

## **Predicción de la demanda eléctrica nacional mediante el uso de redes neuronales recurrentes LSTM**

**Félix Morales<sup>1</sup>; Matías Verdún<sup>1</sup>; Carlos Sauer<sup>1,2</sup>; Diego Stalder<sup>1</sup>**

<sup>1</sup>Facultad de Ingeniería, Universidad Nacional de Asunción

<sup>2</sup>Administración Nacional de Electricidad

**Paraguay**

### ***1.1. Resumen***

La previsión de la demanda eléctrica a corto plazo representa una herramienta fundamental para la toma de decisiones por parte de entidades que se dedican a la administración de energía eléctrica, ya que permite elaborar estrategias para atender las variaciones en la demanda eléctrica en periodos cortos de tiempo. La precisión de los modelos predictivos constituye un factor importante para las operaciones energéticas y la programación de las fuentes de generación de energía para satisfacer a la demanda eléctrica en cada instante. Con esta motivación, se propone un modelo inteligente basado en las redes neuronales recurrentes Long-Short Term Memory (LSTM), que asocia parámetros externos como la temperatura y las variables del calendario que poseen incidencia sobre la demanda eléctrica. La configuración del modelo presentado se encuentra optimizada mediante la utilización de técnicas metaheurísticas. El conjunto de datos utilizado para el entrenamiento y validación del modelo incluye el registro horario del consumo eléctrico y de las variables meteorológicas de Paraguay, correspondientes al lapso de tiempo comprendido entre 2009 y 2017. La precisión del modelo propuesto se ha comparado con la de modelos estadísticos y modelos de aprendizaje automático. Se han utilizado métricas clásicas para medir el desempeño, como la raíz del error cuadrático medio (RMSE) y el error absoluto porcentual medio (MAPE). Además, se introdujeron nuevas medidas especiales para determinar el error en la predicción del modelo en horarios claves. Por ello, las medidas introducidas son: el error porcentual de la hora de máxima demanda (EPHMD) y el máximo error porcentual del día (MEPD). Los resultados han indicado que el modelo sugerido posee una mayor precisión en comparación a los otros métodos utilizados.

### ***1.2. Palabras clave***

Demanda eléctrica, redes neuronales recurrentes, Long-Short Term Memory, técnicas metaheurísticas.

## **1. INTRODUCCIÓN**

La previsión de la demanda de electricidad es un tema ampliamente estudiado y de gran interés para las empresas eléctricas de cualquier país. La misma es un elemento importante para la toma de decisiones estratégicas, como la programación de unidades generadoras y la planificación de operaciones que permitan atender la demanda del sistema eléctrico. Si la previsión de demanda ambientales, tipos de clientes y la fecha, escalas y resolución temporales (muy corto plazo, menor a 1 hora, corto plazo, 1 hora a 7 días, mediano plazo, meses o temporadas, largo-plazo, más de un año) [20], [22]. Los modelos estadísticos permiten prever o extrapolar la demanda en el largo plazo considerando las correlaciones del consumo actual con variables que afectan la demanda como el histórico, variables climáticas, las actividades económicas, las regiones, entre otras [13]. Por otro lado, los modelos basados en el aprendizaje de máquina (ML, del inglés, Machine Learning) y el aprendizaje profundo (DL, del inglés, Deep Learning) han permitido realizar previsiones superiores en comparación con sus competidores, en escalas de tiempo de corto y muy corto plazo.

Los modelos basados en DL utilizan redes neuronales artificiales (RNA). Las mismas utilizan funciones no lineales y estocásticas para capturar la dinámica de las series de tiempo a partir del consumo de energía y las variables exógenas asociadas [12]. Las mismas permiten extraer información de las grandes cantidades de datos, registros históricos disponibles utilizando la capacidad computacional proveídas por los procesadores gráficos (del inglés, Graphics Processors Units). Cuando se trata de series temporales, los modelos basados en redes neuronales recurrentes (RNN) aprovechan la información de salida anteriores (recurrencia) para dar una previsión de la demanda a partir datos históricos del uso de la red eléctrica [10]. Las RNN fueron mejoradas con la utilización de células de memoria de corto y largo plazo (LSTM, del inglés, Long-Short Term Memory) para subsanar problemas ocasionados por los gradientes nulos generados durante el entrenamiento [15]. La célula LSTM permite incluir variables exógenas y capturar información importante para extrapolar los datos. Esta contiene información crítica que ha aprendido con el tiempo, y la red está diseñada para mantener de manera efectiva la información útil en ella, durante muchos pasos de tiempo. Con estas nuevas arquitecturas se han logrado pronosticar series de tiempo y la demanda de energía en países como España y Francia [1,2,5].

Por otro lado, también fue necesario detectar y corregir anomalías en los datos considerando que el registro de los datos del consumo de energía está sujeto a errores durante su lectura, transcripción y/o almacenamiento. Además, la presencia varias componentes periódicas o estacionales en las series temporales del consumo eléctrico hacen que esta tarea no sea trivial [6]. Recientemente [14], han propuesto una nueva metodología estadística para detectar anomalías en series temporales basados en trabajos previos [24]. La metodología S-H-ESD (del inglés, Seasonal-Hybrid Extreme Studentized Deviate) permite mejorar la robustez de la detección utilizando estimadores como la mediana y mediana de desviación absoluta (MAD) y fue aplicada para detectar y corregir las anomalías en los datos.


El trabajo se estructura de la siguiente forma. En la siguiente sección se presentan la metodología y los datos utilizados. Seguidamente se describen las etapas del desarrollo del modelo desde el preprocesamiento de los datos, la detección y corrección de anomalías, el modelo LSTM y la optimización de sus parámetros utilizando un algoritmo genético. A continuación, se presentan los principales resultados obtenidos en cada etapa del trabajo. Finalmente, en la última sección se discuten las contribuciones del trabajo.

## **2. METODOLOGÍA**

En esta sección se inicia presentando el conjunto de datos meteorológicos y de consumo eléctrico correspondientes a Paraguay. Luego se describe el preprocesamiento, así como el análisis y la corrección de anomalías. Para el desarrollo del modelo LSTM se seleccionan los atributos de entrada basados en los datos de demanda, las variables del calendario (día, mes, año, entre otros) y los datos meteorológicos (temperatura, humedad, viento, etc.). Seguidamente se construye el modelo de red neuronal utilizando unidades recurrentes y se definen los hiperparámetros de la red y se proponen los modelos candidatos que finalmente son evaluados

**XIV SEMINARIO DEL SECTOR ELECTRICO PARAGUAYO - CIGRE**  
23 y 24 de Junio 2022

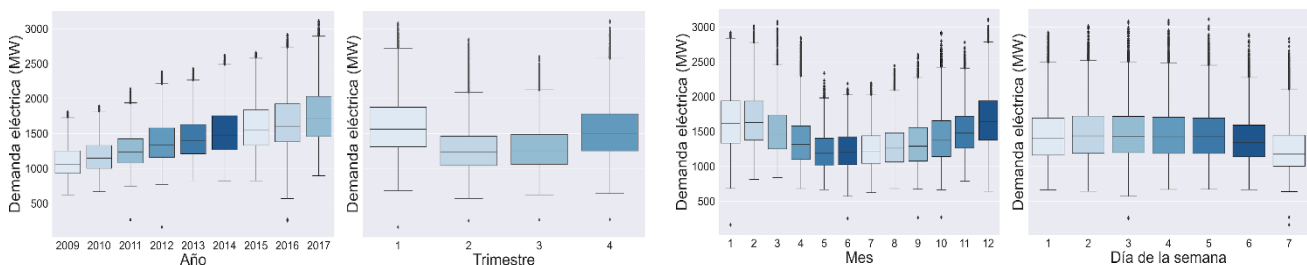
con métricas más específicas como el Máximo Error del día, el Error en la hora de mayor consumo, entre otros. La Figura 1 muestra las etapas de la metodología aplicada.



**Figura 1. Metodología de trabajo**

**2.1. Conjuntos de Datos**

La serie temporal que se modela en este trabajo es el registro de la demanda eléctrica (en MW, Megawatt) del sistema interconectado nacional del Paraguay (SIN). Este conjunto de datos proveído por la Administración Nacional de Electricidad (ANDE), posee un registro horario desde el año 2009 hasta el año 2017. Para evaluar el efecto de la estacionalidad y otras variables del calendario sobre la demanda eléctrica, se utilizan diagramas de caja como en la Figura 2. En la misma se visualizan las variaciones de la demanda eléctrica con respecto a diversas resoluciones temporales como año, mes, trimestre y día de la semana. Se constata una clara tendencia creciente de la demanda eléctrica entre el 2009 y el 2017. Además, se observa una fuerte estacionalidad de la demanda que en promedio es mayor en los meses cálidos por el mayor uso de equipos de refrigeración. Las rutinas de la población se reflejan en general en un menor consumo los fines de semana con respecto a días hábiles. Además, los diagramas de cajas revelan que pueden existir datos anómalos en la serie temporal.



**Figura 2. Gráfico de cajas de la demanda agrupada por variables del calendario.**

En base a la estacionalidad observada y la revisión de la literatura resulta imprescindible considerar datos meteorológicos que puedan influir en la demanda eléctrica. Los datos meteorológicos proveídos por el Centro Meteorológico de la Facultad Politécnica de la Universidad Nacional de Asunción y la Dirección de Meteorología e Hidrología incluyen la temperatura seca del aire, la humedad relativa, velocidad del viento y la dirección del viento de once estaciones meteorológicas distribuidas en diversas zonas del país. Los datos de las estaciones meteorológicas se registran cada 3 horas, consecuentemente se realizó una interpolación lineal para combinarlos con los datos de la demanda.

**3. DESARROLLO DEL MODELO INTELIGENTE**

En esta sección se describen las diferentes etapas del desarrollo del modelo predictivo a partir del preprocesamiento, la selección de atributos de entrada, la optimización de la arquitectura del modelo LSTM, el entrenamiento y ajuste de hiperparámetros. Cada modelo propuesto es entrenado con los valores históricos de demanda eléctrica. En base a las observaciones realizadas sobre el efecto de variables del calendario en la

XIV SEMINARIO DEL SECTOR ELECTRICO PARAGUAYO - CIGRE  
23 y 24 de Junio 2022

misma, se consideran los atributos de año, mes, día de la semana y la hora del día. Los días de la semana y los meses se categorizan con valores numéricos.

### 3.1. Preprocesamiento: Detección y corrección de anomalías

Primeramente, se analizaron los datos a modo de sustituir los valores negativos y nulos por valores válidos. El paso siguiente consiste aplicar la transformación de Box-Cox, cuya ecuación se expresa como:

$$Y^* = \begin{cases} \frac{Y^\lambda - 1}{\lambda}, & \text{if } \lambda \neq 0 \\ \log Y, & \text{if } \lambda = 0 \end{cases}, \quad (1)$$

donde Y representa la serie temporal original, Y\* es la serie temporal luego de la transformación y  $\lambda$  indica el parámetro de transformación, cuyo valor es obtenido por medio del método de la estimación de máxima verosimilitud [3]. Esta transformación permite estabilizar la varianza de los datos y obtener una serie temporal aditiva [7] antes de descomponer la serie temporal por medio de la utilización de la descomposición STL (Seasonal and Trend decomposition using Loess) [9]. De este modo la serie Y\* queda descompuesta en tres componentes: una estacional (Sy), la tendencia (Ty) y un residual (Ry), donde se aplica el algoritmo S-H-ESD sobre la componente residual [14]. Seguidamente para realizar la corrección se suma la componente residual y la tendencia para determinar los datos sin la componente estacional. De estos datos se eliminan los valores anómalos y se realiza una interpolación lineal para rellenar los datos faltantes. Finalmente se añade la componente estacional y se aplica la transformación inversa de Box-Cox para obtener nuevamente la serie temporal Y libre de anomalías. El mismo procedimiento fu aplicado a las variables meteorológicas. Finalmente, para la aplicación de los modelos de redes neuronales, los datos fueron normalizados en el rango de [0,1] utilizando el escalado min-max.

### 3.2. Influencia de la temperatura ambiente

En Paraguay el consumo tiende a aumentar significativamente cuando aumenta la temperatura debido al uso de sistemas de refrigeración. Por este motivo, una entrada del modelo sería la previsión de la temperatura del día siguiente. En los experimentos realizados se consideró la temperatura de la ciudad con mayor cantidad de habitantes (Asunción), la temperatura ponderada por la cantidad de habitantes de cada ciudad y la temperatura aparente o sensación térmica [5]. La temperatura aparente se obtiene mediante la siguiente ecuación:

$$T_A = T_a + 0.348e - 0.70W_s + 0.70 \frac{Q}{W_s + 10} - 4.25, \quad (2)$$

donde  $T_A$  es la temperatura aparente,  $T_a$  es la temperatura seca del aire (Grados Centígrados), e es la presión del vapor de agua (hPa) [humedad],  $W_s$  es la velocidad del viento (m/s) en una elevación de 10 metros y Q es la radiación neta absorbida por unidad de área de superficie corporal ( $w/m^2$ ). Para simplificar el cálculo no se ha utilizado el factor Q de la ecuación anterior, ya que se considera apenas la temperatura aparente en la sombra. Para la variable velocidad del viento, se utilizó la escala de Beaufort para categorizar los valores en la serie temporal. En la sección de resultados se realizan experimentos para determinar cuál de las temperaturas será considerada para el modelo final.

Finalmente, el conjunto de atributos propuesto está conformado por las variables detalladas en la tabla 1. El modelo recibe: los valores actuales de la demanda y la semana anterior, la temperatura, el día de la semana, el mes y el año. También se incluyen como entrada la previsión de la temperatura y los valores del día de la semana, mes, año para el cual se quiere hacer la previsión. En la sección de resultados se realizan experimentos para evaluar la sensibilidad a los errores en la previsión de tiempo.

XIV SEMINARIO DEL SECTOR ELECTRICO PARAGUAYO - CIGRE  
23 y 24 de Junio 2022

Tabla 1. Atributos seleccionados

Atributos	Descripción
Demanda Actual	Valor en $t$
Temperatura Actual	Valor en $t$
Año Actual	Valor en $t$
Mes Actual	Valor en $t$
Día de la semana Actual	Valor en $t$
Demanda de la Semana Anterior	Valor en $t-168$
Temperatura (previsión)	Valor en $t+24$
Año	Valor en $t+24$
Mes	Valor en $t+24$
Día de la semana	Valor en $t+24$

3.3. Modelo LSTM para la previsión de la demanda

Las unidades de nuestro modelo están compuestas por celdas LSTM [15], las mismas permiten evitar el problema del desvanecimiento del gradiente y su funcionamiento está determinado por siguiente conjunto de ecuaciones:

$$\begin{aligned}
 i(t) &= \sigma(W_{xi}^T \cdot x(t) + W_{hi}^T \cdot h_{(t-1)} + b_i) \\
 f(t) &= \sigma(W_{xf}^T \cdot x(t) + W_{hf}^T \cdot h_{(t-1)} + b_f) \\
 o(t) &= \sigma(W_{xo}^T \cdot x(t) + W_{ho}^T \cdot h_{(t-1)} + b_o) \\
 g(t) &= \tanh(W_{xg}^T \cdot x(t) + W_{hg}^T \cdot h_{(t-1)} + b_g) \\
 c(t) &= f(t) \otimes c_{(t-1)} + i(t) \otimes g(t), \\
 y(t) &= h(t) = o(t) \otimes \tanh(c(t)),
 \end{aligned}
 \tag{3}$$

donde  $W_{xi}$ ,  $W_{xf}$ ,  $W_{xo}$ ,  $W_{xg}$  son las matrices de pesos de las conexiones entre las cuatro capas y el vector de entrada  $x(t)$ .  $W_{hi}$ ,  $W_{hf}$ ,  $W_{ho}$ ,  $W_{hg}$  son las matrices de pesos de las conexiones entre las cuatro capas y el estado de corto plazo previo  $h(t-1)$ ,  $b_i$ ,  $b_f$ ,  $b_o$ ,  $b_g$  son términos constantes.

El modelo propuesto consta de una capa de  $k$  celdas LSTM, lo que determina cuantos pasos de tiempo hacia atrás puede ver la red y un vector de estado oculto  $h_t$  de tamaño  $m$ . A continuación, se tienen  $N$  capas totalmente conectadas, con  $N_i$  neuronas en cada capa ( $N_i = N_1, N_2, \dots, N_n$ ). A la salida se utiliza una capa final con 24 neuronas correspondientes a las siguientes 24 horas del día para las cuales se realiza la previsión como se visualiza en la Figura 4. Esta configuración permite un mayor enfoque sobre la curva de demanda por día que sirve por ejemplo para la programación horaria de centrales de generación para el día siguiente.

Los datos se dividen en conjuntos de entrenamiento y validación, pero se mantiene el orden temporal de las observaciones. Los datos de validación se utilizan para evaluar la precisión del modelo de previsión propuesto y no se utilizan durante el entrenamiento. Una práctica estándar para modelos de aprendizaje automático consiste en dividir datos utilizando proporciones 80/20 o 70/30. Sin embargo, la mayoría de los experimentos en este trabajo se realizaron para evaluar la previsión del último año (2017), siendo este nuestro conjunto de validación. Se partieron de las configuraciones del trabajo adoptado como línea de base [2]. El mismo utilizó el error cuadrático medio (del inglés, mean squared error, MSE) como función de costo y sus experimentos numéricos mostraron que el algoritmo ADAM obtenía mejores resultados [19]. Así mismo, la función de activación ReLU fue seleccionada para las capas densas, debido a que evita el problema del desvanecimiento del gradiente [23].

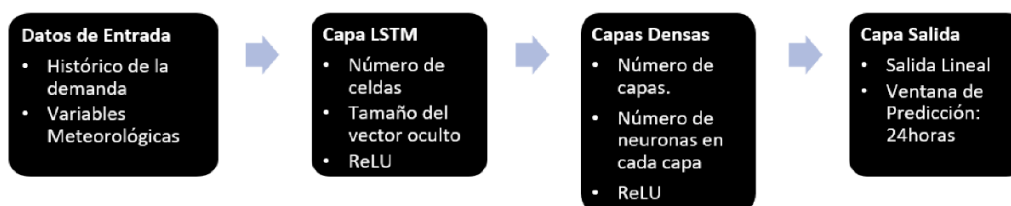


Figura 4. Arquitectura propuesta.

XIV SEMINARIO DEL SECTOR ELECTRICO PARAGUAYO - CIGRE  
23 y 24 de Junio 2022

### 3.4. Métricas de desempeño clásicas y propuestas

Las métricas de desempeño en los modelos predictivos se utilizan para analizar cuantitativamente los errores entre los valores reales y los valores predichos. Esto sirve al momento del entrenamiento para ajustar los parámetros del modelo y realizar una comparativa frente a otros modelos con los datos del conjunto de prueba. La raíz del error cuadrático medio (del inglés, root mean squared error, RMSE) se define como la raíz cuadrada del valor medio de los cuadrados de la diferencia entre los valores reales y los valores predichos en MW. El error porcentual absoluto medio (del inglés, mean percentage absolute error, MAPE) es un indicador del desempeño de la previsión de demanda que mide el tamaño del error absoluto en términos porcentuales, esto lo hace intuitivo al momento de analizar los valores previstos. Para evaluar la dispersión del error absoluto se utilizaron el tercer cuartil Q3 y el máximo valor del error porcentual absoluto, denotados como Q3APE y Max AEP respectivamente. La formulación de estas métricas se representa de la siguiente manera:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}, \quad Q3APE = \left( \frac{|y_i - \hat{y}_i|}{y_i} \right)_{Q_3}, \quad (4)$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n \frac{|y_i - \hat{y}_i|}{y_i}, \quad MaxAPE = \max \left( \frac{|y_i - \hat{y}_i|}{y_i} \right), \quad (5)$$

donde  $y_i$  representa el vector de los n valores de demanda observados, ( $\hat{y}_i$ ) el vector de los n valores de previsión de demanda eléctrica y n indica la cantidad de horas consideradas, que dependiendo del enfoque puede ser, por ejemplo, diario, mensual o anual.

Estas métricas clásicas nos dan una visión global del desempeño de la previsión, pero los responsables del despacho de carga de las empresas eléctricas deben tomar decisiones cada día para la optimización de los

$$EPHMD = \frac{y_p - \hat{y}_p}{y_p}, \quad MEPD = \frac{y_q - \hat{y}_q}{y_q}, \quad (6)$$

sistemas y cada hora en caso de errores en las previsiones. Para un análisis más profundo e intuitivo con respecto al desempeño de la previsión de la demanda a lo largo de un día se han propuesto e implementado dos métricas especiales para cada día del año: el error porcentual a la hora de mayor demanda (EPHMD) y el máximo error porcentual del día (MEPD), cuyas formulaciones se representan como:

donde para un día dado  $n = 24$ ,  $p = \max(y_i)$  es la hora de mayor consumo eléctrico y  $q = \max \left( \frac{|y_i - \hat{y}_i|}{y_i} \right)$  es la hora en que ocurre el mayor error porcentual del día. A diferencia de las métricas clásicas, ambas métricas introducidas pueden asumir valores negativos lo cual es relevante para distinguir si los errores que se cometen poseen sesgo hacia la sobreestimación o subestimación en la demanda eléctrica, lo cual es clave para tomar medidas para la reducción o incremento en la generación de energía en la hora considerada.

## 4. RESULTADOS EXPERIMENTALES

Para este se trabajó se utilizó una estación de trabajo equipada con una GPU RTX2080, un procesador Xeon E52630V3 con 16GB de RAM DDR4. Con este Hardware el tiempo de entrenamiento de cada modelo demanda entre 3 a 5 minutos y menos de 1GB de memoria RAM en la GPU. Para realizar el trabajo de pre-procesamiento de los datos, entrenar los modelos y evaluar los datos se utilizaron las bibliotecas Tensorflow, Keras, Scipy y SKlearn. Para obtener los modelos candidatos presentados en la Tabla 2 se implementó un algoritmo genético que está implementado en la librería DEAP en el entorno de Python.

XIV SEMINARIO DEL SECTOR ELECTRICO PARAGUAYO - CIGRE  
23 y 24 de Junio 2022

Tabla 2. Modelos Candidatos

Modelos	$k$	$m$	$N_i$
1	101	53	179
2	117	92	106, 44
3	117	92	152, 55, 93
4	118	88	82, 77, 186, 126
5	107	94	152, 15, 23, 59, 192
6	101	53	179, 39, 36, 74, 22, 144

Para comparar los modelos candidatos se realizó el entrenamiento (2010 al 2016) y validación (2017). En la Figura 5 se presentan los resultados del RMSE, MAPE, Q3MAPE y Max APE, lo que indica que los modelos son bastante competitivos, principalmente cuando se consideran las diferencias entre los errores porcentuales. El modelo 3 presenta los menores errores máximos porcentuales. El modelo 2 parece ser el menos sensible a la determinación de la semilla. Sin embargo, el modelo 1 además de ser el que tiene un menor número de parámetros presenta los menores valores en cuanto al RMSE, MAPE y Q3MAPE. Motivo por el cual de aquí en adelante los experimentos se centrarán en el modelo 1.


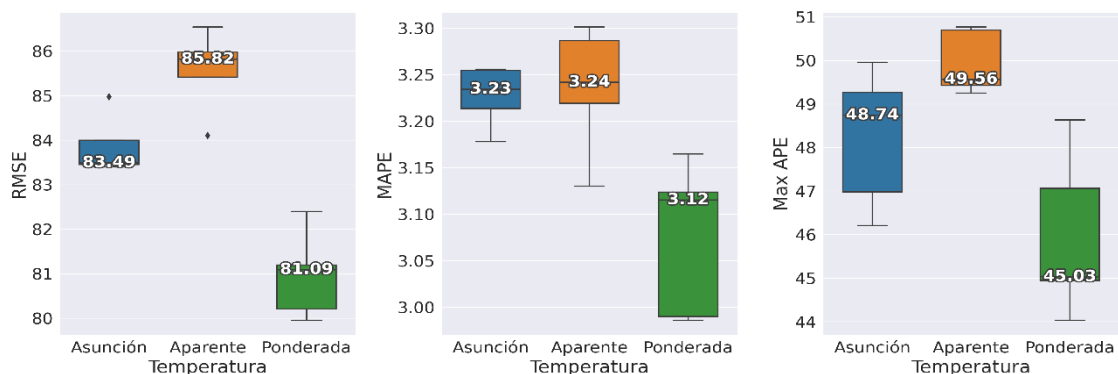


Figura 5. Comparación de Modelos candidatos. Cada modelo fue entrenado y evaluado 5 veces para tener una medida más precisa de los errores.


Una exploración inicial en base a simple correlación estadística con la demanda eléctrica de todo el sistema revela que el atributo de temperatura con mayor correlación es el de la ciudad capital, Asunción, ya que una parte importante de la demanda eléctrica se concentra en el área metropolitana de la capital. Con el modelo ajustado seleccionado, se explora la posibilidad de modificar el atributo de temperatura por la ponderación de la temperatura de otras ciudades por el número de habitantes, o bien, por la temperatura aparente. En la Figura 6 se comparan los errores obtenidos con el atributo de temperatura de Asunción, la Aparente y la Ponderada, observándose errores ligeramente menores con el uso de la temperatura ponderada y mayores con el uso de la temperatura aparente. La temperatura ponderada es seleccionada entonces para los ajustes finos de parámetros y las simulaciones.



XIV SEMINARIO DEL SECTOR ELECTRICO PARAGUAYO - CIGRE  
23 y 24 de Junio 2022

**Figura 6. Selección de las Temperaturas para utilizar en el modelo final.**


En el proceso de validación con los datos de demanda eléctrica de 2017, se utilizan registros observados de temperatura de 2017. Como en una situación real apenas se cuentan con pronósticos de temperatura horarios para el día siguiente, se introducen errores gaussianos aditivos  $G(\mu, \sigma)$  con media  $\mu$  y desviación estándar  $\sigma$  en grados centígrados. Esto permite analizar la robustez del modelo en la previsión de demanda ante posibles errores en los pronósticos de temperatura. En la Figura 7 se comparan los errores obtenidos con las adiciones de error gaussiano  $G(1,1)$ ,  $G(-1,1)$  y  $G(0,2)$ . Los resultados indican que la capacidad de la previsión empeora en cuanto al MAPE en valores menores al 1%, lo que indica que las previsiones de la red son robustas aún en el contexto de pequeños errores en los pronósticos de temperatura.



**Figura 7. Experimento para evaluar la sensibilidad a los errores de la previsión del tiempo.**

Se realizó un análisis del perfil de los errores con nuevas métricas de desempeño, se consideró el Modelo 1. Se tomaron los errores y se agruparon por día de tal forma a calcular las nuevas métricas introducidas EPHMD y MEPD. Las Figuras 8(a) y (b) muestran las distribuciones y los percentiles de los errores. La Figura 8(a) nos indica que a la hora de máximo consumo del día el error porcentual menor al 5% en el 90% y en general es menor que 10%, salvo en casos muy aislados. La Figura 8(b) nos indica que el máximo error porcentual del día (MEPD) tiene una dispersión mayor que el EPHMD. Sin embargo, en el MEPD se observan dos modos alrededor del -5% y 5% y en el 80% de los días el máximo error incurrido es menor al 10%. Existen algunos días (5% o 18 días del año) en que la previsión de la demanda es sobreestimada en más del 20%. Un análisis más detallado de los mismos reveló que en su mayoría corresponden a días feriados. Se concluye además que no existe un sesgo claro para ambas situaciones hacia valores positivos o negativos.



XIV SEMINARIO DEL SECTOR ELECTRICO PARAGUAYO - CIGRE  
 23 y 24 de Junio 2022


**Figura 8 (a) Histograma del error porcentual a la hora de mayor consumo (EPHMD). (b) Histograma del máximo error porcentual del día (MEPD).**

## 5. DISCUSION

Este trabajo desarrolló y caracterizó un modelo basado en redes neuronales LSTM que a partir de los datos históricos y el pronóstico meteorológico es capaz de dar una previsión de la demanda horaria de energía eléctrica de las siguientes 24 horas de manera robusta. El mismo ayudará a las empresas proveedoras de energía eléctrica a realizar la programación horaria de las fuentes de generación para el día siguiente. El modelo puede ser utilizado para anticiparse a picos en los sistemas de generación y transmisión, para identificar anomalías de consumo y para optimizar los costos de generación. Los experimentos numéricos muestran que el MAPE es de alrededor del 3%, aunque que el error porcentual máximo sin asimilación de datos puede llegar al 50%, generalmente en días feriados. Sin embargo, las métricas especiales EPHMD y MEPD introducidas en este trabajo para este tipo de aplicación permiten un análisis detallado de la distribución de los errores revelando que el error máximo cometido cada día es menor al 10% en la mayoría de los casos, y generalmente menor al 5% en las horas de punta de la demanda eléctrica del día, sin sesgos significativos. No obstante, es necesario realizar más experimentos para mejorar la previsión, por ejemplo, en los días feriados o en días con cambios abruptos de temperatura. También es necesario comparar el desempeño del modelo frente a otras arquitecturas emergentes del estado del arte [27]. Como cualquier otra red neuronal compleja, ya que no existe una forma clara de diseñar la topología de la red sobre la configuración de las capas y las unidades o neuronas correspondientes, cada modificación debe ser evaluada, eso demanda bastante tiempo computacional.

## BIBLIOGRAFÍA

- [1] Oscar Barboza. “Automatización de despacho horario de potencia eléctrica en el sistema interconectado nacional del Paraguay”, 2014.
- [2] Salah Bouktif, Ali Fiaz, Ali Ouni, and Mohamed Adel Serhani. “Optimal deep learning lstm model for electric load forecasting using feature selection and genetic algorithm: Comparison with machine learning approaches”. *Energies*, 11(7):1636, 2018.
- [3] George EP Box and David R Cox. “An analysis of transformations”. *Journal of the Royal Statistical Society: Series B (Methodological)*, 26(2):211–243, 1964.
- [4] Nikhil Buduma and Nicholas Locascio. *Fundamentals of deep learning: Designing next-generation machine intelligence algorithms*. O’Reilly Media, Inc., 2017.
- [5] Manchado Cabezon. “Predicción demanda eléctrica española implementación de redes neuronales recurrentes en python”. 2018.
- [6] Varun Chandola, Arindam Banerjee, and Vipin Kumar. “Anomaly detection: A survey”. *ACM Comput. Surv.*, 41(3), July 2009.

**XIV SEMINARIO DEL SECTOR ELECTRICO PARAGUAYO - CIGRE**  
**23 y 24 de Junio 2022**

- 
- [7] Chris Chatfield. *The analysis of time series: an introduction*. Chapman and Hall/CRC, 2003.
- [8] Yao Cheng, Chang Xu, Daisuke Mashima, Vrizlynn LL Thing, and Yongdong Wu. “Powerlstm: power demand forecasting using long, short term memory neural network”. In *International Conference on Advanced Data Mining and Applications*, pages 727–740. Springer, 2017.
- [9] Robert B Cleveland, William S Cleveland, Jean E McRae, and Irma Terpenning. “Stl: A seasonal-trend decomposition. *Journal of official statistics*”, 6(1):3–73, 1990.
- [10] J. L. Elman. Finding structure in time. *Cognitive Science*, 14:213–252, 1990.
- [11] Felix-Antoine Fortin, Francois-Michel De Rainville, Marc-Andre Gard-ner, Marc Parizeau, and Christian Gagne. “DEAP: Evolutionary algorithms made easy”. *Journal of Machine Learning Research*, 13:2171–2175, jul 2012.
- [12] Aurelien Geron. *Hands-on machine learning with Scikit-Learn, Keras, and TensorFlow: Concepts, tools, and techniques to build intelligent systems*. O’Reilly Media, 2019.
- [13] Maria Pilar Gonzalez Casimiro. *Análisis de series temporales: Modelos Arima*. 2009.
- [14] Jordan Hochenbaum, Owen S Vallis, and Arun Kejariwal. “Automatic anomaly detection in the cloud via statistical learning”. *arXiv preprint arXiv:1704.07706*, 2017.
- [15] Sepp Hochreiter and Jurgen Schmidhuber. “Long short-term memory”. *Neural Computation*, 9(8):1735–1780, 1997.
- [16] Chi hsiang Wang, George Grozev, and Seongwon Seo. “Decomposition and statistical analysis for regional electricity demand forecasting”. *Energy*, 41(1):313–325, 2012. 23rd International Conference on Efficiency, Cost, Optimization, Simulation and Environmental Impact of Energy Systems, ECOS 2010.
- [17] Xiao-Bing Hu, Mark Leeson, and Evor Hines. “Dynamic network coding problem: an evolutionary approach”. In *2009 5th International Conference on Wireless Communications, Networking and Mobile Computing*, pages 1–8. IEEE, 2009.
- [18] Pedro Isasi and Ines Galván. *Redes de neuronas artificiales: un enfoque práctico*. Madrid. España, Pearson Educación, SA , 2004.
- [19] Diederik P. Kingma and Jimmy Ba. “Adam: A method for stochastic optimization” In Yoshua Bengio and Yann LeCun, editors, *3rd International Conference on Learning Representations, ICLR 2015, San Diego, CA, USA, May 7-9, 2015, Conference Track Proceedings*, 2015.
- [20] Corentin Kuster, Yacine Rezgui, and Monjur Mourshed. “Electrical load forecasting models: A critical systematic review. *Sustainable cities and society*, 35:257–270, 2017.
- [21] Elena Mocanu, Phuong H. Nguyen, Madeleine Gibescu, and Wil L. Kling. “Deep learning for estimating building energy consumption” *Sustainable Energy, Grids and Networks*, 6:91–99, 2016.
- [22] Isaac Kofi Nti, Moses Teimeh, Owusu Nyarko-Boateng, and Adebayo Felix Adekoya. “Electricity load forecasting: a systematic review”. *Journal of Electrical Systems and Information Technology*, 7(1):13, Sep 2020.
- [23] Nils Reimers and Iryna Gurevych. “Optimal hyperparameters for deep lstm-networks for sequence labeling tasks”. *arXiv preprint arXiv:1707.06799*, 2017.
- [24] Bernard Rosner. “Percentage points for a generalized esd many-outlier procedure. *Technometrics*, 25(2):165–172, 1983.
- [25] Robert G Steadman. “A universal scale of apparent temperature”. *Journal of Climate and Applied Meteorology*, 23(12):1674–1687, 1984.
- [26] Owen Vallis, Jordan Hochenbaum, and Arun Kejariwal. “A novel technique for long-term anomaly detection in the cloud”. In *6th {USENIX} workshop on hot topics in cloud computing (HotCloud 14)*, 2014.
- [27] Neo Wu, Bradley Green, Xue Ben, and Shawn O’Banion. “Deep transformer models for time series forecasting: The influenza prevalence case”, 2020.