





**Recibido:** 15 febrero 2023  
**Aceptado:** 29 agosto 2023  
**Disponible:** 11 septiembre 2023

©Instituto Tecnológico Metropolitano  
Este trabajo está licenciado bajo  
una Licencia Internacional  
Creative Commons Atribución  
(CC BY-NC-SA)



## Estrategias de predicción de consumo energético en edificaciones: una revisión

### Strategies for Predicting Energy Consumption in Buildings: A Review

 Liliana Ortega-Diaz <sup>1</sup>;  
 Jorge Cárdenas-Rangel <sup>2</sup>;  
  German Osma-Pinto <sup>3</sup>

<sup>1</sup> Universidad Industrial de Santander, Bucaramanga-Colombia,  
[liliana2228331@correo.uis.edu.co](mailto:liliana2228331@correo.uis.edu.co)

<sup>2</sup> Universidad Industrial de Santander, Bucaramanga-Colombia,  
[jorge2148225@correo.uis.edu.co](mailto:jorge2148225@correo.uis.edu.co)

<sup>3</sup> Universidad Industrial de Santander, Bucaramanga-Colombia,  
[gealosma@uis.edu.co](mailto:gealosma@uis.edu.co)

---

#### Cómo citar / How to cite

L. Ortega-Diaz, J. Cárdenas-Rangel, G. Osma-Pinto, “Estrategias de predicción de consumo energético en edificaciones: una revisión,” *Tecnológicas*, vol. 26, nro. 58, e2650, 2023.  
<https://doi.org/10.22430/22565337.2650>

---

## **Resumen**

Los edificios son uno de los principales actores contaminantes del medio ambiente, por lo que es necesario fortalecer las estrategias para la reducción de su consumo energético, como el diseño energéticamente eficiente (edificios nuevos) y la gestión energética (edificios existentes). Para ello, es fundamental la predicción del consumo energético que permita conocer el estado de operación de la edificación e inferir sobre las causas de éste y la eficacia de las estrategias de ahorro energético. No obstante, la diversidad de técnicas de predicción del consumo energético existentes dificulta a investigadores su identificación, selección y aplicación. Por ello, a partir de una revisión de la literatura, este artículo identifica técnicas de predicción, expone sus principios teóricos, describe las etapas generales de construcción de un modelo de predicción, reconoce métricas de evaluación, identifica algunas de sus fortalezas y debilidades y presenta criterios para facilitar la selección de una técnica de predicción y métricas de evaluación según las características del caso de estudio. Se realizó un análisis bibliométrico como metodología para identificar y estudiar los artículos más importantes sobre demanda de energía en edificios. Se encuentra que hay tendencia en la aplicación de técnicas de aprendizaje automático y que los modelos de predicción de consumo energético son mayormente aplicados a edificaciones residenciales, comerciales y educativas.

## ***Palabras clave***

Demanda de energía, eficiencia energética, consumo de energía en edificaciones, enfoques de predicción, métricas de desempeño.

## **Abstract**

Buildings are one of the main polluting actors in the environment. Therefore, it is necessary to strengthen strategies to reduce their energy consumption, such as energy-efficient design (new buildings) and energy management (existing buildings). For this, it is essential to predict energy consumption to know the state of the building's operation and infer the causes and effectiveness of energy-saving strategies. However, the diversity of existing energy consumption prediction techniques makes it difficult for researchers to identify, select, and apply them. Therefore, from a literature review, this article identifies prediction techniques, exposes its theoretical principles, describes the general stages of building a prediction model, recognizes evaluation metrics, identifies some of its strengths and weaknesses, and presents criteria to facilitate the selection of a prediction technique and evaluation metrics according to the characteristics of the case study. A bibliometric analysis was carried out to identify and study the most critical articles on energy demand in buildings. It is found that there is a trend in the application of machine learning techniques and that energy consumption prediction models are mainly applied to residential, commercial, and educational buildings.

## ***Keywords***

Energy demand, energy efficiency, energy consumption in buildings, prediction approaches, performance metrics.

## 1. INTRODUCCIÓN

En 2021, los edificios y los sectores de construcción de edificios combinados fueron responsables de cerca del 30 % del consumo de energía final global y del 27 % de las emisiones totales del sector energético [1]. Las principales tendencias mundiales de los edificios y la construcción entre 2015 y 2021 señalan que la intensidad de emisiones de CO<sub>2</sub> producida por estos sectores disminuyó un 7 % y el consumo de energía un 0,7 %. Lo anterior, debido a la pandemia de COVID-19 que representó cambios en el sector de los edificios y la construcción en 2020 en temas de demanda de construcción, cierres de lugares de trabajo y desafíos de asequibilidad energética. A pesar de la disminución de estos porcentajes, el consumo y huella de carbono de las edificaciones aún es muy alto, en 2021 las actividades de construcción recuperaron sus niveles previos a la pandemia y la demanda de energía se intensificó con la apertura de puestos de trabajo [2].

Los problemas ambientales ocasionados por la gran cantidad de energía consumida en los edificios producen efectos adversos sobre la existencia de la humanidad y sobre el planeta [3]. Por lo tanto, el aumento global de la demanda de energía se ha vuelto de suma importancia para propietarios de edificios [4], comunidades científicas, industrias y gobiernos [5].

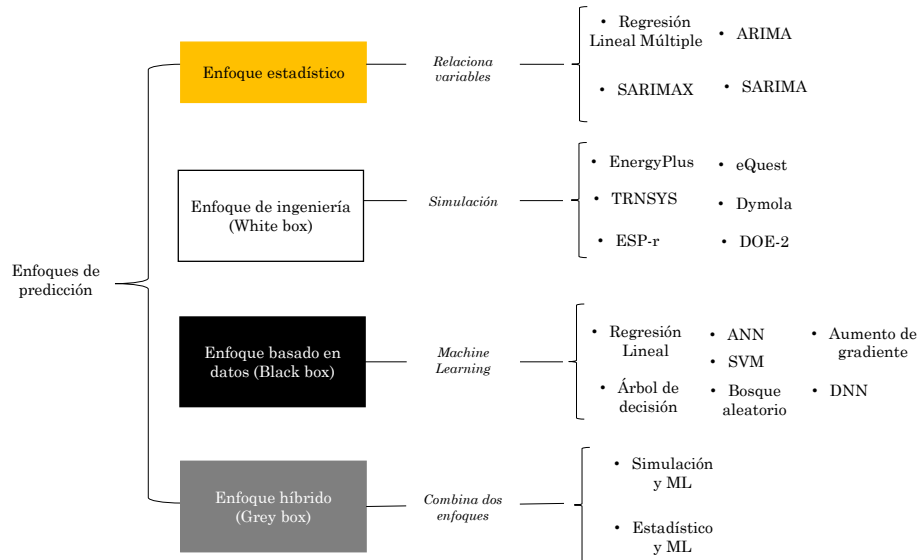
Según A. D. Pham *et al.* [6], los edificios deben ser energéticamente eficientes y sostenibles, pues contribuyen significativamente al consumo mundial de energía y a la emisión de gases de efecto invernadero. La eficiencia energética presenta beneficios ambientales y económicos. Los edificios con sistemas de energía y estrategias de gestión eficientes tienen costos operativos más bajos [7].

La predicción del consumo de energía de los edificios es una herramienta de gran ayuda para investigadores e ingenieros interesados en el comportamiento energético de las edificaciones. Predecir el uso de energía de los edificios es necesario para la planificación, gestión y conservación de la energía [8]. La predicción exacta y rápida del consumo de energía puede ayudar a lograr los objetivos de evaluar nuevas alternativas de diseño de edificios y optimizar los sistemas de energía [9], [10]. El desarrollo de un modelo de predicción de energía con alta exactitud se considera uno de los enfoques más efectivos para comprender la eficiencia energética de los edificios [11]. El conocimiento basado en los patrones de consumo de energía de años anteriores podría usarse para predecir el uso de energía de los edificios y hacer más eficiente el consumo de energía [4].

En los últimos años, las tendencias asociadas al cambio climático han permitido promover el desarrollo de diversas técnicas/estrategias para predecir el consumo energético y el confort térmico de los edificios [12]. La revisión de la literatura permitió reconocer cuatro enfoques de predicción, a saber: estadístico, basado en datos, de ingeniería e híbrido. La Figura 1 presenta estos enfoques con algunas técnicas específicas.

Los modelos de regresión estadística correlacionan el consumo de energía o el índice de energía con las variables influyentes. Estos modelos empíricos se desarrollan a partir de datos históricos, por lo que se debe garantizar una cantidad significativa de éstos para construir un modelo [13].

El enfoque de ingeniería, también denominado de caja blanca, se basa en el modelado físico de la edificación, por lo que requiere información detallada de fenómenos de construcción complejos [14] y depende de las reglas termodinámicas para el modelado y análisis de energía detallados. Algunos de los programas que utilizan modelos físicos son EnergyPlus, TRNSYS, eQuest, ESP-r, Dymola y DOE-2 [15].



**Figura 1.** Enfoques de predicción. Fuente: elaboración propia.

Los modelos basados en datos, conocidos como de caja negra, se basan en datos históricos para deducir o caracterizar la relación oculta entre la salida (e.g., consumo de energía del edificio) y las variables de entrada (e.g., clima, características físicas del edificio, comportamiento de los ocupantes y horarios de uso de los equipos) utilizando métodos matemáticos. Se aprecia el creciente uso de estos modelos para predecir el consumo energético en edificaciones [8], lo cual se debe a la alta confiabilidad de los algoritmos de aprendizaje en la resolución de problemas complejos y no lineales [16] y al aumento de la información disponible sobre las edificaciones [17].

Los enfoques híbridos o modelos de caja gris combinan el enfoque de caja negra y el enfoque de caja blanca. Dado que es posible obtener datos sintéticos sobre el consumo energético a través de software [10], [18], se puede utilizar un modelo físico simplificado y datos de fácil acceso para simular la demanda de energía del edificio, combinando así las ventajas de estos dos enfoques [9]. También se pueden clasificar dentro de este grupo las técnicas que usan modelos estadísticos y aprendizaje automático para mejorar la exactitud de la predicción [19]–[23]. El enfoque basado en datos aprende y mejora a partir de la experiencia adquirida en la etapa de entrenamiento, es capaz de resolver problemas no lineales y está ubicado en el campo de la computación y la inteligencia artificial. El enfoque estadístico utiliza ecuaciones matemáticas para deducir relaciones (lineales) entre variables, por lo que recopila, organiza, analiza, interpreta y presenta datos y utiliza reglas para entrenarse. Aunque ambos enfoques utilizan la técnica de la regresión lineal usando la misma base teórica, note que el enfoque basado en datos absorbe la regresión estadística y busca mejorar su exactitud [24]. Específicamente, la regresión lineal en Machine Learning (ML) busca adaptar los datos de entrada para cumplir con cuatro supuestos, a saber: relación lineal entre las variables, independencia entre la tendencia de los errores (no deben tener un patrón identificable entre ellos), normalidad o ajuste de datos y variación constante del error [25].

Existen gran cantidad de técnicas empleadas para predecir el consumo de energía en edificios; sin embargo, es difícil para los investigadores identificar las técnicas que se usan para predecir el consumo de energía en edificaciones y encontrar esa diferenciación con otras técnicas empleadas para otros fines o predicciones. También resulta tedioso decidir cuál sea la técnica a usar según el caso de estudio, los datos y herramientas disponibles, los

conocimientos de los encargados de entrenar los modelos, etc. Tampoco es claro la manera en que se deben aplicar las técnicas, cómo deben ser sus etapas y qué se debe hacer para entrenar un buen modelo. En consecuencia, este artículo busca ayudar a superar esas dificultades teniendo como objetivo explicar los modelos que más se usan para cada enfoque de predicción, las métricas para evaluar el rendimiento de los modelos, las etapas de construcción, las fortalezas y debilidades y los criterios de selección de un enfoque en específico.

## 2. METODOLOGÍA

La literatura permite apreciar la existencia de cuatro enfoques de predicción de energía; sin embargo, es pertinente mencionar que la selección de una técnica específica según las características del caso es una tarea compleja [13], [14] Esto se debe al número de técnicas asociadas a cada enfoque, al no conocimiento de los principios teóricos, a la diversidad de métricas de evaluación y la carencia de criterios que ayuden a facilitar la selección. Es por esto que, este trabajo presenta una revisión de la literatura que permita facilitar la respuesta a estas inquietudes.

Para ello, se hace un análisis bibliométrico con el propósito de evaluar y analizar la producción académica y científica en el campo de la predicción del consumo de energía de edificaciones y seleccionar los artículos más importantes para ser leídos y estudiados. Esta revisión está basada en la búsqueda de artículos publicados en la base de datos SCOPUS donde se tuvo en cuenta editoriales como ELSEVIER, MDPI, IEEE y Springer, entre otras, con los siguientes términos: edificio, energía, consumo, basado en datos y predicción. Estos términos engloban todo el contexto que se quiere revisar en esta investigación. La ecuación de búsqueda usada es *(ALL (building AND energy AND consumption) AND ALL (data-driven) AND TITLE-ABS-KEY (prediction)). AND PUBYEAR > 2016 AND PUBYEAR < 2024 AND (LIMIT-TO ( OA , "all" ) ) AND ( LIMIT-TO ( DOCTYPE , "cp" ) OR LIMIT-TO ( DOCTYPE , "ar" ) )*. El tipo de documento buscado fue artículo y conferencia, de acceso abierto para el intervalo de años 2017-2023.

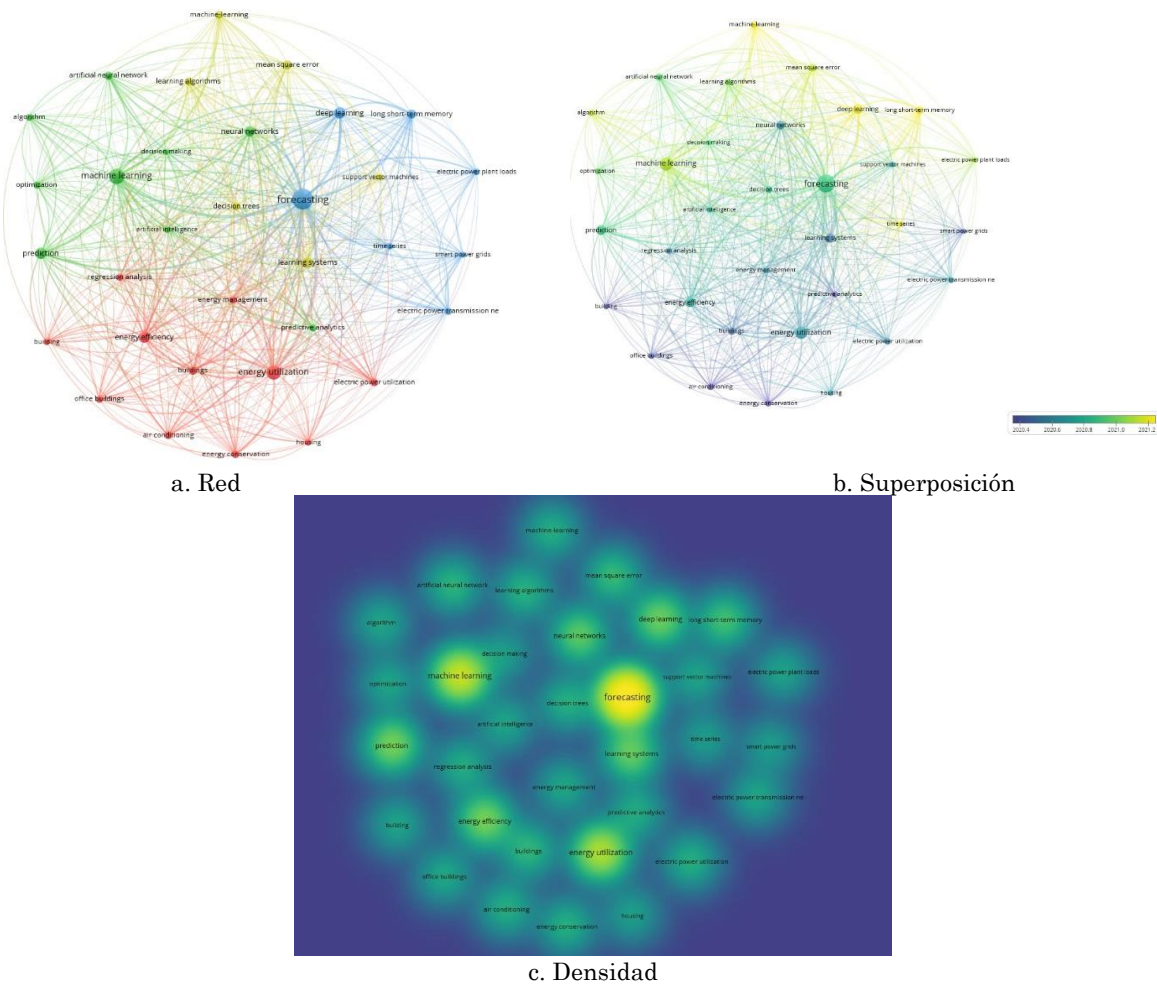
SCOPUS suministró 1257 resultados; mientras VOSVIEWER permitió ahondar en el análisis bibliométrico de los resultados, el cual puede suministrar mapas de visualización de red, superposición y densidad y establecer la co-ocurrencia de las palabras claves, tal como muestra la Tabla 1. Es posible definir 33 términos claves en cuatro grupos usando un número mínimo de ocurrencia de cada palabra de 58 de un total de 8831 palabras claves. Además, la Figura 2 presenta la relación entre las palabras claves.

## 3. RESULTADOS Y DISCUSIÓN

En algunas investigaciones clasifican los enfoques de predicción de energía en tres, cuatro o más grupos. Por ejemplo, Deb *et al.* [7] menciona que los enfoques se dividen en simulación por computadora, estadísticos y aprendizaje automático e híbridos. Chen *et al.* [9] y Gassar *et al.* [15] los clasifican en tres grupos: modelos de energía físicos, basados en datos utilizando aprendizaje automático y modelos híbridos. En este estudio se decidió abordar los cuatro enfoques encontrados en la literatura, lo cual permita considerar la mayor cantidad de técnicas mencionadas en la literatura. A continuación, se presentan algunas técnicas de predicción por enfoque que fueron seleccionadas de acuerdo con la revisión de literatura realizada.

**Tabla 1.** Coocurrencia de palabras clave. Fuente: elaboración propia.

Grupo 1	Grupo 2	Grupo 3	Grupo 4
-Aire acondicionado/Air conditioning	-Algoritmo/ Algorithm	-Aprendizaje profundo/ Deep Learning	-Árboles de decisión/ Decision trees
-Edificio/Building	-Inteligencia artificial/Artificial intelligence	-Cargas de centrales eléctricas/Electric power plants loads	-Algoritmos de aprendizaje/ Learning algorithms
-Edificios/Buildings	-Red neuronal artificial/Artificial neural network	-Transmisión de energía eléctrica/ Electric power transmission	-Sistemas de aprendizaje/ Learning systems
-Utilización de energía eléctrica/Electric power utilization	-Toma de decisiones/ Decision making	-Pronóstico/Forecasting	-Aprendizaje-automático/Machine-learning
-Conservación de energía/ Energy conservation	-Aprendizaje automático/Machine learning	-Memoria a corto y largo plazo/ Long short-term memory	-Error cuadrático medio/ Mean square error
-Eficiencia energética/ Energy efficiency	-Redes neuronales/ Neural networks	-Redes eléctricas inteligentes/Smart power grids	-Máquinas de soporte vectorial/Support vector machines
-Manejo de la energía/ Energy management	-Optimización/ Optimization	-Series de tiempo/Times series	
-Utilización de la energía/ Energy utilization	-Predicción/ Prediction		
-Alojamiento/Housing	-Análisis predictivo/ Predictive analytics		
-Edificios de oficinas/ Office building			
-Análisis de regresión/Regression analysis			



**Figura 2.** Visualización del análisis bibliométrico. Fuente: elaboración propia.

### 3.1 Enfoque estadístico

El método de predicción estadístico es un subcampo de la matemática que trata de encontrar relaciones entre variables para predecir un resultado. Usa ecuaciones matemáticas para crear cada una de estas relaciones. Para el campo de la predicción del consumo de energía, este enfoque de predicción se basa en relacionar el consumo de energía con las diversas variables que inciden en tal consumo. Estos métodos utilizan análisis de series temporales (datos medidos de una variable con un estampado de tiempo) con cierta resolución temporal (*e.g.*, cada 15 minutos) para predecir valores futuros [19].

La Tabla 2 muestra artículos de la literatura que usan técnicas estadísticas para predecir el consumo de energía, siendo las más usadas ARIMA, SARIMA y SARIMAX con una representatividad del 46,7 %, 20 % y 20 %, respectivamente. Tal representatividad fue calculada tomando el número de artículos donde se utilizó la técnica y dividiendo por el total de artículos. Las métricas de rendimiento más usadas son RMSE y MAPE con un 53,3 %. El 35,71 % de los estudios corresponden a edificios comerciales. Para todas las investigaciones, los datos recolectados fueron obtenidos por medición. El 26,7 % de los estudios identificados utilizaron el software MATLAB para el entrenamiento de los modelos. Las etapas generales de construcción de los modelos estadísticos son las presentadas en la Figura 3.

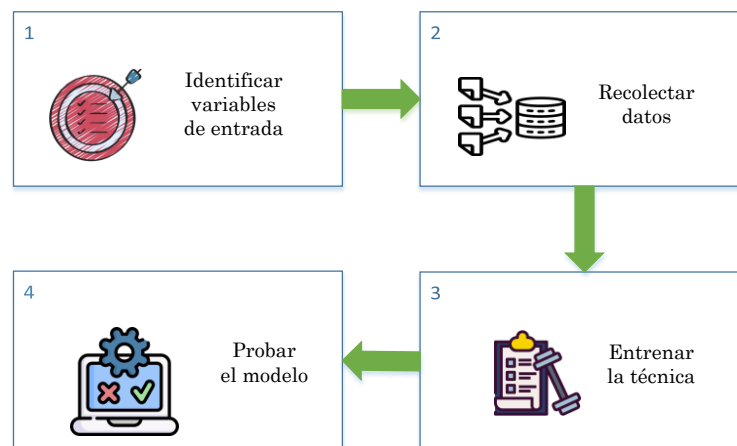


Figura 3. Etapas del enfoque estadístico. Fuente: elaboración propia.

#### 3.1.1 Regresión Lineal Múltiple

El consumo de energía depende de actividades específicas de los ocupantes (como la diferencia entre días festivos y días laborales), condiciones climáticas y eventos inesperados, entre otras. Suponiendo que la variable dependiente y varía con los  $m$  grupos de datos de observación y las  $n$  variables observadas ( $y_k, x_{k1}, x_{k2}, \dots, x_{kn}$ )  $k = 1, 2, \dots, m$ , se puede modelar como muestra (1), donde  $\beta_0, \beta_1, \beta_2, \dots, \beta_n$  son los coeficientes de la regresión,  $e$  son los residuos de la regresión,  $x_1, x_2, \dots, x_n$  son los factores que afectan la variable dependiente y [26].

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_n x_n + e \quad (1)$$

Los coeficientes  $\beta_i$  se pueden calcular utilizando el método de mínimos cuadrados, entonces  $\hat{\beta}_0, \hat{\beta}_1, \hat{\beta}_2, \dots, \hat{\beta}_n$  son las estimaciones de mínimos cuadrados de  $\beta_0, \beta_1, \beta_2, \dots, \beta_n$ , el valor de  $y$  puede ser observado en (2):

$$y_k = \hat{\beta}_0 + \hat{\beta}_1 x_{k1} + \hat{\beta}_2 x_{k2} + \cdots + \hat{\beta}_n x_{kn} + e_k \quad (2)$$

Donde  $e_k$  es el valor estimado del residual  $e$  y es igual a  $y_k - \hat{y}_k$ , donde  $\hat{y}_k$  es el valor estimado de  $y_k$ , entonces se puede obtener una relación como se muestra en (3):

$$\hat{y}_k = \hat{\beta}_0 + \hat{\beta}_1 x_{k1} + \hat{\beta}_2 x_{k2} + \cdots + \hat{\beta}_n x_{kn} \quad (3)$$

$\beta_0, \beta_1, \beta_2, \dots, \beta_n$  deben hacer que  $P$  cumpla con el mínimo, que son los cuadrados de desviación de los valores observados  $y_k$  y los valores de regresión  $\hat{y}_k$ , entonces  $P$  se define en (4):

$$P = \sum_{k=1}^m [y_k - (\hat{\beta}_0 + \hat{\beta}_1 x_{k1} + \hat{\beta}_2 x_{k2} + \cdots + \hat{\beta}_n x_{kn})]^2 \quad (4)$$

Como  $P$  es una cuadrática no negativa de  $\hat{\beta}_0, \hat{\beta}_1, \hat{\beta}_2, \dots, \hat{\beta}_n$ , el valor mínimo debe existir, entonces  $\hat{\beta}_0, \hat{\beta}_1, \hat{\beta}_2, \dots, \hat{\beta}_n$  deben satisfacer las ecuaciones en (5):

$$\begin{cases} \frac{\partial P}{\partial \hat{\beta}_0} = -2 \sum_{k=1}^m [y_k - \hat{y}_k] = 0 \\ \frac{\partial P}{\partial \hat{\beta}_1} = -2 \sum_{k=1}^m [y_k - \hat{y}_k] x_{k1} = 0 \\ \vdots \\ \frac{\partial P}{\partial \hat{\beta}_n} = -2 \sum_{k=1}^m [y_k - \hat{y}_k] x_{kn} = 0 \end{cases} \quad (5)$$

Sustituyendo (3) en (5), se obtiene (6):

$$\begin{cases} m\hat{\beta}_0 + \left[ \sum_{k=1}^m x_{k1} \right] \hat{\beta}_1 + \left[ \sum_{k=1}^m x_{k2} \right] \hat{\beta}_2 + \cdots + \left[ \sum_{k=1}^m x_{kn} \right] \hat{\beta}_n = \sum_{k=1}^m y_k \\ \left[ \sum_{k=1}^m x_{k1} \right] \hat{\beta}_0 + \left[ \sum_{k=1}^m x_{k1}^2 \right] \hat{\beta}_1 + \left[ \sum_{k=1}^m x_{k1} x_{k2} \right] \hat{\beta}_2 + \cdots + \left[ \sum_{k=1}^m x_{k1} x_{kn} \right] \hat{\beta}_n = \sum_{k=1}^m x_{k1} y_k \\ \vdots \\ \left[ \sum_{k=1}^m x_{kn} \right] \hat{\beta}_0 + \left[ \sum_{k=1}^m x_{kn} x_{k1} \right] \hat{\beta}_1 + \left[ \sum_{k=1}^m x_{kn} x_{k2} \right] \hat{\beta}_2 + \cdots + \left[ \sum_{k=1}^m x_{kn}^2 \right] \hat{\beta}_n = \sum_{k=1}^m x_{kn} y_k \end{cases} \quad (6)$$

La matriz de coeficientes de las ecuaciones normales es una ecuación simétrica presentada en (7):

$$Y = \begin{pmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{pmatrix} \beta = \begin{pmatrix} \hat{\beta}_0 \\ \hat{\beta}_1 \\ \vdots \\ \hat{\beta}_n \end{pmatrix} X = \begin{pmatrix} 1 & 1 & \cdots & 1 \\ x_{11} & x_{21} & \cdots & x_{21} \\ \vdots & \vdots & \ddots & \vdots \\ x_{1n} & x_{2n} & \cdots & x_{mn} \end{pmatrix} \quad (7)$$



Entonces (6) puede ser escrita en la forma de matriz  $(X^T X)\beta = X^T Y$  o  $A\hat{\beta} = B$ . En caso de que la matriz de coeficientes  $A$  sea de rango completo, resolviendo la ecuación matricial anterior el valor estimado de  $\hat{\beta}$  se puede obtener como en (8):

$$\hat{\beta} = (X^T X)^{-1} X^T Y = A^{-1} B \quad (8)$$

### 3.1.2 Media móvil integrada autorregresiva (ARIMA)

ARIMA es un modelo básico y general de técnicas de pronóstico de series de tiempo. Transforman la serie temporal en estacionaria mediante el proceso de diferenciación. Una serie temporal es estacionaria si sus propiedades estadísticas son todas constantes en el tiempo. En (9) se muestra la técnica ARIMA para una serie de tiempo como una función lineal donde la entrada consta de retraso de la variable dependiente junto con retrasos del error de pronóstico, donde  $w$  es la suma ponderada de uno o más valores pasados de  $y$ ,  $c$  es una constante y  $e$  es la suma ponderada de uno o más valores pasados del error del pronóstico [7].

$$y = w + c + e \quad (9)$$

Los términos de retraso de la serie de tiempo estacionaria se denominan “autorregresivos”, mientras que los retrasos de los términos de error pronosticados se denominan “promedio móvil”. Estos modelos se denotan como ARIMA  $(p, d, q)$ , donde  $p$  representa el orden de la parte autorregresiva,  $d$  denota el grado de la primera diferencia involucrada y  $q$  representa el orden de la parte media móvil. La parte autorregresiva del modelo con orden  $p$  es representada por (10). El modelo de promedio móvil de orden  $q$  se presenta en (11), donde  $Y_t$  es la salida de una serie de tiempo como datos de consumo de electricidad y  $e_t$  es la serie de error [7]. En (12) se muestra la combinación de las dos anteriores.

$$Y_t = c_1 + \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \dots + \phi_p Y_{t-p} \quad (10)$$

$$Y_t = c_2 + \theta_1 e_{t-1} + \theta_2 e_{t-2} + \dots + \theta_q e_{t-q} + e_t \quad (11)$$


$$Y_t = (c_1 + c_2) + (\phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \dots + \phi_p Y_{t-p}) + (\theta_1 e_{t-1} + \theta_2 e_{t-2} + \dots + \theta_q e_{t-q} + e_t) \quad (12)$$

### 3.1.3 Modelos de promedio móvil integrado autorregresivo estacional (SARIMA)

SARIMA se usa para analizar y pronosticar datos de series temporales que se ocupan especialmente de los efectos estacionales. Está compuesta por tres componentes: autorregresión, media integrada y móvil. La autorregresión significa la relación de dependencia entre una observación y observaciones previas. También está integrada la diferenciación de observaciones sin procesar para hacer que la serie temporal sea estacionaria. El promedio móvil identifica la dependencia entre una observación y un error residual de un modelo de promedio móvil aplicado a observaciones retrasadas.

SARIMA generaliza los modelos de la familia ARIMA, teniendo la misma estructura con nuevos términos estacionales [19], tales como  $P$  (retrasos de la serie estacionaria),  $D$  (diferenciación estacional),  $Q$  (promedio móvil estacional) y  $s$  (longitud estacional en los datos), por lo que estos modelos se denotan como  $SARIMA(p, d, q)(P, D, Q)s$ .

La Figura 4 muestra los programas utilizados en las investigaciones de enfoque estadístico según el año de publicación.



**Figura 4.** Software utilizado en enfoque estadístico. Fuente: elaboración propia.

### 3.2 Enfoque de ingeniería

El enfoque ingeniería, también llamado de caja blanca o físico, se basa en ecuaciones de balance de masa y calor que presentan el comportamiento térmico dinámico de una edificación. El análisis del balance de calor considera tres modelos de transferencia de calor (conducción, convección y radiación) entre la envolvente del edificio y sus alrededores. Por ello, comprender las características físicas generales de los edificios es importante para utilizar estas herramientas de simulación de edificios; por lo que, se requiere información detallada de la envolvente del edificio, configuración de los sistemas de calefacción, ventilación y aire acondicionado (HVAC), ganancias de calor internas, equipos, horarios de ocupación de espacios interiores y de uso de equipo, zonas térmicas, ubicación y datos meteorológicos, entre otros [9]. La Figura 5 presenta el proceso de creación del modelado y de simulación del comportamiento energético de edificaciones.



**Figura 5.** Esquema general del modelado de simulación energética. Fuente: imágenes tomadas de repositorio de imágenes de uso libre.

**Tabla 2.** Enfoque estadístico - Principales características. Fuente: elaboración propia.

Ref.	País	Año	Edificación				Variables de entrada	Técnicas					Datos de comparación		Métricas de evaluación						Software								
			Cantidad	Tipo				ARIMA	ARIMAX	RLM	SARIMA	SARIMAX	Otras	Medición	Simulación	R <sup>2</sup>	MAE	MSE	RMSE	MAPE	CV-RMSE	MSPE	R	N_MBE	RE	Otras	Python	MATLAB	Otros
				Comercial	Residencial	Educativo																							
[27]		2020	1	√			Consumo de electricidad, festivos, días de alta temperatura	√			√						√							-	-	-			
[28]	China	2016	1	√			Tipo de día, tiempo del día, temperatura exterior de bulbo seco	√			√			√	√	√										SPPS Modeler 14.1			
[29]		2015	1	√			Número de cargas de la hora anterior.	√			√						√		√					-	-	-			
[30]		2022	7	√			Potencia activa por hora, superficie, ubicación, información meteorológica		√		√	√	√	√	√	√	√	√						√					
[31]		2021	4	√			Año, mes, día del mes, hora del día, número de la semana, día de la semana, estación del año, vacaciones, clima, temperatura, temperatura de rocío, humedad relativa, dirección del viento, velocidad del viento, consumo de energía	√			√			√	√									-	-	-			
[32]	EE. UU	2021	-	√			Temperatura interior, temperatura exterior, potencia			√	√	√	√	√	√									MAXE	√				
[33]		2019	9	√			Consumo de energía		√	PZ	√													TPR TNR FPR RP AUC F1 FP-100	√				
[34]	Finlandia	2016	1	√			Consumo de calor, temperatura exterior, velocidad del viento	√	√		√				√	√								TIC	√				
[35]	Taiwán	2019	1		√		Temperatura, humedad, nivel de CO <sub>2</sub> , consumo de electricidad, ocupación, estado ventiladores: encendido o apagado	√			√			√	√			√						SI TER	-	-	-		

Ref.	País	Año	Edificación				Variables de entrada	Técnicas					Datos de comparación		Métricas de evaluación						Software											
			Cantidad	Tipo				ARIMA	ARIMAX	RLM	SARIMA	SARIMAX	Otras	Medición	Simulación	R <sup>2</sup>	MAE	MSE	RMSE	MAPE	CV-RMSE	MSPE	R	N_MBE	RE	Otras	Python	MATLAB	Otros			
[36]	Singapur	2019	40	✓			Temperatura de bulbo seco, humedad relativa, radiación solar, número de personas en el edificio, humedad relativa interior, consumo de electricidad de iluminación y electrodomésticos, demanda sensible total de frío para todos los sistemas demanda latente total de frío para todos los sistemas, ganancia de calor sensible de ventilación e infiltración, ganancia neta de calor por radiación temperatura interior			✓					✓													Software R				
[37]	Arabia Saudita	2021	1		Industrial		Consumo de energía	✓						✓		✓	✓	✓										RMSLE				
[38]	Malasia	2021	1	✓			Consumo de energía	✓						✓		✓												ARE				
[39]	India	2022	-		Edificio Inteligente		Temperatura	✓		✓				✓	✓	✓	✓															
[40]	Ecuador	2022	1	✓			Potencia promedio mensual, potencia pico, energía mensual, energía pico, energía diaria				TM		✓									✓						✓				
[41]	Bulgaria	2022	10	✓			Año, mes, consumo de energía, temperatura exterior promedio mensual			✓			✓				✓											✓				
			<i>Representatividad</i>								<i>Representatividad</i>																					
			5	4	4	2					7	1	2	3	3	2	15	1	1	7	4	8	8	2	1	1	1	1	6	3	4	2
			33.3 %	26.7 %	26.7 %	13.3 %					46.7 %	6.7 %	13.3 %	20.0 %	20.0 %	13.3 %	100 %	6.7 %	6.7 %	46.7 %	26.7 %	53.3 %	53.3 %	13.3 %	6.7 %	6.7 %	6.7 %	6.7 %	40.0 %	20 %	26.7 %	13.3 %

*Técnicas* → ARIMA: Media móvil integrado autorregresiva; ARIMAX: Media móvil integrada autorregresiva con variable explicativa; RLM: Regresión Lineal Múltiple; SARIMA: Media móvil integrado autorregresiva; SARIMAX: media móvil integrada autorregresiva estacional con factores exógenos; PZ: Puntuación z; TM: Técnica de Montecarlo

*Datos de comparación* → M: medición; S: simulación

*Métricas de evaluación* → R<sup>2</sup>: Coeficiente de determinación; MAE: Error Absoluto Medio; MSE: Error cuadrático medio; RMSE: Raíz cuadrada del error cuadrático medio; MAPE: Error porcentual absoluto medio; CV-RMSE: Coeficiente de variación de la raíz del error cuadrático medio; MSPE: Error porcentual medio cuadrático; R: Coeficiente de correlación; N\_MBE: Error de sesgo medio normalizado; TIC: Coeficiente de desigualdad de Theil; SI: Índice de síntesis; TER: Tasa de error total; TPR: Tasa verdadera positiva; TNR: Tasa verdadera negativa; FPR: Tasa de falsos positivos; RP: Poder de rango; AUC: Área debajo de la curva; FP-100: Falso positivo cuando la tasa de detección es 100 %; RMSLE: Error de registro de raíz cuadrática media; ARE: Error relativo promedio; MAXE: Máximo error métrico; RE: Relative Error; F1: Puntuación

*Software* → SPSS Modeler: Statistical Product and Service Solution.

Generalmente, los modelos de simulación por computadora son usados para el diseño de nuevas edificaciones, ya que una vez está en operación el edificio se hace complejo monitorizar las condiciones climáticas, el horario de ocupación y las interacciones complejas de los sistemas HVAC e iluminación, lo cual dificulta la estimación del consumo de energía [7], [19]. La Tabla 3 relaciona algunas de las herramientas software más utilizadas para la predicción del consumo de energía en edificaciones. La Tabla 4 muestra los artículos en los que se hizo uso de herramientas de simulación de energía de edificaciones. Los edificios residenciales son de gran interés en este enfoque, tuvieron una representatividad del 55,5 %, EnergyPlus y DesignBuilder son los programas más utilizados con un porcentaje de 27,8 % y 16,7 % respectivamente. El error relativo es la métrica de evaluación que se usa con mayor frecuencia. El enfoque de simulación se usa en mayor medida para calcular el consumo energético de las edificaciones, ya que se predijo para el 66,67 % de las investigaciones estudiadas.

Otra herramienta de simulación es el software DesignBuilder basado en EnergyPlus. Este programa permite estimar energía, emisiones de CO<sub>2</sub>, iluminación y confort. Facilita el proceso de simulación de edificios tridimensionales, sus diseños y rendimiento energético. Es utilizado por arquitectos, ingenieros, trabajadores de la construcción y consultores de energía.

**Tabla 3.** Herramientas de simulación. Fuente: elaboración propia.

Software	Desarrollador	Año	País	Características técnicas	Tipo de modelado
EnergyPlus	U.S. Department of Energy's	1997	EE. UU.	Programa basado en consola que lee la entrada y escribe la salida en archivos de texto. Es de código abierto	Arquitectónico
TRNSYS	Universidad de Wisconsin	1975	EE. UU.	Consta de un motor que lee y procesa el archivo de entrada, a través de iteraciones resuelve el sistema, determina la convergencia y gráfica las variables del sistema.	Diagrama de bloques
DOE-2	Grupo de investigación de simulación Laboratorio Lawrence Berkeley	-	EE. UU.	Recibe un archivo de texto de entrada con parámetros y detalles necesarios que describen el edificio y sus sistemas.	Arquitectónico
eQuest	DOE	1998	EE. UU.	Es el motor DOE-2 con asistentes y gráficos incorporados	Arquitectónico
Dymola	Dassault Systèmes	2006	Francia	Basado en lenguaje Modelica (orientado a objetos), utiliza ecuaciones para modelar sistemas físicos.	Arquitectónico
ESP-r	Universidad de Strathclyde	1974	Reino Unido	Programa de código abierto, su distribución se gestiona bajo el control de código fuente de GitHub.	Arquitectónico



### 3.3 Enfoque de datos

El enfoque basado en datos está dentro del campo de la computación y la inteligencia artificial. Se denomina *Machine Learning* (ML) y se centra en el uso de datos y algoritmos para imitar la forma en que los humanos aprenden, mejorando gradualmente la exactitud.

Mediante el uso de métodos estadísticos, los algoritmos se entrenan para hacer clasificaciones o predicciones y descubrir información clave en proyectos de minería de datos. No requieren la construcción de ecuaciones de balance térmico; por lo tanto, se necesita menos o ninguna información física del edificio. Se basan en datos históricos para reducir la relación oculta entre la salida y las variables de entrada utilizando métodos matemáticos [9].

ML se divide en 4 subgrupos: aprendizaje supervisado, aprendizaje no supervisado, aprendizaje por refuerzo y *Deep Learning* (DL). El aprendizaje supervisado se caracteriza por utilizar datos etiquetados (categorizados); el aprendizaje no supervisado usa gran cantidad de datos sin etiquetar que luego agrupa y asocia según colores, tamaños, formas y diferencias; el aprendizaje por refuerzo se retroalimenta de la experimentación con los datos y conduce al usuario hacia el mejor resultado, aprende a través de la prueba y el error.

DL utiliza arquitecturas profundas o multicapa, lo cual mejora la capacidad de clasificar, reconocer, detectar, describir y entender. La arquitectura puede tener cinco o más capas y presenta algoritmos más eficientes que pueden aumentar aún más la exactitud [60]. Uno de los usos del DL es la clasificación de imágenes, reconocimiento del habla, detección de objetos y descripción de contenido. Sin embargo, demanda un alto costo computacional debido a la naturaleza iterativa de los algoritmos, aumento de la complejidad conforme incrementa el número de capas y grandes volúmenes de datos necesarios para el entrenamiento.

En la Tabla 5 se puede apreciar un resumen de las investigaciones encontradas y revisadas sobre el enfoque basado en datos. Estos modelos de aprendizaje automático se utilizan mayormente para hacer predicciones en edificios residenciales y comerciales. El 44 % de los artículos utilizaron Python para entrenar las técnicas, EE. UU. es el país que más utiliza estos modelos en sus investigaciones, existen gran variedad de técnicas en las que se destaca SVR, ANN y DNN. El 72,2 % de las investigaciones utilizó datos medidos en lugar de datos simulados. También hay gran cantidad de métricas de evaluación, siendo MAE, RMSE y  $R^2$  las más usadas.

#### 3.3.1 Regresión lineal

El método de regresión lineal relaciona variables y ofrece algunas ventajas, como la facilidad de uso y la interpretabilidad. El modelo de regresión lineal es definido en (13), donde  $\hat{y}$  es el valor predicho,  $\beta_0$  y  $\beta_1$  son los coeficientes de regresión y  $X$  son los datos observados. La relación entre la variable medida y la variable de respuesta no sugiere necesariamente causalidad, sino que existe una correlación significativa entre las dos variables [60].

$$\hat{y} = \beta_0 + \beta_1 X \quad (13)$$

Esta regresión lineal se diferencia de la regresión lineal del enfoque estadístico en los datos. Los datos de esta regresión requieren de un tratamiento para cumplir con características como relación lineal entre las variables, tendencia de los errores independiente, normalidad y variación constante del error. Esta técnica se clasifica en tres tipos: regresión lineal simple, regresión lineal múltiple y regresión lineal multivariable [61].





### 3.3.2 Redes neuronales artificiales (ANN)

El principio de ANN se basa en la forma en que los sistemas nerviosos biológicos procesan la información. Consiste en las tres partes mostradas por la Figura 6: (i) primera capa (de entrada), que acomoda todas las variables de entrada del modelo, (ii) la capa final, con cada neurona representando una salida diferente del modelo y (iii) la(s) capa(s) oculta(s), donde los datos proporcionados por la capa de entrada son analizados por un número variable de neuronas en busca de un patrón en la relación entre las distintas variables de entrada y el objetivo.

El patrón se traduce en pesos y sesgos dados a la conexión entre cada neurona y la neurona en la capa anterior. Los pesos muestran la fuerza de cada conexión; mientras los sesgos son un factor agregado a los pesos para imponer compensaciones y aproximar los valores de las series de tiempo pronosticadas a los reales. Dada la flexibilidad de los modelos ANN, se pueden configurar para una sola salida o múltiples salidas [72]. En general, es utilizada como una única técnica o dentro de un conjunto de técnicas donde se evalúa su exactitud. Se pueden identificar cinco tipos de redes neuronales usadas para predecir el consumo energético: perceptrón multicapa (MLP), redes neuronales recurrentes profundas (DRNN), redes neuronales profundas (DNN), red neuronal Elman (ENN) y memoria a largo y corto plazo (LSTM).

MLP es un tipo de red neuronal profunda que utiliza propagación hacia adelante con una capa oculta donde se aprenden las características latentes y abstractas [11]. Está conformado por varios perceptrones simples o redes de una sola capa. Trata de imitar el comportamiento de una red neuronal biológica más grande. Cuenta con la capa de entrada, la capa de salida de la red y las capas ocultas de la red. Una red neuronal de avance de dos capas fue usada por Olu-Ajayi *et al.* [11] para predecir el consumo energético anual en la etapa de diseño de 4500 edificios. Este algoritmo tuvo una precisión de 0,58 y una puntuación F1 de 0,52.

Las DRNN modelan dependencias temporales presentes en los datos de series temporales mediante el uso de conexiones de retroalimentación para recordar los valores en pasos de tiempo anteriores. Las dependencias de la salida de tiempo anteriores utilizan el algoritmo de propagación hacia atrás a través del tiempo [63].




Figura 6. Esquema general de una red neuronal artificial. Fuente: elaboración propia.

Este tipo red neuronal fue usado por Mawson *et al.* [67] para predecir el consumo hora a hora del sistema HVAC de una edificación industrial ubicada en Reino Unido con una exactitud de 96,8 %. Rahman *et al.* [63] usaron DRNN para predecir valores de consumo de electricidad con una resolución de una hora en un periodo de tiempo de mediano a largo plazo para dos casos: predicción del consumo de energía eléctrica en un edificio de seguridad pública durante un período de 83 días y predicción del consumo total de electricidad en edificios residenciales en un horizonte de tiempo de un año.

ENN generalmente tiene dos capas, la capa oculta tiene una realimentación desde su salida a su entrada. La realimentación permite a la red aprender a reconocer y generar patrones temporales o variantes en el tiempo. El retardo de la conexión almacena valores del instante de tiempo anterior, que pueden ser utilizados en el instante actual. Ruiz *et al.* [69] aplicaron este tipo de red neuronal para predecir el consumo de energía de 25 edificios educativos ubicados en España, fue el modelo más preciso y estable en comparación con árboles de regresión y máquinas de vectores de soporte.

LSTM contiene celdas que constan de una puerta de entrada, una puerta de salida y una puerta de olvido, que almacena y transmite datos desde la celda. La puerta de olvido es el proceso de decidir si descartar datos pasados, la puerta de entrada determina si almacenar la información actual y la puerta de salida es el proceso de decidir qué valor de salida generar. Este tipo de red neuronal es adecuada para modelos de predicción basado en el análisis de series temporales. Este algoritmo fue utilizado por Hwang *et al.* [20] junto con otras técnicas de aprendizaje automático para predecir el consumo de 28 edificaciones comerciales basados en información de edificios e instalaciones mediante un enfoque de dos pasos: recopilación y procesamiento previo de datos y desarrollo del modelo de predicción. La Tabla 6 presenta las características principales de las redes neuronales artificiales utilizadas en la predicción del consumo de energía en edificaciones.

**Tabla 6.** Características de las redes neuronales artificiales. Fuente: elaboración propia.

Nombre	Estructura	Conexión	Tipo de aprendizaje	Flujo de información	Información adicional
MLP	Multicapa Capa de entrada- Capa oculta- Capa de salida	Total o parcialmente conectada	Supervisado	Unidireccional	Propagación hacia atrás
DRNN	Multicapa	Parcialmente conectada	Supervisado	Realimentadas	Tipo de red neuronal profunda con realimentación
DNN	Multicapa	Parcialmente conectada	Supervisado No supervisado Por refuerzo	Unidireccional	Posee mayor cantidad de capas ocultas que una red neuronal artificial común
ENN	Multicapa	Parcialmente conectada	Supervisado	Realimentadas	Son un tipo de redes neuronales recurrentes. Tiene entradas adicionales de la capa oculta denominadas capa de contexto.
LSTM	Multicapa	Parcialmente conectada	Supervisado	Realimentadas	Se usa para evitar que el gradiente explote o desaparezca



### 3.3.4 Árboles de decisión

Utiliza una estructura de árbol similar a un diagrama de flujo para segregar un conjunto de datos en varias clases predefinidas, proporcionando así la descripción, categorización y generalización de conjuntos de datos dados. Como modelo lógico, el árbol de decisiones muestra cómo se puede predecir el valor de una variable de destino utilizando los valores de un conjunto de variables predictoras. Para ello, el proceso de entrenamiento se divide en dos etapas: (i) división sucesiva del espacio de los predictores en regiones (*e.g.*, minimización de la raíz de la suma residual) y (ii) predicción de la variable respuesta en cada región establecida. La popularidad del método del árbol de decisión se atribuye principalmente a su facilidad de uso y su capacidad para generar modelos predictivos con estructuras comprensibles e interpretables que, en consecuencia, brindan información clara y útil sobre los dominios correspondientes [75]. Este algoritmo fue utilizado por Ramos *et al.* [76] para evaluar cuál algoritmo era el más adecuado para predecir el consumo de un edificio entre redes neuronales artificiales. La Figura 8 presenta el esquema general de un árbol de decisión, los nodos y la relación entre ellos.

### 3.3.5 Aumento de gradiente (GB)

Este método utiliza un conjunto de modelos débiles que en conjunto forman un modelo más fuerte. El modelo final es una función que recibe un vector de atributos  $x \in \mathbb{R}^n$  como entrada para identificar un valor  $F(X) \in \mathbb{R}$ . Además, una de las razones para utilizar GB se basa en la reputación anterior de métodos de conjunto que superan a otros métodos de aprendizaje automático. Por lo general, se reconocen como los regresores o clasificadores que producen los mejores resultados listos para usar [60].

### 3.3.6 Árbol aleatorio de regresión (RFR)

Es una técnica de conjunto que ofrece varias características beneficiosas, tales como: (i) se basa en la teoría del aprendizaje por conjuntos, lo que le permite aprender tanto problemas simples como complejos; (ii) no exige muchos ajustes de hiperparámetros para lograr un buen rendimiento en comparación con otros algoritmos de ML (*e.g.*, ANN y SVM) y (iii) sus parámetros predeterminados a menudo producen un rendimiento excelente. Por lo tanto, RFR está ganando más atención en el campo del consumo de energía en edificios [60].

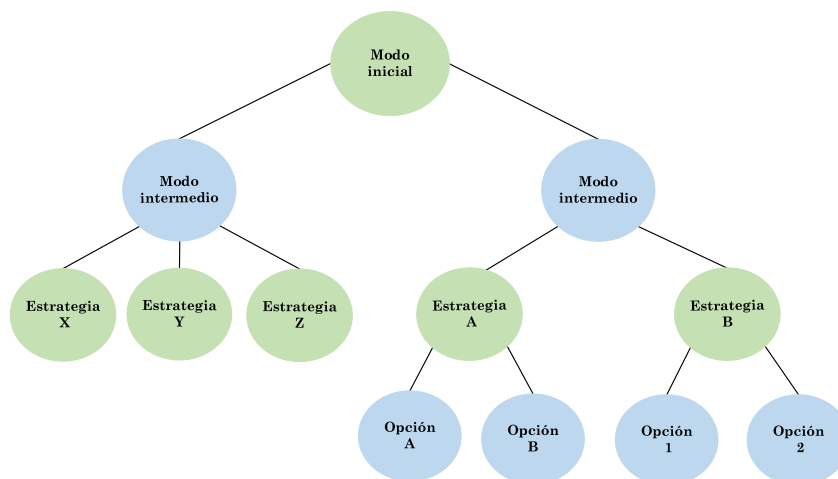
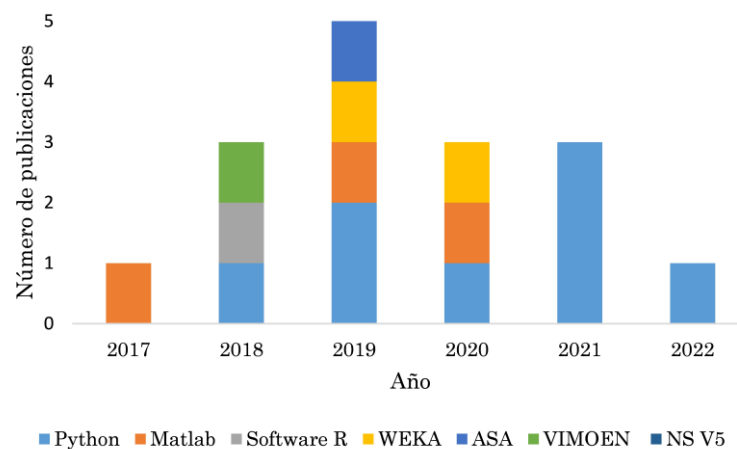


Figura 8. Esquema general de un árbol de decisión. Fuente: elaboración propia.

Con base en lo mostrado en la Tabla 6, se puede apreciar el uso del software utilizado para entrenar las técnicas de aprendizaje automático. La Figura 9 muestra que el software Python es el más utilizado para entrenar las técnicas de predicción basadas en datos. Matlab, Azure Synapse Analytics, WEKA, VIMOEN y NeuroSolutions son programas que también se usan para el entrenamiento de los algoritmos.

### 3.4 Enfoque híbrido

El enfoque híbrido combina dos de los enfoques mencionados, enfoque estadístico & ML o simulación simplificada & ML, lo cual permite mitigar las desventajas que presenta un enfoque; por ejemplo, el tiempo de predicción empleado en simulación se puede reducir utilizando simulación simplificada y aprendizaje automático. También, este enfoque se ha usado para compensar la incapacidad de los modelos SARIMA para tratar con exactitud los componentes no lineales de los datos de predicción de energía de edificios, se combina el modelo estadístico SARIMA y las máquinas de soporte vectorial (SVM) [19]. Otro ejemplo, propone un enfoque de dos pasos basado en estadísticas y ML, para desarrollar un modelo de predicción de consumo de electricidad de alta exactitud superando limitaciones de información insuficiente [20]. Mui *et. al* [77] proponen un enfoque de simulación híbrido (EnergyPlus y ANN) que se puede aplicar a diversos tipos de edificios para estimar el consumo anual de energía de refrigeración. Utiliza el software EnergyPlus para realizar el modelado de los edificios, luego a través de Matlab y Python se gestionan los datos de energía (entregados por EnergyPlus) y se entrenan las redes neuronales artificiales. La Tabla 7 muestra los hallazgos encontrados en los artículos que usaron enfoque híbrido; por ejemplo, los edificios que más se usan para estudiar su comportamiento energético fueron los comerciales y los educativos, la combinación de técnicas estadísticas con técnicas de aprendizaje automático tiene una representatividad del 58,3 % mientras que en los artículos que usaron simulación y aprendizaje automático la representatividad fue del 47,7 %.



**Figura 9.** Programas utilizados para entrenar algoritmos de ML. Fuente: elaboración propia.

**Tabla 7.** Artículos encontrados para enfoque híbrido. Fuente: elaboración propia.

Ref.	País	Año	Edificación				Variables de entrada	Técnicas										Enfoque		Datos de comparación		Métricas de evaluación					Software						
			Cantidad	Residencial	Comercial	Educativo		Otros	SARIMA	SARIMAX	ARIMA	RLM	GD	ANN	LSTM	SVM	EnergyPlus	IES-VE	DesignBuilder	Otras	SS + ML	E + ML	M	S	R <sup>2</sup>	MAE	MSE	RMSE	MAPE	RE	R	CV-RMSE	Otras
[78]		2022	8		✓		Temperatura media del aire exterior, humedad relativa exterior, amplitud de temperatura, género, índice de vacaciones e índice de días soleados.										JPR	✓	✓			✓			✓	✓		✓	N_MBE	✓			
[79]		2022	1		✓		Temperatura, humedad, intensidad de luz, concentración de dióxido de carbono, velocidad del viento y la lluvia. Sensores de monitoreo ambiental interior.										TPM DDM	✓		✓							✓					-	-
[23]	China	2022	1		✓		Datos de carga de calefacción por hora.										DL		✓	✓			✓			✓		✓	MBE		-	-	
[77]		2022	2	✓		Hospital	Temperatura exterior, día en un año, hora en un día, temperatura del aire, área de la ventana, área de la pared externa, superficie del apartamento, orientación, valor U de la ventana, valor U de la pared, coeficiente de sombreado, ángulo de sombra vertical.						✓		✓			✓			✓				✓								✓
[19]		2020	1		✓		Fecha, día de la semana, temperatura exterior, temperatura aparente, temperatura mínima exterior, temperatura máxima exterior, presión del aire, humedad, velocidad del viento, nivel de la nube.												✓	✓			✓			✓						-	-
[80]	Reino Unido	2020	1			No residencial	Temperatura ambiente, punto de ajuste de calefacción, punto de ajuste de refrigeración, perfil de la planta, humedad relativa, contenido de								✓		RNN	✓			✓				✓	✓			N-RMSE				✓







La Figura 10 hace un resumen de los tipos de edificaciones estudiadas por enfoque y el porcentaje de tipo de edificación estudiada a nivel global.




Figura 10. Tipos de edificaciones. Fuente: elaboración propia.


#### 4. MÉTRICAS DE EVALUACIÓN DE DESEMPEÑO

Algunas de las métricas usadas para evaluar el desempeño de las técnicas de predicción del consumo energético de las edificaciones son las mostradas en la Tabla 8. La Figura 11 muestra un resumen de los hallazgos más importantes en cuanto a estos indicadores de rendimiento; por ejemplo, las técnicas que se emplean con mayor frecuencia son RMSE, MAPE, MAE y R<sup>2</sup>. El MAPE estuvo en un rango de [0,05 %-18,95 %], CVRMSE: [0,02 % - 30 %], RE: [0,5 %-17,04 %] y NMBE: [0,2 % -7,7 %]. La mediana de R<sup>2</sup> y R fue 0,903 y 0,885, respectivamente.


**Tabla 8.** Métricas de rendimiento utilizadas en la literatura. Fuente: elaboración propia.

Métrica	Fórmula	Métrica	Fórmula
Mean Squared Error	$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2$	Relative Error	$RE = \frac{ y_i - \hat{y}_i }{y_i} * 100$
R-Squared	$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y}_i)^2}$	Correlation coefficient	$R = \frac{n \sum y_i \hat{y}_i - (\sum y_i)(\sum \hat{y}_i)}{\sqrt{n(\sum y_i^2) - (\sum y_i)^2} \sqrt{n(\sum \hat{y}_i^2) - (\sum \hat{y}_i)^2}}$
Mean Absolute Error	$MAE = \left(\frac{1}{n}\right) \left(\sum_{i=1}^n  y_i - \hat{y}_i \right)$	Coefficient of Variation of the Root Mean Squared Error	$CVRMSE = \frac{\sqrt{n \sum_{i=1}^n (\hat{y}_i - y_i)^2}}{\sum_{i=1}^n y_i}$
Mean Absolute Percentage Error	$MAPE = \left(\frac{1}{n}\right) \left(\frac{\sum_{i=1}^n  y_i - \hat{y}_i }{y_i}\right)$	Normalized Mean Bias Error	$NMBE = \frac{\sum_{i=1}^n  y_i - \hat{y}_i }{y_i}$
Root Mean Squared Error	$RMSE = \sqrt{\frac{1}{n} \left(\sum_{i=1}^n (y_i - \hat{y}_i)^2\right)}$		


+n: número de muestras o mediciones;  $y_i$ : datos reales;  $\hat{y}_i$ : datos predichos;  $y_{max}$ : valor máximo real;  $y_{min}$ : valor mínimo real.



a. Uso según enfoque



b. Boxplot para algunas métricas



c. Boxplot para R<sup>2</sup> y R.

**Figura 11.** Métricas de rendimiento. Fuente: elaboración propia.

MSE es la medida de la variación cuadrática entre los valores estimados y los valores reales. Es una evaluación de la calidad de un predictor.  $R^2$  representa la proporción predecible de la varianza en la variable dependiente que puede ser expuesta por la(s) variable(s). MAE es la diferencia promedio entre las variables esperadas y reales. MAPE es la medida promedio de los errores absolutos de los pronósticos. RMSE es la desviación estándar de los errores de predicción. El error relativo es el cociente entre el error absoluto y el valor real. El coeficiente de correlación R es un valor entre -1 y 1, mide la fuerza y la dirección de la relación lineal entre dos variables, para valores cercanos a 0 la relación lineal es débil, los valores de R igual a 1 y -1 expresan una relación lineal perfecta positiva o negativa, respectivamente. El CV-RMSE es una métrica que indica inestabilidad en la relación observada entre variables en el período de referencia. La N\_MBE es una normalización del índice MBE que se utiliza para escalar los resultados haciéndolos comparables.

## 5. FORTALEZAS Y DEBILIDADES DE LAS TÉCNICAS DE PREDICCIÓN

Los enfoques de predicción utilizados para predecir el consumo de energía en edificaciones presentan algunas ventajas y desventajas. La Tabla 9 muestra las fortalezas y debilidades de cada enfoque. Los datos requeridos por el enfoque estadístico son datos históricos de tipo series temporales, pues necesita datos medidos en intervalos de tiempo secuenciales [32]. Los modelos basados en datos pueden utilizar series temporales, pero no son tan importantes como en el caso del enfoque estadístico, los datos históricos si son relevantes en este enfoque [17]. El enfoque de simulación solo necesita parámetros físicos (de construcción detallada), datos medioambientales y datos de cargas eléctricas. Los datos de la estructura de los edificios se obtienen de los planos de planta y planos eléctricos de las edificaciones [58]. Para el caso del modelo híbrido depende del modelo que se decida utilizar; en ambos casos se requiere de datos históricos, pues en los dos grupos en los que está dividido este enfoque se entrenan técnicas de aprendizaje automático [78]. Los datos meteorológicos se tienen en cuenta en los cuatro enfoques de predicción debido a que el clima afecta en gran medida el consumo energético en los edificios por el uso del aire acondicionado o los sistemas de calefacción. Los datos por lo general son recolectados por sensores, medidores de energía y estaciones meteorológicas.

La Tabla 10 analiza los enfoques de predicción a partir de diez criterios que favorecen el proceso de selección a investigadores

**Tabla 9.** Fortalezas y debilidades de los enfoques de predicción. Fuente: elaboración propia.

Enfoque	Fortalezas		Debilidades	
Estadístico	Fácil desarrollo	Predicción rápida	Inexactitud	Requiere datos históricos
	Modelos sencillos		Falta de flexibilidad	Enfoque mayormente lineal
Simulación	Exactitud		Costos computacionales altos	Requiere gran cantidad de datos físicos y ambientales
	No requiere datos históricos		Alta complejidad	Requiere parámetros de construcción detallados
Basado en datos	Exactitud	Entrenamiento rápido	Requiere datos históricos	Difícil de generalizar
	No requiere muchas entradas	Costos computacionales bajos	Ineficiencia computacional	
	Apropiado para modelado no lineal			
Híbrido	Combina dos de los enfoques anteriores para superar desventajas		Ineficiencia computacional	

**Tabla 10.** Criterios descriptores de los enfoques de predicción. Fuente: elaboración propia.

Criterio	Enfoque					
	Estadístico	Simulación	Basado en datos	Simulación + ML	Híbrido Enfoque estadístico + ML	
Nivel de exactitud	Porcentaje de exactitud que muestra la técnica de predicción. Se mide con las métricas de rendimiento.	Baja	Alta	Media	Alto	Alto
Tiempo de predicción	Es la duración que toma todo el proceso de predicción	Bajo	Alto	Bajo	Medio	Alto
Diseño de edificaciones	Campo de la arquitectura y la ingeniería que se encarga de diseñar y modelar este tipo de construcciones	No recomendable	Recomendable	No recomendable	Recomendable	Recomendable
Edificaciones en operación	Edificaciones habitadas y existentes	Recomendable	No tan recomendable	Recomendable	No tan recomendable	Recomendable
Datos históricos/series temporales	Datos registrados por medio de equipos especializados	Requiere	No requiere	Requiere	No requiere	Requiere
Datos físicos, meteorológicos y de construcción	Datos utilizados como variables de entrada	Algunas veces usa	Usa	Usa	Usa	Algunas veces usa
Número de edificaciones	Cantidad de edificaciones evaluadas en la predicción	Más de uno	Generalmente es uno	Más de uno	Generalmente uno	Más de uno
Modelo	Tipo de forma o modelo matemático que el enfoque predicción calcula con mayor exactitud	Lineal	-	No lineal	-	Lineal y no lineal
Costo computacional	Precio del software de predicción	Bajo	Alto	Bajo	Medio	Bajo
Personal capacitado	Conocimientos de las personas para usar cada enfoque	Estadística	Software de simulación avanzado	Machine Learning	Software de simulación simplificado y estadística	Estadística y Machine Learning

## 6. CONCLUSIONES

Este artículo es una revisión de investigaciones recientes sobre la predicción del consumo energético en edificaciones. Fue posible identificar cuatro enfoques de predicción: estadístico, ingeniería, basado en datos e híbrido. La técnica más utilizada en el enfoque estadístico es ARIMA con una representatividad de 46,7 % del total de las investigaciones estudiadas en este grupo, de segunda posición están SARIMA y SARIMAX con un 20 %. Matlab es uno de los programas utilizados para ensayar estas técnicas, 26,7 % de los artículos usaron este

programa. Por otra parte, existe gran variedad de programas de simulación de energía los cuales se diferencian por sus características técnicas y tipo de modelado. Design Builder y EnergyPlus son programas bastante utilizados para evaluar el comportamiento energético de las edificaciones; note que para este enfoque se requiere de personal altamente capacitado y tiene costos computacionales altos. El enfoque de caja negra o basado en datos es el que se usa con mayor frecuencia en la literatura; se encontraron un promedio de 25 técnicas (es el enfoque que mayor número de técnicas emplea) en 18 artículos estudiados, siendo EE. UU. el país que más investigaciones realiza utilizando este enfoque. Es posible comprobar que el uso del enfoque híbrido mejora significativamente la exactitud de las predicciones como, por ejemplo, el modelo híbrido JP-MLR muestra un  $R^2$  de 0,9577 y los algoritmos separados JPR y MLR tienen un  $R^2$  de 0,8766 y 0,7098 [78]. El enfoque estadístico en conjunto con el aprendizaje automático tuvo una representatividad del 58,3 % y para el enfoque de simulación simplificada y ML fue de 41,7 %. Lo más destacado de estas técnicas es que permiten superar las desventajas presentadas por las técnicas y a través del trabajo en conjunto obtener buenos resultados.

En cuanto al tipo de información a procesar, se recomienda utilizar el enfoque basado en datos o estadístico si se tienen disponibles suficiente cantidad de datos históricos; si, por el contrario, sólo se tienen datos físicos de las edificaciones y ambientales el enfoque de ingeniería es el indicado para la predicción. Para el enfoque híbrido, depende de los criterios mencionados en conjunto con otros criterios, por ejemplo, si se dispone de datos históricos y se desea compensar la incapacidad de los modelos estadísticos de tratar con los componentes no lineales de los datos, se puede usar el enfoque estadístico & ML; pero si se tiene solo datos de construcción de las edificaciones, puede obtener datos de simulación simplificada y mejorar el modelo con técnicas de ML.

La exactitud de las técnicas de predicción puede ser evaluada a través de indicadores de rendimiento; según la Figura 11 a), a nivel general los más utilizados son RMSE y MAPE. Los tipos de edificaciones que más se estudian son residenciales (34 %), comerciales (24 %) y educativas (24 %).

Cada enfoque posee unas debilidades y unas fortalezas identificadas en este artículo que permitieron proponer un listado de diez criterios para la escogencia de una técnica de predicción. Estos criterios se basan en los recursos, habilidades e información disponible en la investigación. Se sugiere aplicar una o varias de las técnicas mencionadas en esta investigación para predecir el consumo energético de edificaciones y hacer uso de las métricas de rendimiento para evaluar la exactitud de las predicciones.

Esta investigación, a diferencia de otras revisiones, clasifica los enfoques en cuatro grupos, abordando la mayor cantidad de técnicas usadas para predecir el consumo de energía en edificios. Las revisiones encontradas muestran que unas dividen en tres enfoques y mezclan el enfoque estadístico con el aprendizaje automático; mientras, otras dejan por fuera los métodos estadísticos.

Este artículo puede ser de utilidad (i) para el sector académico porque puede servir como guía para investigadores que estén interesados en seleccionar y aplicar técnicas de predicción de energía de manera rápida y sencilla, (ii) para el sector de la construcción porque permite promover el uso de nuevas técnicas rápidas y exactas para la construcción de proyectos verdes o con estándares de eficiencia energética, (iii) para el sector gubernamental porque puede ayudar a motivar a los ciudadanos a gestionar el consumo de energía en los edificios donde realizan sus actividades y (iv) para el sector de la construcción podría incentivar a las empresas constructoras por medio de beneficios tributarios a construir proyectos verdes u otorgar becas a investigadores o instituciones educativas para que sigan profundizando en esta temática, lo anterior con el fin de apoyar la transición energética en el país.

## 7. AGRADECIMIENTOS Y FINANCIACIÓN

Este trabajo no cuenta con apoyo económico de ninguna entidad. Se agradece a la Universidad Industrial de Santander por su apoyo en el acceso a material bibliográfico.

## CONFLICTOS DE INTERÉS DE LOS AUTORES

Los autores declaran que no existe ningún conflicto de interés.

## CONTRIBUCIÓN DE LOS AUTORES

Liliana Ortega-Díaz, metodología, investigación, redacción, revisión y edición.  
 Jorge Cárdenas-Rangel, conceptualización, metodología, redacción, revisión y edición.  
 German Osma-Pinto, conceptualización, metodología, redacción, revisión y edición.

## 8. REFERENCIAS

- [1] International Energy Agency, “Buildings,” 2022. <https://www.iea.org/reports/buildings>
- [2] United Nations Environment Programme, “2022 Global Status Report for Buildings and Construction,” Nairobi, Nov. 2022. <https://www.unep.org/resources/publication/2022-global-status-report-buildings-and-construction>
- [3] B. Dandotiya and H. K. Sharma, “Climate Change and Its Impact on Terrestrial Ecosystems,” in *Impacts of Climate Change on Agriculture and Aquaculture*, A. Karmaoui, K. Barrick, M. Reed, and M. Baig (Eds.), IGI Global, 2021, pp. 140–157. <https://doi.org/10.4018/978-1-7998-3343-7.ch007>
- [4] J.-M. Liao, M.-J. Chang, and L.-M. Chang, “Prediction of air-conditioning energy consumption in R&D building using multiple machine learning techniques,” *Energies*, vol. 13, no. 7, p. 1847, Apr. 2020. <https://doi.org/10.3390/en13071847>
- [5] H. Bulkeley and M. M. Betsill, “*Cities and Climate Change: Urban Sustainability and Global Environmental Governance*,” Routledge, 2003. [Cities and Climate Change: Urban Sustainability and Global Environmental Governance \(worktribe.com\)](https://www.worktribe.com/publication/cities-and-climate-change-urban-sustainability-and-global-environmental-governance)
- [6] A.-D. Pham, N.-T. Ngo, T. T. Ha Truong, N.-T. Huynh, and N.-S. Truong, “Predicting energy consumption in multiple buildings using machine learning for improving energy efficiency and sustainability,” *J Clean Prod.*, vol. 260, p. 121082, Jul. 2020. <https://doi.org/10.1016/j.jclepro.2020.121082>
- [7] C. Deb, F. Zhang, J. Yang, S. E. Lee, and K. W. Shah, “A review on time series forecasting techniques for building energy consumption,” *Renewable and Sustainable Energy Reviews*, vol. 74, pp. 902–924, Jul. 2017. <https://doi.org/10.1016/j.rser.2017.02.085>
- [8] N.-T. Ngo, A.-D. Pham, T. T. Ha Truong, N.-S. Truong, N.-T. Huynh, and T. M. Pham, “An Ensemble Machine Learning Model for Enhancing the Prediction Accuracy of Energy Consumption in Buildings,” *Arab J Sci Eng*, vol. 47, pp. 4105–4117, Jun. 2022. <https://doi.org/10.1007/s13369-021-05927-7>
- [9] Y. Chen, M. Guo, Z. Chen, Z. Chen, and Y. Ji, “Physical energy and data-driven models in building energy prediction: A review,” *Energy Reports*, vol. 8, pp. 2656–2671, Nov. 2022. <https://doi.org/10.1016/j.egyr.2022.01.162>
- [10] E. Elbeltagi and H. Wefki, “Predicting energy consumption for residential buildings using ANN through parametric modeling,” *Energy Reports*, vol. 7, pp. 2534–2545, Nov. 2021. <https://doi.org/10.1016/j.egyr.2021.04.053>
- [11] R. Olu-Ajayi, H. Alaka, I. Sulaimon, F. Sunmola, and S. Ajayi, “Machine learning for energy performance prediction at the design stage of buildings,” *Energy for Sustainable Development*, vol. 66, pp. 12–25, Feb. 2022. <https://doi.org/10.1016/j.esd.2021.11.002>
- [12] R. Chen and Y.-S. Tsay, “Carbon emission and thermal comfort prediction model for an office building considering the contribution rate of design parameters,” *Energy Reports*, vol. 8, pp. 8093–8107, Nov. 2022. <https://doi.org/10.1016/j.egyr.2022.06.012>

- [13] H.-x. Zhao and F. Magoulès, “A review on the prediction of building energy consumption,” *Renewable and Sustainable Energy Reviews*, vol. 16, no. 6, pp. 3586–3592, Aug. 2012. <https://doi.org/10.1016/j.rser.2012.02.049>
- [14] Y. Wei *et al.*, “A review of data-driven approaches for prediction and classification of building energy consumption,” *Renewable and Sustainable Energy Reviews*, vol. 82, Part. 1, pp. 1027–1047, Feb. 2018. <https://doi.org/10.1016/j.rser.2017.09.108>
- [15] A. A. Ahmed Gassar and S. H. Cha, “Energy prediction techniques for large-scale buildings towards a sustainable built environment: A review,” *Energy Build.*, vol. 224, p. 110238, Oct. 2020. <https://doi.org/10.1016/j.enbuild.2020.110238>
- [16] A. D’Amico, G. Ciulla, M. Traverso, V. Lo Brano, and E. Palumbo, “Artificial Neural Networks to assess energy and environmental performance of buildings: An Italian case study,” *J Clean Prod.*, vol. 239, p. 117993, Dec. 2019. <https://doi.org/10.1016/j.jclepro.2019.117993>
- [17] Y. Ding, L. Fan, and Xue Liu, “Analysis of feature matrix in machine learning algorithms to predict energy consumption of public buildings,” *Energy Build.*, vol. 249, p. 111208, Oct. 2021. <https://doi.org/10.1016/j.enbuild.2021.111208>
- [18] F. Martellotta, U. Ayr, P. Stefanizzi, A. Sacchetti, and G. Riganti, “On the use of artificial neural networks to model household energy consumptions,” *Energy Procedia*, vol. 126, pp. 250-257, Sep. 2017. <https://doi.org/10.1016/j.egypro.2017.08.149>
- [19] Q. Qiao, A. Yunusa-Kaltungo, and R. Edwards, “Hybrid method for building energy consumption prediction based on limited data,” in *2020 IEEE PES/IAS PowerAfrica*, Nairobi, 2020, pp. 1-5. <https://ieeexplore.ieee.org/document/9219915>
- [20] J. Hwang, D. Suh, and M.-O. Otto, “Forecasting electricity consumption in commercial buildings using a machine learning approach,” *Energies*, vol. 13, no. 22, p. 5885, Nov. 2020, <https://doi.org/10.3390/en13225885>
- [21] N.-T. Ngo, A.-D. Pham, T. T. Ha Truong, N.-S. Truong, and N.-T. Huynh, “Developing a hybrid time-series artificial intelligence model to forecast energy use in buildings,” *Sci Rep.*, vol. 12, p. 15775, Sep. 2022. <https://doi.org/10.1038/s41598-022-19935-6>
- [22] D. Durand, J. Aguilar, and M. D. R-Moreno, “An Analysis of the Energy Consumption Forecasting Problem in Smart Buildings Using LSTM,” *Sustainability*, vol. 14, no. 20, p. 13358, Oct. 2022. <https://doi.org/10.3390/su142013358>
- [23] Y. Zhou, L. Wang, and J. Qian, “Application of Combined Models Based on Empirical Mode Decomposition, Deep Learning, and Autoregressive Integrated Moving Average Model for Short-Term Heating Load Predictions,” *Sustainability*, vol. 14, no. 12, p. 7349, Jun. 2022. <https://doi.org/10.3390/su14127349>
- [24] R. Pino-Mejías, A. Pérez-Fargallo, C. Rubio-Bellido, and J. A. Pulido-Arcas, “Comparison of linear regression and artificial neural networks models to predict heating and cooling energy demand, energy consumption and CO2 emissions,” *Energy*, vol. 118, pp. 24–36, Jan. 2017. <https://doi.org/10.1016/j.energy.2016.12.022>
- [25] T. C. Quevedo, M. S. Geraldi, and A. P. Melo, “Applying machine learning to develop energy benchmarking for university buildings in Brazil,” *Journal of Building Engineering*, vol. 63, Part. A, p. 105468, Jan. 2023. <https://doi.org/10.1016/j.jobe.2022.105468>
- [26] Y. Ma, J.-q. Yu, C.-y. Yang, and L. Wang, “Study on power energy consumption model for large-scale public building,” in *2010 2nd International Workshop on Intelligent Systems and Applications*, Wuhan, 2010, pp. 1–4. <https://doi.org/10.1109/IWISA.2010.5473608>
- [27] F. Gong, N. Han, D. Li, and S. Tian, “Trend Analysis of Building Power Consumption Based on Prophet Algorithm,” in *2020 Asia Energy and Electrical Engineering Symposium*, Chengdu, 2020, pp. 1002-1006. <https://doi.org/10.1109/AEEES48850.2020.9121548>
- [28] D. Zhao, M. Zhong, X. Zhang, and X. Su, “Energy consumption predicting model of VRV (Variable refrigerant volume) system in office buildings based on data mining,” *Energy*, vol. 102, pp. 660–668, May. 2016. <http://dx.doi.org/10.1016/j.energy.2016.02.134>
- [29] Y. Fu, Z. Li, H. Zhang, and P. Xu, “Using Support Vector Machine to Predict Next Day Electricity Load of Public Buildings with Sub-metering Devices,” *Procedia Engineering*, vol. 121, pp. 1016–1022, Jul. 2015. <https://doi.org/10.1016/j.proeng.2015.09.097>
- [30] C. Nichiforov, N. Arghira, G. Stamatescu, I. Stamatescu, I. Făgărăsan, and S. S. Iliescu, “Efficient Load Forecasting Model Assessment for Embedded Building Energy Management Systems,” in *2022 23rd IEEE International Conference on Automation, Quality and Testing, Robotics*, Cluj-Napoca, 2022, pp. 1-6. <https://doi.org/10.1109/AQTR55203.2022.9801969>
- [31] R. K. Jagait, M. N. Fekri, K. Grolinger, and S. Mir, “Load forecasting under concept drift: Online ensemble learning with recurrent neural network and ARIMA,” *IEEE Access*, vol. 9, pp. 98992–99008, 2021. <https://doi.org/10.1109/ACCESS.2021.3095420>

- [32] J. Brusokas, T. B. Pedersen, L. Šikšnys, D. Zhang, and K. Chen, “HeatFlex: Machine learning based data-driven flexibility prediction for individual heat pumps,” in *e-Energy 2021 - Proceedings of the 2021 12th ACM International Conference on Future Energy Systems*, New York, 2021, pp. 160–170. <https://doi.org/10.1145/3447555.3464866>
- [33] M. Gaur, S. Makonin, I. V. Bajic, and A. Majumdar, “Performance Evaluation of Techniques for Identifying Abnormal Energy Consumption in Buildings,” *IEEE Access*, vol. 7, pp. 62721–62733, 2019. <https://doi.org/10.1109/ACCESS.2019.2915641>
- [34] T. Fang and R. Lahdelma, “Evaluation of a multiple linear regression model and SARIMA model in forecasting heat demand for district heating system,” *Appl Energy*, vol. 179, pp. 544–552, Oct. 2016. <http://dx.doi.org/10.1016/j.apenergy.2016.06.133>
- [35] J.-S. Chou, S.-C. Hsu, N.-T. Ngo, C.-W. Lin and C.-C. Tsui, “Hybrid Machine Learning System to Forecast Electricity Consumption of Smart Grid-Based Air Conditioners,” *IEEE Syst J*, vol. 13, no. 3, pp. 3120–3128, Sep. 2019. <https://doi.org/10.1109/JSYST.2018.2890524>
- [36] J. A. Bello, H. Franco, and J. A. Fonseca, “Hybrid Model for Energy Consumption Forecasting in Buildings Stocks in Tropical Regions,” in *16th IBPSA International Conference and Exhibition, Building Simulation*, Rome, 2019. <https://doi.org/10.3929/ethz-b-000349218>
- [37] F. Harrou, T. Cheng, Y. Sun, T. O. Leiknes, and N. Ghaffour, “A Data-Driven Soft Sensor to Forecast Energy Consumption in Wastewater Treatment Plants: A Case Study,” *IEEE Sens J*, vol. 21, no. 4, pp. 4908–4917, Feb. 2021. <https://doi.org/10.1109/JSEN.2020.3030584>
- [38] S. Goudarzi, M. H. Anisi, S. A. Soleymani, M. Ayob, and S. Zeadally, “An IoT-Based Prediction Technique for Efficient Energy Consumption in Buildings,” *IEEE Transactions on Green Communications and Networking*, vol. 5, no. 4, pp. 2076–2088, Dec. 2021. <https://doi.org/10.1109/TGCN.2021.3091388>
- [39] S. S. Kumar, A. Kumar, S. Agarwal, M. Syafrullah, and K. Adiyarta, “Forecasting indoor temperature for smart buildings with ARIMA, SARIMAX, and LSTM: A fusion approach,” in *2022 9th International Conference on Electrical Engineering, Computer Science and Informatics*, Jakarta, 2022, pp. 186–192. <https://doi.org/10.23919/EECSI56542.2022.9946498>
- [40] J. N. Castillo, G. G. Carrillo, L. O. Freire, and B. P. Corrales, “Energy modeling and simulation of a building to perform sensitivity analysis of energy consumption,” *Energy Reports*, vol. 8, Suppl. 16, pp. 659–664, Dec. 2022. <https://doi.org/10.1016/j.egyr.2022.10.197>
- [41] R. D. Kutkarska and D. Y. Koeva, “Heat energy consumption forecast analysis: Model-oriented multi-objective approach,” in *Journal of Physics: Conference Series*, Varna, 2022. <https://doi.org/10.1088/1742-6596/2339/1/012003>
- [42] J. H. Yoon, R. Bladick, and A. Novoselac, “Demand response for residential buildings based on dynamic price of electricity,” *Energy Build.*, vol. 80, pp. 531–541, Sep. 2014. <https://doi.org/10.1016/j.enbuild.2014.05.002>
- [43] S. Duerr, C. Ababei, and D. M. Ionel, “SmartBuilds: An energy and power simulation framework for buildings and districts,” *IEEE Trans Ind Appl.*, vol. 53, no. 1, pp. 402–410, Feb. 2017. <https://doi.org/10.1109/TIA.2016.2611667>
- [44] J. Wang, S. Huang, D. Wu, and N. Lu, “Operating a commercial building HVAC load as a virtual battery through airflow control,” *IEEE Trans Sustain Energy*, vol. 12, no. 1, pp. 158–168, Jan. 2021. <https://doi.org/10.1109/TSSTE.2020.2988513>
- [45] C. Xu, Y. Li, X. Jin, L. Yuan, and H. Cheng, “A real-time energy consumption simulation and comparison of buildings in different construction years in the Olympic Central Area in Beijing,” *Sustainability*, vol. 9, no. 12, p. 2245, Dec. 2017. <https://doi.org/10.3390/su9122245>
- [46] A. Qiu, Z. Yan, Q. Deng, J. Liu, L. Shang, and J. Wu, “Modeling of HVAC Systems for Fault Diagnosis,” *IEEE Access*, vol. 8, pp. 146248–146262, 2020. <https://doi.org/10.1109/ACCESS.2020.3015526>
- [47] Y. Wei, S. Wang, H. Dang, and P. Liu, “Climate Adaptability Analysis on the Shape of Outpatient Buildings for Different Climate Zones in China Based on Low-Energy Target,” *Atmosphere*, vol. 13, no. 12, p. 2121, Dec. 2022. <https://doi.org/10.3390/atmos13122121>
- [48] B. Verbruggen and J. Driesen, “Grid impact indicators for active building simulations,” *IEEE Trans Sustain Energy*, vol. 6, no. 1, pp. 43–50, Jan. 2015. <https://doi.org/10.1109/TSSTE.2014.2357475>
- [49] J. Ferdyn-Grygierek, D. Bartosz, A. Specjał, and K. Grygierek, “Analysis of accuracy determination of the seasonal heat demand in buildings based on short measurement periods,” *Energies*, vol. 11, no. 10, p. 2734, Oct. 2018. <https://doi.org/10.3390/en11102734>
- [50] S. H. Alyami, A. A. Almutlaqa, A. M. Alqahtany, and N. Ashraf, “Likelihood of Reaching Zero Energy Building Design in Hot Dry Climate: Saudi Arabia,” *IEEE Access*, vol. 9, pp. 167054–167066, 2021. <https://doi.org/10.1109/ACCESS.2021.3134365>
- [51] H. Salem, K. Khanafer, M. Alshammari, A. Sedaghat, and S. Mahdi, “Cooling Degree Days for Quick Energy Consumption Estimation in the GCC Countries,” *Sustainability*, vol. 14, no. 21, p. 13885, Oct. 2022. <https://doi.org/10.3390/su142113885>



- [52] S. Samiuddin, I. M. Budaiwi, and M. A. Mohammed, "Impact of HVAC Operation and Air Distribution Schemes on Thermal Comfort and Energy Consumption in Intermittent High-Occupancy Buildings: A Case of Mosques," *Journal of Architectural Engineering*, vol. 29, no. 1, p. 04022039 Nov. 2023. <https://doi.org/10.1061/JAEIED.AEENG-1451>
- [53] D. Kadrić, A. Aganovic, E. Kadrić, B. Delalić-Gurda, and S. Jackson, "Applying the response surface methodology to predict the energy retrofit performance of the TABULA residential building stock," *Journal of Building Engineering*, vol. 61, p. 105307, Dec. 2022. <https://doi.org/10.1016/j.jobbe.2022.105307>
- [54] A. Rasheed, H. T. Kim, and H. W. Lee, "Modeling-Based Energy Performance Assessment and Validation of Air-To-Water Heat Pump System Integrated with Multi-Span Greenhouse on Cooling Mode," *Agronomy*, vol. 12, no. 6, p. 1374, Jun. 2022. <https://doi.org/10.3390/agronomy12061374>
- [55] D. Schiera *et al.*, "A Distributed Multimodel Platform to Cosimulate Multienergy Systems in Smart Buildings," *IEEE Trans Ind Appl*, vol. 57, no. 5, pp. 4428–4440, Oct. 2021. <https://doi.org/10.1109/TIA.2021.3094497>
- [56] F. Tahmasebinia, R. Jiang, S. Sepasgozar, J. Wei, Y. Ding, and H. Ma, "Implementation of BIM Energy Analysis and Monte Carlo Simulation for Estimating Building Energy Performance Based on Regression Approach: A Case Study," *Buildings*, vol. 12, no. 4, p. 449, Apr. 2022. <https://doi.org/10.3390/buildings12040449>
- [57] J. Cárdenas, G. Osma, C. Caicedo, A. Torres, S. Sánchez, and G. Ordóñez, "Building energy analysis of Electrical Engineering Building from DesignBuilder tool: Calibration and simulations," in *IOP Conference Series: Materials Science and Engineering*, Institute of Physics Publishing, 2016. <https://doi.org/10.1088/1757-899X/138/1/012013>
- [58] J. Cárdenas-Rangel, J. Jaramillo-Ibarra, and G. Osma-Pinto, "Estimation of the impact of energy efficiency measures recommended by Colombian legislation on the performance of low- and middle-income housing buildings," *Journal of Building Engineering*, vol. 52, p. 104402, Jul. 2022. <https://doi.org/10.1016/j.jobbe.2022.104402>
- [59] A. M. Bolteya, M. A. Elsayad, O. D. El Monayeri, and A. M. Belal, "Impact of Phase Change Materials on Cooling Demand of an Educational Facility in Cairo, Egypt," *Sustainability*, vol. 14, no. 23, p. 15956, Nov. 2022. <https://doi.org/10.3390/su142315956>
- [60] R. Olu-Ajayi, H. Alaka, I. Sulaimon, F. Sunmola, and S. Ajayi, "Building energy consumption prediction for residential buildings using deep learning and other machine learning techniques," *Journal of Building Engineering*, vol. 45, p. 103406, Jan. 2022. <https://doi.org/10.1016/j.jobbe.2021.103406>
- [61] N. Fumo and M. A. Rafe Biswas, "Regression analysis for prediction of residential energy consumption," *Renewable and Sustainable Energy Reviews*, vol. 47, pp. 332–343, Jul. 2015. <https://doi.org/10.1016/j.rser.2015.03.035>
- [62] S. Touzani, J. Granderson, and S. Fernandes, "Gradient boosting machine for modeling the energy consumption of commercial buildings," *Energy Build.*, vol. 158, pp. 1533–1543, Jan. 2018. <https://doi.org/10.1016/j.enbuild.2017.11.039>
- [63] A. Rahman, V. Srikumar, and A. D. Smith, "Predicting electricity consumption for commercial and residential buildings using deep recurrent neural networks," *Appl Energy*, vol. 212, pp. 372–385, Feb. 2018. <https://doi.org/10.1016/j.apenergy.2017.12.051>
- [64] C. Robinson *et al.*, "Machine learning approaches for estimating commercial building energy consumption," *Appl Energy*, vol. 208, pp. 889–904, Dec. 2017. <https://doi.org/10.1016/j.apenergy.2017.09.060>
- [65] M. Hao, S. Hejiang, L. Junjie, and W. Shen, "Developing window behavior models for residential buildings using XGBoost algorithm," *Energy Build.*, vol. 205, p. 109564, Dec. 2019. <https://doi.org/10.1016/j.enbuild.2019.109564>
- [66] Y. Liu, H. Chen, L. Zhang, X. Wu, X.-j. Wang, "Energy consumption prediction and diagnosis of public buildings based on support vector machine learning: A case study in China," *J Clean Prod.*, vol. 272, p. 122542, Nov. 2020. <https://doi.org/10.1016/j.jclepro.2020.122542>
- [67] V. J. Mawson and B. R. Hughes, "Deep learning techniques for energy forecasting and condition monitoring in the manufacturing sector," *Energy Build.*, vol. 217, p. 109966, Jun. 2020. <https://doi.org/10.1016/j.enbuild.2020.109966>
- [68] M. W. Ahmad, A. Mouraud, Y. Rezgui, and M. Mourshed, "Deep highway networks and tree-based ensemble for predicting short-term building energy consumption," *Energies*, vol. 11, no. 12, p. 3408, Dec. 2018. <https://doi.org/10.3390/en11123408>
- [69] L. G. B. Ruiz, M. C. Pegalajar, M. Molina-Solana, and Y.-K. Guo, "A case study on understanding energy consumption through prediction and visualization (VIMOEN)," *Journal of Building Engineering*, vol. 30, p. 101315, Jul. 2020. <https://doi.org/10.1016/j.jobbe.2020.101315>
- [70] S. Walker, W. Khan, K. Katic, W. Maassen, and W. Zeiler, "Accuracy of different machine learning algorithms and added-value of predicting aggregated-level energy performance of commercial buildings," *Energy Build.*, vol. 209, p. 109705, Feb. 2020. <https://doi.org/10.1016/j.enbuild.2019.109705>

- [71] N.-T. Ngo, “Early predicting cooling loads for energy-efficient design in office buildings by machine learning,” *Energy Build.*, vol. 182, pp. 264–273, Jan. 2019. <https://doi.org/10.1016/j.enbuild.2018.10.004>
- [72] X. Godinho, H. Bernardo, F. T. Oliveira, and J. C. Sousa, “Forecasting heating and cooling energy demand in an office building using machine learning methods,” in *2020 International Young Engineers Forum, YEF-ECE*, Costa de Caparica, 2020, pp. 1–6. <https://doi.org/10.1109/YEF-ECE49388.2020.9171807>
- [73] J. P. Mueller and L. Massaron, *Deep Learning for Dummies*, New Jersey, Wiley & Sons, 2019. [Deep Learning For Dummies | Wiley](https://www.wiley.com/9781119999999)
- [74] I. Goodfellow, Y. Bengio, and A. Courville, *Deep learning*, The MIT Press, 2016. [Deep Learning \(deeplearningbook.org\)](https://www.deeplearningbook.org/)
- [75] Z. Yu, F. Haghighat, B. C. M. Fung, and H. Yoshino, “A decision tree method for building energy demand modeling,” *Energy Build.*, vol. 42, no. 10, pp. 1637–1646, Oct. 2010. <http://dx.doi.org/10.1016/j.enbuild.2010.04.006>
- [76] D. Ramos, P. Faria, A. Morais, and Z. Vale, “Using decision tree to select forecasting algorithms in distinct electricity consumption context of an office building,” *Energy Reports*, vol. 8, Suppl. 3, pp. 417–422, Jun. 2022. <https://doi.org/10.1016/j.egyr.2022.01.046>
- [77] K. W. Mui, M. K. Satheesan, and L. T. Wong, “Building cooling energy consumption prediction with a hybrid simulation Approach: Generalization beyond the training range,” *Energy Build.*, vol. 276, p. 112502, Dec. 2022. <https://doi.org/10.1016/j.enbuild.2022.112502>
- [78] H. Yang, M. Ran, and C. Zhuang, “Prediction of Building Electricity Consumption Based on Joinpoint–Multiple Linear Regression,” *Energies*, vol. 15, no. 22, p. 8543, Nov. 2022. <https://doi.org/10.3390/en15228543>
- [79] X. Han, C. Zhang, Y. Tang, and Y. Ye, “Physical-data Fusion Modeling Method for Energy Consumption Analysis of Smart Building,” *Journal of Modern Power Systems and Clean Energy*, vol. 10, no. 2, pp. 482–491, Mar. 2022. <https://doi.org/10.35833/MPCE.2021.000050>
- [80] J. Ahmad *et al.*, “Energy demand forecasting of buildings using random neural networks,” *Journal of Intelligent & Fuzzy Systems*, vol. 38, no. 4, pp. 4753–4765, Apr. 2020. <https://doi.org/10.3233/JIFS-191458>
- [81] H. S. van der Bent, P. I. van den Brom, H. J. Visscher, A. Meijer, and N. Mouter, “The energy performance of dwellings of Dutch non-profit housing associations: Modelling actual energy consumption,” *Energy Build.*, vol. 253, p. 111486, Dec. 2021. <https://doi.org/10.1016/j.enbuild.2021.111486>
- [82] J. Joe *et al.*, “Development of Simplified Building Energy Prediction Model to Support Policymaking in South Korea—Case Study for Office Buildings,” *Sustainability*, vol. 14, no. 10, p. 6000, May. 2022. <https://doi.org/10.3390/su14106000>
- [83] M. S. Aliero, M. F. Pasha, A. N. Toosi, and I. Ghani, “The COVID-19 impact on air condition usage: a shift towards residential energy saving,” *Environmental Science and Pollution Research*, vol. 29, pp. 85727–85741, Jan. 2022. <https://doi.org/10.1007/s11356-021-17862-z>