

Predicción de Consumo Energético en Edificios Universitarios usando la aplicación Regression Learner de MATLAB

Predicting Energy Consumption in University Buildings Using the Regression Learner App in MATLAB

**Kenneth Wladimir Masabanda Macay, Edison Daniel Segovia Muñoz, Erick José Alcivar
Villamarin, Washington Xavier García Quilachamin**

¹ Universidad Laica Eloy Alfaro de Manabí, Manta, Ecuador, e1317060109@uleam.edu.ec

² Universidad Laica Eloy Alfaro de Manabí, Manta, Ecuador, edisson.segovia@uleam.edu.ec

³ Universidad Laica Eloy Alfaro de Manabí, Manta, Ecuador, erick.alcivar@uleam.edu.ec

⁴ Universidad Laica Eloy Alfaro de Manabí, Manta, Ecuador, washington.garcia@uleam.edu.ec

DOI: <https://doi.org/10.61236/ciya.v10i1.1240>

Recibido: 24 de octubre de 2025 • Revisión aceptada: 28 de diciembre de 2025

Resumen

En este proyecto se analiza la predicción del consumo de potencia eléctrica en tres edificios de la Universidad Laica Eloy Alfaro de Manabí, utilizando la herramienta Regression Learner de MATLAB. La primera fase contempla una revisión de los conceptos clave relacionados con el consumo energético y la importancia de los modelos predictivos para la gestión de la demanda en infraestructuras universitarias. Posteriormente, se recopilaron datos de consumo eléctrico provenientes de tres edificaciones académicas, correspondientes a un período de 10 meses del año 2022, con el objetivo de realizar un análisis detallado del comportamiento energético de cada una. En la fase de modelado, se emplearon algoritmos de regresión disponibles en MATLAB para analizar y predecir las curvas de demanda eléctrica, tomando como variables factores como la hora del día y las condiciones climáticas. Además, se desarrolló una interfaz interactiva mediante App Designer, que permite al usuario obtener predicciones personalizadas de potencia y corriente, según la facultad y la fecha seleccionadas. Finalmente, se presentan las conclusiones del estudio y los resultados obtenidos, los cuales permiten evaluar el

desempeño del modelo y su utilidad como herramienta para mejorar la eficiencia energética y optimizar la planificación del consumo eléctrico futuro.

Palabras claves: *Predicción, consumo de potencia eléctrica, edificios académicos, modelos predictivos, gestión de la demanda, algoritmos de regresión.*

Abstract

This project analyzes the prediction of electric power consumption in three buildings of the Universidad Laica Eloy Alfaro de Manabí using MATLAB's Regression Learner tool. The first phase includes a review of key concepts related to energy consumption and the importance of predictive models for demand management in university infrastructures. Subsequently, electric consumption data were collected from three academic buildings over a 10-month period during the year 2022, with the aim of conducting a detailed analysis of each building's energy behavior. In the modeling phase, regression algorithms available in MATLAB were used to analyze and forecast electric demand curves, considering variables such as time of day and weather conditions. Additionally, an interactive interface was developed using App Designer, allowing users to obtain customized predictions of power and current based on the selected faculty and date. Finally, the study presents its conclusions and the results obtained, which make it possible to evaluate the model's performance and its effectiveness as a tool to improve energy efficiency and optimize future electricity consumption planning.

Keywords: *Prediction, electrical power consumption, academic buildings, predictive models, demand management, regression algorithms.*

1. INTRODUCCIÓN

“Actualmente, debido al creciente consumo energético, se están logrando avances importantes en la reducción y optimización del uso de la energía, especialmente en edificios. Sin embargo, el aumento constante del consumo y la alta dependencia de combustibles fósiles han contribuido al cambio climático, que continúa siendo una de las principales problemáticas ambientales a nivel global. En este contexto, la protección del medio ambiente y el ahorro energético se consideran cuestiones clave en la actualidad”[1].

No obstante, predecir el consumo energético en un plantel educativo resulta complejo, debido a la influencia de múltiples factores, tales como el movimiento de los ocupantes entre habitaciones y áreas comunes, la cantidad y distribución de ventanas, la diversidad en el tipo de espacios, y el uso intensivo de sistemas de aire acondicionado durante el día. Como señala Hernández, “en la actualidad, no existe un método definitivo para predecir el consumo energético en un plantel, ya que este puede variar debido a varios factores, como el desplazamiento de los ocupantes entre las habitaciones y las áreas comunes, la cantidad de ventanas, la diversidad de las habitaciones y el alto uso del sistema de aire acondicionado a lo largo del día” [2].

Para abordar este desafío, se inició con una revisión exhaustiva de los métodos estadísticos empleados en el pronóstico y análisis del consumo energético. Uyaguari y Esteban explican que “se segmentaron los datos por franjas horarias y se realizó un análisis estadístico y los valores máximos y mínimos, entre otros. Además, se agruparon los datos en perfiles de consumo similares entre los días utilizando la distancia” [3].

El presente estudio emplea MATLAB como herramienta principal, específicamente la aplicación Regression Learner, que facilita la creación, ajuste y validación de modelos predictivos basados en técnicas de regresión, tales como regresión lineal, regresión polinómica y máquinas de soporte vectorial, entre otros. Según Uyaguari y Esteban, “se aplicaron diversos métodos de pronóstico mediante un programa desarrollado en el software MATLAB. Finalmente, se estableció una metodología para evaluar los errores de los pronósticos, con el fin de identificar los métodos más adecuados para cada conjunto de datos” [3].

Objetivos

El presente análisis tiene como objetivo optimizar la gestión energética, identificar patrones en el consumo y prever las necesidades futuras de energía. Esto permitirá una toma de decisiones más informada y apoyará la implementación de

estrategias de eficiencia energética en los edificios universitarios.

Mediante el uso de algoritmos de regresión en MATLAB, se modelarán las curvas de demanda de potencia eléctrica, considerando variables como la hora del día, la temporada del año y las condiciones climáticas. Esto facilitará la previsión del consumo energético en los próximos meses, contribuyendo a una mejor planificación del uso de la electricidad.

A través de estos modelos predictivos, se busca no solo mejorar la eficiencia en el consumo, sino también contribuir a la sostenibilidad energética de la universidad. Así, el proyecto se presenta como una herramienta para optimizar el consumo energético y favorecer la gestión responsable y sostenible de los recursos dentro de la institución.

2. METODOLOGÍA

La metodología empleada en este estudio se desarrolló en varias etapas: recopilación de datos, procesamiento, análisis estadístico y creación de modelos predictivos mediante la herramienta *Regression Learner* de MATLAB.

En primer lugar, se recopiló una base de datos correspondiente al consumo energético de tres edificios universitarios durante un período de 10 meses del año 2022. Estos datos incluían información horaria del consumo eléctrico, además

de variables complementarias como la temperatura ambiental, el día del año y la hora del día. Posteriormente, se llevó a cabo un proceso de limpieza y estructuración de los datos, eliminando valores atípicos y corrigiendo registros incompletos.

Durante la fase de modelado, se evaluaron distintos algoritmos de regresión disponibles en MATLAB, entre ellos la regresión lineal, la regresión polinómica, máquinas de soporte vectorial (*Support Vector Machines*, SVM) y, de manera destacada, el modelo *Regression Ensemble: Bagged Trees*. Este último mostró un desempeño superior en términos de precisión y generalización, gracias a su capacidad para combinar múltiples árboles de decisión y reducir el sobreajuste (*overfitting*).

La precisión de cada modelo fue evaluada mediante métricas como el error cuadrático medio (RMSE) y el coeficiente de determinación (R^2). Asimismo, se utilizó validación cruzada (*k-fold cross-validation*) para garantizar la robustez del entrenamiento y evitar sesgos en los resultados. Finalmente, se optimizaron los hiperparámetros de los modelos seleccionados, especialmente en el caso del *ensemble*, lo que permitió mejorar la capacidad predictiva del sistema.

Como complemento, se desarrolló una interfaz interactiva utilizando App Designer, permitiendo a

los usuarios realizar predicciones de consumo energético específicas por facultad y fecha, a partir del modelo más eficiente identificado: Regression Ensemble (Bagged Trees).

3.1.1. Desarrollo del modelo predictivo basado en regresión ensemble (Bagged Trees)

Los árboles de decisión son modelos populares por su interpretabilidad y flexibilidad, pero presentan desventajas como el sobreajuste y la alta varianza. Según Hastie et al., “un solo árbol de decisión puede ser propenso al sobreajuste (*overfitting*) y a una alta varianza, lo que significa que su rendimiento puede ser inconsistente con datos nuevos y no vistos” [4].

Para abordar esta limitación, se utiliza el método de *Bagging*, propuesto por Breiman, que “implica seleccionar muestras aleatorias con reemplazo del conjunto de datos”, entrenar múltiples modelos base y luego combinar sus predicciones [2]. Cuando se aplica este enfoque con árboles de decisión, se obtiene el modelo conocido como *Bagged Trees* o *Random Forest*, el cual “reduce la varianza sin aumentar significativamente el sesgo del modelo” [5].

Imagina que estás intentando predecir el consumo eléctrico de un edificio en función de la hora del día y la temperatura. Supongamos que haces esto usando un solo árbol de decisión.

Ese árbol puede aprender, por ejemplo, que:

- "Si la temperatura es mayor a 30 °C y son las 14:00, el consumo es alto."
- "Si la temperatura es menor a 20 °C y son las 7:00, el consumo es bajo."

El problema es que ese árbol se ajusta demasiado a los datos exactos que vio en el entrenamiento. Si luego le das nuevos datos que son ligeramente diferentes, como 29.9 °C a las 13:55, podría fallar porque no generaliza bien. Esto es lo que se llama alta varianza.

Por eso esta técnica resulta especialmente útil para tareas de predicción como el consumo energético, ya que permite capturar relaciones no lineales entre variables como la hora del día, la temperatura y el uso de los edificios. Así, se logra una predicción más precisa y robusta frente a datos no vistos.

3.1.2 Formalización del modelo Bagged Trees

Supongamos que tienes un conjunto de entrenamiento con n datos:

$$D = \{(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)\} \quad (1)$$

donde x_i es el vector de características (por ejemplo, temperatura, hora) y y_i el valor a predecir (consumo eléctrico).

Se generan B subconjuntos de datos de entrenamiento, cada uno con n muestras tomadas con reemplazo:

$$D1^*, D2^*, \dots, DB^* \quad (2)$$

Para cada muestra D_B^* , se entrena un árbol de decisión $h_B(x)$, que da una predicción para cualquier entrada x .

La predicción final del ensemble para una entrada x es el promedio de las predicciones individuales:

$$\hat{f}(x) = \frac{1}{B} \sum_{b=1}^B h_B(x) \quad (3)$$

Esta fórmula significa que para predecir el consumo energético en un instante x , calculamos la predicción de cada árbol y luego las promediamos.

En términos sencillos, se puede comparar un único árbol de decisión con la opinión de una sola persona, la cual puede ser acertada o equivocada. En cambio, el método Bagged Trees funciona como consultar a un grupo de 100 expertos independientes y promediar sus respuestas; de esta forma, las opiniones extremas se equilibran, resultando en una predicción más fiable y estable.

3.2.3. Análisis Temporal del Comportamiento Energético y su Relación con la Temperatura

"La clave para entender el uso de electricidad en campus universitarios reside en examinar las fluctuaciones temporales de la demanda de potencia y su vínculo con variables ambientales, como la temperatura" [6].

Para comprender mejor el consumo eléctrico en los edificios universitarios, es fundamental analizar cómo varía la demanda de potencia a lo largo del tiempo y cómo esta se relaciona con factores externos, como la temperatura ambiente. A través de gráficas semanales y mensuales, se pueden identificar patrones de comportamiento energético, detectar posibles anomalías y evaluar la influencia del clima en el uso de la energía. Este análisis visual permite no solo interpretar el historial de consumo, sino también proporcionar una base sólida para modelos predictivos y estrategias de eficiencia energética.

A continuación, presentamos la gráfica que muestra la evolución del consumo de potencia eléctrica en la Facultad de Administración de Empresas durante un período de 10 meses. En esta gráfica se representa el promedio semanal de la demanda energética, lo que permite observar con mayor detalle las fluctuaciones y tendencias en el consumo a lo largo del tiempo. Este análisis facilita la identificación de picos y valles en la demanda, información clave para optimizar la gestión energética y diseñar estrategias de eficiencia adecuadas para la facultad.




Figura 1. El análisis de la "Potencia Promedio Semanal" revela una marcada variabilidad en el consumo eléctrico de la facultad de Administración de Empresas a lo largo del periodo de Mayo 2022 a Febrero 2023.

Se observan picos de alta demanda, superando los 10 kW en semanas específicas como Mayo, Septiembre y Enero, mientras que en otros momentos, como finales de Julio (semana del 31) y finales de Octubre (semana del 23), el consumo desciende drásticamente, acercándose a 0 kW.

Valles de bajo consumo: Existen caídas drásticas en el consumo. Lo más notorio son dos períodos donde la potencia se acerca a 0 kW: uno alrededor de la semana del 1 de agosto de 2022 y otro cerca de la semana del 1 de noviembre de 2022. Estos sugieren momentos de inactividad casi total en la facultad.

Fluctuaciones continuas: Fuera de los picos y valles extremos, el consumo fluctúa

constantemente de una semana a otra, mostrando un patrón irregular con ascensos y descensos intermitentes, lo que podría reflejar la dinámica semanal de actividades académicas y administrativas.

La siguiente imagen muestra el gráfico de "Temperatura Promedio Semanal de la Facultad de Administración de Empresas" en grados Celsius (°C), registrado semana a semana desde principios de mayo de 2022 hasta principios de febrero de 2023.




Figura 2. Ilustra un patrón estacional distintivo de la temperatura ambiente en la ubicación de la facultad.

Las observaciones clave de este gráfico, incluyendo las etiquetas de datos, son:

- Rango de Temperaturas: La temperatura promedio semanal oscila desde un mínimo cercano a los 21.7°C (observado alrededor del 15 de mayo) hasta un máximo de

aproximadamente 27.26°C (observado el 01 de enero de 2023).

- Período Inicial (Mayo a Octubre):
 - Durante los meses de mayo a octubre, la temperatura se mantiene en un rango generalmente más bajo y con fluctuaciones menos pronunciadas. Por ejemplo, el 22 de mayo de 2022, la temperatura fue de 23.37°C.
 - Hay un ligero pico alrededor del 31 de julio de 2022 (23.74°C), seguido de un descenso.
 - A finales de agosto (28 de agosto de 2022), la temperatura registra un valor de 21.80°C, y se mantiene relativamente baja o fluctuante alrededor de los 22°C a 23°C hasta principios de noviembre (23.98°C el 06 de noviembre de 2022).
- Período de Ascenso (Noviembre a Febrero):
 - A partir de principios de noviembre, el gráfico muestra un ascenso claro, constante y significativo de la temperatura.

- Este ascenso lleva a la temperatura a sus valores más altos del período registrado. Por ejemplo, el 04 de diciembre de 2022, la temperatura es de 25.70°C, y continúa subiendo hasta alcanzar el pico de 27.26°C el 01 de enero de 2023, manteniéndose en valores elevados hasta febrero.

La siguiente imagen presenta un gráfico combinado que ilustra la Potencia Promedio Semanal (kW) y la Temperatura Promedio Semanal (°C) de la Facultad de Administración de Empresas, desde principios de mayo de 2022 hasta principios de febrero de 2023. Ambas variables se muestran con sus valores exactos en puntos clave a lo largo del tiempo.




Figura 3.- Relación entre Potencia y Temperatura (Análisis Combinado): La imagen revela una relación dual entre el consumo de potencia y la temperatura.

- Períodos de baja ocupación/actividad: Los valles de potencia cercanos a 0 kW (como el 31 de julio y el 23 de octubre) no se correlacionan directamente con una baja de temperatura. Esto sugiere que estos descensos extremos en el consumo están más relacionados con períodos de inactividad académica (vacaciones, feriados largos), donde el edificio está mayormente desocupado, independientemente de la temperatura ambiente.
- Períodos de alta temperatura y consumo: A partir de noviembre, cuando la temperatura comienza su ascenso constante hacia valores más altos, se observa una correlación positiva más clara con el consumo de potencia. Los picos de potencia en diciembre y enero coinciden con las temperaturas más elevadas, lo que indica que el uso de sistemas de climatización (como el aire acondicionado) se convierte en un factor significativo del consumo energético durante los meses más cálidos.

En síntesis, este gráfico combinado con etiquetas es fundamental para entender cómo el consumo energético de la facultad es una función de la ocupación del edificio (ligada al calendario académico) y la demanda de climatización

(impulsada por la temperatura ambiente), con cada factor predominando en diferentes momentos del año.

3.2.4 Tabulación de Datos

Se llevó a cabo la tabulación de los datos correspondientes a un período de diez meses durante el año 2022, en el cual se registraron mediciones de potencia eléctrica (kW) y temperatura ambiental (°C). Los datos fueron organizados en una estructura tipo tabla con tres columnas principales: Tiempo, Potencia y Temperatura, permitiendo así una lectura cronológica precisa de cada registro. El formato utilizado incluyó el registro horario de las mediciones (por ejemplo: 17/05/2022 14:30) acompañado por los valores correspondientes de potencia y temperatura. Esta organización detallada facilitó el análisis temporal del comportamiento energético, permitiendo observar variaciones dentro del día, entre días y entre semanas.

A modo de ejemplo, la tabla a continuación muestra una sección de los datos recolectados durante el mes de mayo de 2022, donde se observa que las mediciones se realizaron a intervalos regulares de 15 minutos. En cada registro se consignaron los valores correspondientes de tiempo, potencia eléctrica (kW) y temperatura ambiente (°C), lo cual permitió una lectura

cronológica detallada y precisa para el análisis energético:

Tabla 1. Registro de Potencia Eléctrica y Temperatura con Intervalos de 15 Minutos (Ejemplo de Mayo de 2022).

Tiempo	Potencia (kW)	Temperatura (°C)
17/05/2022 14:30	27,40	32,23
17/05/2022 14:45	27,67	27,92
17/05/2022 15:00	31,40	28,49
17/05/2022 15:15	29,33	26,61
17/05/2022 15:30	29,75	25,25
17/05/2022 15:45	31,77	25,82

3.2.5. Introducción de datos a Matlab (Regression Learner).

“El Regression Learner facilita la creación de modelos predictivos sin necesidad de escribir código, permitiendo al usuario seleccionar el modelo que mejor se ajusta a sus datos a través de un proceso guiado. Además, la aplicación permite realizar la validación cruzada para garantizar que el modelo generalice bien en nuevos datos. Los resultados y modelos entrenados pueden ser exportados a MATLAB para su uso en otros análisis o para su integración en aplicaciones más complejas” [7].

Hemos tabulado los datos de manera separada por facultad, con el objetivo de contar con tres modelos independientes en Regression Learner. De esta forma, cada facultad tiene su propio conjunto de datos, lo que nos permitirá analizar y predecir el consumo energético de cada una por separado, aplicando técnicas de aprendizaje automático

2.2.6 Selección de Variables Dependientes e Independientes

Al utilizar el Regression Learner, tenemos la opción de seleccionar qué variables incluir, como el día, la hora, el mes y el año. De esta manera, podemos decidir cuántas variables dependientes e independientes se utilizarán en el modelo, lo que nos permite ajustar el análisis según nuestras necesidades.

“Mediante su interfaz, los usuarios tienen la posibilidad de cargar conjuntos de datos, seleccionar las variables a utilizar, escoger entre distintos algoritmos de regresión (como regresión lineal, árboles de decisión, redes neuronales, etc.) y ajustar los parámetros del modelo. Además, la aplicación proporciona herramientas para evaluar el desempeño del modelo utilizando métricas como el error cuadrático medio (RMSE) y el coeficiente de determinación (R^2)”[8].

Predictors			
	Name	Type	Range
☒	Fecha	char	251 unique
☒	Hora	char	723 unique
☐	Potencia	double	0 .. 35.23
☒	Temperatura	double	17.11 .. 39.01

Figura 4.- La imagen es una ventana de interfaz de MATLAB que muestra la configuración para seleccionar variables de un conjunto de datos.

Una vez que hemos seleccionado nuestras variables dependientes e independientes, el siguiente paso es elegir el tipo de regresión y entrenar el modelo. Probaríamos todos los modelos posibles, y se espera que la métrica esté por debajo de un RMSE de 1.4. Sin embargo, los mejores resultados que obtuvimos fueron de RMSE de 2.24. Aunque no son las métricas ideales, se consideran bastante buenas, ya que todo depende de las variables utilizadas en el modelo.

3.2.7 ¿Qué significa un RMSE de 2.2463?

"El RMSE (por sus siglas en inglés, Root Mean Squared Error, o Error Cuadrático Medio Raíz) es una medida que te dice, en promedio, cuánto se equivocan las predicciones de tu modelo respecto a los valores reales. Es como un promedio de esos

errores, pero con un detalle importante: le da más peso a los errores grandes." [9, 10].

Su fórmula es:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (4)$$

Donde

- y_i = valor real (observado)
- $\hat{y}_i$ = valor predicho en el modelo
- n = numero total de observaciones




Figura 5.- Rendimiento de un modelo Ensemble (Bagged Trees), indicando un RMSE (Validation) de 2.2463.

El modelo de regresión empleado arrojó un error cuadrático medio (RMSE) de 2.24, lo que evidencia un buen ajuste entre los valores predichos y los datos reales observados. Esta métrica, ampliamente utilizada para evaluar modelos de predicción. En este caso, un RMSE de 2.24 indica que, en promedio, la diferencia entre los valores estimados por el modelo y los valores reales se mantiene dentro de un margen reducido, lo cual refleja un nivel de precisión aceptable para fines de análisis y planificación

3.2.8 Precisión del Modelo: Cálculo e Interpretación del RMSE

Para calcular el porcentaje de error relativo del RMSE, usamos esta fórmula:

$$\text{Error \%} = \frac{RMSE}{\text{Valor_Medio_Real}} \times 100 \quad (5)$$

Entonces, necesitamos saber el valor medio (promedio) del consumo de potencia real en la base de datos. Supongamos que el consumo promedio en tu base de datos es 30 kW (típico en muchos edificios académicos).

$$\text{Error \%} = \frac{2.24}{30} \times 100 = 7.46 \%$$

Un RMSE de 2.91 equivale a un error promedio de aproximadamente el 9.7 % respecto al valor medio de consumo real (30 kW).

- Si el promedio es 50 kW:

$$\text{Error \%} = \frac{2.24}{50} \times 100 = 4.48 \%$$

Cuanto mayor sea el promedio de tu consumo real, menor será el porcentaje de error relativo de ese RMSE.

3.2.9 Resultados obtenidos en Regression Learner

El análisis se realizó con base en los datos recolectados durante un período de 10 meses, lo que permitió una visión más completa del comportamiento del consumo energético en la

facultad. Entre los distintos algoritmos de regresión evaluados, el modelo que mostró el mejor desempeño fue el Ensemble tipo Bagged Trees, el cual presentó un menor error de predicción en comparación con otros métodos como la regresión lineal o polinómica. Esta capacidad para reducir la varianza y aumentar la estabilidad del modelo lo convierte en una opción más confiable para realizar estimaciones precisas en este contexto.

En la gráfica que acompaña esta sección, el eje X representa la cantidad de registros recolectados en intervalos de 15 minutos a lo largo de los 10 meses, mientras que el eje Y muestra la potencia eléctrica promedio registrada en cada medición, expresada en kilovatios (kW). Esta representación permite visualizar de manera clara cómo varía la demanda energética en el tiempo y refuerza la utilidad del modelo elegido para anticipar comportamientos de consumo.




Figura 6. Los puntos azules indican los valores reales de potencia eléctrica medidos, mientras que

los puntos amarillos reflejan los valores predichos por el modelo de regresión.

3.2.10 Interfaz Interactiva (App Designer)

Aunque el proceso completo para llegar al resultado es muy educativo y permite un buen aprendizaje, puede ser algo complicado y poco práctico de utilizar. Por eso, se propone desarrollar una interfaz más amigable para el usuario, que elimine la necesidad de ingresar la fecha mediante comandos. Además, esta interfaz permitirá cargar los tres modelos de manera automática, en lugar de tener que cargar uno por uno.

Hemos creado una interfaz interactiva utilizando App Designer para facilitar la interacción con el usuario. Esta interfaz permite que cualquier persona pueda ingresar los datos necesarios y obtener de manera rápida y sencilla la predicción de la potencia consumida en base a los modelos de pronóstico aplicados. A través de esta herramienta, el usuario puede visualizar de forma clara los resultados esperados, lo que permite un mejor control y comprensión del consumo energético futuro. La interfaz está diseñada para ser intuitiva, brindando una experiencia de uso amigable y eficiente.

Los usuarios tienen la opción de seleccionar el tipo de facultad para la cual desean realizar la predicción. Además, pueden ingresar la fecha deseada para obtener los resultados de la predicción

tanto de corriente como de potencia consumida. Esta funcionalidad permite a los usuarios personalizar su consulta, proporcionando una herramienta flexible y precisa para anticipar el comportamiento energético de las facultades en un período específico. De esta manera, la interfaz facilita la toma de decisiones informadas basadas en predicciones detalladas y actualizadas.

3.2.11 Creación de Código en Appdesigner en Matlab

A diferencia de la predicción en la ventana de comandos la redacción del código no es tan compleja como en el editor de MATLAB, ya que App Designer es una aplicación que simplifica ciertas tareas. La siguiente imagen muestra el código que se tuvo que implementar, ya que la aplicación se encarga de gestionar otros aspectos, como la posición de los diálogos o las variables de entrada y salida. Así, nosotros somos quienes decidimos cómo manejar esas variables.

La diferencia es que cargamos todos los modelos y utilizamos un if para determinar cuál modelo se debe cargar, dependiendo de la facultad seleccionada, además de eso también se carga la predicción en la misma sección. Después de este bloque if, realizamos la operación matemática utilizando la fórmula descrita en capítulos anteriores para calcular la corriente. Esto se debe a que, al poder predecir la potencia, también podemos predecir la corriente.

Luego, utilizando los comandos propios de App Designer, especificamos en qué parte de la interfaz queremos mostrar los resultados y qué información queremos que se visualice en la pantalla. Esto nos permite personalizar la presentación de los datos de manera más interactiva y organizada dentro de la aplicación.

El código que hemos mencionado se coloca en lo que se conoce como callback en AppDesigner. Un callback es una función o bloque de código que se ejecuta solo cuando se activa una acción específica, como un clic en un botón o la selección de una opción. En otras palabras, las operaciones o ejecuciones de código ocurren solo cuando el usuario interactúa con algún componente de la interfaz, lo que permite un control más dinámico de las operaciones.

Como dato adicional sobre esta aplicación desarrollada en App Designer, es importante mencionar que los elementos de entrada, los diálogos de texto, las fuentes de letras e incluso las imágenes también requieren una programación detrás para su funcionamiento. Sin embargo, lo que hace que App Designer sea una de las mejores herramientas es que esta programación es generada automáticamente por la aplicación, facilitando enormemente el desarrollo.

Esta característica es una de las razones principales por las que se escogió App Designer en lugar de GUIDE. Aunque GUIDE es también una herramienta muy completa, su uso es más complejo y requiere mayor intervención manual para implementar cada funcionalidad.

3.2.12 Presentación Final de la Interfaz.

A continuación, se presenta la interfaz finalizada, lista para ser utilizada por el usuario. Esta interfaz incluye toda la información necesaria y las opciones adecuadas para que el usuario pueda interactuar con la aplicación de manera eficiente y obtener los resultados deseados.

Uleam
UNIVERSIDAD LAICA
ELOY ALFARO DE MANABI

Predicción de Consumo Energético en Facultades
"Hola, esta aplicación predice el consumo de potencia eléctrica para diferentes facultades de la universidad en función de la fecha, la hora y los minutos".

Elija la Facultad que desea Predecir

- ☒ Facultad de Ingeniería Naval
- ☐ Facultad de Administración de Empresas
- ☐ Facultad de Ciencias de la Educación

DIA: 10 MES: 10 HORA: 12 MINUTOS: 10

Formulas de Corriente y de Potencia

$$P = \sqrt{3} \cdot I \cdot V \cdot \cos\theta$$

$$I = P / (\sqrt{3} \cdot V \cdot \cos\theta)$$

Calcular

La Potencia Calculada es 10.75 Kw

La Corriente Calculada es 28.74 Amp

Es importante recordar que una predicción se refiere a un evento que aún no ha ocurrido.
Obtener una predicción al 100% es muy complejo de hacer, ya que ningún sistema actúa de manera completamente ideal.
Lo que podemos lograr es una aproximación lo más precisa posible de dicho evento.

Est: Kenneth Masabanda Macay
Doc: Washington Xavier García Quiachamin
Asignatura: Programación Aplicada a la Ingeniería
Universidad Laica Eloy Alfaro de Manabí

Figura 7. Aplicación de predicción del consumo de energía.

Es importante destacar que el modelo actual se diseñó en base a los datos recolectados de tres edificios. Si en algún momento se desea ampliar la cantidad de edificios, lo único que se necesitaría sería recolectar más datos para incluirlos en el modelo.

Además, un punto clave a recordar es que, cuanto mayor sea la cantidad de datos recolectados, mayor será la precisión de la predicción. Esto se debe a que, con más datos, la regresión y los algoritmos de toma de decisiones pueden ajustarse mejor, mejorando así la capacidad de hacer predicciones más exactas.

3.2.13 Análisis de Resultados

Estos datos fueron recopilados durante un período específico, abarcando los meses de mayo, junio y julio, y se clasificaron según diferentes criterios, como el día de la semana y las horas laborales. A partir de estos datos, se realizaron procesos de tabulación y preprocesamiento para convertir las unidades y hacerlas aptas para su análisis. Además, se aplicaron técnicas de ingeniería de características, como la separación de fechas y horas en componentes individuales, lo que permitió mejorar la precisión de los modelos predictivos desarrollados.

Estos datos fueron esenciales para llevar a cabo el análisis de regresión y obtener las métricas que nos

permitieron evaluar el rendimiento del sistema eléctrico estudiado. Las gráficas presentadas con anterioridad nos dan una comparación visual entre los valores reales de una variable objetivo (que en este caso se denomina "Potencia") y las predicciones realizadas por un modelo de regresión específico, el modelo Regresión de Árbol de Decisión.

Esto nos indica que este modelo no solo funciona correctamente, sino que también tiene un buen rendimiento, lo que lo hace versátil para diversas aplicaciones más allá de calcular la potencia eléctrica de un edificio. Entre las posibles utilidades adicionales, podríamos mencionar:

- Gestión de energía en sistemas industriales: Predecir el consumo energético de máquinas y equipos para optimizar su funcionamiento y reducir costos.
- Monitoreo en tiempo real: Implementar sistemas para anticipar fallos en la red eléctrica de instalaciones, mejorando la eficiencia y la seguridad.
- Estimaciones de consumo eléctrico residencial: Predecir el gasto energético de hogares en

función de patrones históricos y condiciones específicas.

- Optimización en proyectos de energía renovable: Utilizar el modelo para estimar la potencia generada por paneles solares o turbinas eólicas en distintas condiciones climáticas.
- Predicción de demanda eléctrica: Ayudar a las compañías eléctricas a anticipar la demanda y ajustar su distribución de energía eficientemente.
- Simulación y planeación: Aplicar el modelo para estudiar escenarios hipotéticos, como la construcción de nuevos edificios, para predecir el impacto energético en la red.

4. CONCLUSIONES

En conclusión, el análisis llevado a cabo mediante el modelo de regresión ha demostrado ser una herramienta eficaz para predecir la potencia en los diferentes tipos de edificios en función de variables temporales como la fecha y la hora.

A través de la selección adecuada de variables dependientes e independientes, así como la

aplicación de técnicas de ingeniería de características, se logró obtener un modelo capaz de ofrecer estimaciones útiles sobre el comportamiento energético del edificio. Aunque las métricas obtenidas no alcanzaron el valor ideal esperado, con un rendimiento óptimo debajo de 1.4, los resultados obtenidos (con una métrica de 2.2) aún se consideran satisfactorios y suficientemente precisos para la toma de decisiones.

Estos resultados no solo proporcionan una visión detallada del consumo de potencia, sino que también permiten realizar proyecciones sobre el comportamiento futuro del sistema energético en el edificio. Esto es crucial para la planificación de estrategias de optimización y reducción de costos energéticos.

Además, el modelo puede ser ajustado y mejorado en futuras iteraciones al incorporar más datos o probar otros algoritmos de regresión, lo que contribuiría a afinar las predicciones y aumentar su precisión. En general, este estudio subraya la importancia de utilizar métodos de análisis de datos y aprendizaje automático para gestionar de manera más eficiente los recursos energéticos en entornos como edificios de oficinas, industriales o residenciales.

La capacidad de prever el consumo futuro de energía no solo ayuda a optimizar el uso de la

electricidad, sino que también puede tener un impacto positivo en la sostenibilidad y en la reducción de la huella de carbono del edificio.

5. BIBLIOGRAFÍA

[1] J. A. E. García Álvarez, Potencia Eléctrica. 2018.

[2] M. Ilbeigi, M. Ghomeishi, y Dehghanbanadaki, "Electric load forecasting: Literature survey and classification of methods," 2020.

[3] J. E. Hanke y D. W. Wichern, Business Forecasting, 9ª ed., Pearson International Edition. Prentice Hall, 2009.

[4] N. J. A. Hernández, "Estudio del consumo energético en instalaciones universitarias", 2021.

[5] T. Hastie, R. Tibshirani y J. Friedman, The Elements of Statistical Learning: Data Mining, Inference, and Prediction, 2ª ed. Springer, 2009.

[6] L. Breiman, "Bagging predictors", Machine Learning, vol. 24, no. 2, pp. 123–140, 1996.

[7] M. Paluszczek y S. Thomas, MATLAB Machine Learning: A Guided Tour to Machine Learning Using MATLAB. Apress, 2022.

[8] O. Marques, A Guided Tour to Machine Learning Using MATLAB, 2021.

[9] DataCamp. "RMSE Explained: A Guide to Regression Prediction Accuracy". 2022. Fecha de consulta: 29 de junio de 2025. URL: <https://www.datacamp.com/tutorial/rmse>

3. [10] J. Frost. "Root Mean Square Error (RMSE)". 2023. Fecha de consulta: 29 de junio de 2025. URL: <https://statisticsbyjim.com/regression/root-mean-square-error-rmse/>