	Raíz 1	2,2864	0,0000	2,2864	0,0000
	Raíz 2	0,8747	0,5194	1,0173	0,0853
	Raíz 4	-0,7687	-0,6465	1,0044	-0,3887
	Raíz 5	-0,7687	0,6465	1,0044	0,3887
AR (estacional)					
	Raíz 1	4,3212	0,0000	4,3212	0,0000
MA					
	Raíz 1	-0,7640	0,6495	1,0027	0,3879
	Raíz 4	0,9014	0,5460	1,0539	0,0867
	Raíz 5	-7,1344	0,0000	7,1344	0,5000
	Raíz 6	8,1770	0,0000	8,1770	0,0000

Tabla 6.2: Modelo Mejor Adaptado a los Datos

6.2. Paso 3: Análisis de los Residuos

Al modelo final se le realiza un análisis a los residuos y en la figura 6.1 se observa que los residuos del modelo final se distribuyen de manera uniforme (se garantiza que no se distribuyen de forma periódica).




Figura 6.1: Espectro de los residuos del modelo final

Finalmente se muestra en la Figura 6.2 el contraste de normalidad cuyo valor Estadístico de contraste: $\chi^2(2) = 425,944$, garantiza que el error tiene distribución Normal.




Figura 6.2: Distribución normal de los residuos

6.3. Comparación del modelo SARIMA obtenido con la previsión de CAMMESA

6.3.1. Paso 4: Validar el Modelo

Para validar el modelo, el pronóstico se compara con la previsión de CAMMESA y los datos reales de demanda, en una fecha fuera del rango con el que se estimaron los parámetros del modelo mejor adaptado a los datos (en este caso desde el 25 de enero al 31 de marzo 2022 y del 22 al 31 de mayo de 2023¹). En este sentido resulta importante aclarar que los parámetros del modelo son los mismos que se presentan en la tabla 6.2 y además se destaca que para poder hacer el pronóstico de demanda de un día completo, es necesario disponer de los datos reales de demanda de una semana anterior (mismo día), y de los días inmediatos anteriores los cuales sirven de semilla para el polinomio del modelo. Es decir para estimar el 25 de enero de 2022 fue necesario disponer de datos reales del 18, 23 y 24 de enero de 2022.

A continuación, se presentan en las Figuras 6.3, 6.4, 6.5 la demanda real en los meses de febrero y marzo 2022, así como mayo 2023, observando que el modelo SARIMA se ajusta mejor que la previsión de CAMMESA.




Figura 6.3: Resultados 1ra semana de Febrero 2022

¹Los datos de la previsión diaria (Sección Operaciones: Demanda Real y Prevista del SADI) no quedan registrados en CAMMESA, solo se encuentran disponibles los datos del día actual, por lo que fue necesario guardar los datos de la previsión de forma diaria para armar una serie de tiempo que sirva para validar el modelo SARIMA.




Figura 6.4: Resultados 3ra y 4ta semana de Marzo 2022




Figura 6.5: Resultados 22 al 31 de Mayo 2023

Un indicador que permite comparar el nivel de ajuste de la previsión CAMMESA y el pronóstico SARIMA contra los datos reales, es hacer una regresión lineal y comparar los distintos indicadores estadísticos como el R^2 , la función Log-verosimilitud o el criterios de información AKAIKE. Los resultados de la regresión se presentane en las Tablas 6.3 y 6.4.

Modelo 1: MCO, usando las observaciones 1:01–66:24 ($T = 1584$)				
Variable dependiente: REAL				
	Coefficiente	Desv. Típica	Estadístico t	valor p
PREVCAMMESA	0,977460	0,00121142	806,9	0,0000
Media de la vble. dep.	15847,15	D.T. de la vble. dep.	2387,210	
Suma de cuad. residuos	9,87e+08	D.T. de la regresión	789,5248	
R^2 no centrado	0,997574	R^2 centrado	0,890617	
$F(1, 1583)$	651043,9	Valor p (de F)	0,000000	
Log-verosimilitud	−12814,65	Criterio de Akaike	25631,29	
Criterio de Schwarz	25636,66	Hannan–Quinn	25633,29	
$\hat{\rho}$	0,915161	Durbin–Watson	0,168344	

Tabla 6.3: Regresión Modelo CAMMESA

Modelo 2: MCO, usando las observaciones 1:01–66:24 ($T = 1584$)				
Variable dependiente: REAL				
	Coefficiente	Desv. Típica	Estadístico t	valor p
PRONSARIMA	0,999715	0,000290689	3439,	0,0000
Media de la vble. dep.	15847,15	D.T. de la vble. dep.	2387,210	
Suma de cuad. residuos	54440898	D.T. de la regresión	185,4480	
R^2 no centrado	0,999866	R^2 centrado	0,993965	
$F(1, 1583)$	11827529	Valor p (de F)	0,000000	
Log-verosimilitud	−10519,97	Criterio de Akaike	21041,95	
Criterio de Schwarz	21047,31	Hannan–Quinn	21043,94	
$\hat{\rho}$	0,047235	Durbin–Watson	1,904889	

Tabla 6.4: Regresión Modelo CAMMESA

Finalmente, es importante destacar que si bien ambas formas de predicción tienen un grado de ajuste superior al 97 %. Al comparar ambos modelos se observa que en el caso de

la previsión de Cammesa, la misma tiene una desviación 4 veces mayor a la obtenida por el modelo SARIMA. Por otra parte estadísticos como el R^2 centrado, Log-verosimilitud, así como los criterios de Información Akaike y Hannan-Quinn, sugieren que el modelo SARIMA se ajusta mejor a los datos en comparación con la previsión de Cammesa en el Periodo Analizado. De todas formas, resulta interesante comparar el error relativo mediante un histograma de frecuencias y acotar la desviación aceptable, a por ejemplo, un valor de 3 %, que es el porcentaje de regulación primaria de frecuencia que se tiene en cuenta a nivel operativo para garantizar el normal funcionamiento del SADI.




Figura 6.6: Error relativo previsión CAMMESA




Figura 6.7: Error relativo modelo SARIMA

Este resultado permite observar que la previsión de CAMMESA, entra en la banda aceptable (de -3% a 3%) en un 45.2% y tiende a sobreestimar la demanda, mientras que el pronóstico obtenido con el modelo SARIMA, da un resultado mejor ajustado que concentra el 97.97% de la predicción en la banda aceptable.

Conclusiones y Trabajos Futuros

Los objetivos propuestos en el Capítulo 1 fueron cumplidos de forma satisfactoria. En primer lugar se aplicó la metodología Box-Jenkins para pronosticar la demanda horaria de potencia eléctrica. En segundo lugar, los resultados del modelo fueron validados contra la metodología de previsión de la demanda de CAMMESA en un rango de tiempo fuera del usado para estimar el modelo inicial.

La ventaja de usar un modelo SARIMA, es que se puede llegar a tener en una misma ecuación la información necesaria para pronosticar la demanda en un horizonte de una semana, sin importar el tipo de día. La alternativa, es usar un modelo ARIMA para cada día de la semana, tal como lo hicieron [Murillo et al., 2003], donde propusieron 2 tipos de día (hábil y fin de semana), obteniendo un modelo distinto para cada *día tipo*.

El modelo obtenido es SARIMA con dos estacionalidades (DSARIMA), que coincide con los resultados de pronóstico horario de [Mado et al., 2018], presentado en la sección Estado del Arte de esta tesis. El modelo DSARIMA incluye: una primera estacionalidad con período 24 horas (un día) y otra de período 168 horas (una semana). Asimismo, se puede mencionar que la serie es integrada con orden de integración $I(1)$.

El modelo que mejor se ajusta a los datos se muestra en el capítulo anterior, para evitar cualquier confusión en cuanto a la notación, es importante mencionar que el modelo que se muestra en las diferentes tablas corresponde a la serie $dd_{168}d_{24}SERIE$. Se seleccionó el modelo de menor valor AIC. El modelo permite obtener una correlación entre variable observada y estimada del 99,97% para un horizonte diario, mejorando el pronóstico en un 2,23% respecto a la metodología actual llevada por CAMMESA.

Se observó además, que si bien ambas metodologías tienen una bondad de ajuste por encima del 97.0%, la previsión de CAMMESA, entra en la banda aceptable (de -3% a 3%) en un 45.2% y tiende a sobreestimar la demanda, aumentando por una parte las emisiones¹ y el pago a generadores por potencia disponible (que no llega a ser usada), mientras que el pronóstico obtenido con el modelo SARIMA, da un resultado mejor ajustado que concentra el 97.97% de la predicción en la banda aceptable.

¹Las centrales térmicas necesitan un tiempo antes de poder generar energía eléctrica y entregarla a la red, tiempo en que consumen combustibles. Por otra parte de acuerdo a un despacho de cargas que se realice por costo marginal, las últimas máquinas en entrar son las mas costosas y menos eficientes.

Debido a la naturaleza propia de la red de un sistema de potencia, y la forma en la que se adquieren los datos de demanda de los grandes usuarios y distribuidoras, resulta imposible desglosar la demanda de potencia por unidades de consumo (residencial, comercial e industrial) a fin de hacer estudios, por sectores, más precisos y ajustados a la realidad.

Si bien la metodología fue usada para pronóstico horario, resulta importante recordar que la misma permite usarse en otros pasos de tiempo y considerar otras series de datos como temperatura, indicadores económicos, entre otros, para elaborar modelos econométricos más complejos que tomen en cuenta todas las variables mencionadas anteriormente y cuyo análisis lleven a una mejor planificación no solo en el sector energético sino en el económico.

Por otra parte, es importante mencionar que esta metodología también se puede usar en modelos con pasos de tiempo menor (menores a una hora, incluso minutos) y los mismos resultan de suma importancia en el redespacho de energía intermitente: Eólica y Solar.

Resulta interesante aplicar esta metodología en un área o región acotada, donde se pueda correlacionar con otra variable como la temperatura. Sin embargo, se pudo observar que al considerar la demanda total de los diferentes actores que demandan energía en el SADI a lo largo y ancho de todo el país se pudo pronosticar la demanda con un error aceptable, mejor que la predicción realizada por CAMMESA actualmente.

Al momento de implementar el modelo de serie de tiempo para hacer el pronóstico de la demanda, se debe tener en cuenta que el mismo debe revisarse, de forma periódica y evaluar si se mantienen los mismos parámetros explicativos, así como la familia de modelos (evaluar la robustez del modelo). Es importante destacar que, en caso de existir factores externos que pueden causar cambios estructurantes en la demanda, puede afectar los parámetros explicativos cambiando la familia de modelos. Una alternativa es realizar un análisis de sensibilidad del modelo, con métodos como Montecarlo, que puedan permitir evaluar, en distintos escenarios, la sensibilidad y grado de elasticidad de los parámetros del modelo ante cambios como: i) el surgimiento de nuevos artefactos que demanden energía con su propia curva de carga (por ejemplo los coches eléctricos); ii) implementación de políticas sociales y económicas que impacten sobre la demanda (por ejemplo sustitución de lamparas incandescentes por lamparas LED), iii) situaciones inesperadas como la pandemia.

En base a lo anterior, es importante destacar como desde nuevas áreas del conocimiento, en particular el estudio de Big Data, se pueden encontrar patrones de comportamiento y consumo que pueden servir en el mediano plazo, por una parte, de insumo para el diseño e implementación de nuevas políticas que lleven al uso racional y eficiente de la energía, y por otra a la integración armónica, de nuevos actores de la demanda, como los coches eléctricos, en donde la gestión de la demanda y el uso de smart grid que permitan desplazar la demanda a horas de valle, jugaran un papel significativo en cuanto a satisfacer la demanda de todos con una oferta muchas veces limitada, sobre todo en picos de demanda, mientras no se disponga de una forma de almacenar la energía a gran escala.

Se recomienda usar los procedimientos de inteligencia artificial, como algoritmos genéticos, redes neuronales artificiales y máquinas de vector de soporte para minimizar el tiempo de computo al momento de selección de modelos de entre una familia de modelos.

Apéndice A

Programas Informáticos Empleados

A.1. Hoja de Cálculo

Para procesar datos fue necesario usar hojas de cálculo de Microsoft Excel©, bajo la licencia de estudiante del autor provista por la Universidad Tecnológica Nacional (UTN).



Carlos Mora

carlos.mora@alu.inspt.utn.edu.ar

[Ver cuenta](#)

[Información de usuario de Office](#)

Figura A.1: Licencia de Estudiante Excel

A.2. Programa Econométrico

Se empleo un programa de software libre Gretl (Gnu Regression, Econometrics and Time-series Library).




Figura A.2: Interfaz de Gretl.

Apéndice B

Instructivo para Descargar Datos de la Página Web de Cammesa

B.1. Datos de Demanda Horaria

Para descargar los datos en paso horario de la Demanda de Potencia Eléctrica es necesario entrar al portal de Cammesa: <https://cammesaweb.cammesa.com/> e ir a la solapa: *Informes y Estadísticas*.



Figura B.1: Vista de la página de Cammesa

Alternativamente se puede ingresar a la sección *Informes y Estadísticas* escaneando el siguiente código QR.



Figura B.2: QR a la solapa *Informes y Estadísticas*.

Una vez en la sección *Informes y Estadísticas* se debe ir a la sección de la publicación de Síntesis Mensual.



Figura B.3: Vista solapa *Informes y Estadísticas*.

La base de datos del Informe Síntesis Mensual, incluye entre otras cosas, la base de datos de demanda con paso horario.

2 INFORME SÍNTESIS MENSUAL

INFORME MENSUAL

El informe contiene el comportamiento de las principales variables físicas y económicas del MEM a lo largo del mes de análisis y su comparación con meses anteriores; entre las variables se destacan la demanda eléctrica, oferta de energía, potencia instalada, generación, consumo de combustibles, costos y precios de la energía.

El mismo está acompañado por estadísticas de paso: mensual, diario y horario dependiendo de la variable en análisis.

Julio 2022

Potencia Instalada: **42 898 [MW]**

Potencia Máxima Bruta: **24 477 [MW]**
12/7/2022 21:23

Potencia Máxima Hist.: **28 231 [MW]**
18/11/2012 14:32

Demanda Total: **12 439 [GWh]**
1.8% vs. Igual Mes 2021
5.4% Año Menor

PRECIO MONÓMICO MEDIO MES: **16693.3 \$/MWh**
 MONÓMICO MEDIO AÑO MÓVIL: **9597.6 \$/MWh**

BASES DE DATOS

Al Informe Mensual lo acompaña una base de **datos horaria de demanda** y generación por tipo, una base diaria del consumo de combustibles y en paso mensual, el comportamiento de las variables que se visualizan en el informe, agregando además la evolución de las mismas desde el año 2019.

Las distintas variables se encuentran en 3 grandes grupos: Demanda, Generación y Adicionales (que incluye: Balance, Precios, Intercambios, entre otros)

Figura B.4: Información que contiene la Síntesis Mensual.

Se debe descargar los datos del informe mensual (archivo zip), el cual se descarga por defecto en la carpeta descargas. Se requiere tener un programa para leer ese archivo (Ej. WinRAR).




Figura B.5: Vista del Archivo de datos que se descarga en la computadora

Buscar dentro de la carpeta Base informe mensual a la carpeta que contiene información sobre la demanda.




Figura B.6: Vista de la carpeta en donde se encuentra el archivo Excel con datos de demanda

Seleccionar el archivo de demanda con paso horario.




Figura B.7: Vista del archivo excel que contiene los datos de demanda horaria.

Abrir la planilla de cálculo Excel que contiene a los datos de demanda con paso horario.

Autoguardado

Demanda Horaria por Tipo - Solo lec...

Buscar

ArchivoInicioInsertarDisposición de páginaFórmulasDatosRevisarVistaAutomatizarAyudaAcrobatPower PivotComentariosCompartir

Pegar

Proxima Nova Rg

14

A⁺A⁻

General

\$

%

000

00

00

Formato condicional

Dar formato como tabla

Estilos de celda

Insertar

Eliminar

Formato

Celdas

Σ

Ordenar y filtrar

Buscar y seleccionar

Analizar datos

Edición

Análisis

PortapapelesFuenteAlineaciónNúmeroEstilosCeldasEdiciónAnálisis

A1

DEMANDA TOTAL PASO HORARIO POR TIPO

DEMANDA TOTAL PASO HORARIO POR TIPO														
Unidad: MWh														
DEMANDA														
AÑO	MES	N° MES	N° DIA	TIPO DIA	DIA	FECHA	HORA	Gran Usuario MEM	DISTRIBUIDOR (demanda estacional+GUMEs)	DEMANDA LOCAL [MWh]	Exportación	Bombéo	Perdidas	DEMANDA TOTAL [MWh]
2020	ene-20	1	1	No Hábil	Miércoles	1/1/2020	1	1.438	11.892	13.330	0	0	390	13.720
2020	ene-20	1	1	No Hábil	Miércoles	1/1/2020	2	1.428	11.663	13.090	0	0	462	13.552
2020	ene-20	1	1	No Hábil	Miércoles	1/1/2020	3	1.429	11.469	12.898	0	0	425	13.323
2020	ene-20	1	1	No Hábil	Miércoles	1/1/2020	4	1.422	11.233	12.655	0	0	423	13.078
2020	ene-20	1	1	No Hábil	Miércoles	1/1/2020	5	1.439	10.967	12.406	0	0	395	12.801
2020	ene-20	1	1	No Hábil	Miércoles	1/1/2020	6	1.441	10.503	11.944	0	132	353	12.428
2020	ene-20	1	1	No Hábil	Miércoles	1/1/2020	7	1.447	9.489	10.936	0	215	341	11.492
2020	ene-20	1	1	No Hábil	Miércoles	1/1/2020	8	1.460	9.257	10.717	0	384	272	11.373
2020	ene-20	1	1	No Hábil	Miércoles	1/1/2020	9	1.482	9.413	10.895	0	385	293	11.573
2020	ene-20	1	1	No Hábil	Miércoles	1/1/2020	10	1.478	9.718	11.196	0	565	369	12.130
2020	ene-20	1	1	No Hábil	Miércoles	1/1/2020	11	1.495	10.136	11.631	0	574	382	12.588
2020	ene-20	1	1	No Hábil	Miércoles	1/1/2020	12	1.504	10.577	12.081	0	575	374	13.030
2020	ene-20	1	1	No Hábil	Miércoles	1/1/2020	13	1.495	11.004	12.499	0	477	394	13.370
2020	ene-20	1	1	No Hábil	Miércoles	1/1/2020	14	1.488	11.281	12.768	0	386	407	13.561

Figura B.8: Vista de la hoja de calculo Excel con los datos históricos de demanda horaria.

B.2. Previsión Diaria

Para poder realizar la validación del modelo es necesario contar con la Previsión diaria elaborada por Cammesa. En este sentido para poder construir la serie de tiempo *Previsión Cammesa*, fue necesario descargar los datos todos los días y guardarlo en un archivo que iba actualizando día a día, debido a que los datos de previsión solo estan disponibles durante el día de consulta (se pisan).




Figura B.9: Exportar datos de Previsión demanda desde la página de Cammesa

	A	B	C	D	E	F	G	H	I	J	K	L	M	N	O	P	Q	R
1	Fecha	Dem. Hoy	Dem. Ayer	Dem. Semana Ant.	Dem. Previsión	Tem. Hoy	Tem. Ayer	Tem. Semana Ant.	Tem. Previsión									
2	5/7/2023 00:00	15777	16403	18970	17038	18,5	18,6	11,7										
14	5/7/2023 01:00	14756	15156	17396	15160	18,8	18,2	10,9										
26	5/7/2023 02:00	13901	14435	16141	14134	17,9	18	9,6										
38	5/7/2023 03:00	13634	14038	15807	14150	18,5	18	8,8										
50	5/7/2023 04:00	13564	13873	15655	13928	18,2	18	7,5										
62	5/7/2023 05:00	13709	14026	15814	13815	17,4	18,4	7,2										
74	5/7/2023 06:00	14024	14383	16242	14443	17	18,6	6,4										
86	5/7/2023 07:00	15521	16341	18291	15650	16,3	18,4	5,7										
98	5/7/2023 08:00	16389	16521	19334	16415	15,3	18,6	5										
110	5/7/2023 09:00	16684	16610	19948	17056	15,1	19	6,3										
122	5/7/2023 10:00	17111	17125	20423	17675	16,5	19,2	9,4										
134	5/7/2023 11:00	17438	17223	20409	17938	17,7	20,5	12,5										
146	5/7/2023 12:00	17704	17395	20047	17842	18,6	22,1	15,2										
158	5/7/2023 13:00	17311	17190	19343	17682	19,2	22,4	16,7										
170	5/7/2023 14:00	16849	16821	18886	17461	19,1	23,5	17,2										
182	5/7/2023 15:00	16636	16721	18552	17363	19,4	24,3	17,6										
194	5/7/2023 16:00	16429	16386	18337	17081	19,2	24,7	17,5										
206	5/7/2023 17:00	16441	16362	18618	17159	19,1	23,9	16,7										
218	5/7/2023 18:00	17061	17000	19278	17699	18,2	22,9	14,2										
230	5/7/2023 19:00	18841	18360	21593	19383	17,6	21,4	12,2										
242	5/7/2023 20:00	19352	18907	22408	19792	17,2	20,8	11										
254	5/7/2023 21:00	19562	19062	22884	20004	17,1	20,4	9,9										
266	5/7/2023 22:00	18857	18346	22467	19297	16,7	19,8	8,8										
278	5/7/2023 23:00		17140	21413	18464		19,2	8										
290	6/7/2023 00:00		15777	19724	17001		18,5	8										

Figura B.10: Vista de la Planilla Excel con la Previsión de demanda del día

B.3. Para otras Consultas de Información Estadística Pública Oficial de Cammesa

Además de el portal web de Cammesa, es posible contactarse con el grupo de estadísticas y control a través de los datos de contacto presentados en la siguiente imagen.



Figura B.11: Datos de Contacto Estadísticas y Control Cammesa

Asímismo, se recomienda estar atento a las publicaciones y posteos en el linkedin oficial de Cammesa: <https://www.linkedin.com/company/cammesa/posts/> en donde todos los meses presentan una Guía Rápida para descargar Informes de Seguimiento.




Figura B.12: Guía Rápida para Descargar Informes de Seguimiento

Apéndice C

Prueba de Raíz Unitaria

C.1. Introducción

Se dice que una serie tiene una tendencia; Se pueden diferenciar dos tipos de representaciones de series con tendencias:

1. $\longrightarrow$ Tendencia lineal ("Trend stationary"):
 $y_t = \phi_0 + a \cdot t + u_t$.
2. $\longrightarrow$ Tendencia estocástica ("Difference stationary"):
 $y_t = \phi_0 + y_{t-1} + u_t$;

donde u_t es un error o innovación del proceso.

Nota: otro nombre para las tendencias estocásticas es procesos de raíz unitaria ("unit root processes"), porque $\phi_1 = 1$.

Nota: en principio u_t puede tener una estructura ARMA(p,q).

C.1.1. Terminología y Notación

Una serie y_t sera integrada de orden d si $\Delta^d y_t$ es una serie estacionaria. También se dice que d es el orden de integración. se denota por:

$y_t \sim I(d)$ y ARIMA(p,d,q); donde $d \geq 0$.

C.1.2. Ejemplos

- Si y_t no es estacionaria pero, Δy_t lo es, entonces escribimos $y_t \sim I(1)$.
- Si ni y_t ni Δy_t son estacionarias pero, $\Delta^2 y_t$ lo es, entonces escribimos $y_t \sim I(2)$.
- Si y_t ya es estacionarias entonces solo, escribimos $y_t \sim I(0)$.

C.2. ¿Como encontrar el orden de integración adecuado?

Para apoyar o rechazar una hipótesis de orden $d=1$, por ejemplo se pueden usar varios tipos de información:

1. inspección visual de los gráficos.
2. Propiedades y test estadísticos.
3. Sentido Común.
4. Teoría.

C.3. Prueba de Dickey-Fuller

Considerando el modelo:

$$y_t = \Phi_1 y_{t-1} + \epsilon_t \quad (\text{C.1})$$

con ϵ_t , un ruido blanco, varianza constante.

$|\Phi| < 1$:

1. y_t es estacionario.
2. y_t la prueba de los t es valida

$\Phi = 1$:

1. y_t no es estacionario.
2. y_t la prueba de los t no es valida

Dickey y Fuller (1979) mostraron que, aunque la prueba de la t no es válida en (1) cuando $\Phi_1 = 1$, la prueba de la t es válida para la especificación:

$$\Delta y_t = \Phi_0 + \pi y_{t-1} + \epsilon_t \quad (\text{C.2})$$

cuando la hipótesis nula es $\Phi_1 = 1$ y donde $\pi = \Phi_1 - 1$

Esta propiedad la utilizaron Dickey y Fuller (1979) para desarrollar una prueba de estacionalidad.

La prueba Dickey-Fuller es una prueba de raíz unitaria (unit root), y para determinar los valores críticos para la hipótesis nula de $\Phi_1 = 1$ se necesita el método de Monte Carlo (simulación)

La prueba Dickey-Fuller estima:

$$\Delta y_t = \Phi_0 + \pi y_{t-1} + \epsilon_t \quad (\text{C.3})$$

Para los casos:

$$H_0 : \pi = 0 \quad H_1 : \pi < 0$$

Compara el estadístico con el valor de la tabla de Dickey y Fuller (1979) o, mejor, con la tabla de MacKinnon (1996).

C.3.1. Prueba de Dickey-Fuller Aumentada

Normalmente, las variables requieren una representación AR(p) y no sólo AR(1). Por lo que se debe encontrar una forma extendida de prueba de raíz unitaria.

La prueba Dickey-Fuller aumentada:

$$\Delta y_t = \Phi_0 + \pi_0 y_{t-1} + \pi_1 \Delta y_{t-1} + \dots + \pi_p \Delta y_{t-p} + \epsilon_t \quad (\text{C.4})$$

1. $H_0 : \pi_0 = 0$
2. $H_1 : \pi_0 < 0$

Compara el estadístico con el valor de la tabla de Dickey y Fuller (1979) o, mejor, con la tabla de MacKinnon (1996).

Problema práctico: elegir p. Se ensayan las soluciones posibles:

1. Incluir retardos de Δy_t hasta que el error sea ruido blanco.

2. Incluir retardos de Δy_t significativos
3. Information Criteria

Sin embargo, la prueba de Dickey-Fuller es frágil y siempre hay que utilizar información adicional (inspección visual de la serie, sentido común, historia, teoría) antes de aceptar o rechazar lo que sugiere la prueba de Dickey-Fuller.

Tendencia lineal vs. tendencia estocástica: la prueba de Dickey-Fuller nos permite incluir un término de tendencia lineal $a \cdot t$

Es decir, contrastar $\pi_0 = 1$ con la especificación:

$$\Delta y_t = \Phi_0 + a \cdot t + \pi_0 y_{t-1} + \pi_1 \Delta y_{t-1} + \dots + \pi_p \Delta y_{t-p} + \epsilon_t \quad (\text{C.5})$$

Problema: si hay variables innecesarias en la ecuación (C.5), es más difícil rechazar la hipótesis nula de $\pi_0 = 0$ (raíz unitaria) cuando en realidad $\pi_0 < 0$

Solución: se deben hacer tres pruebas:

1. Sin la constante Φ_0 y sin el término at .
2. Con la constante Φ_0 pero sin el término at .
3. Con la constante Φ_0 y el término at .

Se selecciona la que tenga menor valor del estadístico o criterio de información Akaike (AIC).

Apéndice D

Notación de Operadores

D.1. El operador de retardos

Definimos el operador de retardo, B , como un operador lineal que aplicado a una función temporal proporciona esa misma función retardada un periodo. Por definición:

$$Bf(t) \equiv f(t - 1) \quad (\text{D.1})$$

donde, para simplificar la notación, en lugar de utilizar la notación más precisa $B[f(t)] \equiv f(t - 1)$, escribimos el operador como un producto sobre la función. Esta notación debe interpretarse como una operación aplicada a una función, $f(t)$, que proporciona otra función, $f(t-1)$. En particular, si aplicamos el operador de retardo a una serie temporal obtendremos la misma serie temporal retardada un periodo y escribiremos:

$$Bx_t = x_{t-1} \quad (\text{D.2})$$

Una constante se interpreta como una función que es constante en el tiempo, y estableceremos que al aplicar el operador de retardo a una constante ésta no se modifica:

$$B\mu = \mu \quad (\text{D.3})$$

De acuerdo con la definición, si aplicamos este operador al producto de una constante, a , por una serie temporal tenemos que:

$$Bax_t = aBx_t = ax_{t-1} \quad (\text{D.4})$$

El operador de retardo es lineal, es decir:

$$B(af(t) + bg(t)) = af(t-1) + bg(t-1) \quad (D.5)$$

y puede aplicarse sucesivamente:

$$B^k x_t = \underbrace{B \dots B}_k x_t = x_{t-k} \quad (D.6)$$

Definiremos los polinomios en el operador de retardo como nuevos operadores que aplicados a una función proporcionan otra función, de acuerdo con las propiedades anteriores del operador B. Por ejemplo, el operador $\Phi(B) = 1 - \Phi_1 B - \Phi_2 B^2$ aplicado a una serie temporal proporciona otra serie temporal, mediante la operación:

$$(1 - \Phi_1 B - \Phi_2 B^2)x_t = x_t - \Phi_1 Bx_t - \Phi_2 B^2 x_t = x_t - \Phi_1 x_{t-1} - \Phi_2 x_{t-2} \quad (D.7)$$

y al aplicar $\Phi(B)$ a una serie, x_t , se obtiene otra serie, z_t , que se calcula como $x_t - \Phi_1 x_{t-1} - \Phi_2 x_{t-2}$

D.2. El operador diferencia

Un caso particular importante de operador polinómico es el operador $(1 - B)$, que se conoce como operador diferencia, y se denota por $\nabla = (1 - B)$. Entonces:

$$\nabla x_t = (1 - B)x_t = x_t - x_{t-1} \quad (D.8)$$

El resultado de aplicar el operador diferencia a una serie x_t con N observaciones es obtener una nueva serie de N-1 observaciones mediante $z_t = x_t - x_{t-1}$, para $t = 2, \dots, N$. El operador diferencia puede aplicarse más de una vez:

$$\nabla^2 x_t = (1 - B)^2 x_t = (1 - B)(x_t - x_{t-1}) = x_t - 2x_{t-1} + x_{t-2} \quad (D.9)$$

La estacionalidad requerirá tomar diferencias entre observaciones separadas s periodos. Definimos el operador diferencia de orden s como:

$$\nabla_s x_t = (1 - B^s)x_t = (x_t - x_{t-s}) \quad (D.10)$$

Bibliografía

- [Batahona, 2018] Batahona, J. (2018). Pronósticos del consumo y demanda de potencia máxima de energía eléctrica en la ciudad de Riobamba para el periodo 2017 - 2020, mediante modelos arima. Trabajo de titulación, Departamento de Ingeniería Informática, Escuela de Física y Matemáticas, Facultad de Ciencias, Escuela Superior Politécnica de Chimborazo, Riobamba, Ecuador.
- [Beyrne et al., 2015] Beyrne, Malvicino, and Trajtenberg (2015). Modelo estacional de demanda de energía eléctrica. *Documento de Trabajo Nro. 11 de la Secretaría de Política Económica y Planificación del Desarrollo del Ministerio de Economía y Finanzas Públicas de Argentina*.
- [Blancas and Noel, 2018] Blancas, J. and Noel, J. (2018). Pronóstico de la demanda eléctrica a corto plazo con lógica difusa. *Revista de Energía de Latinoamérica y el Caribe*, 2(1):8–27.
- [Box et al., 1976] Box, G., Jenkins, and M., G. (1976). *Time Series Analysis: Forecasting and Control*. Holden-Day series in time series analysis and digital processing. Holden-Day.
- [CAMMESA, 2022] CAMMESA (2022). Página web: <https://cammesaweb.cammesa.com/>.
- [CEPAL et al., 1997] CEPAL, N. et al. (1997). Energía y desarrollo sustentable en américa latina y el caribe: enfoques para la política energética.
- [Chatfield, 2003] Chatfield, C. (2003). *The Analysis of Time Series*. Chapman and Hall/CRC.
- [Chen et al., 2004] Chen, B.-J., Chang, M.-W., and lin, C.-J. (2004). Load forecasting using support vector machines: a study on eunite competition 2001. *IEEE Transactions on Power Systems*, 19(4):1821–1830.
- [CNEA, 2023] CNEA (2023). Síntesis del mercado eléctrico mayorista de la república argentina. <https://www.cnea.gob.ar/nuclea/handle/10665/803>.
- [CNEA, 2021] CNEA, P. E. (2021). *Edición Especial 20 Aniversario Síntesis del MEM, ISBN 978-987-1323-79-1*. Subgerencia Planificación Estratégica CNEA, Buenos Aires, Argentina. <https://www.cnea.gob.ar/nuclea/handle/10665/1905>.

- [Escobar et al., 2009] Escobar, L., Valdes, J., and Zapata, S. (2009). Redes neuronales artificiales en predicción de series de tiempo. una aplicación a la industria. Technical report, Working Paper Series Universidad de Palermo.
- [Fabrégas et al., 2018] Fabrégas, J., Luna, J., Riquelme, J., A.Arcos, and J.Tejedor (2018). Análisis big data para la respuesta a la demanda en el mercado eléctrico. In *CAEPIA 2018: XVIII Conferencia de la Asociación Española para la Inteligencia Artificial.*, pages 777–783, Granada, España. ISBN: 978-84-09-05643-9.
- [Fattaheian-Dehkordi et al., 2014] Fattaheian-Dehkordi, Fereidunian, Dehkordi, and Lesani (2014). Hour-ahead demand forecasting in smart grid using support vector regression (svr). *International Transactions on Electrical Energy Systems*, pages 1650–1663. <http://dx.doi.org/10.1002/etep.1791>.
- [Fernández, 2007] Fernández, L. (2007). *Modelos avanzados para la predicción a corto plazo de la producción eléctrica en parques eólicos*. PhD thesis, Universidad de La Rioja.
- [Ghalekhondabi et al., 2016] Ghalekhondabi, I., Ardjmand, E., Weckman, G., and Young, W. (2016). An overview of energy demand forecasting methods published in 2005–2015. *Working paper of Ohio University.*, page NA. DOI: 10.1007/s12667-016-0203-y.
- [Gutiérrez, 2003] Gutiérrez, E. (2003). La demanda residencial de energía eléctrica en la comunidad autónoma de andalucía un análisis cuantitativo, tesis doctoral, universidad de sevilla. disponible en la biblioteca virtual miguel de cervantes.
- [Halepoto et al., 2014] Halepoto, Uqaili, and Chowdhry (2014). Least square regression based integrated multi-parameteric demand modeling for short term load forecasting. *Mehran University Research Journal of Engineering and Technology*, pages 215–226. License CC BY 4.0.
- [Hassani et al., 2014] Hassani, Abdollahzadeh, Iranmanesh, and Miranian (2014). A self-similar local neuro-fuzzy model for short-term demand forecasting. *Journal of Systems Science and Complexity*, pages 3–20. <https://link.springer.com/article/10.1007/s11424-014-3299-y>.
- [Herrera, 2007] Herrera, L. (2007). Pronóstico de la demanda de muy corto plazo utilizando inteligencia artificial. B.S. thesis, QUITO/EPN/2007.
- [Ismail et al., 2008] Ismail, Z., Jamaluddin, F., and Jamaludin, F. (2008). Time series regression model for forecasting malaysian electricity load demand. *Asian Journal of Mathematics and Statistics*, 1(3):139–149. DOI: 10.3923/ajms.2008.139.149.
- [Mado et al., 2018] Mado, I., Soeprijanto, A., and Suhartono, S. (2018). Applying of Double Seasonal ARIMA Model for Electrical Power Demand Forecasting at PT. PLN Gresik Indonesia. *International Journal of Electrical and Computer Engineering*, 8(6):4892–4901. DOI: <https://doi.org/10.11591/ijece.v8i6.pp4892-4901>.

- [Martin, 2005] Martin, C. (2005). *Prognóstico de demanda de potência elétrica para planejamento e operação de sistemas elétricos*. PhD thesis, Tese apresentada ao Curso de Pós-Graduação em Engenharia de Produção Universidade Federal de Santa Catarina para obtenção do título de Doutor em Engenharia de Produção, Florianópolis, SC.
- [Mastronardi et al., 2016] Mastronardi, Sfeir, and Sánchez (2016). La temperatura y su influencia en la demanda de energía eléctrica: Un análisis regional para argentina usando modelos econométricos. *Documento de trabajo de la Subsecretaría de Escenarios y Evaluación de proyectos del Ministerio de Energía y Minería de la Nación Argentina*.
- [Mishra et al., 2019] Mishra, S., Bordin, C., Würsig, C., and Palu, I. (2019). Multivariate scenario generation – an arima and copula approach. *International Journal of Modeling and Optimization*, 9(3):146–149. DOI: <https://doi.org/10.7763/IJMO.2019.V9.700>.
- [Molnar et al., 2016] Molnar, Do, and Lin (2016). Electricity consumption modelling: A case of germany. *Volumen 55 Economic Modelling.*, pages 92–101. <https://doi.org/10.1016/j.econmod.2016.02.010>.
- [Mora and Iglesia, 2022] Mora and Iglesia (2022). Comportamiento del sadi durante la ola de calor 2022. <https://www.cnea.gob.ar/nuclea/handle/10665/1914>.
- [Mora C., 2020] Mora C., Gómez F., M. V. (2020). Demanda eléctrica bajo el efecto COVID-19. <https://www.cnea.gob.ar/nuclea/handle/10665/962>.
- [Moreno, 2006] Moreno, J. (2006). Control de la demanda de energía eléctrica. *Física y Sociedad, Revista del Colegio Oficial de Físicos*, Número 17:20–23.
- [Murillo et al., 2003] Murillo, J., Trejos, A., and Carvajal, P. (2003). Estudio del pronóstico de la demanda de energia electrica, utilizando modelos de series de tiempo. *Scientia et Technica*, 3(23).
- [Ortiz, 2015] Ortiz, M. (2015). Pronóstico de la demanda eléctrica residencial basado en el modelo de regresión adaptativa multivariante spline (mars). B.S. thesis, Universidad Politécnica Salesiana. Quito. Ecuador. <http://dspace.ups.edu.ec/handle/123456789/11290>.
- [Pappas et al., 2008] Pappas, Ekonomou, Karampelas, and Moussas (2008). Adaptive load forecasting of the hellenic electric grid. *Journal of Zhejiang University - Science A: Applied Physics and Engineering*, pages 1724–1730. <http://dx.doi.org/10.1631/jzus.A0820042>.
- [Peña, 2005] Peña, D. (2005). *Análisis de series temporales*. Ciencias sociales. Editorial Alianza, Madrid, España.
- [Psiloglou et al., 2009] Psiloglou, Giannakopoulos, Majithia, and Petrakis (2009). Factors affecting electricity demand in athens, greece and london, uk: A comparative assessment. *Energy Economics, Volume 34, Issue 11. ISSN 0360-5442.*, pages 1855–1863. <https://doi.org/10.1016/j.energy.2009.07.033>.

- [Sanjinés, 2011] Sanjinés, G. (2011). Análisis y pronóstico de la demanda de potencia eléctrica en bolivia: una aplicación de redes neuronales. *Red Latinoamericana de Desarrollo Económico*, 15:45–77.
- [Tabares and Hernández, 2009] Tabares, H. and Hernández, J. (2009). Pronósticos demanda de energía y potencia a corto plazo. caso de estudio: Unidad de control de pronóstico noroeste (Área antioquia-chocó).
- [Tarade and Katti, 2011] Tarade, R. and Katti, P. (2011). A Comparative Analysis for Wind Speed Prediction. In *International Conference on Energy, Automation and Signal*, pages 1–6, Bhubaneswa, India. DOI: <https://doi.org/10.1109/ICEAS.2011.6147167>.
- [Valor et al., 2001] Valor, Meneu, and Caselles (2001). Daily air temperature and electricity load in spain. *Journal of Applied Meteorology.*, pages 1413–1421. [https://doi.org/10.1175/1520-0450\(2001\)040<1413:DATAEL;2.0.CO;2](https://doi.org/10.1175/1520-0450(2001)040<1413:DATAEL;2.0.CO;2).
- [Vu et al., 2015] Vu, D., Muttaqi, K., and Agalgaonkar, A. (2015). A variance inflation factor and backward elimination based robust regression model for forecasting monthly electricity demand using climatic variables. *Applied Energy*, 140:385–394. DOI: 10.1016/j.apenergy.2014.12.011.
- [Watson et al., 2005] Watson, Hor, and Majithia (2005). Analyzing the impact of the weather variables on monthly electricity demand. *IEEE Transactions on Power Systems*, pages 2078–2085. DOI: 10.1109/TPWRS.2005.857397.
- [Zotelo, 2016] Zotelo (2016). Modelo de predicción de consumo eléctrico en función de la temperatura para amba.
- [Şişman, 2016] Şişman, B. (2016). A Comparison of ARIMA and Grey Models for Electricity Consumption Demand Forecasting: The Case of Turkey. *Kastamonu Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 13(3):234–245.