

PLANTILLA DE PRESENTACIÓN DE TRABAJO COMPLETO

INGENIERÍA Y TECNOLOGÍA

ANÁLISIS MULTICRITERIO DE MÉTODOS DE PROYECCIÓN DE LA DEMANDA DE ENERGÍA ELÉCTRICA A CORTO, MEDIANO Y LARGO PLAZO EN LA REPÚBLICA DEL PARAGUAY

Autor: De Oliveira, Jairo; jairooliveirasn@pol.una.py

Co-autor(es): González, Arturo; Riveros, Estela; Fernández, Félix

Orientador/a: González, Arturo; arturogonzalez@pol.una.py

Facultad Politécnica, Universidad Nacional de Asunción

Resumen

El pronóstico de la demanda de electricidad es una herramienta esencial para la toma de decisiones de empresas distribuidoras de la energía eléctrica. El presente trabajo tuvo por objetivo modelar y pronosticar la demanda de energía eléctrica del Paraguay en horizontes de corto plazo (48 horas), mediano plazo (24 meses) y largo plazo (2023 - 2050). En este sentido, se trabajó con datos de demanda de energía eléctrica proveídos por la Administración Nacional de Electricidad (ANDE). Se utilizaron diversos modelos de series de tiempo (AR, MA, ARMA, ARIMA, SARIMA, ARIMAX, SARIMAX, *Holt-Winters*) y regresión lineal múltiple (RLM). Además, una exhaustiva revisión sistemática de la literatura ha sido la base para el desarrollo de este trabajo. Los datos analizados comprendieron series históricas de demanda máxima horaria año 2022, demanda de energía eléctrica mensuales y anuales desde 1990 al 2022. En los tres horizontes, se compararon modelos con métricas de error (RMSE, MAE, MAPE), coeficiente de determinación R^2 , criterios estadísticos AIC, BIC, log-verosimilitud, autocorrelaciones ACF, PACF y se seleccionó el modelo más adecuado mediante la herramienta de proceso analítico jerárquico (AHP, por sus siglas en inglés), todo a partir del entrenamiento de los datos acompañado por un riguroso

análisis estadístico garantizan la coherencia en los resultados obtenidos. Para corto y mediano plazo, SARIMAX fue el modelo con mayor preferencia teniendo en cuenta los múltiples criterios propuestos, utilizando como regresor exógeno la temperatura media. En el largo plazo, *Holt-Winters* resultó el modelo más adecuado determinado por el AHP y a la vez el modelo de RLM con variables socioeconómicas (PIB, inflación y número de población) que también mostró una sólida capacidad de previsión para el pronóstico de la demanda de energía al 2050. Por último, mediante este estudio se proporciona un análisis detallado en esta línea de investigación y las posibles direcciones para futuras investigaciones sobre el pronóstico de la demanda eléctrica para la República del Paraguay.

Palabras clave: Series Temporales; Demanda de Energía Eléctrica; Demanda Máxima; *Holt-Winters*; SARIMAX.

I. INTRODUCCIÓN

Los pronósticos precisos de la demanda de electricidad desempeñan un rol relevante en la planificación de la expansión de los sistemas eléctricos, evaluación de proyectos de inversión y la elaboración de políticas energéticas confiables (Akhtar et al., 2023; Steinbuks, 2019). El interés de

los pronósticos es proporcionar información valiosa para la toma de decisiones a los agentes responsables de la operación del sistema eléctrico. Sin embargo, elaborar pronósticos confiables representa un desafío, dados a los múltiples criterios en juego (Hor et al., 2008).

En este sentido, la electricidad es un recurso esencial para el progreso y el bienestar de la sociedad moderna (Torres et al., 2022; Kok et al., 2022). La misma es indispensable para el impulso de los sectores comercial e industrial, y en menor medida, del sector transporte debido a la introducción de vehículos eléctricos en la demanda. (Torres et al., 2022). Este recurso por su naturaleza presenta características únicas y si bien existen tecnologías para su almacenamiento, la misma aún debe producirse, transmitirse y distribuirse al mismo tiempo que la demanda (Hadjout et al., 2022, Sinha et al., 2022). Es por esto una gestión eficaz de la demanda eléctrica es fundamental para el funcionamiento entre las entidades generadoras y las empresas distribuidoras de electricidad.

En este contexto, el consumo histórico de electricidad como datos de series temporales puede contener patrones lineales y no lineales. La literatura evidencia que la previsión de la demanda de electricidad es un tema muy bien investigado. Según Sharma et al. (2023), define: “*como parte de la ciencia de datos que permite predecir parámetros futuros a partir de un conjunto de datos históricos y tendencias*”.

En el presente trabajo se realizan pronósticos de la demanda de energía eléctrica para horizontes de corto plazo (48 horas), mediano plazo (24 meses) y largo plazo (hasta el 2050). Para lograr esto, se emplean diversas técnicas estadísticas de series de tiempo, analizando datos históricos horarios, mensuales y anuales de demanda eléctrica de la República del Paraguay.

En Paraguay, la Administración Nacional de Electricidad (ANDE) es la institución encargada de la planificación del abastecimiento de la demanda de energía eléctrica. Su principal objetivo es satisfacer integralmente las necesidades de energía eléctrica, promover el desarrollo económico y mejorar el bienestar de las personas, a través del aprovechamiento de los recursos naturales del país (ANDE, 2023). En este sentido, se utilizaron datos de series temporales proveídos por la empresa eléctrica para el análisis a corto, mediano y largo plazo.

Para este trabajo se examina varios modelos de series temporales y estos son: modelos autorregresivos (AR), de medias móviles (MA), autorregresivos de medias móviles (ARMA), autorregresivos integrados de medias móviles (ARIMA), y el método de *Holt-Winters*. Adicionalmente, se incorporan variables exógenas relevantes en modelos ARIMAX y SARIMAX para mejorar el ajuste de los modelos. También, se analizan correlaciones con factores socioeconómicos y se construye un modelo de regresión lineal múltiple a largo plazo. Para cada horizonte de predicción, se comparan los modelos mediante métricas de error, métricas estadísticas y el análisis de autocorrelaciones.

En este contexto, ante la compleja tarea de identificar el modelo de pronóstico más preciso y confiable a partir de la consideración de múltiples criterios, tanto cuantitativos como cualitativos, surge la necesidad de un enfoque integral capaz de incorporar esta diversidad de factores relevantes en la evaluación de diferentes alternativas. En este sentido, el Proceso Analítico Jerárquico (AHP) es una herramienta eficaz para abordar problemas de decisión multicriterio como este (Saaty, 1990; Nantes, 2019; Blanco et al., 2017).

En la literatura actual el AHP es una herramienta muy utilizada para la toma de decisiones y que constituyen un área muy

importante dentro de la investigación de operaciones. Esta herramienta se enfoca en la toma de decisiones bajo incertidumbre (Saaty, 1990). El AHP permite analizar en detalles todos los posibles criterios relevantes, así como todas las alternativas viables para apoyar la toma de la mejor decisión (Deina et al., 2023).

En este sentido, el desafío en este trabajo es seleccionar el mejor modelo de series temporales para cada horizonte temporal. Entonces, mediante las operaciones de comparaciones pareadas del AHP, se calcularon los pesos relativos que reflejan la importancia de cada uno de estos modelos respecto a los múltiples criterios. Al final, el AHP genera una calificación final para cada modelo, identificando en definitiva el mejor modelo para cada horizonte temporal analizado, cumpliendo el propósito de determinar los

métodos más adecuados para pronosticar la demanda de energía eléctrica, basándose en una herramienta de toma de decisiones multicriterio (Saaty, 1990).

II. REVISIÓN DE LA LITERATURA

La etapa dedicada a la revisión del estado del arte brinda una sólida base de evidencias, el cual permite tener una visión general de los trabajos previos vinculados al análisis multicriterio y el pronóstico de la demanda de energía eléctrica, identificar nuevas investigaciones, enfoques metodológicos y las brechas de conocimientos a fin de orientar a futuras investigaciones vinculados al tema. Seguido, se presenta el esquema metodológico de revisión (Ver Figura 1), el cual se despende otro trabajo sometido a su revisión por pares.

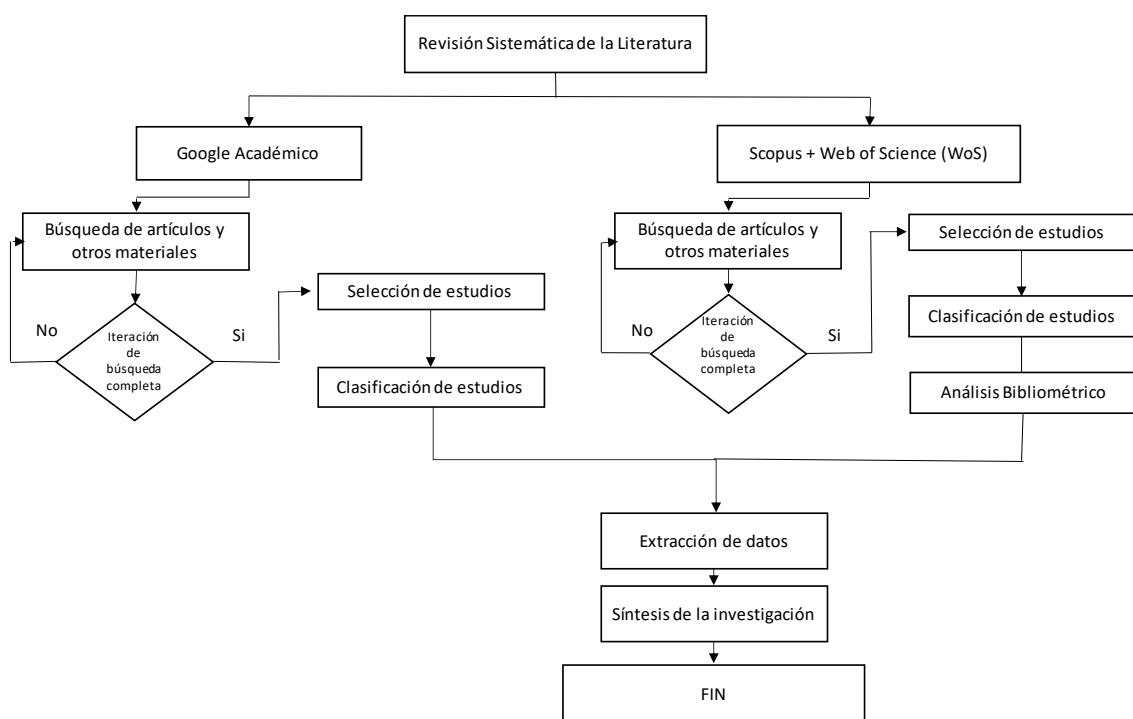


Figura 1: Diagrama de flujo de la metodología de revisión sistemática [*]¹.

¹ De Oliveira, J., González, A., Riveros, E., E., & Fernández, F. (2024). Worldwide Research on Models for Short-, Medium- and Long-Term Electrical Demand Forecasting: A Systematic Literature Review.

Los hallazgos como el estudio realizado por [Deina et al. \(2023\)](#) presenta una investigación que combina un enfoque multicriterio para la selección de variables independientes relevantes y el uso de redes neuronales para pronosticar la demanda de electricidad del Estado de Paraná, Brasil. Utilizaron la herramienta de decisión multicriterio ELLECTRE I para determinar las variables independientes con mayor relevancia e incluir en sus modelos de pronósticos.

Por otra parte, el trabajo de ([Prasad & Raturi, 2017](#)) realizaron un estudio sobre el pronóstico de electricidad a largo plazo y utilizaron el AHP para decidir el mejor modelo de pronóstico de demanda. En el análisis utilizaron modelos de regresión lineal con variables independientes como producto interno bruto (PIB), población y precio de la electricidad para pronosticar la demanda a 2040.

En Paraguay, como antecedente en la literatura se encuentra el estudio de ([Rodriguez & Trotter, 2019](#)), el cual propone un modelo autorregresivo de retardos distribuidos (ARDL) para modelar la demanda de electricidad. El modelo incluye como variables independientes: PIB, población, temperatura máxima y mínima. El modelo se utiliza para generar seis escenarios de demanda eléctrica en Paraguay hasta 2050 bajo diferentes supuestos climáticos y socioeconómicos.

También, como antecedente en Paraguay la investigación de ([Morales-Mareco et al., 2023](#)) compara modelos estadísticos, *machine learning* y *deep learning* para la predicción de la demanda a corto plazo de electricidad en los períodos entre el 2009 y 2022. Entrenaron modelos como ARIMAX, regresión lineal, *random forest* y modelos de redes neuronales recurrentes: LSTM, GRU, BiLSTM y BiGRU. En su investigación utilizaron como regresor exógeno la temperatura y humedad e indican que las mismas están altamente

correlacionadas con la demanda eléctrica y concluyen que la incorporación de estas variables exógenas permite mejorar el contexto y poder predictivo del conjunto de datos

Ahora bien, en cuanto a trabajos relacionados con revisiones de la literatura, se tiene el estudio de ([Mir et al., 2020](#)), que presentan una revisión de las metodologías de pronósticos de la demanda de electricidad y sus determinantes en un grupo de países de ingresos bajos y medios, utilizando a Pakistán como país de referencia para la comparación. El artículo analiza cómo estas variables determinantes cambian de acuerdo al horizonte de predicción (corto, mediano o largo plazo) y cómo se han utilizado en los estudios de predicción de demanda eléctrica en Pakistán en comparación con otros. Para predicciones a corto plazo, las técnicas basadas en *machine learning* y *deep learning* prevalecen en la literatura. Sin embargo, estudios como el de ([Hadjout et al., 2022](#)) sugiere su aplicación también a análisis a mediano plazo. Asimismo, la investigación menciona para los pronósticos a largo y mediano plazo, los modelos de series de tiempo tipo estadísticos han sido ampliamente utilizados por los investigadores.

Asimismo, el trabajo hecho por ([Kuster et al., 2017](#)), realizaron una revisión sistemática con el objetivo de identificar diferentes modelos de previsión. Sus hallazgos mencionan que los modelos de regresión lineal simple y regresión múltiple son eficientes para pronósticos a largo plazo, mientras que los modelos de *machine learning* son más utilizados para predicciones a corto plazo.

Por otra parte, [Rueda et al. \(2011\)](#) realizaron su revisión para determinar las técnicas y modelos más utilizados en el pronóstico de la demanda de electricidad. Entre sus hallazgos los modelos más utilizados para el pronóstico de la demanda

de energía eléctrica son los modelos ARIMA y las redes neuronales artificiales (RNA). De manera similar [Maniatis \(2017\)](#) realizaron una revisión de la literatura y apoyaron su metodología mediante consulta a expertos para identificar criterios y modelos para el pronóstico de la demanda de energía eléctrica. Los hallazgos de este trabajo sugieren que los modelos más utilizados son el ARIMA con suavizado exponencial y ARIMAX. El segundo enfoque más popular es el de las RNA con entradas lineales y difusas preprocesadas. También, concluyen

III. MATERIALES

III. 1 Descripción de base de datos

En esta sección se detallan los datos utilizados para el análisis. Los datos para el análisis a corto plazo corresponden a datos de la demanda máxima horaria del Sistema Interconectado Nacional (SIN) de Paraguay correspondiente al 2022. Así mismo, para el mediano y largo plazo, se utilizan datos mensuales y anuales de energía requerida correspondiente al período 1990-2022, todos los datos provistos por la ANDE para el desarrollo del trabajo de investigación.

Por otra parte, las informaciones correspondientes al número de clientes de la ANDE fueron extraídas de la compilación estadística ([ANDE, 2022](#)). Así también, el histórico del número de población se utilizó a partir de los datos abiertos del Instituto Nacional de Estadísticas (INE) ([INE,2023](#)). Ahora bien, los datos referentes a las variables macroeconómicas como la inflación fueron consultados a partir de los datos disponibles del Banco Mundial ([Banco Mundial, 2023](#)) y los datos de PIB per cápita en la página web del Banco Central del Paraguay ([Banco Central del Paraguay, 2023](#))

Ahora bien, para la inclusión como variable exógena se utiliza la temperatura horaria de 2022, la temperatura mensual de 1990 – 2022 y la temperatura anual de 1990

que el modelo *support vector regression* (SVR), está siendo aplicada por muchos ingenieros eléctricos.

Por último, de acuerdo con [Mokilane et al., \(2019\)](#), los factores a considerar para la selección de los modelos, a partir de consulta a expertos son: precisión, facilidad de interpretación, calidad de datos, eficiencia del modelo de pronóstico en términos de costo computacional, recursos, y facilidad de implementación de los modelos.

- 2022, todos estos datos fueron consultados en la página de *Power LAC NASA* ([Power LAC NASA ,2023](#)) y se utilizaron específicamente para los modelos ARIMAX y SARIMAX. En este sentido, para los pronósticos de la demanda de electricidad horaria, mensual y anual, se consultaron las proyecciones de temperatura media y máxima disponibles en la página web de los datos abiertos del Gobierno Nacional de Paraguay ([Datos abiertos del Gobierno Nacional del Paraguay, 2023](#)).

III. 2 Herramientas computacionales

Las herramientas computacionales utilizadas en este estudio son mediante el lenguaje de programación en *Python*, trabajando en *Google Colab*, para los análisis respecto a las series temporales, entrenamiento y el modelado de las mismas. Ahora bien, se utilizó la herramienta de *Microsoft Excel* para los cálculos del AHP y análisis de sensibilidad.

IV. METODOLOGÍA

IV. 1 Diseño metodológico

El trabajo de investigación presenta un enfoque cuantitativo; pues, usa la recolección de datos para probar hipótesis con base en la medición numérica y el análisis estadístico, con el fin establecer pautas de comportamiento y probar teorías.

Asimismo, el estudio es descriptivo ya que busca especificar las características, patrones y propiedades importantes de la demanda de energía eléctrica. También, tiene un nivel exploratorio; pues, el trabajo aborda un problema de investigación poco indagado y prepara terreno para futuros nuevos estudios. Además, es correlacional debido a que se realizan predicciones y se analizan las variables macroeconómicas (PIB e inflación), temperaturas, población y su grado de relación con la demanda de energía eléctrica. También, este estudio es experimental debido a que se manipulará datos históricos de energía y demanda máxima generados por el SIN para el análisis y presenta un corte longitudinal; pues, se trabaja con datos en diferentes períodos de tiempo; es decir, se manipulará datos de años pasados y se proyectará para los próximos años dando un seguimiento longitudinal ([Hernández Sampieri et al., 2014](#)).

IV. 2 Ingeniería de Diseño

Se propone el siguiente esquema metodológico de como se ha estudiado el problema (Ver Figura 2), estructurado en tres etapas bien definidas:

IV.2. 1. Primera etapa: Revisión sistemática de la literatura.

Este trabajo se apoyó previamente en una revisión sistemática de la literatura que tiene como propósito conocer el estado del arte respecto al pronóstico de la demanda de electricidad de manera global, siguiendo una metodología bien definida para una revisión sistemática a partir de experiencias en trabajos como de ([De Oliveira et al., 2022](#); [Fernández et al., 2023](#)). Los resultados evidencian que los modelos de series temporales tipo estadísticos y económicos son bastante empleados y permitió la identificación de los criterios a

utilizar para el análisis multicriterio de esta investigación para la selección del modelo en el análisis en el corto, mediano y largo plazo.

IV.2. 2. Segunda etapa: Estructuración para la aplicación del AHP a corto, mediano plazo y largo plazo.

La estructuración de la metodología AHP desarrollada por *Thomas Saaty* demuestra ser determinante cuando es necesario considerar simultáneamente múltiples criterios y alternativas para la toma de decisiones ([Saaty, 1990](#)). Para esta investigación, se estableció como objetivo para mejorar la situación existente "*Obtener el mejor modelo de pronóstico a corto, mediano y largo plazo*" para la República del Paraguay (Ver Figura 3 y Figura 4). Luego, se definieron cinco criterios a ser considerados en el análisis multicriterio. Asimismo, se consideraron cuatro métricas de error como subcriterios y se seleccionaron ocho alternativas posibles correspondientes a distintos modelos para el pronóstico de la demanda de electricidad, a ser analizados en el corto, mediano plazo y seis alternativas de los ocho modelos para el largo plazo, sujeto previo a la etapa anterior el de la revisión sistemática realizada en esta investigación. El árbol jerárquico de la estructuración planteada se puede observar en la Figura 3 y Figura 4.

En cuanto a las métricas de error, los subcriterios presentados en el árbol jerárquico, se utilizaron cuatro métricas para las comparaciones y son el error absoluto medio porcentual (MAPE), error cuadrático medio (RMSE), error absoluto medio (MAE) y el coeficiente de determinación (R^2). Segundo, se presenta las fórmulas correspondientes a las métricas de error mencionadas:

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{y_t - y^*_t}{y_t} \right| \quad \dots (1)$$

$$MAE = \frac{1}{n} \sum_{t=1}^n |y_t - y^*_t| \quad \dots (3)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (y_t - y^*_t)^2} \quad \dots (2)$$

$$R^2 = 1 - \frac{\sum_{t=1}^n (y_t - y^*_t)^2}{\sum_{t=1}^n (y_t - \hat{y}_t)^2} \quad \dots (4)$$

En la ecuación (1), (2) y (3) y_t indica los valores reales de la serie temporal, el y^*_t indica los valores pronosticados, n es el número de observaciones y en la ecuación (4) el \hat{y}_t , indica la media de la variable dependiente de todas las observaciones.

Previo al análisis de los resultados del AHP, se efectuaron un análisis de correlación de Pearson el cual tiene el fin de brindar información de la relación entre las variables utilizando variables como la demanda máxima y temperatura media en

el análisis a corto plazo. Así también, la correlación entre las variables macroeconómicas y demanda de energía eléctrica a largo plazo, resultados que se presenta en la sección de resultados y discusiones.

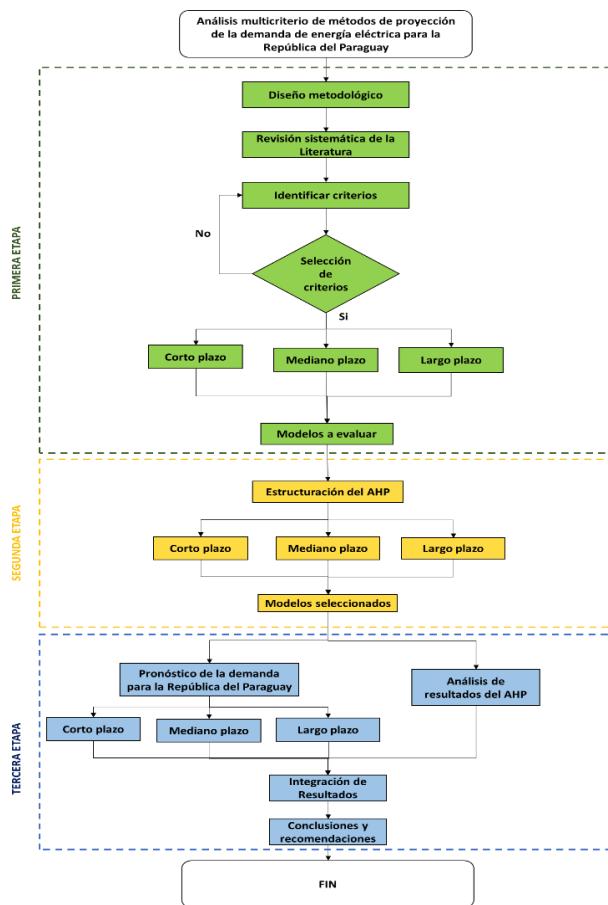


Figura 2: Esquema metodológico.

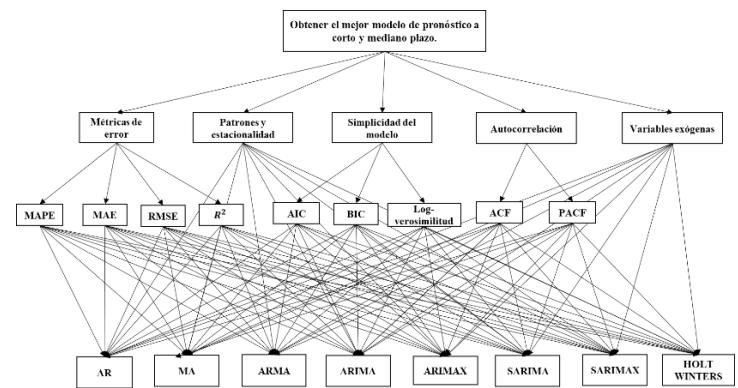


Figura 3: Árbol jerárquico a corto y mediano plazo.

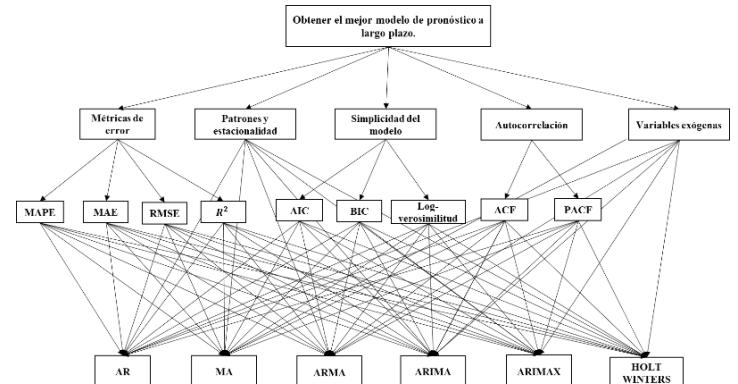


Figura 4: Árbol jerárquico a largo plazo.

En este sentido, se presenta la fórmula correspondiente a la correlación de Pearson:

$$r = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2} \sqrt{\sum_{i=1}^n (y_i - \bar{y})^2}} \dots (5)$$

En la ecuación (5), el x_i indica los valores de una variable y el y_i el valor de otra variable. Por otra parte, el \bar{x} y \bar{y} son respectivamente los valores medios de las dos variables.

Ahora en cuanto a los subcriterios del criterio simplicidad del modelo, los valores de AIC, BIC y log-verosimilitud se obtiene a partir de los resúmenes estadísticos obtenidos mediante la programación en Python puestos a disposición en el siguiente repositorio².

IV.2. 3.Tercera etapa: Pronóstico de la demanda de electricidad.

Esta etapa consiste en realizar los pronósticos de la demanda de electricidad teniendo como resultados los modelos obtenidos con el AHP, para los horizontes de corto, mediano y largo plazo. Asimismo, en esta última etapa se realiza el análisis de sensibilidad de las alternativas, con la finalidad de determinar la robustez de los mismos. También, a partir de la integración de estos resultados, se elaboran las conclusiones que buscan aportar al campo del pronóstico de acuerdo al comportamiento de la demanda de electricidad en la República del Paraguay.

V. RESULTADOS Y DISCUSIONES

V. 1. Pronóstico para un horizonte a corto plazo.

El presente análisis a corto plazo corresponde al análisis de series de tiempo de la demanda máxima horaria del SIN de Paraguay del año 2022. La evaluación general obtenida mediante el AHP de los ocho modelos con respecto a los cinco criterios considerados para el análisis multicriterio, mostró que el modelo SARIMAX es el más adecuado debido a su mejor desempeño en comparación con las

demás alternativas (Ver Figura 5). Se incorporó temperatura media horaria año 2022 como variable exógena en este análisis. En este sentido, este resultado es coherente con los hallazgos en la literatura sobre la relevancia de incluir variables exógenas como la temperatura en el análisis de la demanda para mejorar los pronósticos, tal como sugieren los trabajos de [Tarsitano & Amerise \(2017\)](#) y [Eshragh et al. \(2022\)](#).

A partir de los resultados, se ajustaron los modelos SARIMA, SARIMAX y *Holt-Winters* (Ver Figura 6). Estos son los modelos con mejor ajuste a la demanda máxima horaria de electricidad a todos los modelos mencionados. En cuanto al análisis de sensibilidad, presenta que el modelo SARIMAX resultó el más adecuado y presenta mayor preponderancia en casi todas las variaciones a partir de la evaluación de desempeño de todos los criterios considerados con el AHP. Además, la demanda máxima se da en los meses de verano por el intenso calor, encontrado en trabajos similares como el [De Felice et al. \(2013\)](#), reflejando la importancia de la inclusión de temperatura como variable exógena para mejorar los pronósticos, tal como se aplicó para el caso del modelo SARIMAX en este trabajo.

En la Figura 6, se puede observar el pronóstico de la demanda de electricidad para las próximas 48 horas. De acuerdo a los resultados obtenidos con el modelo SARIMAX dentro de las primeras 24 horas, el pico máximo se da entre las 20 horas y 22 horas y se tendría un valor de 3112 MW

² **Repositorio: GitHub:** Enlace:
https://github.com/jairooliveirasn/TFG_JDO
drive: https://bit.ly/TFG_JDO_repositorio

(megawatt). Así también, al día siguiente se tiene un segundo pico máximo entre 20

horas y 22 horas con un valor pico de 3029 MW

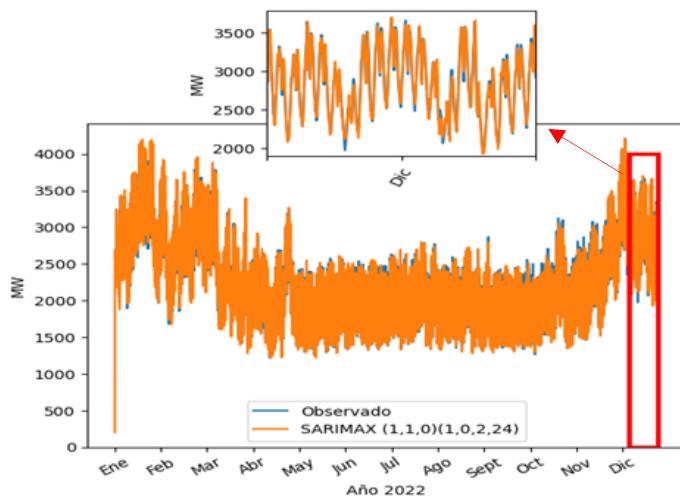


Figura 5: Ajuste de modelo SARIMAX a corto plazo.

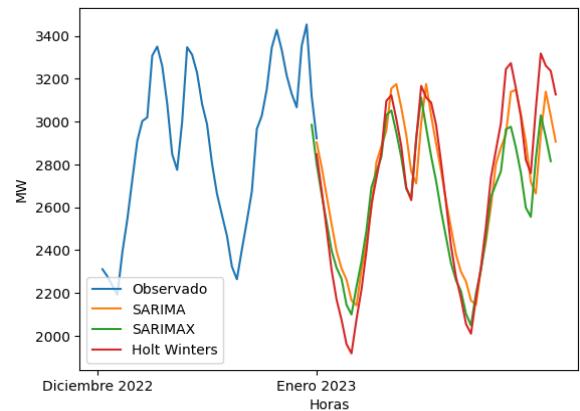


Figura 6: Pronóstico de la demanda máxima horaria en las próximas 48 horas.

V. 2. Pronóstico para un horizonte a mediano plazo.

Seguido, se analiza la demanda de electricidad del Paraguay a partir de datos mensuales de energía requerida provistos por la ANDE del período 1990-2022. El objetivo de este pronóstico es estimar la demanda futura de electricidad a nivel nacional mediante técnicas estadísticas aplicadas sobre la serie histórica, se

modelará como proyecciones mensuales futuras para el período enero 2023 a diciembre del 2024, basado en un historial de más de 30 años. La evaluación general de los resultados estadísticos (Ver Figura 3) de los ocho modelos respecto a los cinco criterios considerados para el AHP, el modelo SARIMAX resultó el más adecuado debido a su mejor desempeño en comparación a las demás alternativas, tal como se puede observar en la Figura 8.

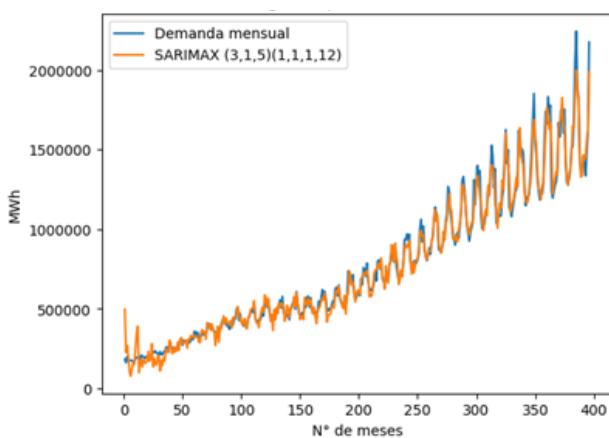


Figura 7: Ajuste del modelo SARIMAX a la demanda de energía mensual desde 1990 - 2022.

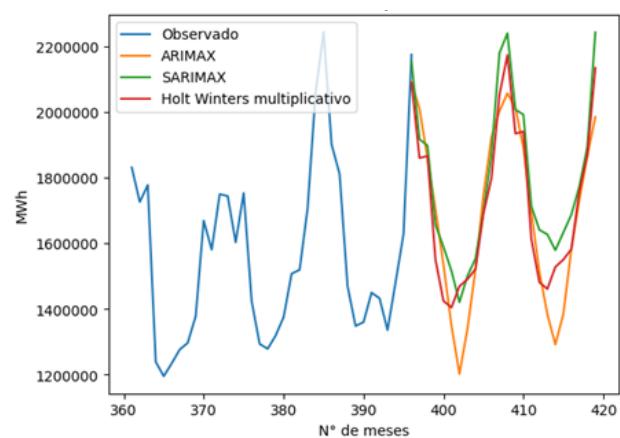


Figura 8: Pronóstico de la demanda de energía para los meses del 2023 - 2024.

Para el 2023, la mayor demanda de energía requerida se dará entre los meses de enero y diciembre con valores de 2.152.624,38 MWh (*megawatt hora*) y 2.178.851,41 MWh respectivamente, mientras que, la menor demanda de energía requerida se da en julio y agosto del 2023 con los valores de 1.420.849,86 MWh y 1.500.894,21MWh respectivamente, a partir de los resultados del modelo SARIMAX (Ver Figura 7). Para el 2024, también la mayor demanda de energía requerida se dará entre los meses de enero y diciembre con valores de 2.239.288,37 MWh y 2.241.932,74 MWh respectivamente. Y la menor demanda de energía requerida también se requerida se da en junio y julio con los valores de 1.627.135,42 MWh y 1.579.134,49 MWh respectivamente, a partir de los resultados del modelo SARIMAX (Ver Figura 8). Cabe destacar que el análisis de sensibilidad del mediano plazo arroja al modelo SARIMAX como el más adecuado ante las variaciones de todos los criterios considerados con el AHP.

V. 3. Pronóstico para un horizonte a largo plazo.

En el pronóstico a largo plazo se presenta un análisis de series de tiempo de la demanda anual de energía eléctrica en Paraguay entre 1990 y 2022. A diferencia en

los horizontes de corto y mediano plazo, se ajustaron seis de los modelos para el análisis. La evaluación general de los seis modelos respecto a los cinco criterios considerados para el análisis multicriterio, el modelo *Holt-Winters* resultó el más adecuado debido a su mejor desempeño en comparación a las demás alternativas. En la Figura 9, se puede observar el ajuste del modelo *Holt-Winters*, modelo con mejor desempeño multicriterio. En la Figura 10, el trazado color azul corresponde a los datos observados, el trazado color naranja corresponde al pronóstico del modelo ARIMAX y el color verde corresponde al pronóstico de la demanda de energía requerida del modelo *Holt-Winters*.

Los resultados de proyección del modelo *Holt-Winters* presentan que la demanda de energía es creciente y se estima un valor de 73.809.478,84 MWh se demandará al SIN para el año 2050.

Al mismo tiempo, al realizar el análisis de sensibilidad de la variación de preferencias de los criterios a largo plazo, el modelo de *Holt-Winters* no sufrió cambios, constando la robustez del resultado obtenido ante los cambios en las preferencias.

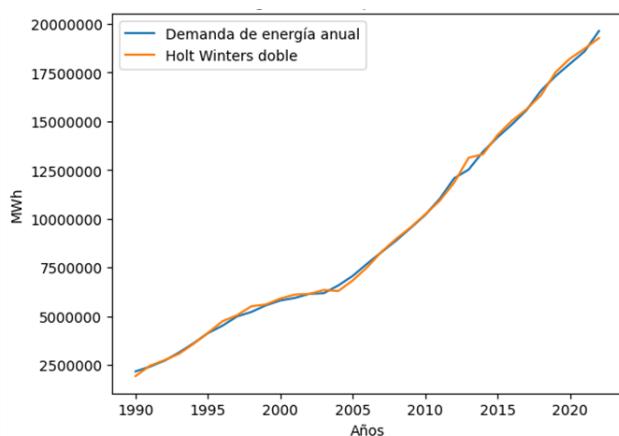


Figura 9: Ajuste del modelo *Holt Winters* a la demanda de energía anual desde 1990 – 2022.

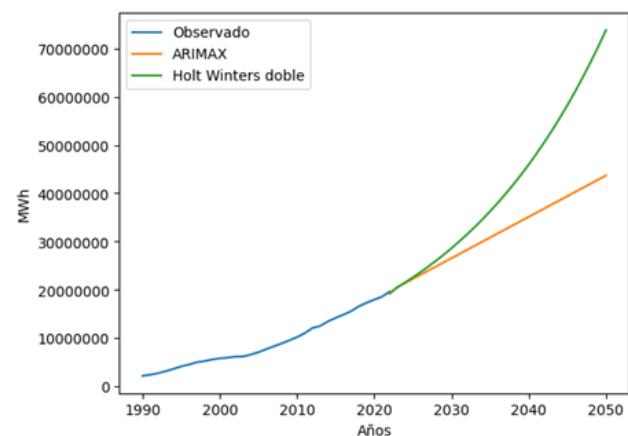


Figura 10: Pronóstico de demanda de energía anual al largo plazo 2023 – 2050.

V. 4. Regresión y análisis de correlación de variables.

Previo al análisis del modelo de regresión lineal se analizó la correlación entre diversas variables mediante el coeficiente de Pearson con el fin de validar los hallazgos determinados con los modelos de series temporales analizados anteriormente. Se hallaron correlaciones

fuertes entre la energía demandada y la población (0,98) y entre la energía y el PIB per cápita (0,89). La correlación entre energía e inflación resultó moderada (-0,65), tal como se puede observar en la Figura 14. Llegar a estos resultados son coherentes de acuerdo a otros trabajos similares determinados por (Solyali, 2020; Tena García et al., 2019 y Verdejo et al., 2017).

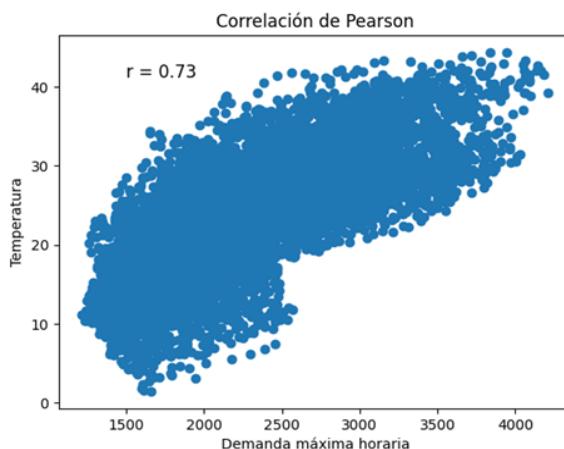


Figura 11: Correlación de Pearson de la demanda máxima horaria y temperatura media.

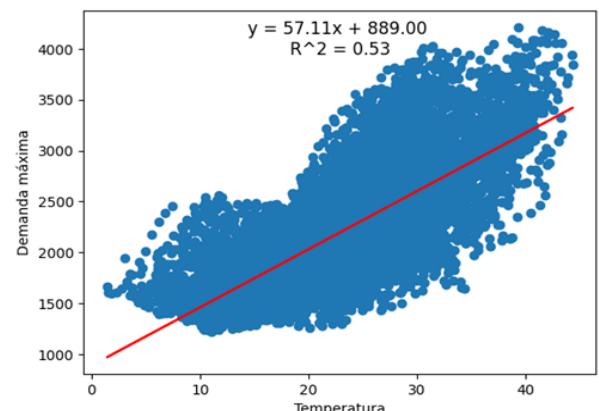


Figura 12: Regresión lineal de demanda máxima horaria y temperatura.

Asimismo, se estudió la correlación horaria entre demanda máxima y temperatura del 2022, encontrándose una fuerte correlación positiva (0,73), indicando una fuerte influencia de la temperatura sobre los picos de demanda máxima (Ver Figura 11).

Para el desarrollo del modelo de RLM se consideró como variable dependiente la energía anual demandada (en MWh) y como variables independientes la población, el PIB per cápita y la inflación anual. El modelo presentó un alto coeficiente de determinación (R^2 igual a 98,9 %), lo que indica un buen ajuste a los datos históricos (Ver Figura 13).

Además, se realizaron pruebas para detectar problemas de multicolinealidad, heterocedasticidad, normalidad de los

residuos y autocorrelación (Ver Repositorio¹). Se detectó un cierto grado de heterocedasticidad, aunque el modelo en general cumple con los supuestos necesarios para ser considerado apropiado. Además, se calculó el factor de inflación de varianza (VIF) que está por debajo de 10, indicando que no hay multicolinealidad fuerte entre las variables consideradas. Asimismo, con base en las proyecciones disponibles de las variables explicativas, se consideró como entradas para el modelo el PIB, población e inflación. En la Figura 13, se presenta la matriz de correlación de Pearson de las diversas variables analizadas teniendo como referencia el análisis de Lee & Cho (2022) y Hassani et al. (2014).

En la Figura 14, se puede observar la proyección de la energía requerida para el

periodo 2023 al 2050. Se utiliza para la proyección un modelo de regresión lineal múltiple, modelos implementados por lo general a largo plazo de acuerdo a la literatura [Elkamel et al. \(2020\)](#); [Angelopoulos et al. \(2019\)](#) y [Gul et al.](#)

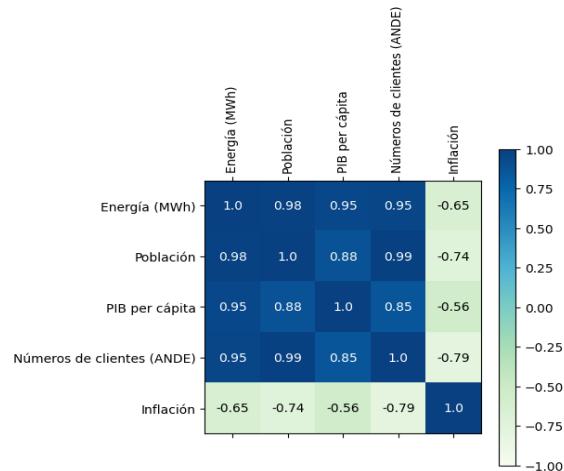


Figura 13: Matriz de correlación de Pearson de variables socioeconómicas.

(2011). Los resultados indican una tendencia creciente, pasando de los 20.361.961,08 MWh en 2022 a 65.259.685,63 MWh en 2050, impulsada principalmente por el aumento poblacional y PIB per cápita.

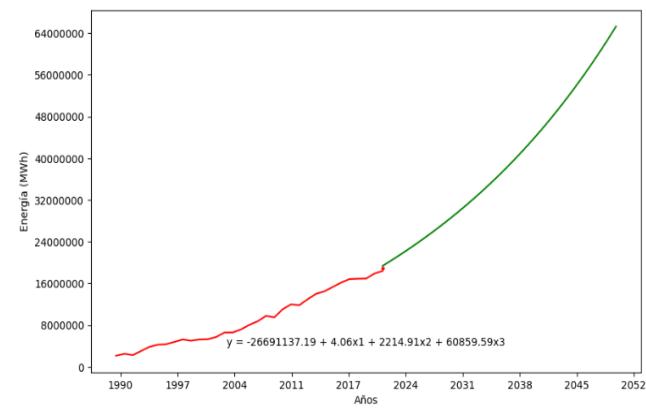


Figura 14: Proyección de la demanda de energía anual a largo plazo 2023 – 2050.

VI. CONCLUSIONES

Este estudio presenta los resultados de una investigación rigurosa y considera los criterios estadísticos más habituales constatados en la literatura para el análisis multicriterio apoyado en la herramienta AHP para la selección de modelos y la previsibilidad de la demanda de electricidad del SIN de la República del Paraguay. En este sentido, el estudio de las series temporales de la demanda de electricidad permitió construir una propuesta de modelos de pronóstico adecuados y, a partir de los resultados del AHP, un análisis de sensibilidad robusto, herramienta que prioriza aquellos modelos con mayor capacidad según múltiples criterios estadísticos para los horizontes de corto, mediano y largo plazo.

En el corto plazo, el modelo SARIMAX resultó el más adecuado de acuerdo a los múltiples criterios analizados en el AHP, modelo que pronostica un pico máximo de 3112 MW en las primeras 48 horas del 2023. Asimismo, en el proceso de este análisis se pudo notar la relevancia de la incorporación de variables exógenas en el modelo. Al incorporar la temperatura como variable, se ha logrado mejorar el ajuste y, en efecto, un mejor pronóstico, además, esto comprueba la fuerte correlación que tiene la temperatura en la demanda máxima.

En el mediano plazo, también el modelo SARIMAX resultó con mayor capacidad para un pronóstico de 24 meses, correspondiente a meses del año 2023 y 2024. Se observa una tendencia creciente en ambos años, con mínimos de energía en meses de otoño

e invierno y máximos en meses de primavera y verano. Los resultados indican un aumento de la energía requerida para el 2024 en comparación 2023 para el SIN. Los valores máximos de energía pronosticada se darán para el 2023 y 2024 de manera particular en los meses de enero y diciembre.

Para el largo plazo, el modelo *Holt Winters* resultó con mayor preferencia teniendo en cuenta los múltiples criterios estadísticos analizados con el AHP, el modelo captura eficientemente la tendencia histórica para el pronóstico 2023-2050. Los resultados indican que para el 2050 se tendría una demanda anual de 73,8 TWh.

Adicionalmente, para el horizonte a largo plazo se construyó un modelo de regresión lineal múltiple utilizando variables socioeconómicas constatadas en la literatura, el cual también mostró una capacidad robusta de previsión de la demanda hasta 2050. Se reveló que los datos de población resultaron ser una variable con una fuerte correlación, así como también el PIB y la inflación para la formulación del modelo RLM. Estos hallazgos revelan la importancia de tener en cuenta tanto los factores climáticos para el corto y mediano plazo, así como los factores socioeconómicos para el largo plazo, como variables para el pronóstico de la demanda de electricidad.

Por último, las centrales hidroeléctricas de Itaipú, Yacyretá y Acaray, con una capacidad instalada de 8825 MW, podrían generar aproximadamente 77,3 TWh de energía si se operaran a máxima capacidad durante un año para cubrir la demanda. En consecuencia, según los hallazgos de este trabajo, el abastecimiento de la creciente demanda de electricidad se

convertiría en un desafío crítico para la República del Paraguay entre los años 2045 y 2050.

VII. AGRADECIMIENTOS

Agradecimientos especiales al Departamento de Estudios y Tarifas de Mercado de la Administración Nacional de Electricidad (ANDE) por los datos e informaciones brindadas durante el desarrollo de este trabajo de investigación.

VIII. BIBLIOGRAFIA

Akhtar, S., Shahzad, S., Zaheer, A., Ullah, H. S., Kilic, H., Gono, R., Jasiński, M., & Leonowicz, Z. (2023). Short-Term Load Forecasting Models: A Review of Challenges, Progress, and the Road Ahead. *Energies*, 16(10), 4060.

ANDE, 2022. Compilación estadística 1990-2022. Recuperado el 15 de diciembre 2023, de <https://bit.ly/3TqGCyn>

ANDE, 2023. Misión Visión y Valores de la Administración Nacional de Electricidad. Recuperado 18 de octubre de 2023, de <https://www.ande.gov.py/mision.php>

Angelopoulos, D., Siskos, Y., & Psarras, J. (2019). Disaggregating time series on multiple criteria for robust forecasting: The case of long-term electricity demand in Greece. *European Journal of Operational Research*, 275(1), 252-265. <https://doi.org/10.1016/j.ejor.2018.11.003>

Banco Central del Paraguay, 2023. Datos históricos de PIB per cápita de la República del Paraguay. Recuperado el 15 de diciembre 2023, de <https://www.bcp.gov.py/>

Banco Mundial, 2023. Datos históricos de inflación de la República del Paraguay. Recuperado el 15 de diciembre 2023, de <https://bit.ly/3RJqxlh>

Blanco, G., Amarilla, R., Martinez, A., Llamosas, C., & Oxilia, V. (2017). Energy transitions and emerging economies: A multi-criteria analysis of policy options for hydropower surplus utilization in Paraguay. *Energy Policy*, 108, 312-321. <https://doi.org/10.1016/j.enpol.2017.06.003>

Datos abiertos del Gobierno Nacional del Paraguay. Escenario RCP 4.5, Variable Temperatura Media, Temperatura Máxima,

Periodo 2006 - 2099. Recuperado el 15 de diciembre 2023, de <https://www.datos.gov.py/>

De Felice, M., Alessandri, A., & Ruti, P. M. (2013). Electricity demand forecasting over Italy: Potential benefits using numerical weather prediction models. *Electric Power Systems Research*, 104, 71-79. <https://doi.org/10.1016/j.epsr.2013.06.004>

De Oliveira, J., Riveros, N., González, A., & Oxilia, V. (2022). Energy Efficiency Labels in the World and Latin America: A Survey. *2022 IEEE Biennial Congress of Argentina (ARGENCON)*, 1-8.

Deina, C., dos Santos, J. L. F., Biuk, L. H., Lizot, M., Converti, A., Siqueira, H. V., & Trojan, F. (2023). Forecasting Electricity Demand by Neural Networks and Definition of Inputs by Multi-Criteria Analysis. *Energies*, 16(4), Article 4. <https://doi.org/10.3390/en16041712>

Elkamel, M., Schleider, L., Pasiliao, E. L., Diabat, A., & Zheng, Q. P. (2020). Long-Term Electricity Demand Prediction via Socioeconomic Factors—A Machine Learning Approach with Florida as a Case Study. *Energies*, 13(15), Article 15. <https://doi.org/10.3390/en13153996>

Eshragh, A., Ganim, B., Perkins, T., & Bandara, K. (2022). The Importance of Environmental Factors in Forecasting Australian Power Demand. *Environmental Modeling & Assessment*, 27(1), 1-11. <https://doi.org/10.1007/s10666-021-09806-1>

Fernández, K., Lezcano, L., & González, A. (2023). Medición de la pobreza energética con enfoque multidimensional: Revisión sistemática de la literatura. *Revista INVI*, 38(109), Article 109. <https://doi.org/10.5354/0718-8358.2023.70574>

Gul, M., Qazi, S. A., & Qureshi, W. A. (2011). Incorporating economic and demographic variables for forecasting electricity consumption in Pakistan. *2011 2nd International Conference on Electric Power and Energy Conversion Systems (EPECS)*, 1-5. <https://doi.org/10.1109/EPECS.2011.6126852>

Hadjout, D., Torres, J. F., Troncoso, A., Sebaa, A., & Martínez-Álvarez, F. (2022).

Electricity consumption forecasting based on ensemble deep learning with application to the Algerian market. *Energy*, 243, 123060. <https://doi.org/10.1016/j.energy.2021.123060>

Hassani, H., Abdollahzadeh, M., Iranmanesh, H., & Miranian, A. (2014). A self-similar local neuro-fuzzy model for short-term demand forecasting. *Journal of Systems Science and Complexity*, 27, 3-20.

Hernández Sampieri, R., Fernández, C., & Baptista, P. (2014). *Metodología de la investigación. 6ta edición*, editorial McGraw Hill Education.

Hor, C., Watson, S., Infield, D., & Majithia, S. (2008). *Assessing load forecast uncertainty using extreme value theory*. 16th Power Systems Computation Conference, PSCC 2008. Scopus.

Kok, A., Yükseltan, E., Hekimoğlu, M., Aktunc, E. A., Yücekaya, A., & Bilge, A. (2022). Forecasting hourly electricity demand under COVID-19 restrictions. *International Journal of Energy Economics and Policy*, 12(1), 73-85.

Kuster, C., Rezgui, Y., & Mourshed, M. (2017). Electrical load forecasting models: A critical systematic review. *Sustainable Cities and Society*, 35, 257-270. <https://doi.org/10.1016/j.scs.2017.08.009>

Lee, J., & Cho, Y. (2022). National-scale electricity peak load forecasting: Traditional, machine learning, or hybrid model? *Energy*, 239, 122366. <https://doi.org/10.1016/j.energy.2021.122366>

Maniatis, P. (2017). A taxonomy of electricity demand forecasting techniques and a selection strategy. *International Journal of Management Excellence (ISSN: 2292-1648)*, 8(2), 881-894.

Mir, A. A., Alghassab, M., Ullah, K., Khan, Z. A., Lu, Y., & Imran, M. (2020). A Review of Electricity Demand Forecasting in Low and Middle Income Countries: The Demand Determinants and Horizons. *Sustainability*, 12(15), Article 15. <https://doi.org/10.3390/su12155931>

Mokilane, P., Debba, P., Yadavalli, V. S. S., & Sigauke, C. (2019). *Bayesian structural time-series approach to a long-term*

electricity demand forecasting.
<https://doi.org/10.18576/AMIS/130206>

Morales-Mareco, F., Ayala, C. S., Stalder, D. H., Salgueiro, L., & Grillo, S. A. (2023). Short-Term Electricity Demand Forecasting: Evaluating the Effectiveness of Statistical, Machine Learning, and Deep Learning Models. *2023 XLIX Latin American Computer Conference (CLEI)*, 1-10. <https://doi.org/10.1109/CLEI60451.2023.10346118>

Nantes, E. A. (2019). *Método analytic hierarchy process para la toma de decisiones: Repaso de la metodología y aplicaciones.*

Power LAC NASA. Temperatura media y máxima, horaria, mensual y anual de la República del Paraguay. Recuperado el 15 de diciembre 2023, de <https://power.larc.nasa.gov/data-access-viewer/>

Prasad, R. D., & Raturi, A. (2017). Grid electricity for Fiji islands: Future supply options and assessment of demand trends. *Energy*, 119, 860-871. <https://doi.org/10.1016/j.energy.2016.11.054>

Rodriguez, A. M. B., & Trotter, I. M. (2019). Climate change scenarios for Paraguayan power demand 2017–2050. *Climatic Change*, 156(3), 425-445.

Rueda, V. M., Velásquez Henao, J. D., & Franco Cardona, C. J. (2011). RECENT ADVANCES IN LOAD FORECASTING USING NONLINEAR MODELS. *DYNA*, 78(167), 36-43.

Saaty, T. L. (1990). How to make a decision: The analytic hierarchy process. *European journal of operational research*, 48(1), 9-26.

Sharma, M., Mittal, N., Mishra, A., & Gupta, A. (2023). Survey of Electricity Demand Forecasting and Demand Side Management Techniques in Different Sectors to Identify Scope for Improvement. *Smart Grids and Sustainable Energy*, 8(2), 9. <https://doi.org/10.1007/s40866-023-00168-z>

Sinha, A., Tayal, R., Vyas, R., & Vyas, O. P. (2022). Operational Flexibility with Statistical and Deep Learning Model for Electricity Load Forecasting. En G. Sanyal, C. M. Travieso-González, S. Awasthi, C. M. A. Pinto, & B. R. Purushothama (Eds.), *International Conference on Artificial Intelligence and Sustainable Engineering* (pp. 219-239). Springer. https://doi.org/10.1007/978-981-16-8546-0_19

Solyali, D. (2020). A Comparative Analysis of Machine Learning Approaches for Short-/Long-Term Electricity Load Forecasting in Cyprus. *Sustainability*, 12(9), Article 9. <https://doi.org/10.3390/su12093612>

Steinbuks, J. (2019). Assessing the accuracy of electricity production forecasts in developing countries. *International Journal of Forecasting*, 35(3), 1175-1185. <https://doi.org/10.1016/j.ijforecast.2019.04.009>

Tarsitano, A., & Amerise, I. L. (2017). Short-term load forecasting using a two-stage sarimax model. *Energy*, 133, 108-114. <https://doi.org/10.1016/j.energy.2017.05.126>

Tena García, J. L., Cadenas Calderón, E., Rangel Heras, E., & Morales Ontiveros, C. (2019). Generating electrical demand time series applying SRA technique to complement NAR and sARIMA models. *Energy Efficiency*, 12(7), 1751-1769. <https://doi.org/10.1007/s12053-019-09774-2>

Torres, J. F., Martínez-Álvarez, F., & Troncoso, A. (2022). A deep LSTM network for the Spanish electricity consumption forecasting. *Neural Computing and Applications*, 34(13), 10533-10545. <https://doi.org/10.1007/s00521-021-06773-2>

Verdejo, H., Awerkin, A., Becker, C., & Olgui, G. (2017). Statistic linear parametric techniques for residential electric energy demand forecasting. A review and an implementation to Chile. *Renewable and Sustainable Energy Reviews*, 74, 512-521. <https://doi.org/10.1016/j.rser.2017.01.110>