

# **Trazando el Futuro Eléctrico Residencial de Salta: Comparación entre Modelos Estocásticos y Redes Neuronales Artificiales para Simulación de Consumo Eléctrico Horario Anual Residencial**

***(Mapping the Residential Electric Future of Salta: Comparison  
between Stochastic Models and Artificial Neural Networks for  
Annual Hourly Residential Electrical Consumption Simulation)***

Franco Zaneck<sup>1</sup>

*Material original autorizado para su primera publicación en la revista Ciencia y Tecnología de la  
Facultad de Ingeniería de la Universidad de Palermo.*

*Campo temático: Ciencias de la computación.*

*Recepción: 7/5/2024 | Aceptación: 15/10/2024.*

## **Resumen**

La simulación del consumo eléctrico horario anual en hogares de la ciudad de Salta puede realizarse mediante un modelo estocástico dinámico o el uso de redes neuronales artificiales (RNA). El modelo estocástico considera la variabilidad natural de factores como el clima y la actividad económica, utilizando técnicas probabilísticas para prever la demanda eléctrica. Por otro lado, las RNA emplean algoritmos de aprendizaje automático para analizar patrones complejos en los datos históricos y generar predicciones. La elección entre ambos modelos depende de la disponibilidad de datos, la capacidad de procesamiento y los objetivos de la simulación. Mientras que el modelo estocástico ofrece una comprensión probabilística de la demanda eléctrica, las RNA pueden capturar relaciones no lineales y patrones más sutiles, conduciendo a predicciones más precisas en ciertas circunstancias. En Salta, donde el clima y la actividad económica son muy variables, combinar ambos enfoques podría proporcionar una simulación más completa del consumo eléctrico anual. Aunque el modelo estocástico muestra resultados estadísticamente superiores, las RNA son más eficientes computacionalmente, lo

---

<sup>1</sup> Departamento de Informática, Facultad de Ciencias Exactas, Universidad Nacional de Salta.  
zaneckfranco@gmail.com

que sugiere que la elección depende de consideraciones específicas del contexto y los recursos disponibles.

**Palabras claves:** Modelo estocástico, dinámico y Discreto; Redes Neuronales; Consumo Eléctrico Horario

## **Abstract**

The simulation of annual hourly electrical consumption in homes in the city of Salta can be carried out through a dynamic stochastic model or the use of artificial neural networks (ANNs). The stochastic model considers the natural variability of factors such as climate and economic activity, using probabilistic techniques to forecast electrical demand. On the other hand, ANNs employ machine learning algorithms to analyze complex patterns in historical data and generate predictions. The choice between both models depends on data availability, processing capacity, and simulation objectives. While the stochastic model provides a probabilistic understanding of electrical demand, ANNs can capture non-linear relationships and subtler patterns, leading to more accurate predictions in certain circumstances. In Salta, where climate and economic activity are highly variable, combining both approaches could provide a more comprehensive simulation of annual electrical consumption. Although the stochastic model shows statistically superior results, ANNs are more computationally efficient, suggesting that the choice depends on specific contextual considerations and available resources.

**Keywords:** Stochastic, Dynamic, and Discrete Model; Neural Networks; Hourly Electricity Consumption.

## 1. Introducción

La electricidad es fundamental para las actividades cotidianas y el desarrollo económico, pero la creciente demanda energética presenta desafíos, requiriendo una planificación precisa para equilibrar oferta y demanda. Se han propuesto diversos métodos para estimar esta demanda, desde análisis de tendencias hasta modelos basados en inteligencia artificial. Los primeros, como los trabajos de (Elsaraiti et al. 2021) (Divina et al.2019), se centran en series de tiempo, incorporando variables como el consumo eléctrico histórico y la variación del PBI, aunque (Iftikhar et al. 2023) introducen la variación del precio de la electricidad. Estos modelos, aunque efectivos, omiten variables climáticas. Por otro lado, los modelos basados en inteligencia artificial, como los de (Somu et al. 2021) (Fekri et al. 2021) (Eskandari et al. 2021), utilizan redes neuronales para predecir el consumo eléctrico considerando datos históricos, climáticos y socioeconómicos, logrando una mayor precisión aunque requieren más tiempo computacional debido a la optimización de la arquitectura de la red.

El artículo presenta dos modelos para estimar el consumo eléctrico horario en hogares de la Ciudad de Salta: uno basado en un enfoque estocástico y discreto, y otro en RNA. Estos modelos se desarrollan utilizando datos de encuestas sobre hábitos de consumo eléctrico, analizados con técnicas estadísticas avanzadas. El trabajo se estructura en secciones que detallan las metodologías empleadas, los resultados obtenidos y su comparación con la literatura existente, así como un análisis exhaustivo seguido de conclusiones derivadas del estudio. El propósito final es proporcionar una solución para la toma de decisiones en el sector eléctrico, contribuyendo así al desarrollo y la eficiencia del suministro eléctrico en la región.

## 2. Metodología de Trabajo

Para el modelo estocástico, se ha seguido una metodología que combina enfoques cuantitativos y cualitativos, basados en discusiones con académicos, profesionales de la Empresa de Distribuidora de Energía de Salta (EDESa) y expertos del sector público y privado, así como en encuestas y entrevistas con usuarios residenciales. Este enfoque integrado ha permitido validar y refinar el modelo mediante el análisis estadístico de los datos cuantitativos y la integración de la experiencia práctica y el rigor científico.

En cuanto al modelo basado en RNA, se propone el uso de Redes Neuronales Artificiales Feed Forward con Backpropagation para el aprendizaje supervisado. Se detallan las metodologías utilizadas para definir las variables involucradas y la estructura de red más adecuada para adaptarse al problema específico, proporcionando una visión completa de los procesos seguidos para la construcción de ambos modelos.

## 2.1 Modelo Estocástico

### 2.1.1 Relevamiento de datos

Se llevaron a cabo encuestas y entrevistas en diversas áreas de la Ciudad de Salta para comprender los hábitos de consumo en los hogares. Además de investigar la cantidad, tipo y frecuencia de uso de los artefactos, se exploraron aspectos como el tamaño y la composición del grupo familiar, así como los períodos de ausencia y baja actividad en el hogar. Para garantizar la fiabilidad de los resultados, se emplearon metodologías estadísticas sólidas para calcular el tamaño óptimo de la muestra, basándose en investigaciones previas establecidos por (García-García et al. 2013) y (Valdivieso et al. 2011), ecuación (1).

Es esencial definir una muestra poblacional representativa, para capturar la diversidad de tipos de viviendas en la ciudad. Se utilizó la clasificación de viviendas propuesta por EDESA como referencia, considerando el cuadro tarifario de la compañía y los diferentes rangos de consumos mensuales en kWh (Cuadro 1). Al establecer un nivel de confianza del 95%, se aseguró un alto grado de certeza en los resultados obtenidos, lo que es fundamental para la validez y fiabilidad de la investigación.

$$n = \frac{Z_{\alpha}^2 N \sigma^2}{e^2 (N-1) + Z_{\alpha}^2 \sigma^2} \quad (1)$$

**Cuadro 1: Categorización de las viviendas y definición del tamaño muestral**

Categoría	Consumo Máximo Mensual (kWh)	Cantidad de Viviendas	Total a Encuestar
R1	(0, 192]	160570	391
R2	(192,500]	116964	391
R3	(500,700]	13382	381
R4	(700,1400]	7765	373
R5	>1400	1319	302

### 2.1.2 Datos Climáticos

La predicción del consumo energético se ve influenciada significativamente por variables climáticas como la temperatura y la humedad relativa, cruciales para el confort térmico según la Norma ISO7730. Para mejorar la precisión del modelo, se incorporaron métodos para estimar estas variables.

En (Meira et. al., 2003), se simula la humedad relativa considerando la temperatura en períodos horarios anteriores mediante la ecuación (2). Está respaldada por la validación con datos climáticos del Instituto Nacional de Tecnología Agropecuaria (INTA) y un error cuadrático medio (RMSE) del 2.66%, se integra al modelo para proporcionar una representación más precisa y fiable del comportamiento energético.

$$HR = 100 \cdot \frac{e_s(T_n)}{e_s(T_m)} \quad (2)$$

$$e_s(T) = 6.11 \cdot e^{25.22(1 - \frac{213.16}{T})} \cdot \frac{213.16}{T}^{5.31} \quad (3)$$

El estudio de (Chabane et. al., 2013) ofrece métodos para simular la temperatura horaria en entornos urbanos, utilizando datos como la temperatura mínima y máxima del día anterior. Estos modelos, respaldados por la ecuación (4) (5) y (6), descomponen la temperatura ambiente en función de parámetros clave, permitiendo capturar con precisión las variaciones de temperatura a lo largo del día. Las ecuaciones (7) y (8), basadas en un análisis detallado de las distribuciones de probabilidad de las temperaturas mensuales, incorporan términos que permiten ajustar las temperaturas máximas y mínimas del día siguiente, asegurando la precisión del modelo en periodos más extensos. Estos ajustes, junto con la validación estadística con datos del INTA, que arrojan un valor del RMSE del 4.23%, confirman la capacidad del modelo para simular la temperatura horaria a lo largo de un año con alta precisión. Esta mejora en la capacidad del modelo proporciona una herramienta más robusta y confiable para abordar el problema en cuestión.

$$T_{a,b} = T_1 + T_2 \cdot \cos\left(\frac{\pi}{12} \cdot (14 - AST)\right) \quad (4)$$

$$T_1 = \frac{T_{\max} + T_{\min}}{2} \quad (5)$$

$$T_2 = \frac{T_{\max} - T_{\min}}{2} \quad (6)$$

$$T_{\max(i+1)} = T_{\max(i)} + \text{valor } 1 \quad (7)$$

$$T_{\min(i+1)} = T_{\min(i)} + \text{valor } 2 \quad (8)$$

### 2.1.3 Salida y Puesta del Sol

El estudio incorpora procedimientos para calcular la salida y la puesta del sol, aspectos fundamentales en la gestión del consumo energético para mantener condiciones de confort térmico adecuadas. Utilizando las ecuaciones (9) y (10), se logra una representación precisa de los momentos de aparición y desaparición del sol en el horizonte, obteniendo la Hora Solar Real (HSR). Sin embargo, se ajusta a la Hora Solar Aparente (HSA) mediante la ecuación (13), que considera la ecuación del tiempo para corregir las irregularidades en la velocidad de la Tierra en su órbita elíptica alrededor del Sol.

$$h_{ss} = 12 - \frac{\omega_s}{15} \quad (9)$$

$$h_{ps} = 12 + \frac{\omega_s}{15} \quad (10)$$

$$\omega_s = \arccos(-\tan \phi \cdot \delta \cdot \tan \varphi) \quad (11)$$

$$\delta = 23.45 \cdot \sin\left(\frac{(284+n)}{365} \cdot 360\right) \quad (12)$$

Las ecuaciones (9) y (10) utilizan parámetros astronómicos como la latitud del lugar ( $\phi$ ) y la declinación ( $\delta$ ) para calcular el ángulo horario en la puesta y salida del sol, esenciales en la determinación de los períodos de luz solar disponibles. La Hora Solar Aparente (HSA) resultante se descompone en varios componentes clave, incluyendo el meridiano de referencia ( $\lambda_0$ ), el meridiano del lugar ( $\lambda$ ) y la ecuación del tiempo ( $E_t$ ), determinada por la ecuación (14), que a su vez utiliza el ángulo diario ( $B$ ) calculado mediante la ecuación (15). Este enfoque mejora la exactitud del modelo al considerar los factores astronómicos, contribuyendo a una planificación más eficaz y precisa del consumo energético.

$$HSA = HSR - 4 \cdot (L_S - L_E) - E_t \quad (13)$$

$$E_t = 229.2 \cdot (0.000075 + 0.001868 \cos B - 0.032077 \sin B - 0.014615 \cos 2B - 0.04089 \sin 2B) \quad (14)$$

$$B = \frac{(n-1) \cdot 360}{365} \quad (15)$$

### ***2.1.4 Encendido y Apagado de Artefactos***

Para simular el encendido y apagado de los artefactos, se han establecido categorías que consideran su funcionamiento y su relación con factores externos. Esto incluye artefactos de uso continuo, artefactos de iluminación cuyo funcionamiento varía según la luz natural disponible, artefactos de climatización regulados por la temperatura y la humedad relativa del ambiente, artefactos de lavado y secado de ropa cuyo tiempo de funcionamiento se basa en la frecuencia de uso y el ciclo de lavado, y artefactos con batería interna que funcionan de manera autónoma. Para los artefactos restantes, se genera aleatoriamente el tiempo de funcionamiento, asegurando una simulación precisa y realista del consumo energético en un hogar, considerando condiciones como la presencia de personas en la vivienda y la existencia de personas despiertas, que son cruciales para aquellos artefactos que dependen de la interacción humana.

Cada procedimiento de simulación se realiza bajo una triple condición de control: la presencia del artefacto en la vivienda, la presencia de personas en el hogar para su uso y la existencia de personas despiertas en la vivienda, garantizando así una representación precisa del consumo energético. Estas condiciones son especialmente relevantes para artefactos que requieren interacción humana para su funcionamiento, mientras que para aquellos de uso continuo no es necesario aplicarlas. Las ecuaciones específicas y las cartas psicométricas se emplean para calcular tiempos de encendido y apagado basados en datos ambientales y comportamentales, contribuyendo a una simulación detallada del consumo eléctrico en un entorno doméstico.

### ***2.1.5 Generación de Viviendas***

El desarrollo del modelo implica la generación de viviendas, que se basa en análisis detallados de datos recopilados en encuestas y entrevistas para determinar qué artefactos y en qué cantidad estarán presentes en cada unidad habitacional. Esto permite establecer funciones de densidad para cada variable aleatoria y definir la cantidad de artefactos en una vivienda típica. Posteriormente, se verifica que el consumo mensual de energía esté dentro de los límites establecidos para su categoría mediante simulaciones durante los picos de consumo invernal y estival. Si una vivienda excede el límite máximo de consumo, se descarta y se reinicia el proceso de generación, asegurando la coherencia de los resultados y proporcionando una simulación más precisa y confiable del consumo eléctrico.

### 2.1.6 Modelo

El modelo se destaca por su metodología discreta, dinámica y estocástica, que analiza el consumo eléctrico en intervalos de un minuto, capturando su evolución a lo largo del tiempo. A través de un pseudo-código, se describe el modelo desarrollado. Este enfoque garantiza una representación precisa y profunda del comportamiento energético residencial al considerar la variabilidad climática y los hábitos de consumo de manera detallada y precisa.

*#Generación de los datos climáticos para todas las viviendas para todo el año  
Para cada uno de los 365 días del año:*

*Generar temperatura y humedad horaria (sección 2.1.2)*

*# Generación de las viviendas*

*Para cada una de las 5 categorías de viviendas:*

*Para cada vivienda de la categoría:*

*Generar y verificar la vivienda (sección 2.1.5)*

*# Simulación de las viviendas de la Ciudad para un año y cálculo del consumo eléctrico*

*Para cada uno de los 365 días del año:*

*Para cada una de las viviendas generadas:*

*Para cada minuto del día:*

*Determinar encendido y/o apagado de cada aparato (sección 2.1.4)*

*Calcular el consumo diario*

*Acumular el consumo mensual*

## 2.2 Modelo basado en Redes Neuronales Artificiales

La predicción mediante redes neuronales requiere una precisa definición de las variables de entrada y los conjuntos de datos, como temperatura, humedad, hora y día del año, expresado en tiempo juliano. Estas variables se seleccionan debido a su fuerte correlación con el consumo eléctrico residencial, mientras que factores estáticos como la tarifa eléctrica o el tamaño poblacional se descartan. Se establece el período de trabajo de 2018 a 2023 con datos de consumo de la Compañía Administradora del Mercado Mayorista Eléctrico S.A (CAMMESA) y datos climáticos del INTA, previo a un tratamiento de datos para regularizarlos y asegurar su idoneidad para el modelado.

Para evitar que variables con valores más altos dominen el modelo, se aplica un proceso de estandarización y normalización, asegurando que todas las variables tengan un peso equitativo. Para determinar el proceso de normalización adecuado, se

emplean técnicas estadísticas como el chi-cuadrado para analizar la distribución de los datos (cuadro 2). Esta fase de preparación es crucial para garantizar la precisión y la validez del modelo de redes neuronales en la predicción del consumo eléctrico horario residencial.

**Cuadro 2: Distribución de las variables aleatorias**

Mes	Día	Hora	Temperatura	Humedad	Consumo Eléctrico
Enero	U(1,31)	U(0,23)	N(23,4)	N(71,17)	N(139,25)
Febrero	U(32,59)	U(0,23)	N(22,4)	N(82,13)	N(134,26)
Marzo	U(60,90)	U(0,23)	N(20,4)	N(82,13)	N(132,25)
Abril	U(91,120)	U(0,23)	N(17,4)	N(82,12)	N(124,22)
Mayo	U(121,151)	U(0,23)	N(14,4)	N(83,11)	N(133,27)
Junio	U(152,181)	U(0,23)	N(12,5)	N(76,16)	N(142,27)
Julio	U(182,212)	U(0,23)	N(12,5)	N(72,18)	N(133,25)
Agosto	U(213,243)	U(0,23)	N(15,6)	N(64,21)	N(127,223)
Septiembre	U(244,273)	U(0,23)	N(17,5)	N(60,18)	N(125,22)
Octubre	U(274,304)	U(0,23)	N(18,6)	N(61,20)	N(128,25)
Noviembre	U(305,334)	U(0,23)	N(20,5)	N(67,19)	N(128,26)
Diciembre	U(335,365)	U(0,23)	N(22,5)	N(72,17)	N(131,26)

Las distribuciones predominantes identificadas son la Uniforme (U) y la Normal (N) para distintas variables aleatorias de cada mes, como Día y Hora para la primera, y Temperatura, Humedad y Consumo Eléctrico para la segunda. Basándose en estas distribuciones, se eligen procesos de estandarización específicos: la estandarización de la distribución normal para las variables normales y la técnica de estandarización de mínimo y máximo para las variables uniformes. Este enfoque garantiza una preparación adecuada de los datos para su integración en el modelo de predicción de consumo eléctrico.

### 2.2.1 Descripción del modelo

La selección adecuada del número de neuronas ocultas en una red neuronal es esencial para evitar problemas de generalización y garantizar su capacidad para resolver el problema de predicción o clasificación. Un exceso de neuronas ocultas puede conducir a un ajuste excesivo, deteriorando la capacidad de la red para generalizar las predicciones. Por lo tanto, determinar el número óptimo de neuronas ocultas es crucial para evitar este ajuste excesivo y garantizar un rendimiento óptimo del modelo. En este estudio, se aborda este desafío al diseñar modelos de redes neuronales específicos para cada mes del año, con una arquitectura que incluye

una capa de entrada de 4 neuronas representando las variables pertinentes y una capa de salida con una neurona que estima el consumo eléctrico. Estos modelos se detallan en la cuadro 3, proporcionando una estructura clara para el análisis y la predicción del consumo eléctrico mensual.

**Cuadro 3: Distribución de las variables aleatorias**

Mes	Arquitectura adoptada
Enero	5
Febrero	8
Marzo	5
Abril	8
Mayo	8
Junio	5
Julio	17
Agosto	8
Septiembre	8
Octubre	5
Noviembre	17
Diciembre	5

Los parámetros utilizados para el proceso fueron:

- Función de Pérdida: se tuvo en cuenta el error cuadrático medio.
- Optimizador: Se utilizó la técnica SGD con tasa de aprendizaje de 0.1.
- Epochs: 1000

### 3. Resultados

#### 3.1 Modelo Estocástico

La validación del modelo se efectuó comparando los resultados de la simulación con los datos reales de consumo residencial proporcionados por EDESA para los años 2021 y 2022 en Salta, Cuadro 4. El análisis revela un RMSE de 1.63 para 2021 y 0.085 para 2022, con un RMSE promedio de 0.85 para ambos años, indicando una buena concordancia entre los datos simulados y reales. Además, se detallan los tiempos promedio de generación de viviendas y simulación en una computadora con 8 GB de RAM y un procesador Intel Core i7 en la Cuadro 5, ofreciendo información clave sobre la eficiencia computacional del modelo y su aplicabilidad en diversos escenarios.

**Cuadro 4: Comparación de los resultados obtenidos con los datos suministrados por EDESA para el período comprendido entre los años 2020 y 2022.**

Mes	Consumo Anual 2021 (GWh)	Consumo Anual 2022 (GWh)	Consumo Anual Modelo Estocástico
Enero	74.89	84.57	83.04
Febrero	59.61	75.44	77.29
Marzo	61.08	73.02	73.18
Abril	58.11	69.16	74.45
Mayo	62.61	80.99	81.77
Junio	68.25	88.15	84.58
Julio	72.18	83.10	81.97
Agosto	65.78	72.67	74.9
Septiembre	61.36	70.03	73.3
Octubre	68.37	72.45	75.42
Noviembre	68.24	72.3	77.1
Diciembre	72.11	83.32	81.1

**Cuadro 5: Comparación de tiempos computacionales para la generación y simulación de las viviendas**

Categoría	Tiempo de Generación (seg)	Tiempo de Simulación (seg)
R1	499.03	69.25
R2	151.41	58.24
R3	177.22	52.29
R4	154.6	61.15
R5	508.23	65.45

### 3.2 Modelo basado en Redes Neuronales

Se han aplicado rigurosas estrategias de validación para asegurar la fiabilidad de los modelos basados en redes neuronales, que abarcan desde la validación del proceso de entrenamiento hasta la evaluación con datos reales para medir la capacidad de generalización. La cuidadosa división de los datos en conjuntos de entrenamiento y validación considera diversos patrones climáticos y sociales para garantizar la representatividad de los escenarios evaluados.

Se optó por no usar validación cruzada en la etapa final para demostrar la capacidad de generalización de los modelos sobre conjuntos de datos nuevos. Los resultados indican un RMSE promedio de 1.0807 para entrenamiento y 1.295 para

validación, con tiempos promedio de 38.64 y 20.34 segundos, respectivamente, como se detalla en la cuadro 6.

**Cuadro 6: Comparación de tiempos y RMSE mensuales**

Mes	RMSE Entrenamiento	Tiempo ejecución entrenamiento (seg)	RMSE Validación	Tiempo de ejecución validación (seg)
Enero	1.33453	38.56	1.50327	20.63
Febrero	1.36198	49.12	1.70324	15.75
Marzo	1.44738	29.63	1.75	19.58
Abril	0.82974	35.45	0.89	22.56
Mayo	0.99979	40.23	1.24	18.63
Junio	1.4448	42.36	1.53	24.86
Julio	0.70346	29.23	1.13	22.63
Agosto	0.9304	32.56	1.02327	24.01
Septiembre	0.7921	42.23	0.89	17.63
Octubre	1.22677	36.56	1.4	14.96
Noviembre	0.71934	42.12	1.12	16.45
Diciembre	1.17847	45.63	1.36	26.48

## 4. Conclusiones

La precisión en la predicción de la demanda eléctrica es crucial para la eficiencia económica y la seguridad operativa de los sistemas de energía eléctrica, así como para la planificación estratégica y la toma de decisiones en el sector energético. En un entorno dinámico como el de Salta, Argentina, los modelos tradicionales de pronóstico enfrentan desafíos debido a factores como cambios demográficos, patrones de consumo variables y eventos climáticos extremos. Los modelos presentados en este estudio, tanto el estocástico como los basados en redes neuronales artificiales, ofrecen soluciones innovadoras para abordar estos desafíos. Si bien el modelo estocástico proporciona resultados sólidos y precisos, los modelos de RNA, al aprender de datos históricos, pueden capturar relaciones complejas y ofrecer una mayor precisión estadística. La combinación de estos enfoques brinda una visión integral de la demanda eléctrica en Salta, permitiendo una mejor anticipación y gestión de los desafíos futuros en el suministro eléctrico y contribuyendo al desarrollo sostenible de la comunidad.

## Referencias

- Chabane, F., Moumimi, N., & Brima, A. (2016). Prediction of the theoretical and semi-empirical model of ambient temperature. *Frontiers in Energy, 10*(3), 268–276.
- Divina, F., Garcia Torres, M., Gomez Vela, F. A., & Vazquez Noguera, J. L. (2019). A comparative study of time series forecasting methods for short term electric energy consumption prediction in smart buildings. *Energies, 12*(10), 1934.
- Elsaraiti, M., Ali, G., Musbah, H., Merabet, A., & Little, T. (2021). Time series analysis of electricity consumption forecasting using ARIMA model. *IEEE Green Technologies Conference (GreenTech), 259-262*.
- Eskandari, H., Imani, M., & Moghaddam, M. P. (2021). Convolutional and recurrent neural network based model for short-term load forecasting. *Electric Power Systems Research, 195*, 107173.
- Fekri, M. N., Patel, H., Grolinger, K., & Sharma, V. (2021). Deep learning for load forecasting with smart meter data: Online adaptive recurrent neural network. *Applied Energy, 282*, 116177.
- García-García, J. A., Reding-Bernal, A., & López-Alvarenga, J. C. (2013). Cálculo del tamaño de la muestra en investigación en educación médica. *Investigación En Educación Médica, 2*(8), 217–224.
- Iftikhar, H., Bibi, N., Canas Rodrigues, P., & López-Gonzales, J. L. (2023). Multiple novel decomposition techniques for time series forecasting: Application to monthly forecasting of electricity consumption in Pakistan. *Energies, 16*(6), 2579.
- Meira, G. R., Padaratz, I. J., Alonso, C., & Andrade, C. (2003). Efecto de la distancia al mar en la agresividad por cloruros en estructuras de hormigón en la costa brasileña. *Materiales de Construcción, 53*(271–272), 179–188.
- Shine, P., Scully, T., Upton, J., & Murphy, M. D. (2018). Multiple linear regression modelling of on-farm direct water and electricity consumption on pasture-based dairy farms. *Computers and Electronics in Agriculture, 148*, 337-346.
- Somu, N., MR, G. R., & Ramamritham, K. (2021). A deep learning framework for building energy consumption forecast. *Renewable and Sustainable Energy Reviews, 137*, 110591.
- Valdivieso, C., Valdivieso, R., & Valdivieso, O. (2011). Determinación del tamaño muestral mediante el uso de árboles de decisión. *UPB- Investigación & Desarrollo, 11*(2000), 148–176.

