

Universidad Autónoma de Querétaro

Facultad de Ingeniería

Maestría en Ciencias en Inteligencia Artificial

Optimización de la operación de un sistema HVAC para ahorro energético, mediante estrategias de Inteligencia Artificial

Tesis

Que como parte de los requisitos para obtener el grado de Maestro en Ciencias en Inteligencia Artificial

Presenta:

**Alma Eliza Guerrero Sánchez**

Dirigido por:

**Dr. Edgar Alejandro Rivas Araiza**

SINODALES

Dr. Edgar Alejandro Rivas Araiza  
Presidente

Dr. Jesús Carlos Pedraza Ortega  
Secretario

Dr. Saúl Tovar Arriaga  
Vocal

Dr. Jose Luis Gonzalez-Cordoba  
Suplente

Dr. Andrés Takacs  
Suplente

Centro Universitario Querétaro, QRO

Julio 2020

México.

*Para todas las mujeres que lucharon para que nosotras pudiéramos hacer lo que a ellas les negaron. Para todas las que no están, a las que les truncaron sus sueños. Para todas mis ancestas.*

*Nos sembraron miedo, nos crecieron alas.*

Dirección General de Bibliotecas UAQ

## **Agradecimientos.**

Al Consejo Nacional de Ciencia y Tecnología (CONACYT) por el apoyo para el desarrollo de esta investigación y al fondo mixto CONACyT-Gobierno del Estado de Querétaro (FOMIX-QRO-2016-02-279773) para la realización del presente trabajo. A la Universidad Autónoma de Querétaro UAQ y a la Facultad de Ingeniería. Al Doctor Rivas por todos los años de trabajo desde que estaba en la carrera de ingeniería, por darme la oportunidad de pertenecer a su equipo de trabajo y por orientarme para llegar a los objetivos que nos hemos puesto los últimos años. Al Doctor José Luis González y Doctor Andras Takacs por orientarme en la redacción de los artículos, en mi investigación y por empujarme a ir por más para sacar un mejor trabajo, a pesar del poco tiempo que llevamos trabajando hacemos un buen equipo. A mis profesores de la maestría Doctor Pedraza, Doctor Aceves, Doctor Emilio y Doctor Saúl. Por el apoyo y orientación para escribir y desarrollar esta investigación y por sus clases.

A mi Mamá Alma Isela y mis hermanos Ángel y Armando por el apoyo. Por estar conmigo en los momentos más pesados y difíciles. Pero sobre todo por las risas y buenos momentos porque gracias a eso sé que al final del día todo estará bien. Por enseñarme a enfrentar todas las adversidades que la vida pone, a ser fuerte, mantenerme positiva y ayudarme a explotar mis habilidades. A mi abuelita Guadalupe, mi madrina Beatriz, mi tía Juanita Sánchez, mi Bisabuela Vicenta Juárez y a todas mis tías maternas por enseñarme con el ejemplo a no rendirme, a

vivir una vida sencilla, a siempre seguir mis sueños y a ser una mujer fuerte en todos los sentidos.

A todos mis primos maternos, por el apoyo, los recuerdos y porque sé que siempre contaré con ellos de manera incondicional. A Monse por estar conmigo siempre en las buenas y en las malas, por ser tan buena amiga conmigo todos estos años, siempre tienes las palabras correctas que decirme. A Lupita por tantos años de amistad incondicional, recomendaciones de películas y videos, por tantos buenos recuerdos e historias que tenemos juntas.

Pero, sobre todo, a Dios y a la Virgen por permitirme llegar hasta donde estoy el día de hoy y por colocar a las personas que necesito en mi camino.

# ÍNDICE GENERAL

Dedicatoria	
Reconocimientos	
Índice General	I
Índice de Figuras	IV
Índice de Ecuaciones	VIII
Índice de Tablas	IX
Índice de Abreviaturas	X
Resumen	XI
Summary	XII
1 Introducción	1
1.1 Inteligencia Artificial .....	1
1.2 Planteamiento del Problema.....	3
1.3 Justificación.....	6
1.4 Objetivos.....	6
1.5 Hipótesis.....	7
1.6 Alcances.....	7
2 Antecedentes	9
2.1 Modelos matemáticos como estrategias de control en sistemas HVAC.....	9
2.2 Modelos de Inteligencia Artificial como estrategias de control en sistemas HVAC .....	13
2.3 Resumen.....	15

3 Materiales y Métodos	17
3.1 Metodología.....	17
3.2 Aprendizaje Automático .....	18
3.2.1 Regresión Lineal Múltiple.....	21
3.2.2 Regresión Forestal Aleatoria .....	22
3.3 Aprendizaje profundo .....	24
3.3.1 Redes Neuronales Artificiales.....	25
3.3.2 Long Short Term Memory.....	30
3.4 Métricas de Evaluación .....	32
3.5 Confort Térmico Y Consumo Eléctrico En Sistemas HVAC.....	35
3.5.1 Variables Ambientales y el Confort Térmico.....	35
3.5.1.1 Escala confort térmico de Fanger.....	37
3.5.2 Sistemas HVAC potencia y consumo energético.....	39
3.6 Monitoreo de variables ambientales por medio del Internet de las Cosas con Mecanismo Blockchain y encriptación simétrica.....	41
3.6.1 Redes de sensores Inalámbricas.....	41
3.6.2 Encriptación Simétrica y Mecanismo de Blockchain.....	43
3.6.3 Arquitectura final y pruebas de rendimiento. ....	47
3.7 Materiales.....	52
4 Pruebas y Resultados	60
4.1 Desempeño de modelos de predicción.....	60
4.2 Modelos y Metodología de pruebas .....	65

4.3 Potencia y Consumo de Energía.....	68
4.3.1. Consumo eléctrico de Sistema de climatización de 1 tonelada.....	68
4.3.2 Consumo eléctrico de Sistema de climatización de 1.5 toneladas.....	71
4.3.3 Consumo eléctrico de un sistema de climatización de 2.....	74
4.4 Confort térmico.....	77
4.4.1 Análisis de Confort térmico sistema HVAC de 1 tonelada.....	78
4.4.2 Análisis de Confort térmico sistema HVAC de 1.5 toneladas.....	83
4.4.3 Análisis de Confort térmico sistema HVAC de 2 toneladas.....	85
5 Conclusiones y Trabajo Futuro.....	89
Referencias.....	91
Anexos.....	97

# ÍNDICE DE FIGURAS

Figura 1. Campos de la Inteligencia Artificial.....	2
Figura 2 Consumo energético por Sectores.....	4
Figura 3 Distribución de consumo energético.....	5
Figura 4. Mapa Climatológico del Estado de Querétaro.....	8
Figura 5. Metodología.....	18
Figura 6. Tipos de Aprendizaje.....	20
Figura 7. Pseudo Código Método del Gradiente Descendiente.....	22
Figura 8. Pseudo Código de regresión Forestal Aleatoria	24
Figura 9 Arquitectura de una Neurona.....	26
Figura 10. Arquitectura básica de una red neuronal.....	28
Figura 11. Estructura de una neurona LSTM.....	30
Figura 12. Diagrama de redes neuronales.....	31
Figura 13. Diagrama k-fold .....	35
Figura 14. Escala Confort Fanger.....	38
Figura 15 Esquema de funcionamiento de encriptación AES.....	44
Figura 16 Estructura básica de un bloque de Blockchain.....	45
Figura 17 Enlace de cubos de Blockchain.....	46
Figura 18 Diagrama de Red De sensores Inalámbrica.....	47
Figura 19 Arquitectura de Propuesta para redes de sensores inalámbricas con encriptación simétrica y mecanismo de Blockchain. ....	48



Figura 20 Nodos de Sensores Inalámbricos. ....	48
Figura 21 Sensor Telaire T9602. Microcontrolador Wipy 3.0 .....	49
Figura 22.- Visualización de datos ambientales en software Grafana.....	50
Figura 23 Temperatura del hardware.....	51
Figura 24 Porcentaje de uso de la CPU.....	51
Figura 25 Diagrama simulación EnergyPlus.....	53
Figura 26 Modelo de Base de datos.....	54
figura 27 Grafica temperatura externa e interna.....	54
Figura 28. Grafica Humedad Externa e Interna.....	55
Figura 29. Grafica Radiación solar.....	56
Figura 30 Metodología para entrenamiento de modelos predictivos.....	57
Figura 31 Diagrama del proceso de simulación 3D.....	58
Figura 32 Captura de modelo 3D en Autodesk CFD 2019.....	59
Figura 33 Curva de entrenamiento RLM.....	60
Figura 34 Curva de entrenamiento Random Forrest con Sobreajuste.....	61
Figura 35 Curva de aprendizaje Regresión Forestal Aleatoria.....	61
Figura 36. Curva de aprendizaje Red Neuronal LSTM con sobreajuste.....	62
Figura 37. Arquitectura Inicial para pruebas.....	62
Figura 38 Curva de aprendizaje Red Neuronal LSTM. ....	63
Figura 39 Arquitectura de red Neuronal LSTM.....	63
Figura 40 Metodología para probar Estrategias de Control.....	65

Figura 41 Modelo 1 .....	66
Figura 42 Modelo 2 .....	66
Figura 43 Modelo 3.....	67
Figura 44 Graficas de potencia de sistema HVAC de 1 Tonelada control RLM.....	69
...	
Figura 45 Graficas de potencia de sistema HVAC de 1 Tonelada control RF.....	70
Figura 46 Graficas de potencia de sistema HVAC de 1 Tonelada control LSTM.....	71
Figura 47 Graficas de potencia de sistema HVAC de 1.5 Tonelada control RLM .....	72
Figura 48 Graficas de potencia de sistema HVAC de 1.5 Tonelada control RF.....	73
Figura 49 Graficas de potencia de sistema HVAC de 1.5 Tonelada control LSTM.....	73
Figura 50 Graficas de potencia de sistema HVAC de 1.5 Tonelada control RLM.....	74
Figura 51 Graficas de potencia de sistema HVAC de 1.5 Tonelada control RF .....	75
Figura 52 Graficas de potencia de sistema HVAC de 1.5 Tonelada control LSTM....	76
Figura 53 Modelo de casa de un piso vista térmica.....	78
Figura 54 Modelo de casa de un piso vista térmica.....	78
Figura 55 Modelo de casa de un piso vista térmica.....	79
Figura 56 Modelo de casa de un piso vista térmica.....	79
Figura 57 Confort térmico simulación en casa de un piso.....	80
Figura 58 Confort térmico simulación en casa.....	80
Figura 59 Confort térmico simulación en casa de un piso.....	81
Figura 60 Confort térmico simulación en casa de un piso.....	81
Figura 61. Confort térmico simulación en casa de un piso.	82

Figura 62 Confort térmico simulación en oficina.....	83
Figura 63. Confort térmico simulación.....	83
Figura 64 Confort térmico simulación en una oficina.....	84
Figura 65 Confort térmico simulación en una oficina.....	84
Figura 66 Confort térmico simulación en una oficina.....	85
Figura 67. Confort térmico simulación en una sala de exhibición.....	85
Figura 68. Confort térmico simulación en una sala de exhibición.....	86
Figura 69 Confort térmico simulación en una sala de exhibición.....	86
Figura 70 Confort térmico simulación en una sala de exhibición.....	87
Figura 71 Confort térmico simulación en una sala de exhibición.....	87
Figura 72 Confort térmico simulación en una sala de exhibición.....	88
Figura 73 Confort térmico simulación en una sala de exhibición.....	88

# ÍNDICE DE ECUACIONES

Ecuación 1. Modelo de control predictivo lineal .....	12
Ecuación 2 Ley de Enfriamiento De Newton.....	13
Ecuación 3. Ecuaciones de restricción .....	13
Ecuación 4. Predicted Mean Vote.....	14
Ecuación 5 Ecuación de modelos lineales múltiples.....	23
Ecuación 6 Función Sigmoide.....	28
Ecuación 7 Función tangente hiperbólica.....	28
Ecuación 8 Root-Mean-Square Error.....	33
Ecuación 9 Coeficiente de Determinación.....	33
Ecuación 10 Mean Absolute Error.....	33
Ecuación 11 Mean Absolute Percentage Error.....	33
Ecuación 12 Normalización MinMax.....	52

## ÍNDICE DE TABLAS

Tabla 1. Factores que influyen en el comportamiento térmico .....	34
Tabla 2 Tabla de Consumo y potencia en sistemas HVAC .....	38
Tabla 3. Parámetros de entrada.....	53
Tabla 4 Parámetro de salida .....	53
Tabla 5 Desempeño de modelos de predicción de datos.....	59
Tabla 6 Porcentaje de precisión de los modelos predictivos.....	60
Tabla 7. Consumo de energía de sistemas HVAC.....	72

## Índice de Abreviaturas.

HVAC	Heating, ventilating and Air conditioning
RF	Random Forrest
ML	Machine Learning
DL	Deep Learning
LSTM	Long Short Term Memory
RNA	Redes Neuronales Artificiales
CFD	Computational Fluid Dynamics
PVM	Predicted Mean Vote
ASHRAE	American Society of Heating, Refrigerating, and Air-Conditioning Engineers

# Resumen

El uso de un modelo de control predictivo para sistemas de gestión de energía se está volviendo más popular. Estos sistemas controlan el rendimiento del edificio basándose en un pronóstico del control basado en un modelo de edificio. Las incertidumbres en la operación del edificio son un problema importante en el uso del modelo de control predictivo, ya que disminuyen la precisión del pronóstico. Esto incluye los requisitos térmicos variables del usuario. El objetivo de esta tesis es desarrollar un predictor de temperatura de confort para sistemas HVAC controlables individualmente en función de las condiciones climáticas utilizando técnicas de inteligencia artificial. Para este propósito, se presentan los fundamentos del confort interior y el aprendizaje automático y aprendizaje profundo. Se revisan las tendencias recientes en la investigación sobre inteligencia artificial en edificios. Se explica la metodología para desarrollar y probar el predictor de temperatura de confort. Posteriormente se describen los resultados de pronosticar la temperatura de confort y el impacto energético del predictor.

Los resultados muestran que las herramientas de regresión de aprendizaje automático y aprendizaje profundo pueden predecir las temperaturas de confort en función de las condiciones climáticas con suficiente precisión, mejor que los puntos de ajuste de temperatura comunes actualmente. La tesis se cierra con una revisión de la herramienta, una perspectiva hacia sus mejoras y aplicaciones, y el impacto general del aprendizaje automático y aprendizaje profundo en el sector de la construcción.

**Palabras clave:** Confort Térmico, Inteligencia Artificial, Aprendizaje Automático, Aprendizaje Profundo, Control Predictivo.

# Summary

The use of a predictive control model for energy management systems is becoming more popular. These systems monitor building performance based on a control forecast based on a building model. Uncertainties in building operation are a major problem in the use of the predictive control model, as they decrease forecast accuracy. This includes variable user thermal requirements. The objective of this thesis is to develop a comfort temperature predictor for individually controllable HVAC systems depending on weather conditions using artificial intelligence techniques. For this purpose, the fundamentals of interior comfort and machine learning and deep learning are presented. Recent trends in Artificial Intelligence research in buildings are reviewed. The methodology for developing and testing the comfort temperature predictor is explained. The results of forecasting the comfort temperature and the energy impact of the predictor are described below.

The results show that machine learning and deep learning regression tools can predict comfort temperatures based on weather conditions with sufficient accuracy, better than today's common temperature set points. The thesis closes with a review of the tool, a perspective towards its improvements and applications, and the general impact of machine learning and deep learning in the construction sector

**Key words:** Thermal Comfort, Artificial Intelligence, Machine Learning, Deep Learning, Predictive Control.



## Introducción.

En esta tesis se presenta la aplicación de técnicas de inteligencia artificial en el control del punto de ajuste de un sistema Heating, Ventilating and Air Conditioning (HVAC, por sus siglas en inglés) a partir de la medición de variables de ambiente que influyen en el comportamiento térmico de un edificio. Se presenta el desarrollo de técnicas del campo de aprendizaje automático (Machine Learning, ML) y aprendizaje profundo (Deep Learning, DL). Las pruebas del sistema de control inteligente se llevaron a cabo en tres diferentes modelos de edificios. Una casa convencional de un piso, una sala de exhibición de un museo y una oficina. Son los modelos que se utilizaron en esta investigación con el fin de probar los sistemas de control inteligentes modelados con metodologías de predicción de datos pertenecientes a las áreas de aprendizaje automático y aprendizaje profundo.

### 1.1 Inteligencia Artificial

Según la Real Academia de la Lengua (RAE) define la Inteligencia Artificial (IA) como “Disciplina científica que se ocupa de crear programas informáticos que ejecutan operaciones comparables a las que realiza la mente humana, como el aprendizaje o el razonamiento lógico” [1]. La inteligencia artificial (IA) es una rama amplia de la ciencia de la computación que se ocupa de construir máquinas inteligentes capaces de realizar tareas que generalmente requieren inteligencia humana [2]. La IA es una ciencia interdisciplinaria con múltiples enfoques, pero los avances en el aprendizaje automático y el aprendizaje profundo están creando un cambio de paradigma en prácticamente todos los sectores de la industria tecnológica [3]. Como lo dice su definición por la RAE la IA busca simular la habilidad de la inteligencia humana para la resolver un problema u optimizar una solución que se tiene en un problema, utilizando los paradigmas de programación que tenemos

actualmente Redes Neuronales Artificiales (Artificial Neural Network, ANN), Aprendizaje Automático (Machine Learning, ML), Computación Evolutiva (Evolutionary Computation), Inteligencia de Enjambre (Swarm Intelligence), Sistemas Difusos (Fuzzy Systems), entre otros. Gran parte de la inteligencia artificial estrecha está impulsada por los avances en el aprendizaje automático y el aprendizaje profundo, los cuales son campos dentro de la Inteligencia Artificial (figura 1).

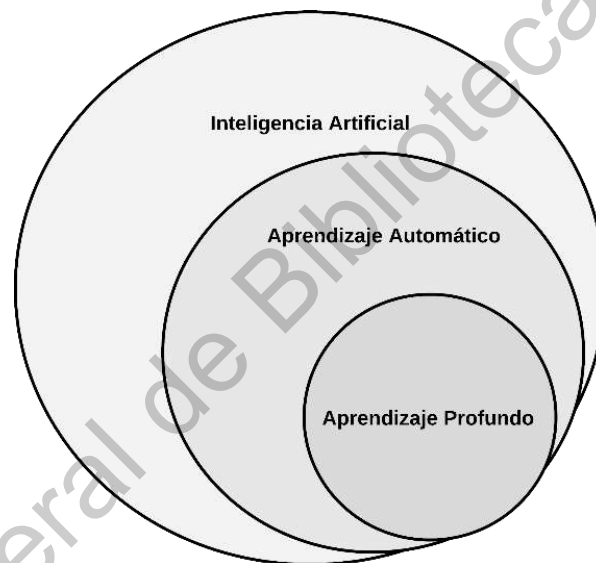


Figura 1. Campos de la Inteligencia Artificial. (Fuente Propia)

El aprendizaje automático alimenta los datos de una computadora y utiliza técnicas estadísticas para ayudarlo a "aprender" cómo mejorar progresivamente en una tarea, sin haber sido programado específicamente para esa tarea, eliminando la necesidad de millones de líneas de código escrito [4]. El aprendizaje automático consiste tanto en aprendizaje supervisado (usando conjuntos de datos etiquetados) como en aprendizaje no supervisado (usando conjuntos de datos no etiquetados) [5]. El aprendizaje profundo es un tipo de aprendizaje automático que ejecuta entradas a través de una arquitectura de red neuronal inspirada biológicamente [6]. Las redes neuronales contienen una serie de capas ocultas a través de las cuales se procesan los datos, lo que permite que la máquina profundice en su aprendizaje,

haciendo conexiones y entradas de ponderación para obtener los mejores resultados [7].

## 1.2 Planteamiento del Problema

El crecimiento de la población y el desarrollo constante de las naciones ha incrementado la demanda de energía [8]. La energía se ha convertido en un factor clave para el crecimiento de una nación. Hasta ahora los combustibles fósiles han sido uno de los mayores recursos para la producción de energía [9]. Con el incremento en la demanda de energía, los recursos no renovables han ido causando un desgaste en la capa de ozono y de igual forma causan cambios climáticos en la tierra como calentamiento global, aumento en el nivel de los océanos entre otras cosas [10]. Para detener el impacto que genera en la tierra por el frecuente de combustibles fósiles, la mayoría de las investigaciones en el área de energía se enfocan primariamente en la eficiencia y la economía del consumo, así como la generación de nuevas fuentes de poder como lo son energía solar, energía eólica entre otras. Sin embargo, para poder liberarnos totalmente de las energías no renovables y trabajar de total con energías renovables tomará algunas décadas. Es por esto que mientras tanto la eficiencia en la energía se centra en la reducción del consumo energético.

El mantenimiento y la optimización de casas residenciales consiste en la mejora del desempeño en áreas como consumo energético, calidad de aire, entre otras características [11]. Para la evaluación del desempeño en casas residenciales debemos identificar qué tipos de energía se consume (eléctrica, solar, eólica, entre otras) y que área es la más demandante. Del total del consumo eléctrico normalmente es distribuido en iluminación, climatización, equipamiento (cafeteras, refrigeradores, microondas, ascensores, entre otros) [12].

En la figura 2 observamos una gráfica de los sectores con mayor consumo

energético a nivel mundial. Según datos de la Agencia Internacional de Energía (IEA por sus siglas en inglés, International Energy Agency), el sector que presenta un mayor porcentaje son los edificios, en esta categoría se encuentra casas residenciales, casas convencionales, bloques de departamentos y edificios con oficinas [13].




Figura 2 Consumo energético en diferentes Sectores. (Fuente Propia)

En la figura 3 se presenta una gráfica donde se muestra el consumo de energía en una casa convencional. Según [14] la distribución de energía en el hogar se divide entre la climatización, el sistema hidráulico (agua caliente), electrodomésticos, cocina y la iluminación. Siendo la climatización el que el mayor porcentaje de distribución en una casa convencional.

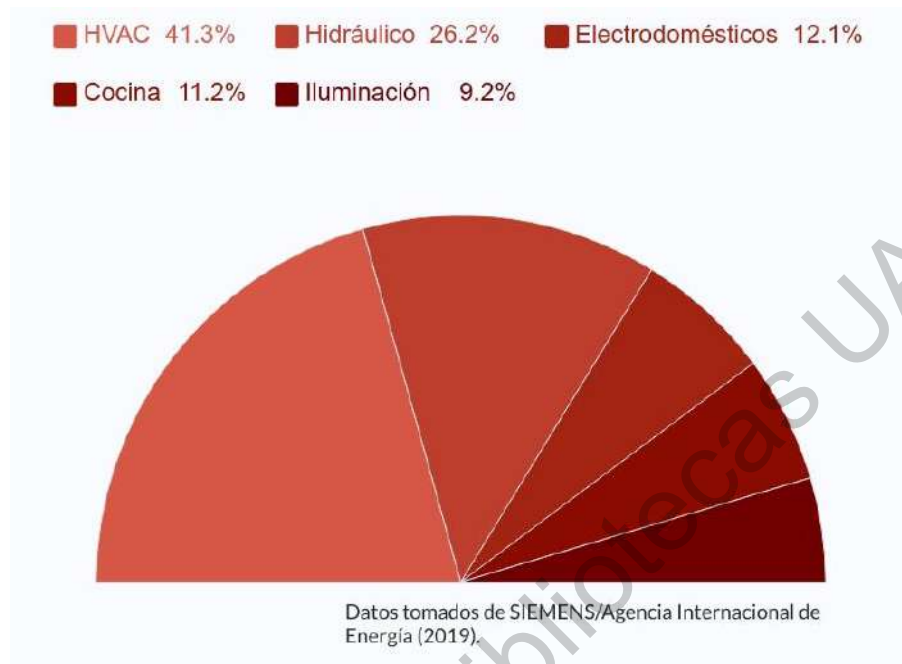


Figura 3. Distribución de consumo energético. (Fuente Propia)

Las estrategias de control tradicionales de los sistemas HVAC son muy sencillas basadas en un termostato o en un control remoto que el usuario manipula de acuerdo a las necesidades de climatización que requiera en ese momento. Este tipo de controles tradicionales en los sistemas HVAC generan un alto consumo energético y una vida productiva corta en el sistema de climatización [15]. Es por esto que desarrollar formas de control eficientes es crucial para la reducción del consumo energético de los sistemas HVAC y para incrementar la vida productiva de los sistemas de climatización.

La propuesta es utilizar un control utilizando metodologías de la inteligencia artificial en los sistemas HVAC con en las variables ambientales que interactúan en un edificio. Se proyecta la reducción del consumo energético, aumentar la productividad de los sistemas HVAC y mejorar la calidad del aire en los espacios donde el sistema de climatización se encuentre en funcionamiento.

## **1.3 Justificación**

Existen alternativas para el control inteligente de los sistemas de ventilación como los termostatos de aprendizaje, controles PID, controles basados en el método de Fanger. Sin embargo, algunos son programables según las preferencias y horario de los usuarios, otros se basan en datos muy explícitos como la ropa y las actividades que se realizan en el espacio donde el sistema de ventilación se encuentra [16]. Estos métodos de control ocasionan variaciones bruscas de temperatura en los sistemas que pueden indicar la necesidad de un control más preciso y totalmente automatizado obteniéndolo mediante dispositivos electrónicos especiales [17].

Al desarrollar controles más precisos pueden involucrar desde variables complejas dentro del sistema de ventilación hasta datos más personales de los usuarios o llevar un control del número de personas que se encuentran dentro del espacio [18]. Este tipo de controles suelen ser más complejos computacionalmente y conseguir los datos que requieren suelen llevar una instrumentación más compleja. Es por eso que al utilizar controles utilizando variables más accesibles o menos personales de los usuarios. Además de asegurar que no generan cambios bruscos en la temperatura, ya que estos cambios generan más consumo eléctrico y reducen la vida productiva del sistema de ventilación.

## **1.4 Objetivos.**

### **Objetivo General**

Implementar técnicas de inteligencia artificial para la optimización de variables de ambiente y del ahorro de energía en un sistema HVAC tradicional.

## Objetivos Específicos

- Generar un banco de pruebas para la adquisición y análisis de datos ambientales bajo la acción de un sistema HVAC para el confort térmico.
- Generar una base de datos de dichas variables ambientales.
- Desarrollar una metodología de optimización para ajustar las secuencias de presión del sistema HVAC.
- Evaluar el desempeño del algoritmo implementado.
- Cuantificar las variaciones en las variables ambientales y el ahorro energético en el sistema propuesto.

### 1.5 Hipótesis

El uso de algoritmos de inteligencia artificial permite optimizar la operación de un sistema HVAC para ahorrar energía eléctrica y mantener las variables ambientales en los niveles deseados con un margen de error aceptable.

### 1.6 Alcances

La presente investigación aborda el tema de reducción del consumo energético en un edificio a través del uso adecuado de los sistemas HVAC a partir del comportamiento térmico. Los factores que afectan el comportamiento térmico en un edificio se definen a profundidad en capítulos más adelante. Pero es importante dejar en claro que la ubicación geográfica afecta en los resultados de consumo de energía y en el punto de ajuste, así como en las normas para evaluar el confort térmico. La investigación que se desarrolla en esta tesis es dentro de México en

específico, el estado de Querétaro. El cual, según fuentes del INEGI, el 51% de la superficie del estado presenta clima seco y semiseco localizado en la región centro; el 24.3% presenta clima cálido subhúmedo en la región de la Sierra Madre Oriental; el 23% presenta clima templado subhúmedo localizado en la región sur, centro y noreste; el 1% presenta clima cálido húmedo hacia el noreste y el restante 0.7% presenta clima templado húmedo al noreste de estado [19]. Además, la temperatura media anual del estado es de 18°C, la temperatura máxima promedio es de 28°C y se presenta en los meses de abril y mayo, la temperatura mínima promedio es de 6°C durante el mes de enero. En la figura 4 se presenta un mapa climatológico de la región.

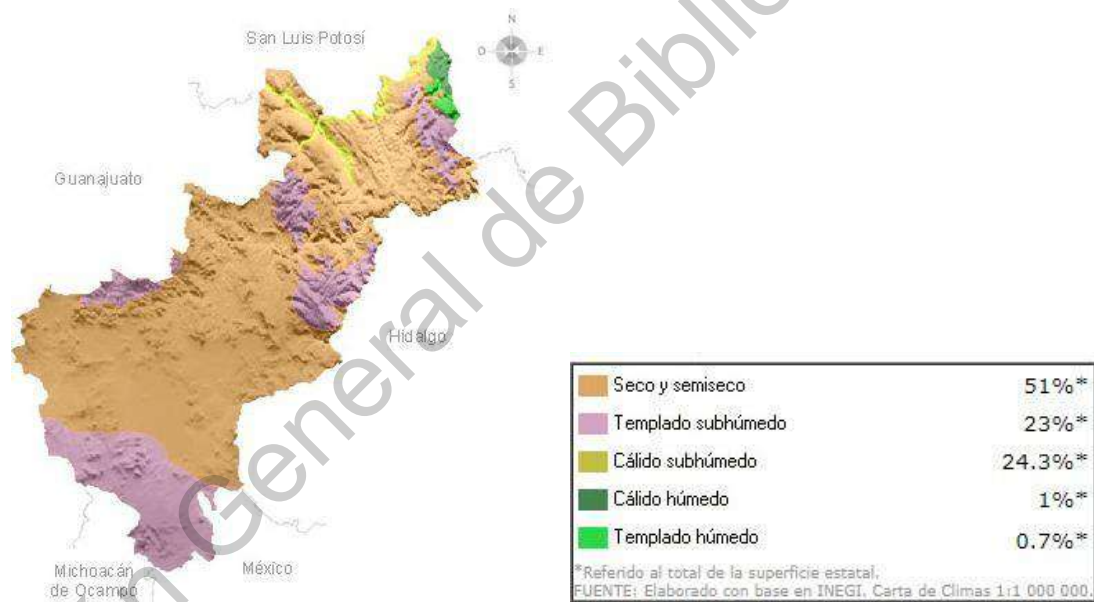


Figura 4. Mapa climatológico del Estado de Querétaro. (Fuente INEGI)

Es importante este punto dado que los datos utilizados para el entrenamiento y pruebas de las metodologías son pertenecientes a la región del estado de Querétaro. Si este control se aplica a regiones externas donde la climatología es diferente el sistema pudiera tener el desempeño que se espera.



### **Antecedentes.**

La reducción del consumo energético en sistemas como de iluminación, ventilación entre otros. Han sido principales temas de investigación en edificios o casas-habitación, esto para mejorar el desempeño de los recursos que se utilizan. Es por esto que existe una amplia gama de investigaciones cuyo objetivo es optimizar un sistema HVAC para el ahorro energético. Los autores que aquí se presentan se dividen en dos paradigmas, el basado en modelos matemáticos y el paradigma basado en estrategias de inteligencia artificial. Es importante mencionar el paradigma del control basado en modelos matemáticos. Puesto que antes de que la inteligencia artificial tomara valor en esta área, el paradigma matemático proponía controles inteligentes eficientes para sus propósitos, complejos varios en ámbitos como el computacional. Además, es interesante ver algunas semejanzas entre ambos ámbitos y como la inteligencia artificial brinda la misma solución con un planteamiento menos complejo.

### **2.1 Modelos matemáticos como estrategias de control en sistemas HVAC.**

Existen estudios basados en modelos dinámicos de fluidos, este tipo de modelos regularmente son utilizados en estudios hidráulicos pero el autor [20] propone un estudio basado en dos tipos de modelos dinámica de fluidos computacional (Computational Fluid dynamic, CFD por sus siglas en inglés) y simulación dinámica de carga de enfriamiento con el objetivo de predecir el comportamiento térmico en un edificio de oficinas. El modelo de HVAC que utilizan para el desarrollo y aplicación de este proyecto lo denominan como sistema de distribución de aire debajo del piso (Under-Floor Air Distribution,UFAD) este modelo

12 tiene como ventaja que ofrece una oportunidad para reducir la carga de enfriamiento en la zona ocupada. Para demostrar el método, se realiza una implementación en una sala de oficina utilizando datos meteorológicos de Hong Kong. Con el suministro de volumen de aire constante en el sistema UFAD, se encuentra que el coeficiente de temperatura adimensional es casi constante, cuando las ubicaciones de las fuentes de calor son fijas. En los resultados y conclusiones el autor demuestra que su propuesta proporciona ahorro de energía dado que proporciona tres factores: un tiempo de enfriamiento libre prolongado, una carga de ventilación reducida y mayores coeficientes de rendimiento para enfriadores. Esto gracias a los modelados basados en las teorías y formulas CFD.

En el trabajo desarrollado por [21] aplica un modelo de control predictivo estocástico para la automatización de un sistema HVAC en un edificio utilizando la predicción climática esto con el objetivo del uso eficiente de la energía en un edificio. La estrategia de control que aplica el autor es el Modelo Control Predictivo (Model Predictive Control, MPC) en la ecuación 1 podemos ver la fórmula del modelo.

$$MPC = \sum_{i=1}^N w_{x_i} (r_i - x_i)^2 + \sum_{i=1}^N w_{u_i} \Delta u_i^2 \quad (1)$$

Donde las variables representan;  $X_i$  es la variable controlada (p. ej. temperatura medida),  $r_i$  es una variable de referencia (p. ej. temperatura requerida),  $u_i$  es variable manipulada (p. ej. válvula de control, punto de ajuste),  $w_i$  es coeficiente de ponderación que refleja la importancia relativa de  $X_i$  y finalmente,  $w_i$  es Coeficiente de ponderación que penaliza cambios relativos grandes en  $u_i$ . El modelo es probado en un software de simulación de desempeño de edificios llamado TRNSYS según el autor se logró reducir el consumo energético en un 4% en comparación del consumo energético que se tenía antes de implementar la metodología. Este modelo es uno de los más implementados no solo en edificios, de igual forma en casas residenciales, centros comerciales, entre otros.

Otro modelo matemático propuesto por [22] presenta un modelo térmico semi-no lineal una ecuación diferencial ordinaria, con parámetros como funciones no lineales de temperatura ambiente y caudal de aire de enfriamiento. Que el autor deduce a partir de la ley de enfriamiento de Newton.

$$\frac{dT}{dt} = k(A - T) \quad (2)$$

Donde T es la temperatura de un cuerpo en el tiempo t, A la temperatura del medio y k es una constante positiva. Para validar el rendimiento del modelo, se modela un edificio de tres habitaciones, equipado con un sistema de aire acondicionado, y se resuelven las ecuaciones de Navier-Stokes para simular la evolución temporal de las temperaturas para diferentes temperaturas ambientales y caudales de aire de enfriamiento. La alta precisión de predicción del modelo térmico propuesto lo convierte en un candidato potencial para el diseño de un regulador de temperatura óptimo.

El autor [23] se centraliza en la optimización de los controles de los sistemas de aire acondicionado y ventilación de mecanismos en los edificios. Es por esto que su propuesta es un modelo de controlador de temperatura óptimo basado en control predictivo (MPC) que a diferencia al presentado en la referencia [21], esta propuesta está basada en restricciones.

$$\begin{aligned} U_{min} &\leq u(t) \leq U_{max} \\ \Delta U_{min} &\leq u(t) - u(t-1) \leq \Delta U_{max} \\ y_{min} &\leq y(t) \leq U_{max} \end{aligned} \quad (3)$$

Donde los subíndices min y max significan valor mínimo y máximo respectivamente, u(t) y Δu(t) son la señal de entrada y el valor de cambio, y y (t) es la salida. El controlador MPC propuesto integra la termodinámica del edificio, los datos de ocupación, los datos de pronóstico del tiempo, así como los modelos de

componentes ACMV para minimizar el consumo de energía y estabilizar la temperatura del edificio. En este artículo se concluye que, en los estudios de simulación, el controlador MPC propuesto puede lograr hasta un 18,2% de ahorro de energía con diferentes configuraciones de regulación de temperatura.

En el trabajo desarrollado por [24] muestra la aplicación de un modelo matemático para la predicción del confort y comportamiento térmico en un edificio. Voto medio previsto (Predicted Mean Vote, PMV) es un modelo matemático que es muy frecuente en estudios de este tipo, esta modelo no se enfoca en el consumo eléctrico de un edificio solo se puntualiza en el confort térmico de los ocupantes.

$$PMV=(0.303e^{-0.036M}+0.028) L \quad (4)$$

Donde PMV es el Predicted Mean Vote, M es el tasa metabólica y L representa la carga térmica, definida como la diferencia entre la producción interna de calor y la pérdida de calor en el entorno real, para una persona con la temperatura de la piel confortable y la pérdida de calor por evaporación al sudar al nivel de actividad real. PMV es un modelo matemático que eran muy utilizado para el estudio del comportamiento térmico en edificios antes de la aplicación de metodologías más óptimas, daban resultados relativamente buenos, pero solo se enfocan en el confort térmico no en el ahorro de energía ni en la calidad del aire en los espacios cerrados. El autor se enfoca en dos puntos en su aportación que tan buenos son los modelos en su desempeño y en la comparación de ambos modelos. Para la evaluación de desempeño y el error de los modelos el autor utiliza la base de datos de confort termal de la asociación ASHRAE. En las conclusiones el autor destaca como PMV es un mejor modelo para la predicción del confort termal.

## 2.2 Modelos de Inteligencia Artificial como estrategias de control en sistemas HVAC

En el trabajo desarrollado por [25] utilizó el programa EnergyPlus para simular el consumo de energía de los sistemas de climatización en edificios de oficinas. Los datos medidos de energía de las oficinas se utilizaron para validar los resultados simulados. Al utilizar el comportamiento real de las oficinas, la diferencia entre los resultados simulados y los datos medidos fue inferior al 13%. Cuando se implementó un modelo conductual de red neuronal artificial (ANN) en la simulación de energía, la simulación de energía se realizó tan bien como el comportamiento real del ocupante. Sin embargo, la simulación de energía usando el punto de ajuste constante del termostato sin considerar el comportamiento de los ocupantes no fue precisa. Otras simulaciones demostraron que ajustar el punto de ajuste del termostato y el nivel de vestimenta de los ocupantes podría generar una variación del 25% en el uso de energía en las oficinas interiores y del 15% en las oficinas exteriores. Los datos de comportamiento obtenidos de los otros edificios revelaron una menor ocurrencia de comportamiento entre los ocupantes, y la simulación de energía con el modelo de comportamiento ANN calculó una zona de confort más amplia y una mayor variación en el uso de energía debido al comportamiento de los ocupantes. Finalmente, el consumo de energía podría reducirse en un 30% con el control de retroceso del termostato y en un 70% con el control de ocupación.

En el trabajo desarrollado por [26] el autor desarrolla una simulación en el software energy plus. Además, para el control inteligente utiliza metodologías como autorregresión con perturbación externa (ARX) y la regresión de vectores de soporte (SVR). El autor propone tres casos de simulación para probar ambos modelos y compararlo con un control tradicional. Teniendo como resultado que la regresión de vectores de soporte obtiene un desempeño más relevante, ahorrando cerca de un 30% de energía.

En el trabajo desarrollado por [27] propone tres modelos de edificios y espacios completamente diferentes entre ellos. El autor realiza la implementación de una red neuronal artificial para el control de punto de ajuste en el sistema HVAC de los tres modelos. En los resultados reporta el buen desempeño del modelo de red neuronal, el autor reporta un ahorro energético entre 4.4% y 19.23%. Esta reducción energética en comparación a otras metodologías pudiera ser vista como baja, pero en sistemas de ventilación residenciales son buenos porcentajes.

En el trabajo desarrollado por [28] pronosticar con precisión la energía de enfriamiento del edificio necesaria por hora para los edificios educativos de la Universidad Tecnológica de Iraq. Los autores optaron por una red neuronal artificial de alimentación directa (feed forward artificial neural network) para desarrollar dicho sistema de predicción. Para evaluar el rendimiento del modelo ANN optimizado, se ha adoptado el coeficiente de correlación (R). Para los resultados de la predicción demostraron que el modelo ANN optimizado tiene una alta precisión de predicción con 0.9994, respectivamente. Recordando que en esta métrica de evaluación los valores van desde 0 a 1, mientras más alto sea el valor mejor. Si se tiene un valor negativo existe un caso de sobreajuste y si se tiene un valor arriba de 1 se tiene un caso de subajuste.

En el trabajo desarrollado por [29] prueba seis diferentes técnicas dentro del aprendizaje automático con el objetivo de predecir el confort térmico y así reducir el consumo eléctrico. El autor realiza las pruebas con Classification Tree, Gaussian Process Classification, Gradient Boosting Method, Kernel Support Vector Machine, Random Forest, Regularized Logistic Regression. En los resultados presenta como random forest, kernel support vector machine y logistic regression, como las metodologías que mayor precisión tuvieron.

En el trabajo desarrollado por [30] propuso una estrategia de control inteligente utilizando técnicas de aprendizaje automático junto con su proceso de

diseño para crear un clima interior centrado en los ocupantes. Se verificaron entre un 4% y un 25% de ahorro de energía potencial y la mejora del confort de temperatura mediante una prueba del mundo real. Los autores extraen cuatro variables esenciales de cuatro dominios: tiempo, climas interiores y exteriores, y comportamiento de los ocupantes, para construir conjuntos de datos para modelos de preferencia. Se sugiere un algoritmo de red neuronal y los hiperparámetros correspondientes para modelar las preferencias de temperatura. Según los puntos de ajuste dependientes del tiempo aprendidos de contextos dinámicos, se utiliza un conjunto de reglas específicas para determinar los puntos de ajuste para los sistemas HVAC.

## **2.3 Resumen.**

En este capítulo se muestran dos paradigmas en el contexto planteado para esta investigación, con algunas variantes tales como ubicación geográfica del lugar donde se realiza la investigación, tipo de edificio (casa o bloque de oficinas), los materiales con los que el edificio está construido.

Por un lado, se presentan los modelos matemáticos que han sido implementados por diversos investigadores, estos modelos parten de principios o leyes como, la ley de enfriamiento de Newton, así como métodos antiguamente propuestos como el método de Fanger. Normalmente este tipo de metodologías solo tienen un objetivo el cual es el confort térmico de los usuarios, basándose en parámetros físicos arbitrarios como la actividad que las personas realizan en ese espacio, tipo de ropa que se utiliza en la temporada, entre otros aspectos. Por otro lado, el costo computacional es elevado y los resultados no son del todo satisfactorios. Este tipo de metodologías son ideales cuando se requieren experimentaciones previas en este tema, esto para cuantificar las variables que influyen de manera predominante en el comportamiento térmico.

El otro paradigma que se presenta son metodologías que se ha propuesto en años recientes con técnicas en inteligencia artificial. Es interesante ver el contraste que existe en los resultados y el desempeño de los modelos. Se puede ver un notable optimización en los resultados finales del ahorro energético al aplicar estas metodologías en los sistemas HVAC. Por otro lado, el desarrollo de la aplicación de técnicas de inteligencia artificial llega a requerir más tiempo de desarrollo e implementación, en ciertas metodologías más complejas como redes neuronales, metodologías que trabajan con aprendizaje por refuerzo, entre otras, pero si se implementan metodologías más simples como regresión lineal, regresión lineal múltiple los resultados que se obtienen son satisfactorios y no requieren demasiado consumo de recursos computacionales.



### **Materiales y Métodos.**

En esta sección se presentan las metodologías de aprendizaje automático y aprendizaje profundo que se utilizaron para cumplir el objetivo general y específicos de esta investigación. Además de presentar las herramientas utilizadas, se habla de los tipos de aprendizaje que se tienen en estas áreas de la inteligencia artificial y de las métricas de evaluación que se utilizan para la regresión de datos. Machine Learning y Deep Learning, en español Aprendizaje Automático (AA) y Aprendizaje Profundo (AP), junto con la IA (Inteligencia Artificial), han sido mencionados en incontables artículos y medios de comunicación, regularmente fuera de las esferas de las publicaciones meramente tecnológicas. Se nos promete un futuro de chatbots inteligentes, coches autónomos y asistentes digitales, un futuro algunas veces pintado con un tinte sombrío y otras veces de manera utópica, en donde los trabajos serán escasos y la mayoría de la actividad económica será manejada por robots y maquinas embebidas con IA.

#### **3.1 Metodología.**

En la figura 5 se presenta la metodología que se utilizó para el desarrollo de la investigación. Iniciando por el monitoreo de datos ambientales (externos e internos) del espacio de pruebas. Después se creó y diseño una base datos para estas variables ambientales monitoreadas. Estos dos procesos son fundamentales para el tercer procedimiento el cual es el desarrollo de los modelos predictivos. Esto por las fases de desarrollo de los modelos. Después siguen las pruebas de los modelos como estrategias de control en un sistema HVAC tradicional. Por ultimo una validación y análisis de los datos arrojados en las pruebas.

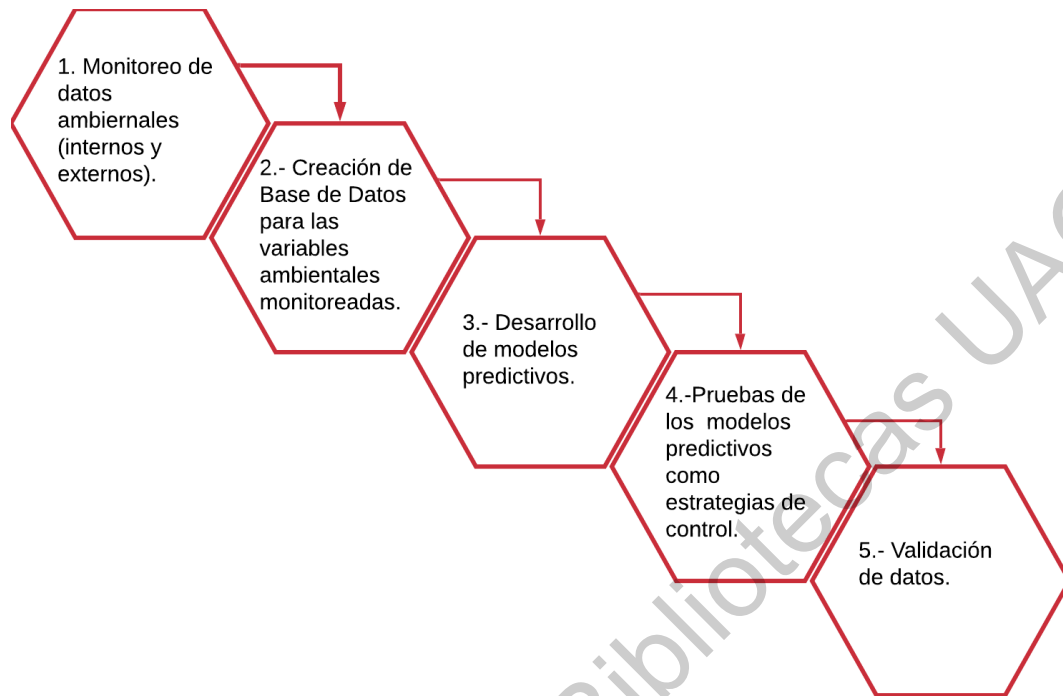


Figura 5. Metodología. (Fuente Propia)

## 3.2 Aprendizaje Automático.

Según [31] publicado por el MIT en el 2018, los algoritmos de aprendizaje automático encuentran y aplican patrones en los datos. El aprendizaje automático tiene como meta construir sistemas informáticos que mejoren automáticamente con la experiencia. Un sistema de Aprendizaje Automático es “entrenado” en vez de ser explícitamente “programado” [32]. A este sistema se le presentan muchos ejemplos relevantes para la tarea en cuestión y este encuentra la estructura estadística o patrones en dichos ejemplos que eventualmente permiten al sistema aprender las reglas para automatizar dicha tarea. Para cumplir este objetivo es necesario tres puntos importantes:

- Datos de entrada: Por ejemplo, si la tarea es reconocimiento de voz, estos datos de entrada serían archivos de sonido o grabaciones de gente hablando. Si la tarea es etiquetada de imágenes, estos datos

podrían ser fotos o imágenes.

- Ejemplos de lo que se espera como salida: En la tarea de reconocimiento de voz, estos podrían ser transcripciones generadas por humanos de los archivos de audio. En la tarea de etiquetado de imágenes, las salidas esperadas pueden ser etiquetas tales como “perro”, “gato”, “persona”, etc.
- Métricas de evaluación: Este paso es necesario para determinar la distancia o desvío entre la salida actual generada por el algoritmo y la salida esperada. Esta medida es usada como señal de realimentación para ajustar la forma en la que el algoritmo trabaja y se actualiza. Este paso del ajustamiento es lo que llamamos “Aprendizaje”.

Estos tres elementos son necesarios no solo para el desarrollo de Aprendizaje automático, de igual forma son necesarios para el aprendizaje profundo. Además, otro elemento importante el cual es el método de aprendizaje.

El aprendizaje en aprendizaje automático y profundo, se puede clasificar en tres tipos principales de aprendizaje: aprendizaje supervisado, aprendizaje no supervisado y aprendizaje de refuerzo. También hay híbridos entre los tipos de aprendizaje, como el aprendizaje semi-supervisado [33]. En la figura 6 se muestra una representación gráfica de estos tipos, su tipo de datos de salida típico, el método utilizado y un ejemplo de aplicación. El aprendizaje supervisado, el más frecuente, el sistema de aprendizaje se entrena con entradas y salidas deseadas correspondientes, llamados datos entrenamiento o datos etiquetados [34]. Depende del tipo de etiqueta, el desempeño, el enfoque y resultados finales del aprendizaje difiere. Por ejemplo, para datos continuos como precios de casas, se puede utilizar alguna clase de regresión como lineal, regresión múltiple o regresión polinomial. Mientras que los datos con etiquetas categóricas, como de diagnóstico médico,

usan la clasificación. Los sets de datos de entrenamiento de un algoritmo de aprendizaje automático, normalmente dependen del ser humano y tienen un impacto significativo de calidad en el proceso de aprendizaje. En el aprendizaje no-supervisado, no existen datos etiquetados solo tenemos datos de entrada para el entrenamiento. Es por esto que solo podemos describir la estructura de los datos, para tratar de encontrar algún tipo de patrón que haga más simple el análisis de los datos [35]. Generalmente usa medidas de distancia o similitud entre puntos de datos para encontrar patrones.

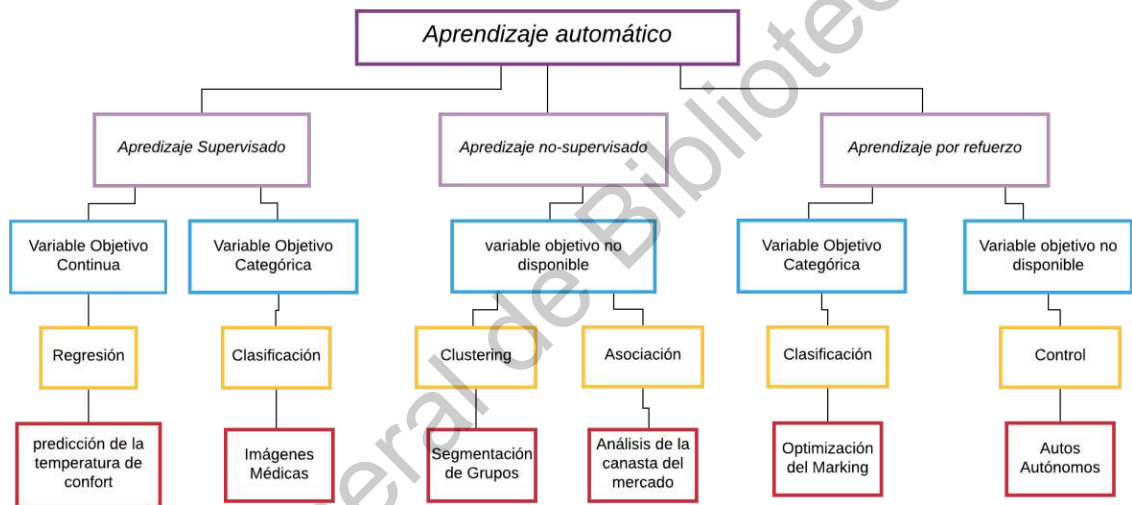


Figura 6. Tipos de aprendizaje. (Fuente Propia)

El aprendizaje por refuerzo o aprendizaje reforzado, no depende de datos existentes, sino que aprende de la interacción con su entorno. A través de su entorno, la máquina de aprendizaje (agente) recibe una evaluación (recompensa o castigo) sobre una acción elegida. Utilizando una combinación de explotación del conocimiento existente y exploración de lo desconocido, el agente intenta maximizar su recompensa o minimizar el castigo, respectivamente. Es muy adecuado en situaciones donde no hay datos de aprendizaje disponibles o se producen actualizaciones en intervalos muy cortos [36].

## 3.2.1 Regresión Lineal Múltiple.

Regresión Lineal Múltiple (RLM) es un subcampo de “machine learning supervisado”. Su propósito es establecer un modelo para la relación entre un cierto número de características y una variable objetivo continua [37]. En los problemas de regresión perseguimos obtener una respuesta cuantitativa. La regresión lineal múltiple permite generar un modelo lineal en el que el valor de la variable dependiente o respuesta ( $Y$ ) se determina a partir de un conjunto de variables independientes llamadas predictores ( $X_1, X_2, X_3\dots$ ) [38].

Los modelos lineales múltiples siguen la siguiente ecuación:

$$Y(x) = (\beta_0 + \beta_1 X_{1i} + \beta_2 X_{2i} + \dots + \beta_n X_{ni}) + e_i \quad (5)$$

- $\beta_0$  es la ordenada en el origen, el valor de la variable dependiente  $Y$  cuando todos los predictores son cero.
- $\beta_1$  es el efecto promedio que tiene el incremento en una unidad de la variable predictora  $X_i$  sobre la variable dependiente  $Y$ , manteniéndose constantes el resto de variables. Se conocen como coeficientes parciales de regresión.
- $e_i$  es el residuo o error, la diferencia entre el valor observado y el estimado por el modelo.

En muchas de las técnicas de aprendizaje automático, el aprendizaje consiste en encontrar qué parámetros  $W$  minimizan la función de coste. Esto es así para la regresión lineal y polinómica, la regresión logística, entre otros. El gradiente descendiente es un método de optimización numérica para estimar los mejores coeficientes. En la figura 7 se presenta el algoritmo de este método.

---

```

Input:  $Y, \alpha, X, \theta, tolerancia, iteraciones$ 
Output:  $\Theta$ 
Data: Set de Entrenamiento  $x$ 
1 for  $i = 0 : i < maxIteraciones : i ++$  do
2   |  $\_costoActual = Cost(Y, X, \theta)$ 
3 if  $costoActual \leq tolerancia$  then
4   |  $break$ 
5 else
6   |  $gradient = Gradient(Y, X, \Theta)$ 
7   |  $\_theta_j \leftarrow \theta_j - \alpha * gradient$ 
8

```

---

Figura 7. Pseudo Código Método del Gradiente Descendiente

### 3.2.2 Regresión Forestal Aleatoria.

Regresión Forestal Aleatoria o mejor conocido como Random Forest Regression (RF) es una técnica utilizada para modelar predicciones y análisis de comportamiento y se basa en árboles de decisión [39]. Contiene muchos árboles de decisión que representan una instancia distinta de la clasificación de la entrada de datos en el bosque aleatorio. La técnica de bosque aleatorio toma en cuenta las instancias individualmente, tomando el que tiene la mayoría de los votos como la predicción seleccionada. Según aportaciones de varios autores como [40] Random Forest es uno de los modelos de aprendizaje automático más eficaces para el análisis predictivo, lo que lo convierte en una opción efectiva para el aprendizaje automático. Hay dos formas principales de combinar los resultados de múltiples árboles de decisión en un bosque aleatorio. Bagging, que también se denomina agregación Bootstrap utilizado en bosques aleatorios y Boosting el cual es utilizado en máquinas de refuerzo de gradiente. Los árboles de decisión se entrenan en subconjuntos de datos muestreados al azar, mientras que el muestreo se realiza con reemplazo. Bagging es el método predeterminado utilizado con los bosques

aleatorios [41]. Una gran ventaja sobre árboles individuales es que bagging disminuye la variación del modelo. Los árboles individuales son muy propensos al sobreajuste y son muy sensibles al ruido en los datos. Mientras nuestros árboles individuales no estén correlacionados, combinarlos con bagging los hará más robustos sin aumentar el sesgo).

Los hiperparámetros son los argumentos que se pueden establecer antes del entrenamiento y que definen cómo se realiza el entrenamiento. Los principales hiperparámetros en los bosques aleatorios son:

- El número de árboles de decisión que se combinarán.
- La profundidad máxima de los árboles
- El número máximo de características consideradas en cada división.

Entre las ventajas que se presentan son que es un algoritmo relativamente rápido y poderoso para el aprendizaje de clasificación y regresión. Los cálculos pueden ser paralelos y funcionar bien en muchos problemas, incluso con pequeños conjuntos de datos y la salida devuelve probabilidades de predicción.

En la figura 8 se representa el pseudocódigo de la regresión forestal aleatoria. Random Forests es una herramienta de predicción efectiva en la minería de datos. Emplea el método de Bagging (embolsado) para producir un conjunto de datos de entrenamiento muestreados al azar para cada uno de los árboles. Este método de bosques aleatorios también selecciona de forma semi aleatoria las características de división; Se produce un subconjunto aleatorio de un tamaño dado a partir del espacio de posibles características de división. La mejor división es la característica seleccionada determinísticamente de ese subconjunto. Para clasificar una instancia de prueba, Random Forests clasifica la instancia simplemente combinando todos resultados de cada uno de los árboles en el bosque. El método

utilizado para combinar los resultados puede ser tan simple como prediciendo la clase obtenida del mayor número de árboles. Es decir, Regresión forestal aleatoria construye N número de árboles, determina el promedio para ponderar y dar una respuesta final.

---

**Algoritmo** Pseudo código para regresión forestal aleatoria.

---

```
Para generar muestras de arranque de C.  
for i =1 to C do  
    Muestra aleatoriamente los datos de entrenamiento D con reemplazo para producir Di  
    Crear un nodo raíz, Ni que contenga Di  
    BuildTree(Ni)  
end for  
BuildTree(N):  
if N contiene instancia solo para una clase then  
    return  
else  
    aleatoriamente selecciona x% de las posibles funciones de división en N  
    seleccione la función F con la mayor ganancia de información para dividir  
    crear f nodo hijo N, N1..Nf, donde F tiene f valores posibles (F1, ..., Ff)  
for i =1 to f do  
    establezca el segmento de datos de Ni en Di, donde Di son todas las instancias en N que coinciden  
    Fi  
    BuildTree(Ni)  
end for  
end if
```

---

Figura 8. Pseudo Código de regresión Forestal Aleatoria.

### 3.3 Aprendizaje Profundo.

El Aprendizaje Profundo o Deep Learning es un sub-campo específico del Aprendizaje Automático. Un nuevo intento en aprender representaciones idóneas de los datos en el que se pone un énfasis en aprender dichas representaciones de manera sucesiva mediante lo que se denominan capas [42]. El término “Profundo” en Aprendizaje Profundo no hace ninguna referencia a un tipo de entendimiento profundo alcanzado mediante la utilización de este tipo de enfoque, en vez de ello, el término representa la idea de la representación sucesiva y jerarquizada de los datos por medio de capas [43]. La cantidad de capas que contribuyen a un modelo es denominada la “profundidad del modelo”. Modelos de Aprendizaje Profundo



modernos normalmente involucran decenas o cientos de capas sucesivas de representación, y todos los parámetros que ellas contienen son aprendidos automáticamente mediante la exposición de dichos modelos a los denominados datos de entrenamiento [44]. Mientras tanto, otros enfoques en el Aprendizaje Automático tienden a enfocarse en el aprendizaje utilizando sólo una o dos capas de representación para sus datos, por lo tanto, este tipo de enfoques son denominados modelos de Aprendizaje Superficial, lo contrario al Aprendizaje Profundo o Deep Learning [45]. En Deep Learning, estas representaciones por capas son casi siempre aprendidas mediante modelos llamados Redes Neuronales los cuales están literalmente estructurados en capas apiladas una después de la otra.

### **3.3.1 Redes Neuronales Artificiales.**

Las redes neuronales artificiales (RNA) son modelos matemáticos que intentan reproducir el funcionamiento del sistema nervioso. Como todo modelo, realizan una simplificación del sistema real que simulan y toman las características principales del mismo para la resolución de una tarea determinada [46].

La unidad más pequeña en las RNA es la neurona que la podemos ver en la figura 6, la neurona tiene la función de procesar y transmitir de manera continua la información.

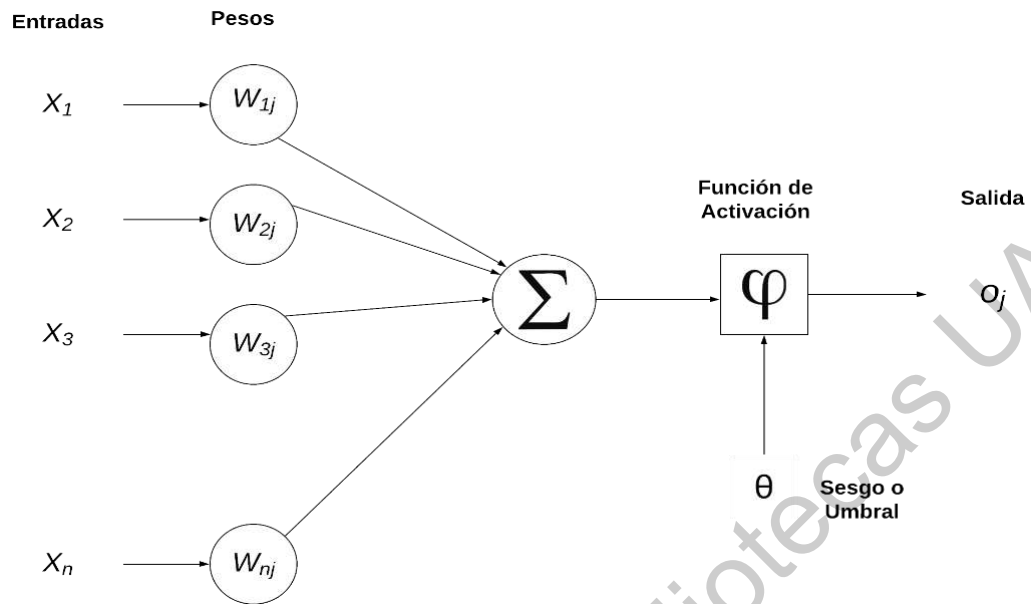


Figura 9. Arquitectura de una neurona. (Fuente Propia)

En la figura 9 se presenta la arquitectura básica de una neurona artificial. Los elementos que la componen son:

- Entradas ( $x_n$ )
- Pesos sinápticos ( $w_{nj}$ )
- Función de activación  $\varphi$
- Sesgo o umbral  $\theta_i$
- Salida  $O_j$

Partiendo de la neurona la entrada está compuesta de un vector de tamaño (esto no siempre es verdad, es decir, la cantidad de neuronas puede ser diferente al tamaño del vector de entrada). Se realiza la suma producto  $w_j x = \sum w_{jki} n 1$  y a esta cantidad se le suma el sesgo  $\theta_i$ . La cantidad  $w_{jki} + \theta_i$  es la entrada a una

función de activación, la cual puede estar definida de muchas formas, las clásicas son: escalón, sigmoidal, tangencial, signo, entre otras. Existen diversas formas de determinar los pesos de una red neuronal. Una de ellas es la asignación aleatoria realizando pruebas de ensayo y error. Otra forma es usar el algoritmo del bolsillo (Pocket Algorithm) que consiste en almacenar los mejores pesos en función del mínimo error generado por la red. Los conjuntos de entrada y salidas de una neurona son clasificadas en dos grandes grupos las neuronas binarias que solo admiten valores de 0 y 1 o -1 y 1. El otro grupo admiten entradas en el rango de [-1 a 1]. El tipo de entrada y salida depende de la aplicación y el modelo que se va a construir [47]. El peso sináptico define la fuerza de una conexión sináptica entre dos neuronas, la neurona pre sináptica  $i$ , la neurona post sináptica  $j$ . Los pesos sinápticos pueden tomar valores positivos, negativos o el cero, en caso que el valor sea cero quiere decir que no existe conexión en esa neurona con alguna otra. Mediante el ajuste de pesos la red es capaz de mejorar el desempeño de cada neurona. La capacidad principal de este modelo cae en el procesamiento paralelo realizado por las neuronas artificiales. La neurona artificial es un elemento de procesamiento simple y es la unidad principal de un sistema neuronal artificial. La función de activación se encarga de devolver una salida a partir de un valor de 27 entrada. Normalmente, se buscan funciones cuyas derivadas sean simples, para minimizar el coste computacional. Existen diferentes tipos de activación, una de ellas es la Sigmoide. La función Sigmoide transforma los valores introducidos a una escala (0,1), donde los valores altos tienen de manera asintótica a 1 y los valores muy bajos tienden de manera asintótica a 0.

$$f(x) = \frac{1}{1-e^{-x}} \quad (6)$$

Otra función de activación que se tienen es la tangente hiperbólica o como en algunas literaturas le llaman Tanh. La función tangente hiperbólica transforma los valores introducidos a una escala (-1,1), donde los valores altos tienen de

manera asintótica a 1 y los valores muy bajos tienden de manera asintótica a -1.

$$f(x) = \frac{2}{1+e^{-2x}} - 1 \quad (7)$$

Las redes neuronales artificiales se combinan en estructuras denominadas capas. Una red neuronal está compuesta por un conjunto de capas de esta manera la información está distribuida a lo largo de la red dándole a la estructura de la red cierta tolerancia a los errores [48]. Al mismo tiempo las neuronas artificiales pueden adaptar su funcionamiento de diferentes entornos y problemas modificando sus conexiones entre neuronas.

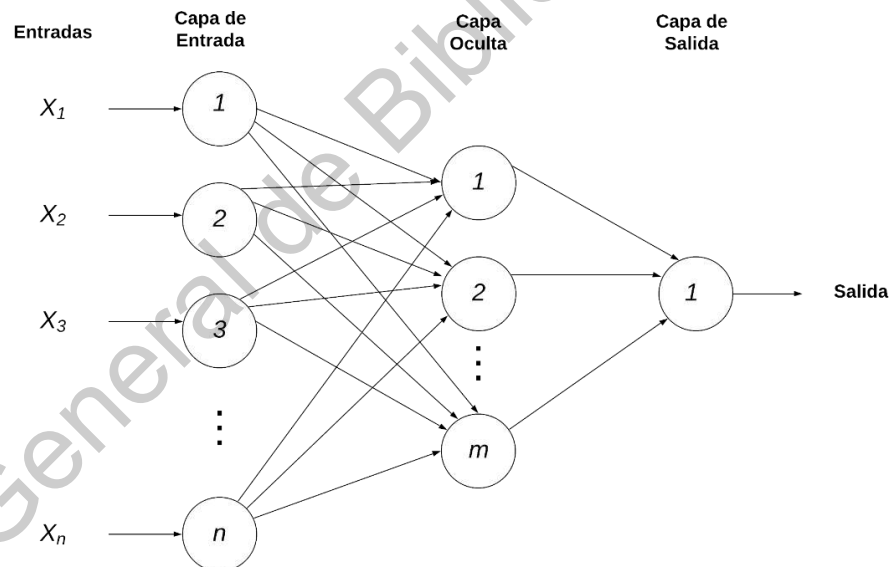


Figura 10. Arquitectura básica de una red neuronal artificial. (Fuente Propia)

En la figura 10 se muestra la arquitectura básica de una red neuronal. Como se mencionó anteriormente la unidad básica de una red neuronal es la neurona, estas se organizan y se disponen dentro de la red neuronal a esto se le llama topología y está dada por 3 capas que son las mostradas en la figura 6, la cantidad de neuronas en cada capa y la conectividad entre neurona. Las neuronas se agrupan en unidades llamadas capas y son 3 capas entrada, oculta y de salida. La capa de entrada está compuesta por las neuronas de entrada que son las que

reciben información del exterior. Se denominan capas ocultas y de salidas a aquellas que se componen de neuronas ocultas y de salida. Entre todas las neuronas existe una conexión que se llama sinapsis, tienen asociadas un peso sináptico, y son direccionales [49]. Cuando la conexión se establece entre dos neuronas de una misma capa hablamos de conexiones laterales o conexiones intra-capas. Si la conexión se establece entre neuronas de distintas capas se la denomina conexión inter-capas. Si la conexión se produce en el sentido inverso al de entrada-salida la conexión se llama recurrente [50]. Una red puede estar conformada por una sola capa de neuronas ocultas estas son conocidas como redes mono capa y las neuronas de estas redes cumplen de la función de entrada y salida de manera simultánea. Al mismo tiempo podemos hablar de redes en las cuales su conexión es hacia adelante son conocidas como redes feedforward cuando las conexiones siguen un solo sentido hacia adelante partiendo desde la entrada y terminando en la salida sin realizar un regreso. Cuando las conexiones pueden ser hacia adelante como hacia atrás son redes recurrentes (feedback). Las Redes neuronales recurrentes son una clase de redes neuronales adaptadas para manejar datos temporales. Las neuronas de RNN tienen un estado / memoria celular, y la entrada se procesa de acuerdo con este estado interno, que se logra con la ayuda de bucles en la red neuronal. Hay módulos recurrentes de capas "tanh" en los RNN que les permiten retener información. Sin embargo, no por mucho tiempo, por eso necesitamos modelos dentro del subcampo del aprendizaje profundo, como redes LSTM [51].

### 3.3.2 Redes Neuronales Artificiales Long Short Term Memory (LSTM)

Es un tipo especial de red neuronal recurrente que es capaz de aprender dependencias a largo plazo en los datos. Esto se logra porque el módulo recurrente del modelo tiene una combinación de cuatro capas que interactúan entre sí [52].

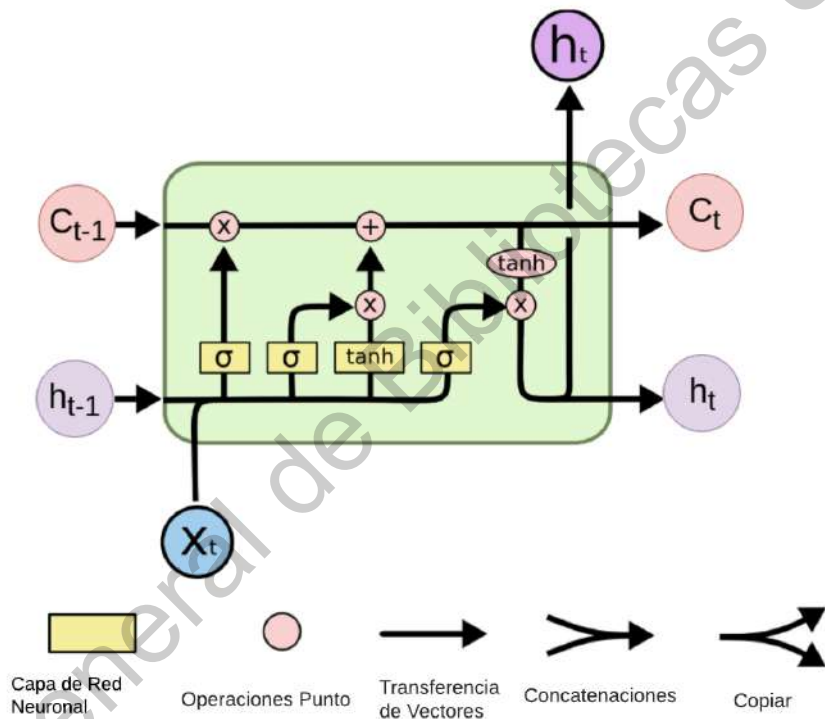


Figura 11. Estructura de una neurona LSTM. (Fuente CIMAT)

La imagen de arriba muestra cuatro capas de red neuronal en cuadros amarillos, operadores puntiagudos en círculos morados, entrada en círculos amarillos y estado de la celda en círculos azules. Un módulo LSTM tiene un estado de celda y tres puertas que les proporciona el poder de aprender, desaprender o retener selectivamente información de cada una de las unidades. El estado de la celda en LSTM ayuda a que la información fluya a través de las unidades sin ser alterada al permitir solo unas pocas interacciones lineales. Cada unidad tiene una

entrada, salida y una puerta de olvido que puede agregar o eliminar la información al estado de la celda. La puerta de olvido decide qué información del estado de celda anterior debe olvidarse para la cual utiliza una función sigmoidea. La puerta de entrada controla el flujo de información al estado actual de la celda mediante una operación de multiplicación puntual de "sigmoide" y "tanh" respectivamente. Finalmente, la puerta de salida decide qué información debe pasar al siguiente estado oculto. El concepto central de LSTM es el estado de la celda, y son varias puertas. El estado de la celda actúa como una carretera de transporte que transfiere información relativa en toda la cadena de secuencia. Puede pensarlo como la "memoria" de la red. El estado celular, en teoría, puede transportar información relevante a lo largo del procesamiento de la secuencia. Por lo tanto, incluso la información de los pasos de tiempo anteriores puede pasar a los pasos de tiempo posteriores, reduciendo los efectos de la memoria a corto plazo. A medida que el estado celular avanza, la información se agrega o elimina al estado celular a través de puertas. Las puertas son diferentes redes neuronales que deciden qué información se permite en el estado de la célula. Las puertas pueden aprender qué información es relevante para guardar u olvidar durante el entrenamiento. Se puede llegar a confundir una red neuronal recurrente con una red neuronal LSTM, es por esto que en la figura 12 se presenta un diagrama con el funcionamiento interno de 3 diferentes tipos de neuronas. Una red neuronal estándar, una red neuronal recurrente y una red neuronal LSTM.

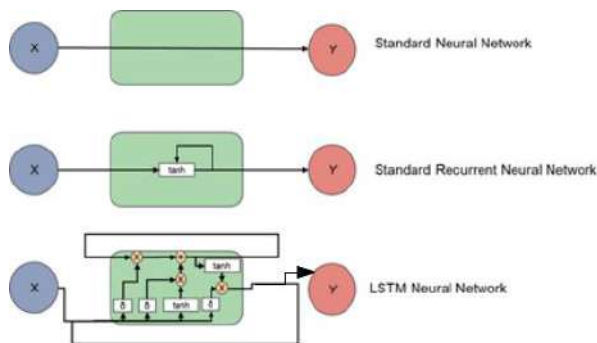


Figura 12. Diagrama de Redes Neuronales. (Fuente CIMAT)

### 3.4 Métricas de Evaluación.

Al evaluar modelos, la elección de las métricas de evaluación está vinculada a la tarea específica de aprendizaje automático. Por ejemplo, si creó un clasificador para detectar correos electrónicos no deseados frente a correos electrónicos normales, entonces debe considerar las métricas de rendimiento de clasificación, como la precisión promedio, la pérdida de registros, entre otros. Si está tratando de predecir un puntaje, como el precio diario de las acciones de Google, puede considerar las métricas de regresión como el error cuadrático medio (MSE, por sus siglas en inglés Mean Squared Error). Todos estos son ejemplos de métricas de rendimiento específicas de tareas. En la regresión de datos las métricas más utilizadas son raíz del error cuadrático medio (RMSE, por sus siglas en inglés RootMean-Square Error), coeficiente de determinación ( $R^2$ ), Error absoluto medio (MAE, por sus siglas en inglés Mean Absolute Error) y Error Porcentual Absoluto Medio (MAPE, por sus siglas en inglés Mean Absolute Percentage Error).

RMSE se calcula el valor medio de la diferencia al cuadrado entre el valor real y el predicho para todos los puntos de datos [53]. Todos los valores relacionados se elevan a la segunda potencia y se realiza la raíz cuadrada. Además, debido a las características de esta métrica, el impacto de los errores es mayor. En la ecuación 8 se presenta la fórmula de esta métrica.

$$RMSE = \sqrt{\frac{1}{n} \sum (y - \hat{y})^2} \quad (8)$$

El coeficiente de determinación (ecuación 9), se define como la proporción de la varianza total de la variable explicada por la regresión. El coeficiente de determinación, también llamado R cuadrado, refleja la bondad del ajuste de un modelo a la variable que pretender explicar [54]. Es importante saber que el resultado del coeficiente de determinación oscila entre 0 y 1.



$$R^2 = \frac{\sum_{t=1}^T (y - \hat{y})^2}{\sum_{t=1}^T (y - \bar{y})^2} \quad (9)$$

Después tenemos MAE, en la ecuación 10 se presenta la formula. Donde  $y$  es el valor real,  $\hat{y}$  es el valor que se predice y  $n$  la cantidad de datos.

$$MAE = \frac{1}{n} \sum (y - \hat{y}) \quad (10)$$

Y por último MAPE (ecuación 11) es una medida de precisión basada en errores porcentuales (o relativos). Esta métrica de evaluación, así como MSE son utilizadas en la plataforma de UBER para calcular la demanda esperada en ciertas épocas del año [55] Por lo general, se define de la siguiente manera:

$$MAPE = \left( \frac{1}{n} \sum_{t=1}^n \frac{|y_i - \hat{y}_i|}{y_i} \right) * 100 \quad (11)$$

Donde  $N$  es el número de datos, donde  $\hat{y}_i$  es el dato que se predice y  $y_i$  es el valor real. 33 Otra herramienta que se tiene para poder medir el desempeño de los algoritmos de regresión de datos es la curva de aprendizaje. Una curva de aprendizaje es una gráfica del rendimiento del aprendizaje modelo sobre la experiencia o el tiempo. Las curvas de aprendizaje son una herramienta de diagnóstico ampliamente utilizada en el aprendizaje automático para algoritmos que aprenden de un conjunto de datos de entrenamiento de forma incremental. El modelo se puede evaluar en el conjunto de datos de entrenamiento y en un conjunto de datos de validación después de cada actualización durante el entrenamiento y se pueden crear gráficos del rendimiento medido para mostrar las curvas de aprendizaje [56].

Otro método para visualizar y para mejorar el desempeño es validación cruzada o K-Fold. La validación cruzada es una técnica para evaluar modelos de ML mediante el entrenamiento de varios modelos de ML en subconjuntos de los

datos de entrada disponibles y evaluarlos con el subconjunto complementario de los datos. Se utiliza la validación cruzada para detectar el sobreajuste, es decir, en aquellos casos en los que no se logre generalizar un patrón. El procedimiento tiene un único parámetro llamado  $k$  que se refiere al número de grupos en los que se dividirá una muestra de datos determinada. El valor  $k$  debe elegirse cuidadosamente para su muestra de datos. Un valor mal elegido para  $k$  puede dar lugar a una idea mal representativa de la habilidad del modelo, como un puntaje con una alta varianza (que puede cambiar mucho en función de los datos utilizados para ajustar el modelo), o un alto sesgo, (como una sobreestimación de la habilidad del modelo). En la figura 13 se presenta diagrama del funcionamiento de K-Fold.

1. Mezcle aleatoriamente el conjunto de datos.
2. Dividir el conjunto de datos en  $k$  grupos
3. Para cada grupo único:
  - Tome un segmento del conjunto de datos como datos de prueba.
  - Tome los grupos restantes como un conjunto de datos de entrenamiento.
  - Ajuste un modelo en el conjunto de entrenamiento y evalúelo en el conjunto de prueba.
  - Conserve el puntaje de evaluación y descarte el modelo.
4. Resuma la habilidad del modelo utilizando la muestra de puntajes de evaluación del modelo.

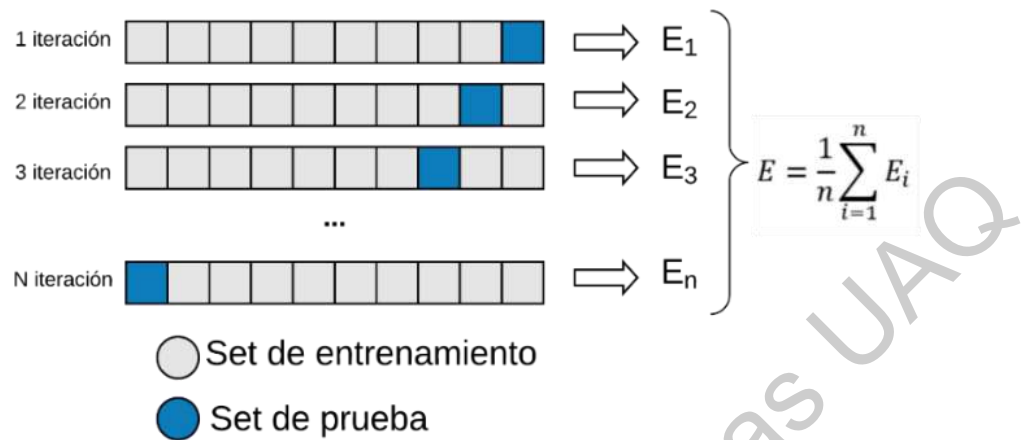


Figura 13. Diagrama K-Fold.(fuente propia)

### 3.5 Confort Térmico y Consumo eléctrico en sistemas HVAC.

En esta sección se presentan conceptos que se utilizaron para el desarrollo de esta investigación. Entre ellos están el confort térmico, el comportamiento térmico y que variables influyen de manera primaria y secundaria. Además de métricas de evaluación para el confort térmico en espacios cerrados. De igual forma el consumo eléctrico de los sistemas de climatización y la potencia en los sistemas de climatización tradicionales.

#### 3.5.1 Variables Ambientales y el Confort Térmico.

El confort térmico lo define la Norma ISO 7730 como “Esa condición de mente en la que se expresa la satisfacción del ambiente térmico” [57]. Una definición que muchos podemos estar de acuerdo, pero también es una definición difícil de trasladar a parámetros físicos. En [58] se expresa que el confort térmico se logra cuando un ser humano no siente la necesidad de cambiar el estado del entorno térmico o de adaptarse a él. Esta condición se alcanza cuando el equilibrio térmico

de un ser humano es neutral, es decir, el calor producido por el metabolismo es igual al calor disipado en el medio ambiente. La percepción del entorno térmico es influenciada de manera principal por seis factores: temperatura del aire, velocidad y humedad, temperatura, ropa y las actividades que las personas desempeñan. Además, existen otros factores como físicos, psicológicos y étnicos que influyen en el confort térmico, como lo muestra la tabla 1.

Tabla 1. Factores que influyen en el comportamiento térmico.

condiciones fisiológicas	condiciones físicas	condiciones a considerar
Nutrición ●	Temperatura del aire ●	Adaptación y aclimatización ●
Influencia étnica ●	Velocidad del aire ●	Actividades Diarias ●
Edad ●	Humedad relativa ●	Tipo de ropa ●
Género ●	Presión del aire ●	Ocupación de los espacios ●
Constitución física ●	Composición del aire ●	
	Electricidad atmosférica ●	
	Influencias acústicas ●	
	Influencias visuales ●	

En la tabla 1 está dividida en tres secciones considerados factores que influyen en el confort térmico, cada uno de estos factores está acompañado de un punto de color cada uno con significados diferentes. El punto verde significa que son factores adicionales para el confort térmico, el punto azul significa que son puntos secundarios y los que tienen el punto amarillo significa que son factores predominantes en el confort térmico. El entorno térmico puede tener un impacto significativo en la salud y en la calidad productiva del usuario y al mismo tiempo muestra una influencia en el comportamiento humano. Las definiciones de estas variables no se establecieron de una manera arbitraria, existen múltiples organizaciones que se dedican al estudio del comportamiento térmico de un edificio y al confort térmico dentro de los edificios, una de estas organizaciones es la Sociedad Americana de Ingenieros de Calefacción, Refrigeración y Aire Acondicionado (ASHRAE, por su significado en inglés American Society of Heating,

Refrigerating and Air-Conditioning Engineers). Según su sitio de internet ellos se definen como una asociación global que promueve el bienestar humano y fomenta un mundo más sostenible mediante propuestas tecnológicas que favorezcan el desarrollo de las artes y de las ciencias en materia de climatización, ventilación y refrigeración aplicadas a edificios [59]. En [60] muestran que las temperaturas cálidas se adaptan al trabajo creativo, mientras que los ambientes más fríos ayudan a mantener a las personas alertas durante las actividades monótonas. Adaptar las condiciones ambientales a los 38 ocupantes es, por lo tanto, una tarea importante en los sistemas de acondicionamiento. En este capítulo, se presentarán enfoques de ingeniería para evaluar el confort térmico en interiores: el voto medio previsto (PMV) y el porcentaje previsto de insatisfacción (PPD) desarrollado por Fanger, entre otras que se describen en esta sección.

### **3.5.1.1 Escala de Confort de Fanger.**

El Ingeniero Danés Povl Ole Fanger fue un estudioso de la calidad del aire interior y del confort térmico, trabajo en la Universidad Técnica de Dinamarca y fue profesor invitado en la de Syracuse (USA). Sus teorías, estudios y métodos siguen plenamente vigentes hoy en día. Fanger desarrollo un modelo de confort termal basado en un modelo de equilibrio térmico del cuerpo humano. El modelo de confort de Fanger fue probado y confirmado mediante diversos experimentos en cámaras climáticas, con varios sujetos de prueba expuestos a diferentes condiciones térmicas y respondiendo un cuestionario sobre su percepción térmica. A partir de los resultados que los diversos experimentos arrojaron, Fanger desarrollo una ecuación que se puede utilizar para predecir el confort térmico de un grupo de personas en función de las condiciones interiores, y es especialmente adecuado para espacios climatizados artificialmente [61]. El método de Fanger considera el nivel de actividad, las características de la ropa, la temperatura seca, la humedad relativa, la temperatura radiante media y la velocidad del aire. Todas estas variables influyen en los intercambios térmicos hombre-entorno, afectando a la sensación de

confort. El método de Fanger, en la actualidad uno de los más utilizados para la estimación del confort térmico, calcula dos índices denominados Voto medio estimado (PMV, Predicted Mean Vote) y Porcentaje de personas insatisfechas (PPD, Predicted Percentage Dissatisfied), que indican la sensación térmica media de un entorno y el porcentaje de personas que se sentirán inconfortables en un ambiente determinado. Esto resulta de gran interés no sólo cuando se trata de evaluar una situación sino cuando se pretende proyectar o modificar un ambiente térmico. La importancia y aplicación generalizada del método queda patente en su inclusión como parte de la norma ISO 7730 relativa a la evaluación del ambiente térmico. El PMV es una escala que va desde - 3 (frío) a + 3 (caliente), con un voto 0 siendo neutral. Fanger definió el rango de - 0,5 a + 0,5 como condiciones aceptables. El PPD se utiliza para evaluar el porcentaje de ocupantes que estarán insatisfechos bajo ciertas condiciones ambientales. El PPD está relacionado con el PMV: para un PMV de  $\pm 3$ , el 90% de los ocupantes estarán descontentos con su entorno, mientras que, con un PMV de 0, el 5% de los ocupantes estarán descontentos. Ambos índices se muestran en la figura 14. PMV se utiliza en varias normas nacionales e internacionales, entre ellas la norma ASHRAE para el confort interior [62], la norma europea EN 15251 [63] y la ISO 7730 [64].




Figura 14. Escala de Confort de Fanger. (Fuente Propia)

### **3.5.2 Sistemas HVAC potencia y consumo energético.**

El uso de los aires acondicionados ocupa el segundo lugar en el consumo de energía eléctrica en México, solo por debajo de la iluminación, lo que se traduce en 75 mil millones de pesos anuales [65]. En 2015, el sector de los comercios grandes y medianos, junto con el residencial, consumió la mayor parte de la energía. El consumo de estos equipos fue de 22.6 terawatts por hora (TWh), es decir, 8.9 por ciento del total de la energía generada en ese año, lo que se traduce en 10 millones de toneladas de bióxido de carbono. Además [66] expone que en el mercado existen equipos con un nivel de eficiencia de casi el doble con respecto al promedio de los equipos que actualmente están en uso, así que lo recomendable es sustituirlos y lograr ahorros acumulados de 39 TWh para el periodo 2019-2030, de acuerdo a estimaciones de la Agencia Internacional de Energía (AIE). La AIE, además, señala que el crecimiento de las ciudades y el aumento en la densidad urbana han ocasionado que el uso de aires acondicionados aumente considerablemente. Para el año 2050, la Agencia prevé que la demanda de estos equipos se triplicará a nivel mundial. En México se aplican las normas NOM-023-ENER-2018 que hace referencia a aires acondicionados mini-split con tecnología on-off, y la NOM-026-ENER-2015 para aires acondicionados tipo mini-split con tecnología inverter, las cuales establecen los límites mínimos de eficiencia energética que deben contar los equipos vendidos en el país. ICM aseguró que, con base en lo anterior, es evidente que una NOM que esté particularmente enfocada a aires acondicionados en el sector comercial puede traer beneficios ambientales y económicos. Por ello, se debe continuar, de manera acelerada, con la regulación de la eficiencia energética de los equipos en el sector comercial y avanzar, de manera significativa, en el cumplimiento de los acuerdos firmados a nivel internacional relacionados con la protección de la capa de ozono y con la mitigación de emisiones de gases de efecto invernadero. Además, según estimaciones iniciales del LBNL, si en México existieran regulaciones similares a las de Estados Unidos, se podrían obtener

ahorros por 400 millones de dólares adicionales a la reducción de los subsidios que también se obtendrían; mientras que la electricidad disminuiría a 4 TWh, lo que significa una reducción de 2.3 toneladas de Bióxido de carbono anuales [67].

Para el sector residencial, actualmente la tecnología que más se utiliza es la de mini-split, en la que se encuentra la tecnología on-off que introduce picos de corriente cada vez que enciende el compresor para llegar a la temperatura deseada. Este tipo de aparatos se están clasificados como de consumo de consumo alto según [68]. A continuación, se presenta una tabla de consumo eléctrico de sistemas de climatización que regularmente son los más usados en casas convencionales, casas residenciales y algunos edificios de oficinas.

Tabla 2. Tabla de Consumo y potencia en sistemas HVAC

Aparato	Potencia (Promedio) watts	Tiempo de consumo (periodos típicos)	Tiempo de uso al mes/horas	Consumo mensual kilowatts-hora ((watts/1000)xhora)
Aire acondicionado dividido (minisplit) 1 ton.	1160	8 hrs. diarias	240	278
Aire acondicionado dividido (minisplit) 1.5 ton.	1680	8 hrs. diarias	240	403
Aire acondicionado dividido (minisplit) 2 ton.	2280	8 hrs. diarias	240	547

En la tabla de arriba se presenta 3 tipos de sistemas de climatización típicamente usados, cada uno de diferencia potencia frigorífica. La potencia de enfriamiento en los sistemas de ventilación en el continente de América es la tonelada de refrigeración en continentes como el europeo se usa la Unidad Térmica Británica (British Thermal Unit, BTU por sus siglas en inglés). Según Instituto Nacional de Estándares y Tecnología (National Institute of Standards and Technology, NIST por sus siglas en inglés), una tonelada de refrigeración es igual





Las Redes de sensores tienen la capacidad de enviar y recibir datos de manera inalámbrica. Constan de un microprocesador, un sistema de radiofrecuencia, una fuente de energía (la mayoría de las veces batería) y un sensor para monitorear [71].

Una red de sensores de manera general se compone por:

- Sensores: De distintos tipos, los requeridos para realizar el monitoreo del fenómeno a analizar.
- Nodos de sensores: Toman todos los datos de los sensores a través de sus puertas de datos y mandan toda la información a la estación base.
- Gateway: Elemento para la interconexión entre la red de sensores y una red TCP/IP
- Estación base: Es la que se encarga de la recolección de todos los datos y muchas veces de igual forma se encarga de realizar la interpretación de los datos.
- Protocolo de comunicación: Es el encargado de comunicar los nodos con la estación base. La comunicación entre nodos y estación base puede ser de una vía o de dos vías.

Las redes de sensores se caracterizan por su fácil integración en otras tecnologías y con otras áreas como los son la agricultura, medio ambiente, en el ámbito militar, monitoreo de estructuras, en área de medicina, solo por mencionar algunas. De igual forma se caracterizan por ser desatendidas (sin intervención humana) [72].

La columna vertebral de las redes de sensores de casi cualquier dispositivo perteneciente al internet de las cosas es el protocolo de comunicación. Según la RAE un protocolo de comunicación son un conjunto de pautas que hacen posible que dos elementos que forman parte de un sistema establezcan comunicaciones entre sí, intercambiando información.

Los protocolos de comunicación instituyen los parámetros que determinan cuál es la semántica y cuál es la sintaxis que deben emplearse para realizar la comunicación entre dos elementos. Las reglas fijadas por el protocolo también permiten recuperar los eventuales datos que se pierdan en el intercambio [73]. Existen muchas formas para realizar la comunicación M2M (Machine-to-Machine) y con el desarrollo exponencial en las telecomunicaciones y el impulso de internet no hay límites en la comunicación, sin embargo, en el campo de IoT se tienen requisitos que hacen que las habituales formas de comunicación entre dispositivos no sean del todo adecuadas.

Un protocolo de comunicación que se utilizó en esta red de sensores inalámbricas fue MQ Telemetry Transport (MQTT, por sus siglas en inglés). Transporte de telemetría de mensajes o Message Queuing Telemetry Transport (MQTT, por sus siglas en inglés) es un protocolo de mensajería basado en una arquitectura publish-subscribe funciona sobre TCP/IP, usado en sistemas donde se tiene poco ancho de banda [73]. El protocolo es basado en una arquitectura publish and subscribe basada en tópicos.

### **3.6.2 Encriptación Simétrica y Mecanismo de Blockchain.**

Estándar de cifrado avanzado (AES, por sus siglas en inglés Advanced Encryption Standard). AES es un algoritmo de cifrado simétrico con un alto grado de seguridad. La Figura 15 muestra el proceso de encriptación AES. El cifrado

convierte los datos en una forma ininteligible llamada texto cifrado, mientras que el descifrado convierte este texto cifrado en texto plano original. El algoritmo AES puede usar claves criptográficas de 128, 192 o 256 bits para cifrar y descifrar datos en bloques de 128 bits [74]. En la figura 15 podemos observar la metodología que realiza este algoritmo.

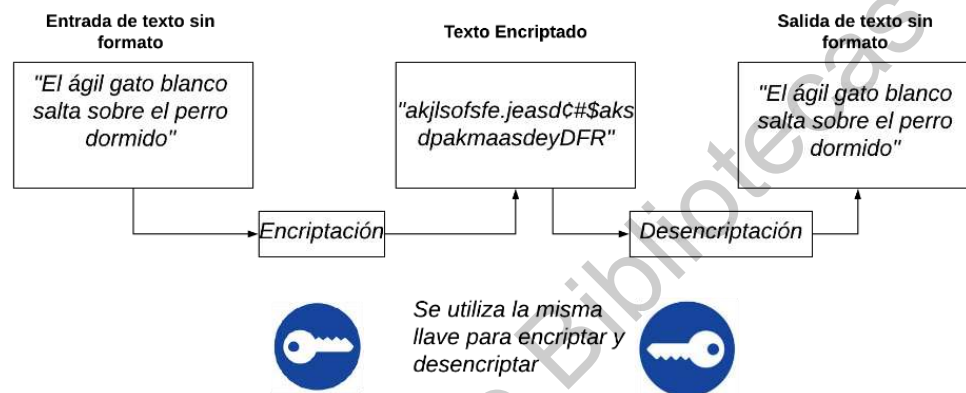


Figura 15. Esquema de funcionamiento de encriptación AES. (Fuente Propia)

El mecanismo de criptomoneda conocido como Blockchain nació a partir del Bitcoin. La criptomoneda Bitcoin fue propuesta en 2008 por Satoshi Nakamoto [75]. Satoshi Nakamoto en esta aportación define una criptomoneda como un medio de intercambio como el dinero tradicional como el Dólar. La criptomoneda está diseñada para realizar el intercambio mediante principios de la criptografía [76]. No puede haber Bitcoin sin blockchain, pero si Blockchain sin Bitcoin [77]. Esto hace que blockchain no se limite solo en el área financiera esto porque permite grabar cualquier tipo de información que se comparta en el internet [78]. Diariamente se producen grandes cantidades de transacciones de criptomonedas alrededor del mundo. Cada registro incluye información específica como pagador, beneficiario, hora, fecha de la transacción y puede tener otros datos adicionales si así se requiere [79]. Todas las transacciones se recolectan en un set de datos en un cierto intervalo de tiempo. A este set de datos se le llama bloques. Los bloques se cargan al internet en orden cronológico, entonces los bloques son un conjunto de datos. Este tipo de

cadena de bloques muy simple se puede manipular y falsificar de manera muy simple, es por esto que blockchain está diseñado para no ser falsificado ni modificado. Para lograr este objetivo se utiliza una función hash como SHA-256 desarrollada por el NIST (Instituto Nacional de Estándares y Tecnología, EE.UU.) [80]. La función hash es un protocolo de cálculo irreversible, es decir un hash el valor se puede calcular a partir de los datos de origen, pero no viceversa. Cuando se agrega un nuevo bloque para cargar a la cadena, se calcula el hash a partir del bloque nuevo como se hizo con el bloque anterior. El hash se registra en el bloque nuevo junto con la información que contenga. Si alguien quiere hacer una modificación o falsificación en el bloque que acaba de ser agregado, una discrepancia entre los datos y el hash es notoria. Si este bloque fuera independiente nadie se daría cuenta de la discrepancia, pero como el hash también se calcula utilizando el hash del bloque anterior la discrepancia es notoria. Para arreglar esto todos los hashes de todos los bloques deben de ser falsificarse y esta tarea es muy exhaustiva de la cual se requiere demasiado esfuerzo y es por esto que la cadena de bloques se hace inmune a la falsificación. En la figura 16 podemos observar la estructura básica de Blockchain que se acaba de describir. La cabecera contiene el valor del hash del actual bloque y del bloque anterior, un nonce y una marca de tiempo. La parte del cuerpo consiste en transacciones o los datos.

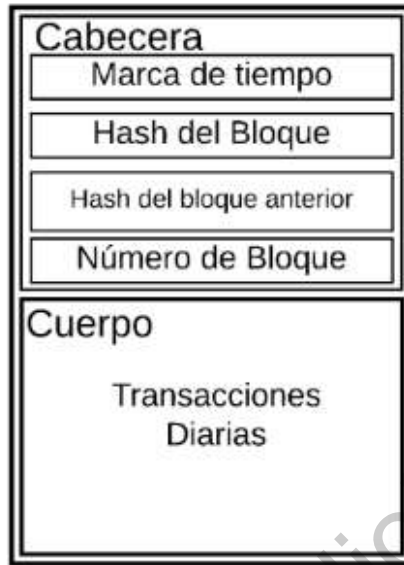


Figura 16. Estructura básica de un bloque de Blockchain. (Fuente Propia)

La Figura 17 muestra la creación de los bloques y su unificación en un sistema blockchain. En el primer bloque se llama bloque de génesis esto respetando el diseño original de Blockchain para Bitcoin, Satoshi Nakamoto propone este bloque, con el propósito de ser la base de la construcción de toda la cadena [77]. El diseño de este bloque contiene todos los campos excepto el hash del bloque anterior.




Figura 17. Enlace de cubos de Blockchain. (fuente Ethereum)

### 3.6.3 Arquitectura final y pruebas de rendimiento.

En la figura 16 se presenta el proceso del envío de los datos mediante un cifrado simétrico y por medio del protocolo de comunicación MQTT.

La llave de encriptación para este ejemplo es el ID del nodo. Para la implementación real por cuestiones de seguridad la llave debe tener una longitud de 128, 192 o 256 bits. Los elementos que conocen la llave son el nodo y el Broker. Primero el nodo de sensores realiza el monitoreo de las variables de humedad y temperatura, después a partir de la llave que tiene asignada de manera estática realiza el proceso de encriptación, viaja de manera inalámbrica hasta llegar al bróker donde se desencripta y los datos se suben a la base de datos para poder ser interpretados de manera gráfica. El Broker/Servidor fue una Raspberry Pi 3B+.

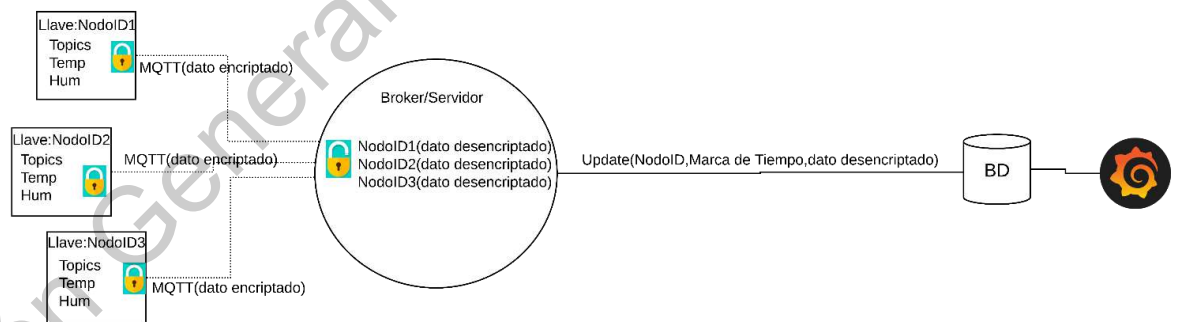


Figura 18. Diagrama de Red De sensores Inalámbrica. (Fuente Propia)

En la figura 19 observamos un diagrama del sistema de redes de sensores inalámbricas para la recolección de los datos. Se presenta un diagrama que se divide en capas. La primera capa es el ambiente donde encontramos las señales de humedad y temperatura. La segunda capa es donde se encuentran los nodos de sensores que forman la red de sensores inalámbricos se le denomina capa de

percepción porque en ella residen los dispositivos inteligentes que interactúan con el medio físico. La capa de transporte es donde el protocolo de comunicación entra en acción, en el diagrama observamos como los datos viajan encriptados con la herramienta criptográfica AES (por sus siglas en inglés, Advanced Encryption Standard) mediante el protocolo de comunicación MQTT (por sus siglas en inglés, Message Queue Telemetry Transport). La capa de Middleware es donde la descriptación de los datos y la actualización de la base de datos con los datos recibidos se realiza. En la capa de aplicación dos procesos importantes se llevan a cabo. Por un lado, tenemos la visualización gráfica de los datos recolectados mediante el software de Grafana. Y por otra parte se encuentra el mecanismo de Blockchain para compartir datos con múltiples usuarios de manera segura.

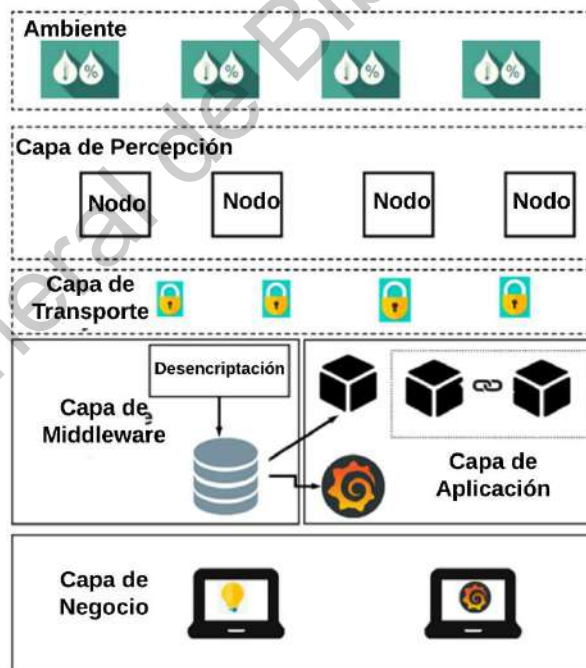


Figura 19. Arquitectura de Propuesta para redes de sensores inalámbricas con encriptación simétrica y mecanismo de blockchain. (Fuente Propia)

En la figura 20 observamos los nodos de sensores los cuales conforman la



red de sensores inalámbricas.



Figura 20. Nodos de Sensores Inalámbricos. (Fuente Propia)

Estos nodos de sensores constan de un sensor Telaire modelo T9602 (figura 21 izquierda) para monitoreo ambiental este sensor es uno de tipo industrial, utilizado desde tecnologías para el hogar para monitoreo de calidad del aire hasta en estaciones ambientales. Además, el nodo consta de un microcontrolador de la marca Pycom llamado WIPY modelo 3.0 (figura 21 derecha) con tecnología wifi y bluetooth diseñado exclusivamente para implementaciones en el internet de las cosas.



Figura 21. Sensor Telaire T9602(izquierda). (fuente página amphenol sensors).  
Microcontrolador Wipy 3.0(derecha). (fuente página Pycom).

En la figura 22 se muestra cómo funciona el software de visualización Grafana. El software Grafana es libre basado en licencia de Apache 2.0, que permite la visualización y el formato de datos métricos. Permite crear cuadros de mando y gráficos a partir de múltiples fuentes, incluidas bases de datos de series de tiempo como Graphite, InfluxDB y OpenTSDB. Grafana le permite consultar, visualizar, alertar y comprender sus métricas sin importar dónde estén almacenadas. Cree, explore y comparta paneles con su equipo y fomente una cultura basada en datos.



Figura 22. Visualización de datos ambientales en software Grafana.(Fuente Propia)

Este tipo de sistemas de monitoreo con mecanismo de blockchain y encriptación simétrica en la capa de transporte tienden a tener la fama de ser sistemas con un alto consumo computacional. En el caso de esta propuesta se demuestra todo lo contrario. En la figura 23 se presenta una gráfica donde compara la temperatura de CPU con y sin el sistema de seguridad. La línea azul es el sistema sin mecanismo propuesto y la línea negra es con el mecanismo propuesto. Viendo como no llega ni al 58°C, la temperatura máxima registrada es de 85°C si una Raspberry Pi modelo 3B+ sobrepasa esta temperatura sufre daños en el sistema a nivel hardware [80].

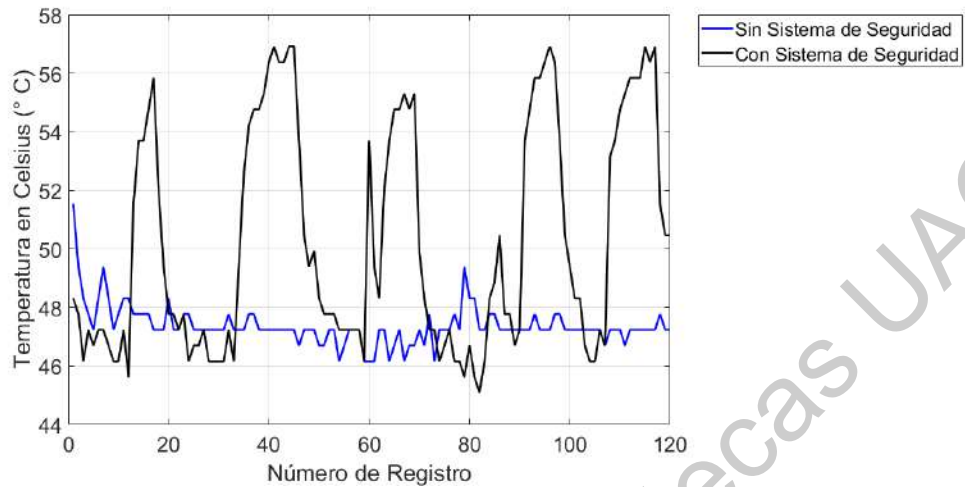


Figura 23. Temperatura del hardware. (Fuente Propia)

En la siguiente figura, es una gráfica del porcentaje de uso del CPU. La línea azul es el sistema sin mecanismo propuesto y la línea negra es con el mecanismo propuesto vemos claramente como nuestra propuesta no llega ni al 50% de la capacidad de la Raspberry Pi 3B+. Probando, así como nuestro mecanismo, además de proveer aspectos básicos de seguridad al sistema de redes de sensores inalámbricos es ligero y ofrece interoperabilidad al sistema de redes de sensores inalámbricos. Aspectos que son importantes para cualquier sistema de Internet de las cosas.




Figura 24. Porcentaje de uso de la CPU. (Fuente Propia)

## 3.7 Materiales.

En esta sección se presentan los elementos de software y hardware necesarios para el desarrollo de esta investigación. Estos elementos fueron vitales para cumplir con cada uno de los puntos dentro de los objetivos específicos.

El lenguaje de programación Python versión 3.7 fue parte primordial para el desarrollo de esta investigación. Además, se usaron librerías adicionales para trabajar de manera paralela al lenguaje de programación. Una de ellas es Matplotlib, según su página principal [81] se describe como una librería para crear visualizaciones estáticas, animadas e interactivas en cualquier versión de Python. Otra librería que se debe mencionar es Numpy esta librería en su página principal se describe paquete fundamental para la computación científica con Python [82]. Esta librería es útil para manejar matrices y vectores con dimensión  $N$ , para realizar procesos matemáticos de algebra lineal entre otras características. Para la manipulación de los datos se utilizo la librería Pandas, según su página se describe como una herramienta de análisis y manipulación de datos de código abierto rápida, potente, flexible y fácil de usar [83]. Para obtener ciertos datos que son complicados de obtener por la instrumentación que se requiere. Para este punto se utilizó la herramienta Energy Plus aprobada por varias instituciones a nivel internacional entre ellas la Agencia Internacional de Energía entre otros que presenta en su página principal [84]. Este software se describe en su página principal como un programa completo de simulación de energía del edificio que los ingenieros, arquitectos e investigadores usan para modelar tanto el consumo de energía (para calefacción, enfriamiento, ventilación, iluminación y carga de enchufes y procesos) como el uso de agua en los edificios. En la figura 23 se presenta un diagrama del funcionamiento del gestor de simulación.

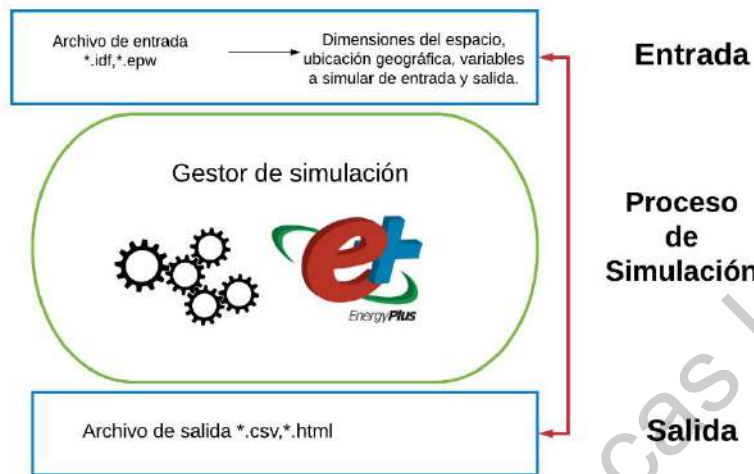


Figura 25. Diagrama simulación EnergyPlus. (Fuente Propia)

Además, para poder ligar el simulador con Python se utilizó una herramienta llamada BCVTB, el cual se describe como un entorno de software que permite a los usuarios acoplar diferentes programas de simulación para la cosimulación, y acoplar programas de simulación con hardware real. Además, se utilizaron herramientas para auxiliar en la visualización de datos y comportamiento térmico, para esto se utilizó, Grafana. El cual se define en su página principal como un software libre basado en licencia de Apache 2.0, que permite la visualización y el formato de datos métricos. Permite crear cuadros de mando y gráficos a partir de múltiples fuentes, incluidas bases de datos de series de tiempo como Graphite, InfluxDB y OpenTSDB. En Además, se utilizó una base de datos para guardar los datos ambientales y de potencia en su mayoría simulados requeridos para el desarrollo de este proyecto y para la visualización en tiempo real del comportamiento de los modelos. El modelo de la base de datos se muestra en la figura 26.

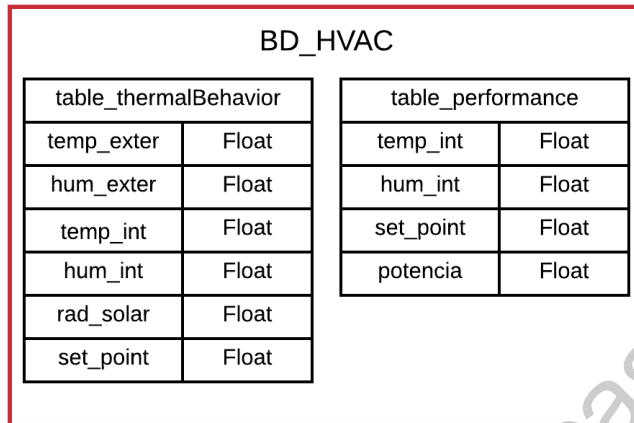


Figura 26. Modelo de Base de datos. (Fuente Propia)

En la figura 27 se muestra la gráfica de los datos ambientales, como temperatura externa y temperatura interna, ambos expresados en Grados Centígrados (°C). La línea roja es la temperatura externa al espacio de pruebas y la línea negra es la temperatura interna del espacio de pruebas.




Figura 27. Grafica temperatura externa e interna. (Fuente Propia)

En la figura 28 se muestra la gráfica de los datos ambientales, como humedad externa y humedad interna. La línea roja es la temperatura externa al espacio de pruebas y la línea negra es la temperatura interna del espacio de pruebas. La unidad de medida de esta variable es el porcentaje (%) dado que es humedad relativa.




Figura 28. Grafica Humedad Externa e Interna. (Fuente Propia)

En la figura 29 se muestra la gráfica de la radiación solar al exterior del espacio de pruebas. La unidad de medida de esta variable es el Watts por Metro cuadrado ( $W/m^2$ ).




Figura 29. Grafica Radiación solar. (Fuente Propia)

En la figura 30 se muestra el proceso que se utilizó para el desarrollo de los modelos predictivos. Donde los datos seleccionados desde la base de datos pasan por un proceso de pre procesamiento el cual consiste en eliminar campos vacíos, eliminar datos atípicos y la normalización con la fórmula de normalización min max.

$$Min - Max = \frac{x - \min(x)}{[\max(x) - \min(x)]} \quad (12)$$

Inicia el entrenamiento, prueba y validación de los datos. Quedando 70% de los datos para entrenamiento 15% para validación y 15% para pruebas.



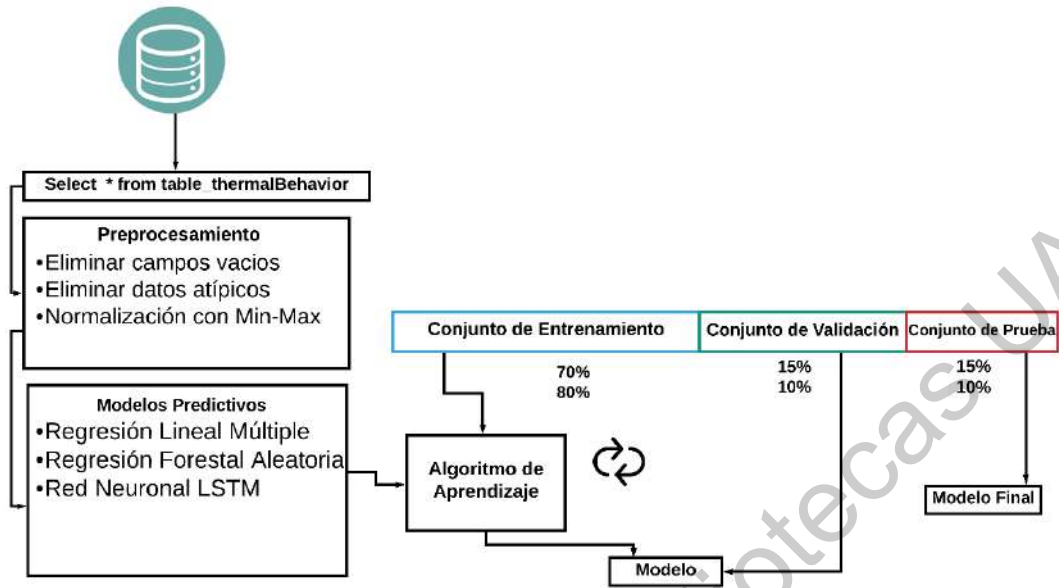


Figura 30. Metodología para entrenamiento de modelos predictivos. (Fuente Propia)

En la tabla 3 se muestra las señales de entrada que se utilizaron para los tres modelos que se entrenaron con su unidad de medida. Y en la tabla 4 se muestra la señal de salida del modelo predictivo con su respectiva unidad de medida.

Tabla 3. Parámetros de entrada.

Señal Ambiental	Unidad de medida
Temperatura Exterior	°C
Temperatura Interior	°C
Humedad Interior	%
Humedad Exterior	%
Radiación solar	W/m <sup>2</sup>

Tabla 4. Parámetro de salida

Señal Ambiental	Unidad de medida
Punto de ajuste	°C

Para los modelos de los sitios de prueba se utilizaron dos softwares de arquitectura el primero es AutoCAD Desktop 2019, para realizar el modelado en 3D. AutoCAD es un software reconocido a nivel internacional por sus amplias capacidades de edición, que hacen posible el dibujo digital de planos de edificios o la recreación de imágenes en 3D; es uno de los programas más usados por arquitectos, ingenieros, diseñadores industriales y otros. Por otro lado, para realizar las simulaciones donde se observa de forma gráfica el confort térmico de edificio se ocupó Autodesk CFD. El cual se define como un software inteligente para simular el comportamiento térmico y de fluidos. Permite la realización de simulaciones dinámicas y térmicas de fluidos para ayudar al usuario a realizar sus productos.

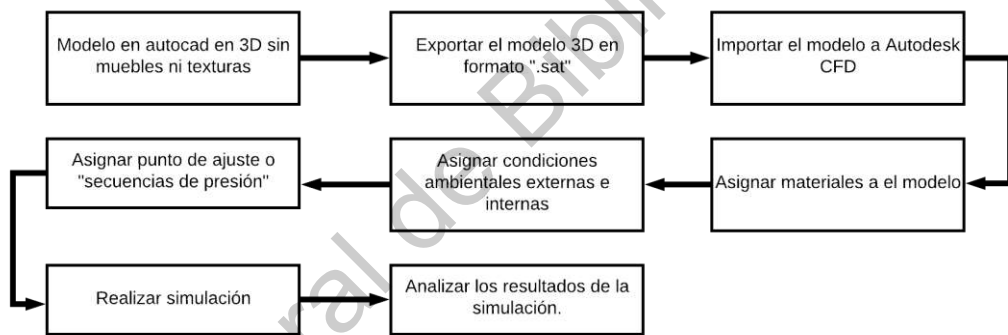


Figura 31. Diagrama del proceso de simulación 3D. (Fuente Propia).

En la figura 31 se muestra el proceso para la simulación inicial con el modelado del espacio en 3D en el software de AutoCAD. Sin muebles y sin texturas dado que estos elementos pudieran entorpecer la simulación. Después se exporta el modelo a un archivo con extensión “.sat”, posteriormente se crea el modelo en Autodesk y se importa el archivo que previamente se creó. Después se asignan los materiales a la estructura como concreto, madera o césped. Queda un modelo como el de la figura 32.

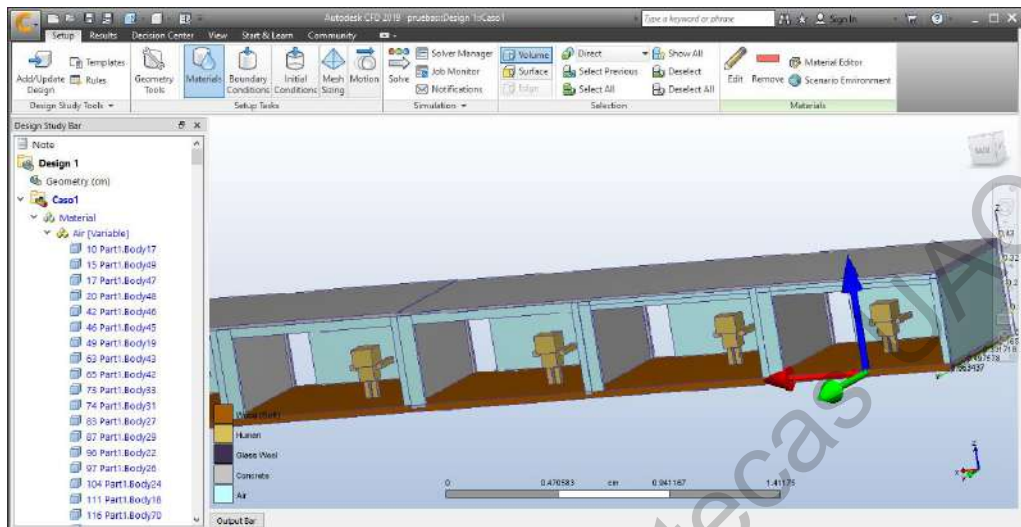


Figura 32. Captura de modelo 3D en Autodesk CFD 2019. (Fuente Propia)

Después se asignan las condiciones ambientales externas e internas para realizar la simulación, estos datos se obtienen de la simulación anterior con los diferentes modelos de control. Se asignan los valores del punto de ajuste mostrando al software de simulación, que valores debe de tomar en ciertas condiciones climáticas. Es como enseñar al software, pero manualmente ya que no existe algún conector para con el sistema. Se corre la simulación y se analizan los resultados.

## Pruebas y Resultados.

### 4.1 Desempeño de los modelos predictivos.

En la figura 33 se presenta una comparación de curvas de aprendizaje con diferentes valores de alpha. Este valor es el hiperparámetro para medir el costo de error en un modelo de regresión lineal múltiple con el algoritmo de gradiente descendiente. Mientras más bajo sea el costo es mejor el valor, este costo se calcula con la métrica de evaluación de Error Absoluto Medio (MAE por sus siglas en inglés Mean Absolute Error). Teniendo como resultado que alpha con el valor de 0.3 es la mejor opción para nuestro modelo. Esto se verá reflejado en resultados más adelante en el ámbito de desempeño del modelo.

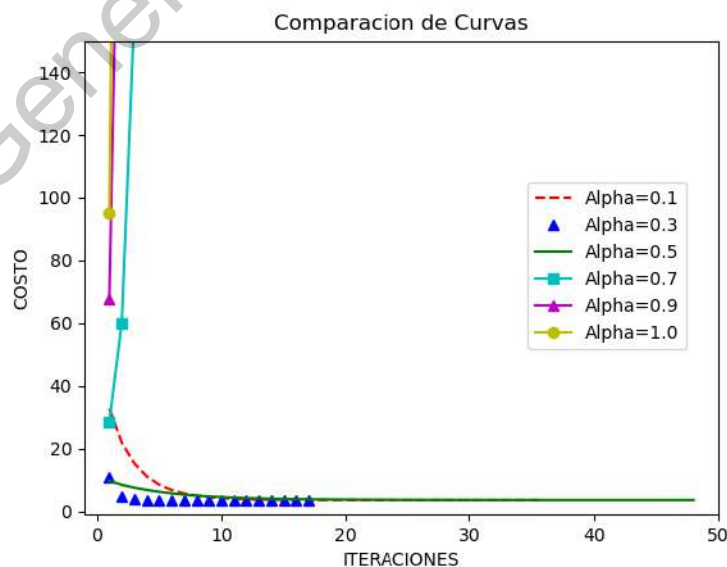
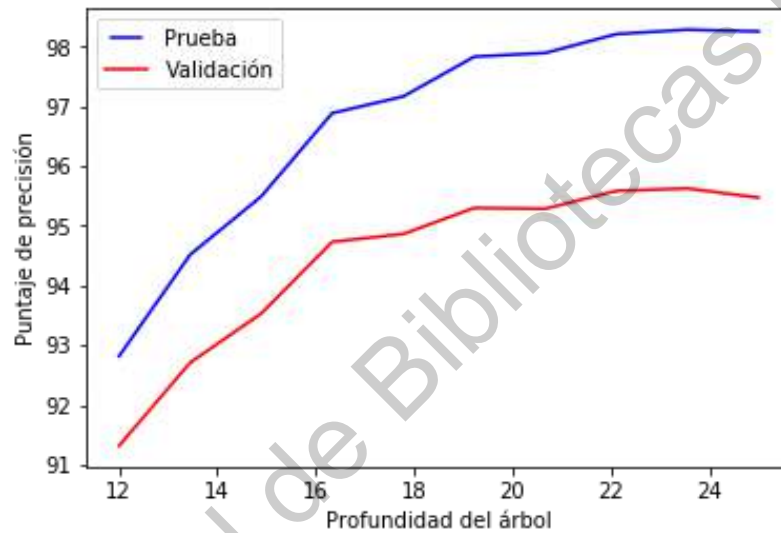


Figura 33 Curva de entrenamiento RLM. (Fuente Propia)

En la figura 34 se presenta la curva de aprendizaje con sobreajuste de un modelo de Regresión forestal aleatorio. En el caso si los datos no son procesados, esto con el objetivo de mostrar la importancia del pre procesamiento de los datos. En la figura 35 es un modelo donde los datos pasaron por la fase de pre procesamiento.



Fuente 34. Curva de aprendizaje aprendizaje Regresión Forestal Aleatoria con sobreajuste. (Fuente Propia)




Figura 35. Curva de aprendizaje Regresión Forestal Aleatoria. (Fuente Propia)

En la gráfica 36 se presenta el desempeño de la arquitectura inicial que se presenta en la figura 37. Vemos como existe una separación notoria entre las curvas lo cual nos indica sobreajuste. Para estos casos se recomienda usar una herramienta llamada Drop Out. Esta herramienta es un método de regularización donde las entradas y las conexiones recurrentes a las unidades LSTM se excluyen probabilísticamente de las actualizaciones de activación y peso durante el entrenamiento de una red. Esto tiene el efecto de reducir el sobreajuste y mejorar el rendimiento del modelo.

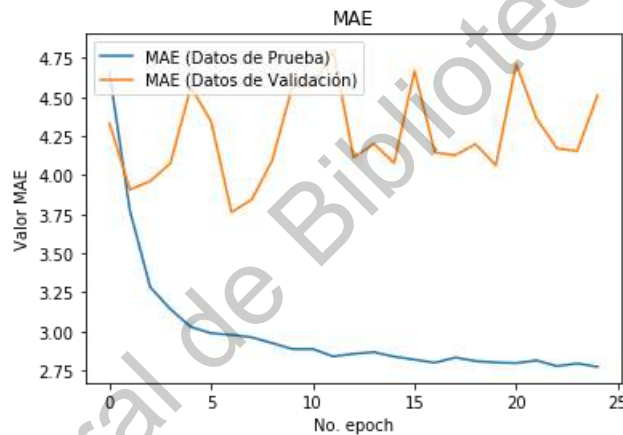


Figura 36. Curva de aprendizaje Red Neuronal LSTM con sobreajuste. (Fuente Propia)




Figura 37. Arquitectura Inicial para pruebas. (Fuente Propia)

En la figura 38 se muestra la curvatura de aprendizaje con una reducción notoria de sobreajuste. Esa curvatura es de la arquitectura final presentada en la figura 40. El cual se utiliza la herramienta de Drop Out, con dos capas de ocultas con 30 neuronas ocultas cada una.




Figura 38. Curva de aprendizaje Red Neuronal LSTM. (Fuente Propia)




Figura 39. Arquitectura de red Neuronal LSTM. (Fuente Propia)

En la tabla 5 se presentan los valores de las métricas de evaluación. Se presenta el promedio que se obtuvo utilizando K-Fold, de la misma forma que se obtuvo la desviación típica o la desviación estándar.

Tabla 5. Desempeño de modelos de predicción de datos.

Modelo	RMSE mean	RMSE STD	MAE mean	MAE STD	r <sup>2</sup> mean	r <sup>2</sup> STD
Entrenamiento						
RLM	3.38668	0.999342	2.77124	0.113453 4	0.86934	0.013423
RF	0.41668	0.59834	0.24235	0.03234	0.9503	0.027343
LSTM	0.85384	0.30435	0.50069	0.04523	0.97835	0.012343
Validación						
RLM	3.238764	0.912343	2.60234	0.10232	0.70234	0.01234
RF	0.382381	0.502948	0.223423	0.02923	0.9642	0.028243
LSTM	0.804321	0.28423	0.49533	0.047723	0.98234	0.015453
Prueba						
RLM	3.427664	1.013726	2.808149	0.118867	- 0.012250	0.014465
RF	1.162098	0.487434	0.548104	0.06713	0.881047	0.037005
LSTM	0.959495	0.255992	0.596005	0.055864	0.922612	0.013905

Por otro lado, en la tabla 6 se presenta el porcentaje de precisión de los algoritmos, en la fase de prueba. Colocando a la red neuronal LSTM con un puntaje alto y suficiente con 99.98%. Seguido de Random Forrest con 98.74% y al final regresión lineal múltiple con 74.56%.

Tabla 6. Porcentaje de precisión de los modelos predictivos.

Modelo	Precisión(Accuraccy)
MLR	74.56%
RF	98.74%
LSTM	99.98%



## 4.2 Modelos y Metodología para Pruebas.

En la figura 40 observamos la metodología utilizada para poder evaluar la eficacia como estrategias de control de los modelos de aprendizaje automático y el de aprendizaje profundo. Para tener un diseño estructurado se dividió por capas en la primera tenemos al software de simulación Energyplus. Este software de simulación apoya para estructura, simulando las variables ambientales externas e internas, así como la potencia del sistema de ventilación según el comportamiento que este tenga con las diferentes estrategias de control. En el diagrama observamos como el punto de ajuste o set point es manipulado por las estrategias de control a través de una capa de transporte la cual se llama BCVTB el cual es un software para poder manipular ciertas variables de simulación del software EnergyPlus.

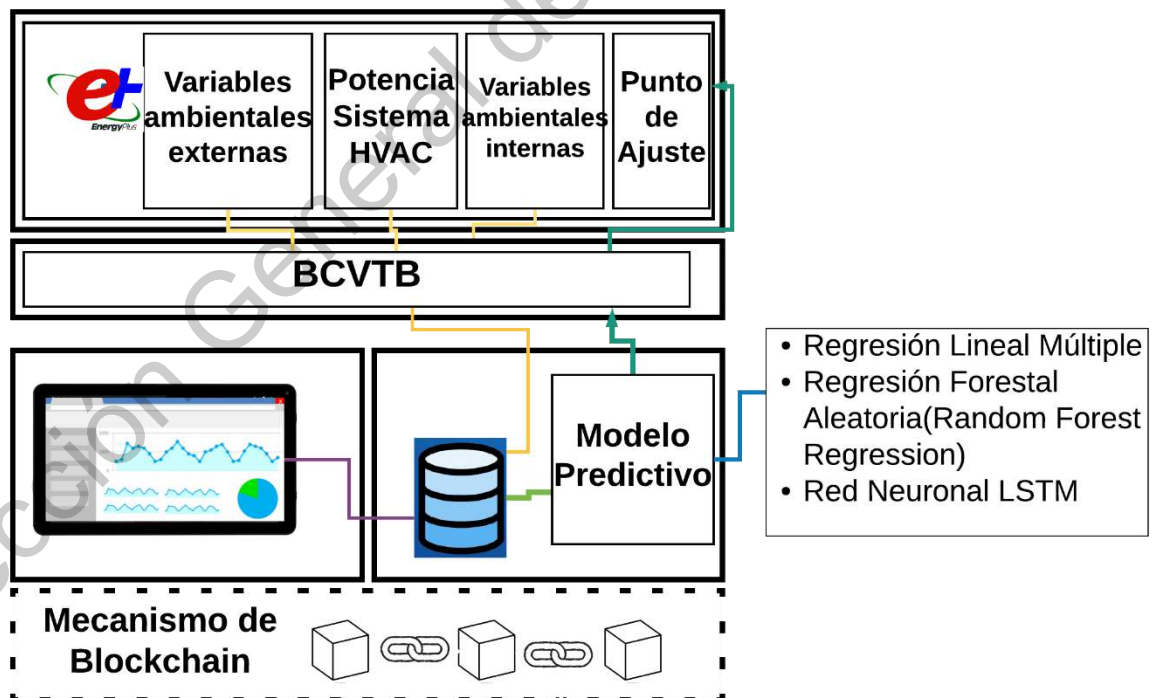


Figura 40. Metodología para probar Estrategias de Control. (Fuente Propia)

Además, el resultado de la simulación se guarda en una tabla dentro de la base de datos. Esto con el fin de analizar los datos más adelante de manera más profunda tanto del comportamiento en el desempeño del sistema HVAC como el comportamiento térmico de los espacios. Es decir, evaluar las variables ambientales. Además de tener en la última capa un mecanismo de blockchain para compartir de manera descentralizada la información obtenida para futuras investigaciones.

Para evaluar las estrategias de control fueron necesarios modelos en distintos ámbitos y de distinta potencia. Los tres modelos utilizados son descritos a detalles en esta sección, así como el tipo de sistema HVAC que se utilizó. El primer modelo es una casa convencional de un piso, la cual aparece en la figura 41 El modelo cuenta con los elementos esenciales de una casa, una sala, cocina, dos habitaciones, baño compartido, patio de servicio y jardín. El espacio donde se encuentra el sistema de ventilación es en la sala-comedor la cual tienen un área de 16 m<sup>2</sup>. Es decir, la sala donde el sistema HVAC se localiza tiene medidas de 4 metros por 4 metros. Es por eso que un sistema HVAC de 1 Tonelada tiene la suficiente potencia para espacios con esta área.

**1** Casa convencional de un piso con un sistema HVAC de 1 Tonelada.




Figura 41. Modelo 1. (Fuente Propia)

En la figura 42 se muestran 3 bloques de oficinas, son independientes entre ellas, pero tienen las mismas características. Como el área la cual es de 25 m<sup>2</sup> es por esto que el sistema de ventilación para este espacio tiene una potencia de 1.5 toneladas.

**2** Oficina con un sistema de HVAC de 1.5 toneladas.



Figura 42. Modelo 2. (Fuente Propia)

El último modelo es una pequeña sala de exhibición de un museo, el cual en la figura 43 se encuentra el modelo que se utilizó. El área de este espacio es de 32 m<sup>2</sup> es por esto que un sistema de ventilación de 2 toneladas es suficiente para cubrir este espacio.

**3** Sala de exhibición de un museo con un sistema HVAC de 2 toneladas.




Figura 43. Modelo 3. (Fuente Propia)

## **4.3 Potencia y Consumo de Energía.**

En esta sección se presentan las gráficas de la potencia de los sistemas de climatización y una tabla del consumo final. Las simulaciones se llevaron a cabo en los tres modelos que se realizaron. Una casa de un piso con un sistema de climatización de 1 tonelada. Una oficina con un sistema con una capacidad de 1.5 toneladas. Y una sala de exhibición de un museo con un sistema con una capacidad de 2 toneladas. Las capacidades de los sistemas de ventilación se asignaron tomando en cuenta el área de los modelos. Las horas de pruebas fueron 480 horas lo equivalente a 2 meses de uso del sistema. Tomando en cuenta el tiempo promedio de uso de sistemas de ventilación de 8 horas. Sobre todo, en épocas calurosas en el territorio de Querétaro, las cuales comprenden los meses de abril a Julio. Los meses de prueba en esta investigación son los meses de Abril y Mayo.

### **4.3.1.- Sistema de climatización de 1 tonelada.**

En la figura 44 se presentan dos gráficas, la superior pertenece al comportamiento del sistema de climatización de 1 Tonelada con un control tradicional On-Off. La grafica inferior es el mismo sistema de climatización, pero con una estrategia de control con un modelo predictivo de regresión lineal Múltiple. Podemos observar como en el control tradicional genera cambios bruscos en la potencia del sistema, esto se observa en los picos de la gráfica. Estos picos son los causantes del consumo excesivo de energía y de disminuir la vida útil de los sistemas HVAC. En el grafica inferior observamos hay una reducción de estos picos esto por la estrategia de control que se implementa.




Figura 44. Graficas de potencia de sistema HVAC de 1 Tonelada control RLM. (Fuente Propia)

En la figura 45 se presentan dos gráficas, la superior pertenece al comportamiento del sistema de climatización con un control tradicional On-Off. La grafica inferior es el mismo sistema de climatización, pero con una estrategia de control con un modelo predictivo de regresión forestal aleatoria. En la gráfica inferior se observa una disminución considerable en los cambios bruscos de operación, esto se verá reflejado más adelante en el consumo energético y en el comportamiento térmico.




Figura 45. Graficas de potencia de sistema HVAC de 1 Tonelada control RF. (Fuente Propia)

Y finalmente para este modelo, en la figura 46 se presentan dos gráficas, la superior pertenece al comportamiento del sistema de climatización con un control tradicional On-Off. La grafica inferior es el mismo sistema de climatización, pero con una estrategia de control con un modelo predictivo de regresión forestal aleatoria. Se observa una disminución en los cambios bruscos, de manera considerable.

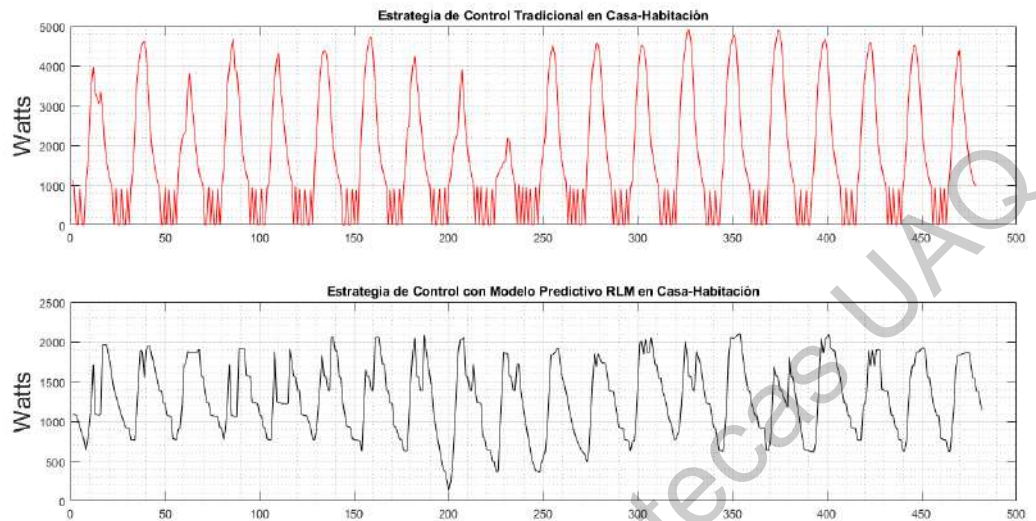


Figura 46. Graficas de potencia de sistema HVAC de 1 Tonelada control LSTM. (Fuente Propia)

### 4.3.2 Sistema de climatización de 1.5 toneladas.

En la figura 47 observamos la potencia del sistema HVAC con un control tradicional ON-OFF la gráfica superior. Por otro lado, la gráfica superior presenta la potencia del sistema de climatización con un control basado en el modelo predictivo de regresión lineal múltiple (Multiple Linear Regression, MLR). El consumo promedio en sistemas de climatización de 1.5 toneladas es de 1680 Watts. En la gráfica superior se puede observar como el sistema sobrepasa del promedio, sobre todo en los picos que vemos en la gráfica estos suceden cuando el sistema es apagado y encendido un tiempo después, y estos son los que causan el consumo elevado de energía. En este caso se reporta un consumo total de 954 kWh en un periodo de dos meses. Este valor se encuentra por arriba del promedio que es 806 kWh, en el mismo periodo de dos meses. El valor total del consumo con este tipo de control se coloca con 16% arriba del promedio. Por otro lado, la gráfica superior el consumo en un periodo de dos meses con este control inteligente es de 814 kWh.



El cual es 1% arriba del promedio y 15% por debajo del control anterior.




Figura 47. Graficas de potencia de sistema HVAC de 1.5 Tonelada control RLM. (Fuente Propia)

En la figura 48 grafica inferior se presenta la potencia del sistema de climatización de 1.5 toneladas controlado con el modelo de aprendizaje automático de árboles aleatorios de regresión (Random Forrest, RF). Con este sistema de control se reportó un consumo de 577 kWh. Esta cantidad está por debajo del promedio con 28%. De igual manera se reporta con el sistema de control manual y clásico con una reducción del 40%.



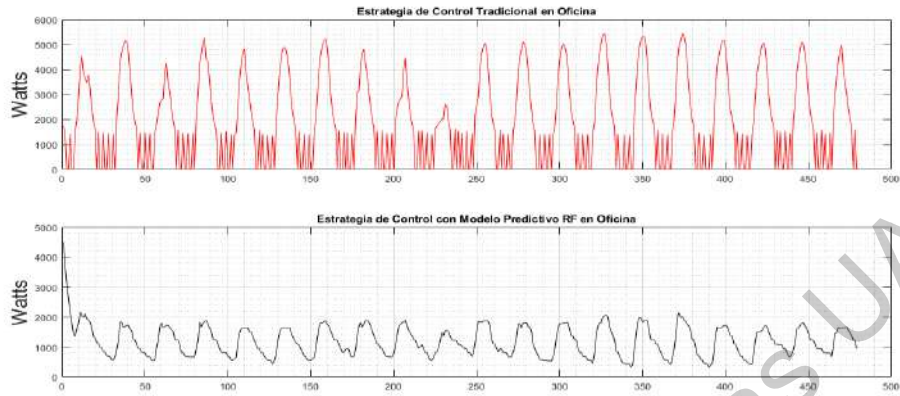


Figura 48. Graficas de potencia de sistema HVAC de 1.5 Tonelada control RF (Fuente Propia)

La ultima grafica inferior presenta el desempeño del sistema de climatización. Donde vemos la potencia del sistema con un control inteligente con el modelo de aprendizaje profundo LSTM. Teniendo un consumo de 453 kWh, el cual representa un 44% menos que el consumo promedio y un 56% menos que con el control clásico de control. Además, de una reducción notoria en los cambios bruscos en la operación del sistema HVAC.

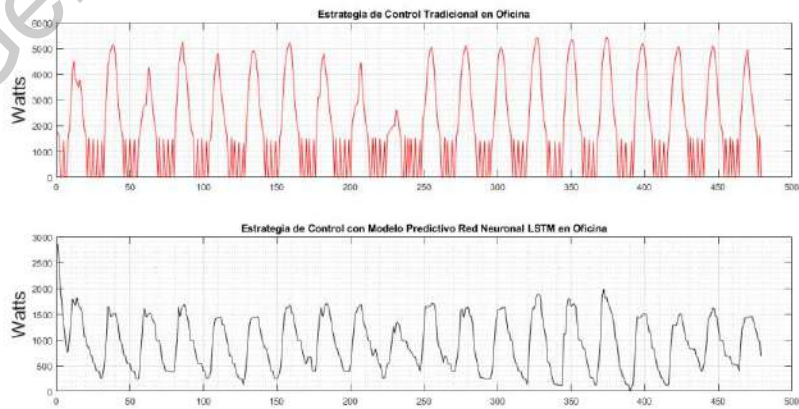


Figura 49. Graficas de potencia de sistema HVAC de 1.5 Tonelada control LSTM. (Fuente Propia)

### 4.3.3 Sistema de climatización de 2 Toneladas.

En la figura 50 en la gráfica superior se presenta la potencia de un sistema HVAC de 2 toneladas con un control tradicional On-Off. La gráfica inferior presenta de la potencia del sistema de 2 toneladas, pero con el control inteligente basado en regresión lineal múltiple. El consumo promedio en sistemas de climatización de dos toneladas es de 2280 Watts. En esta gráfica se puede observar como el sistema sobrepasa del promedio, sobre todo en los picos que vemos en la gráfica estos suceden cuando el sistema es apagado y encendido un tiempo después, y estos son los que causan el consumo elevado de energía. En este caso se reporta un consumo total de 2551 kWh en un periodo de dos meses. Este valor se encuentra por arriba del promedio que es 1094 kWh, en el mismo periodo de dos meses, lo cual es 58% arriba del promedio. Este sistema de control reporta un consumo en un periodo de dos meses de 1619 kWh. El cual esta con un 37% por debajo del control tradicional y 33% por arriba del promedio.

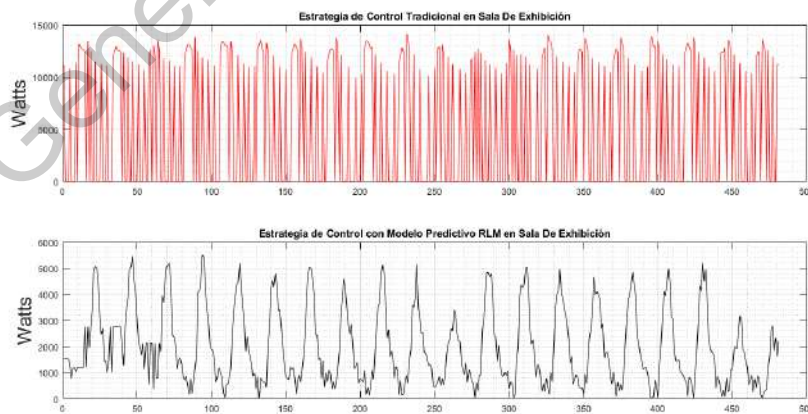


Figura 50. Graficas de potencia de sistema HVAC de 1.5 Tonelada control RLM. (Fuente Propia)

En la figura 51 gráfica inferior, presenta la potencia del sistema de ventilación

de 2 toneladas con el control basado en el modelo de aprendizaje automático Random Forrest. El cual reporta un consumo final de 1003 kWh en un periodo de dos meses. El cual se encuentra por debajo del promedio con un porcentaje del 8 % y del control tradicional con un porcentaje del 45%. La gráfica superior es el sistema con una estrategia de control tradicional. En comparación entre las gráficas observamos como existe una optimización en la operación del sistema de ventilación.




Figura 51. Graficas de potencia de sistema HVAC de 1.5 Tonelada control RF. (Fuente Propia)

En la figura 52 en la gráfica inferior se presenta la potencia del sistema de ventilación de 2 toneladas con el control basado en el modelo de aprendizaje profundo de redes neuronales LSTM. El cual reporta un consumo final de 997 Kwh en un periodo de dos meses. El cual se encuentra por debajo del promedio con un porcentaje del 5% y del control tradicional con un porcentaje del 44%




Figura 52. Graficas de potencia de sistema HVAC de 1.5 Tonelada control LSTM. (Fuente Propia)

En la tabla 7 es una vista general del consumo de los sistemas de HVAC todos expresados en kilowatts-hora (kWh). En la tabla tenemos la columna de modelo que es donde se encuentra el tipo de espacio donde se realizaron las pruebas del sistema de control, también especifica la potencia del sistema HVAC. En las demás columnas, tenemos el consumo con el control tradicional de control, seguido del control RLM (Regresión Lineal Múltiple), después RF (Random Forrest). Seguido del control basado en aprendizaje profundo, la red neuronal LSTM y la última columna es el consumo promedio esperado en kWh según datos proporcionados por la Secretaría de Energía (SENER) [85].

Tabla 7. Consumo de energía de sistemas HVAC. (\*El consumo se expresa en Kwh).

Modelo	Control tradicional	RLM	RF	LSTM	Promedio
Casa (HVAC 1 Ton)	827	634	619	451	556
Oficina (HVAC 1.5 Ton)	954	814	577	452	806
Sala de exhibición (HVAC 2 Ton)	2550	1619	1003	997	1094

## 4.4 Confort Térmico

Es importante tomar en cuenta el confort térmico, esto porque así definimos si el control inteligente no solamente genera una reducción del consumo del sistema de ventilación. Es importante evaluar el confort térmico. Para esto se utilizó un software de simulación Autodesk CFD. Basándose en los resultados anteriores se cada modelo utilizo un distinto modelo de control. La casa de un piso con un sistema HVAC de una tonelada utilizo el control de regresión lineal múltiple. La oficina con un sistema de 1.5 toneladas uso el sistema con el modelo de aprendizaje automático de Random Forrest. La sala de exhibición por su volumen y basándose en los resultados de consumo energético, se le asignó el sistema de control basado en el 70 modelo de aprendizaje profundo red neuronal artificial LSTM. Las pruebas térmicas se realizaron con dos casos cuando la temperatura exterior se encuentra agradable rondando en las temperaturas de 20 a 23 °C con una humedad de 60% a 70%, una sensación térmica exterior no seca. El otro caso es algo más extremo con una temperatura que ronda entre los 28°C a 30°C con una humedad por debajo del 15% una sensación térmica extremadamente seca pero que se tiene registros de estos dos casos de sensación térmica en el estado de Querétaro.

## 4.4.1 Análisis de Confort térmico sistema HVAC de 1 tonelada.

En las figuras 53 y 54, vemos el comportamiento exterior de modelo. Es interesante ver como las paredes exteriores se encuentran en valores ligeramente altos pero las paredes dentro de la casa mantienen una temperatura baja, esto por el sistema de ventilación el cual está funcionando.




Figura 53. Modelo de casa de un piso vista térmica. (Fuente Propia)




Figura 54. Modelo de casa de un piso vista térmica. (Fuente Propia)

Las siguientes imágenes son importantes para observar el confort térmico. Utilizando la métrica de evaluación de Opinión media estimada u Opinión media predecible mejor conocida como método de Fanger o Predicted Mean Vote (PMV).



En la figura 55 observamos primero que del lado izquierdo de la imagen está el indicar de PMV. Recordamos que 0 significa neutro, esto quiere decir que, basándose en las variables ambientales, el espacio es adecuado térmicamente para el ser humano. Este rango tiene un rango de error razonable al cual se encuentra entre -1 y 1. En las figuras 55 y 56 observamos cómo el interior de la casa se mantiene en un rango aceptable de -0.6 a 0.2. Y el exterior del modelo se sale de estos rangos, eso es por las variables exteriores.




Figura 55. Modelo de casa de un piso vista térmica.(Fuente propia)

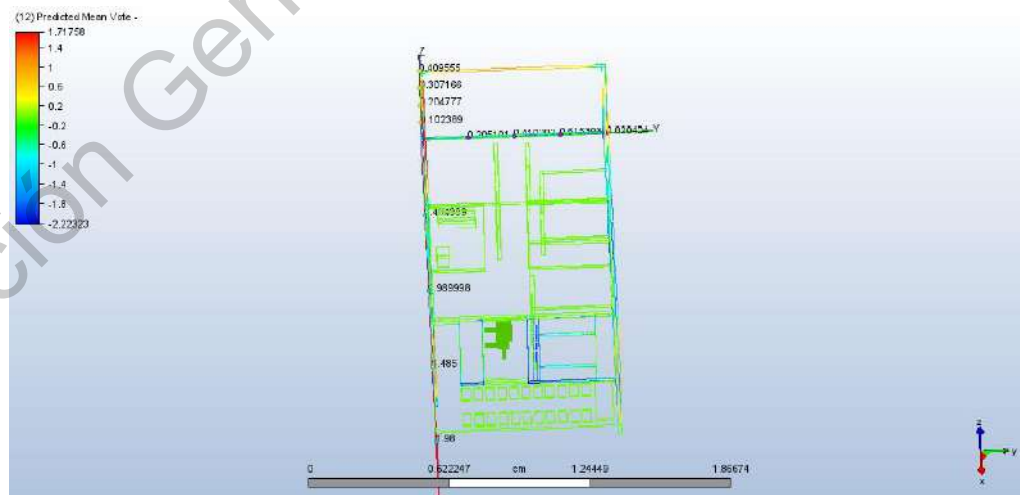


Figura 56 Modelo de casa de un piso vista térmica. (Fuente Propia)

En las figuras 57 y 58 vemos a una figura el cual representa a una persona. Este personaje tiene las características físicas de una persona normal, esto se puede simular gracias al software. Observamos el confort térmico en una persona el cual se encuentra en el rango aceptable de -0.6 y 0.2.




Figura 57. Confort térmico simulación en casa de un piso. (Fuente Propia)




Figura 58. Confort térmico simulación en casa. (Fuente Propia)

En las figuras 59 y 60 se muestra el segundo caso que se describió anteriormente. Podemos observar en estas imágenes dos cosas importantes. En la primera el confort térmico, en el interior de la casa se mantiene dentro de un rango



aceptable entre -0.5 y 0.5, mientras que las paredes exteriores de la casa se encuentran en 3 el cual representa un nivel de sofocación extremo para un ser humano. Por otro lado, la siguiente figura se observa las temperaturas dentro de la casa y como se distribuyen por la estructura.




Figura 59. Confort térmico simulación en casa de un piso. (Fuente Propia)

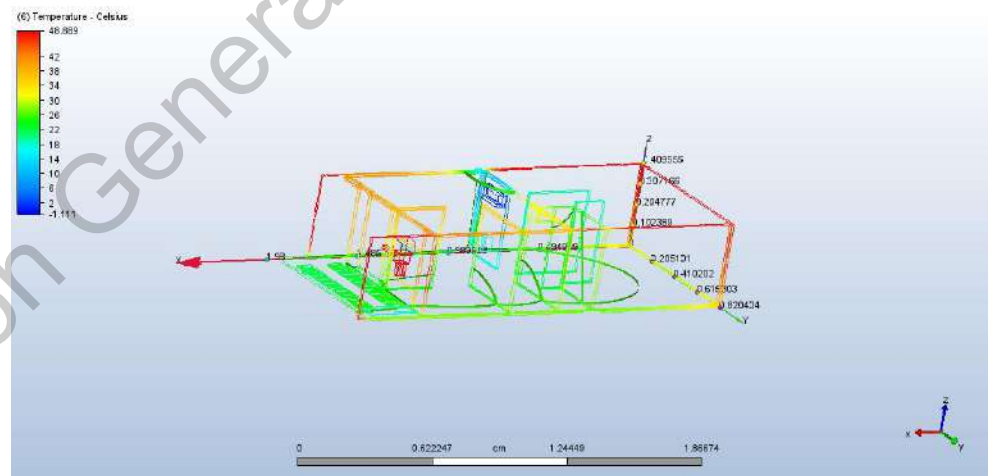


Figura 60 Confort térmico simulación en casa de un piso. (Fuente Propia)

En la figura 61 observamos el confort térmico de un ser humano dentro de la vivienda y con las condiciones climáticas un poco extremas. El confort térmico se

encuentra dentro de los rangos respetables y con cierto margen de error de 0.5. Oscilando entre -0.5 y 0.5 puntos en la escala de Fanger PMV.




Figura 61 Confort térmico simulación en casa de un piso. (Fuente Propia)

#### 4.4.2 Análisis de Confort térmico sistema HVAC de 1.5 toneladas.

La sala de exhibición. Recordando que para este modelo se utilizó el modelo de aprendizaje automático Random Forrest, el cual basándonos en los resultados del consumo de energía tuvo un buen desempeño en este modelo.

En las figuras 62 y 63 se presenta el modelo de oficinas. Como vemos son 6 oficinas, pero todas tienen las mismas configuraciones. Vemos las temperaturas exteriores del modelo.




Figura 62 Confort térmico simulación en oficina. (Fuente Propia)




Figura 63 Confort térmico simulación. (Fuente Propia)

En la figura 64 vemos la evaluación del confort térmico con el método de Fanger, PMV. Observamos como en este caso el rango es aceptable dado que se encuentra entre 0.4 y -0.4.




Figura 64. Confort térmico simulación en una oficina. (Fuente Propia)

En las figuras 65 y 66, se presenta el segundo caso. En el cual observamos el confort térmico en condiciones ambientales secas. Vemos como el sistema de control mantiene en un margen de error aceptable el confort térmico, en este caso [-0.4-0.4].




Figura 65 Confort térmico simulación en una oficina. (Fuente Propia)




Figura 66 Confort térmico simulación en una oficina. (Fuente Propia)

#### 4.4.3 Análisis de Confort térmico sistema HVAC de 2 toneladas.

En las figuras 67 y 68 se presenta el primer caso de condiciones térmicas, en la sala de exhibición del museo con el sistema de control con el modelo de aprendizaje profundo. Observamos los rangos de temperaturas del interior del espacio, así como la evaluación según el método de Fanger del confort térmico. Vemos como el margen de error se reduce en un rango de -0.4 a 0.4.




Figura 67. Confort térmico simulación en una sala de exhibición. (Fuente Propia)




Figura 68. Confort térmico simulación en una sala de exhibición. (Fuente Propia)

En la imagen 69 observamos la temperatura en grados centígrados dentro del modelo.




Figura 69 Confort térmico simulación en una sala de exhibición. (Fuente Propia)

En la figura 70 vemos el segundo caso donde las condiciones externas son extremadamente secas. Observamos el rango de temperaturas dentro del modelo de la sala de exhibición.




Figura 70 Confort térmico simulación en una sala de exhibición. (Fuente Propia)

En las figuras 71 y 72 observamos otras perspectivas de las temperaturas internas del modelo.




Figura 71 Confort térmico simulación en una sala de exhibición. (Fuente Propia)






Figura 71 Confort térmico simulación en una sala de exhibición. (Fuente Propia)

En la figura 73 vemos el confort térmico de la persona dentro de nuestro modelo. Vemos como margen de error es de 0.4 sabiendo que 0 es el valor aceptable para el confort térmico dentro de un espacio cerrado para un ser humano.




Figura 73 Confort térmico simulación en una sala de exhibición. (Fuente Propia)



## CAPÍTULO 5

---

### Conclusiones y Trabajo Futuro.

El comportamiento del usuario es un gran factor de incertidumbre en la operación del edificio. Si bien el seguimiento y la predicción de la ocupación están cada vez más disponibles a través de diversas herramientas, como los termostatos de aprendizaje, aún se carece de predicciones de temperaturas de confort. El uso del modelo PMV de Fanger es problemático para la predicción individual, ya que se desarrolló teniendo en cuenta a grupos de personas, mientras que las preferencias entre personas pueden diferir. Además, requiere datos difíciles de medir o muy específicos, lo que hace que su aplicación a gran escala sea complicada y costosa. La temperatura de confort está influenciada, entre otras cosas, por el clima, principalmente la temperatura del aire exterior, ya que influye en factores como la ropa y la tasa metabólica para determinadas actividades. El aprendizaje automático tiene el potencial de encontrar la relación entre los parámetros climáticos y la temperatura de confort de un individuo, ya que permite un análisis eficiente de grandes cantidades de datos. Si hay datos medidos disponibles, el aprendizaje supervisado puede establecer una conexión entre los datos de entrada y la salida deseada y deseada para hacer predicciones futuras. Se observó cómo los modelos de aprendizaje automático y aprendizaje profundo son buenas opciones para trabajar predicción de series de tiempo. Esto los métodos que usan para el entrenamiento de los modelos. La varianza y el sesgo o Bias altos, afectan considerablemente el desempeño y precisión (accuracy). Para poder obtener niveles bajos de varianza y bias algunos algoritmos como random Forrest con boosting, Support Vector Regression, redes neuronales recurrentes y redes neuronales LSTM utilizan tácticas para la reducción de estos valores. En el caso de regresión lineal múltiple y regresión del árbol de decisión, estas dos técnicas presentan problemas de valores altos de bias y varianza y al mismo tiempo de baja precisión. Es por eso que en estos modelos es necesario ajustar los 84 hiperparámetros y realizar un pre procesamiento de los datos más profundo que

solo la normalización de ellos. Además, en aprendizaje profundo y aprendizaje automático un buen modelo de predicción es ideal que tenga una precisión arriba del 90%. Si este valor es menor es necesario realizar ajustes en el modelo, desde el diseño, entrenamiento y valores de los hiperparámetros. Por otro lado, podemos afirmar basándonos en los resultados del consumo de energía y del confort térmico, que al tener un control primitivo de un sistema de ventilación afecta en varios aspectos no solo en consumo de energía del sistema de climatización. Afecta en el tiempo de vida útil del sistema de ventilación reduciéndolo desde un 20% hasta un 50%. Además de afectar el confort térmico del espacio al no tener una variedad de la temperatura, y solo oscilar entre una temperatura alta (28-30 °C) cuando el sistema de climatización no funciona y una temperatura baja (13-15 °C) cuando el sistema de ventilación funciona. De esta manera, se puede evaluar según normas de gestión y organizaciones internacionales como ASHRAE. Por último, se puede concluir basándose en la sección de resultados que este tipo de controles inteligentes pueden ser una gran opción para espacios de más de 50 m<sup>2</sup> de área. Dado que este tipo de espacios pueden llegar a ocupar una cantidad mayor de electricidad en sistemas de climatización en comparación de casas convencionales o residenciales.

Como trabajos futuros para esta investigación se pudieran utilizar técnicas en aprendizaje reforzado, como la metodología Q-learning la cual está dentro del campo de aprendizaje automático. De igual forma la metodología dentro del campo de aprendizaje automático máquinas de vectores soporte con el fin de realizar pruebas con tres tipos de kernel de esta metodología. Además de probar una clase de red neuronal que ha estado a tomar fuerza desde finales del año pasado, más por el desarrollo de la capacidad en las computadoras. Transformer Neural network el cual DeepMind uso para desarrollar AlphaStar. [86]. AlphaStar es un programa informático de DeepMind que juega al videojuego StarCraft II. Se dio a conocer al público por su nombre en enero de 2019. En un hito importante para la inteligencia artificial, AlphaStar alcanzó el estatus de Gran Maestro en agosto de 2019.

# REFERENCIAS

- [1] R.- Asale and Rae, "inteligencia: Diccionario de la lengua española," "Diccionario de la lengua española" - Edición del Tricentenario, 01-Jan-1970. [Online]. Available: <https://dle.rae.es/inteligencia?m=form#2DxmhCT>. [Accessed: 06-Jun-2020].
- [2] L. Steels and R. A. Brooks, *The artificial life route to artificial intelligence: building embodied, situated agents*. London: Routledge, 2018.
- [3] D. Jakhar and I. Kaur, "Artificial intelligence, machine learning and deep learning: definitions and differences," *Clinical and Experimental Dermatology*, vol. 45, no. 1, pp. 131–132, Sep. 2019.
- [4] A. Burkov, *The hundred-page machine learning book*. Quebec City, Canada: Andriy Burkov, 2019.
- [5] S. Raschka and V. Mirjalili, *Python machine learning: machine learning and deep learning with Python, scikit-learn, and TensorFlow 2*. Birmingham: Packt Publishing, 2019.
- [6] E. Charniak, *Introduction to deep learning*. Cambridge, Massachusetts; London, England: The MIT Press, 2019.
- [7] B. Ramsundar, P. Eastman, P. Walters, and V. Pande, *Deep learning for the life sciences: applying deep learning to genomics, microscopy, drug discovery, and more*. Beijing: O'Reilly, 2019.
- [8] M. Escamilla, "Energía, ¿la próxima crisis en la Ciudad de México? • Forbes México," *Forbes México*, 11-Sep-2014. [Online]. Available: <https://www.forbes.com.mx/energia-la-proxima-crisis-en-la-ciudad-de-mexico/>. [Accessed: 06-Jun-2020].
- [9] H. Lund, "Renewable energy strategies for sustainable development," *Energy*, vol. 32, no. 6, pp. 912–919, 2007.
- [10] Ú. Oswald, "Seguridad, disponibilidad y sustentabilidad energética en México," *Revista Mexicana de Ciencias Políticas y Sociales*, vol. 62, no. 230, pp. 155–195, 2017.
- [11] K. Fong, V. Hanby, and T. Chow, "HVAC system optimization for energy management by evolutionary programming," *Energy and Buildings*, vol. 38, no. 3, pp. 220–231, 2006.
- [12] J. R. R. Sánchez and R. C. Rivera, "Consumo energético y económico de las celdas fotovoltaicas en viviendas de estrato social de clase media-alta de Victoria, Tamaulipas México," *Revista Cimexus*, vol. 14, no. 1, pp. 13–31, Jan. 2019.
- [13] Iea, "International Energy Agency," IEA. [Online]. Available: <https://www.iea.org/>. [Accessed: 06-Jun-2020].
- [14] A. Ávila-Hernández, E. Simá, J. Xamán, I. Hernández-Pérez, E. Téllez-Velázquez, and M. Chagolla-Aranda, "Test box experiment and simulations of a green-roof: Thermal and energy performance of a residential building standard for Mexico," *Energy and Buildings*, vol. 209, p. 109709, 2020.
- [15] R. Adhikari, M. Pipattanasomporn, and S. Rahman, "Heuristic Algorithms for Aggregated HVAC Control via Smart Thermostats for Regulation Service," *IEEE Transactions on Smart Grid*, vol. 11, no. 3, pp. 2023–2032, 2020.

- [16] Tado. So steuert tado° die Heizung. [March 28, 2019]; Available from: <https://www.tado.com/de/thermostat-heizung>.
- [17] Y. Sun, J. Hou, R. Cheng, Y. Sheng, X. Zhang, and J. Sundell, "Indoor air quality, ventilation and their associations with sick building syndrome in Chinese homes," *Energy and Buildings*, vol. 197, pp. 112–119, 2019.
- [18] W. W. Che, C. Y. Tso, L. Sun, D. Y. Ip, H. Lee, C. Y. Chao, and A. K. Lau, "Energy consumption, indoor thermal comfort and air quality in a commercial office with retrofitted heat, ventilation and air conditioning (HVAC) system," *Energy and Buildings*, vol. 201, pp. 202–215, 2019.
- [19] Instituto Nacional de Estadística and Inegi, "Mapas. Climatológicos," Instituto Nacional de Estadística y Geografía (INEGI). [Online]. Available: <https://www.inegi.org.mx/temas/climatologia/>. [Accessed: 06-Jun-2020].
- [20] K. H. Cheong, Y. H. Teo, J. M. Koh, U. R. Acharya, and S. C. M. Yu, "A simulation-aided approach in improving thermal-visual comfort and power efficiency in buildings," *Journal of Building Engineering*, vol. 27, p. 100936, 2020.
- [21] T. Pippia, J. Lago, R. D. Coninck, J. Sijs, and B. D. Schutter, "Scenario-based Model Predictive Control Approach for Heating Systems in an Office Building," 2019 IEEE 15th International Conference on Automation Science and Engineering (CASE), 2019.
- [22] S. Karmacharya, G. Putrus, C. Underwood, and K. Mahkamov, "Thermal modelling of the building and its HVAC system using Matlab/Simulink," 2012 2nd International Symposium On Environment Friendly Energies and Applications, 2012.
- [23] A. Wemhoff and M. Frank, "Predictions of energy savings in HVAC systems by lumped models," *Energy and Buildings*, vol. 42, no. 10, pp. 1807–1814, 2010.
- [24] P. M. Ferreira, S. M. Silva, A. E. Ruano, A. T. Negrier, and E. Z. Conceicao, "Neural network PMV estimation for model-based predictive control of HVAC systems," The 2012 International Joint Conference on Neural Networks (IJCNN), 2012.
- [25] Z. Deng and Q. Chen, "Simulating the impact of occupant behavior on energy use of HVAC systems by implementing a behavioral artificial neural network model," *Energy and Buildings*, vol. 198, pp. 216–227, 2019.
- [26] J. Wang, S. Li, H. Chen, Y. Yuan, and Y. Huang, "Data-driven model predictive control for building climate control: Three case studies on different buildings," *Building and Environment*, vol. 160, p. 106204, 2019.
- [27] A. Javed, H. Larijani, A. Ahmadinia, and D. Gibson, "Smart Random Neural Network Controller for HVAC Using Cloud Computing Technology," *IEEE Transactions on Industrial Informatics*, vol. 13, no. 1, pp. 351–360, 2017.
- [28] A. A. Jaber, A. Saleh, and H. F. M. Ali, "Prediction of Hourly Cooling Energy Consumption of Educational Buildings Using Artificial Neural Network," *International Journal on Advanced Science, Engineering and Information Technology*, vol. 9, no. 1, p. 159, 2019.
- [29] J. Kim, Y. Zhou, S. Schiavon, P. Raftery, and G. Brager, "Personal comfort models: Predicting individual's thermal preference using occupant heating and cooling behavior and machine learning," *Building and Environment*, vol. 129, pp. 96–106, 2018.

- [30] Y. Peng, Z. Nagy, and A. Schlüter, "Temperature-preference learning with neural networks for occupant-centric building indoor climate controls," *Building and Environment*, vol. 154, pp. 296–308, 2019.
- [31] E. Alpaydm, *Introduction to machine learning*. Cambridge, MA: MIT Press, 2020.
- [32] E. Brynjolfsson, T. Mitchell, and D. Rock, "What Can Machines Learn and What Does It Mean for Occupations and the Economy?," *AEA Papers and Proceedings*, vol. 108, pp. 43–47, Jan. 2018.
- [33] Díez Raúl Pino, Gómez Alberto Gómez, and de Abajo Martínez Nicolás, *Introducción a la inteligencia artificial: sistemas expertos, redes neuronales artificiales y computación evolutiva*. Oviedo: Servicio de Publicaciones, Universidad de Oviedo, 2001.
- [34] J. Padarian, B. Minasny, and A. B. Mcbratney, "Machine learning and soil sciences: a review aided by machine learning tools," *Soil*, vol. 6, no. 1, pp. 35–52, Jun. 2020.
- [35] T. P. Trappenberg, "Introduction," *Fundamentals of Machine Learning*, pp. 1–14, 2019.
- [36] J. Manasa, R. Gupta, and N. S. Narahari, "Machine Learning based Predicting House Prices using Regression Techniques," *2020 2nd International Conference on Innovative Mechanisms for Industry Applications (ICIMIA)*, 2020.
- [37] D. C. Montgomery, E. A. Peck, and G. G. Vining, *Introduction to linear regression analysis*. Hoboken, NJ: Wiley, 2012.
- [38] S. Boslaugh, *Statistics in a nutshell*. Farnham: OReilly, 2013.
- [39] C. N. Nguyen and O. Zeigermann, *Machine Learning - kurz & gut: Eine Einführung mit Python, Pandas und Scikit-Learn*. Heidelberg: OReilly, 2018.
- [40] M. Dehmer and S. C. Basak, *Statistical and machine learning approaches for network analysis*. Hoboken, NJ: Wiley, 2012.
- [41] A. Scherbart and T. W. Nattkemper, "The Diversity of Regression Ensembles Combining Bagging and Random Subspace Method," *Advances in Neuro-Information Processing Lecture Notes in Computer Science*, pp. 911–918, 2009.
- [42] I. Goodfellow, Y. Bengio, and A. Courville, *Deep learning*. Cambridge, MA: The MIT Press, 2017.
- [43] S. Yan, "Keynotes: Deep learning for visual understanding: Effectiveness vs. efficiency," *2016 Visual Communications and Image Processing (VCIP)*, 2016.
- [44] Q. Chen, G. Pan, M. Yu, and J. Wang, "Unsupervised Feature Learning in Time Series Prediction Using Continuous Deep Belief Network," 2018.
- [45] H. Ohsugi, H. Tabuchi, H. Enno, and N. Ishitobi, "Accuracy of deep learning, a machine-learning technology, using ultra-wide-field fundus ophthalmoscopy for detecting rhegmatogenous retinal detachment," *Scientific Reports*, vol. 7, no. 1, 2017.
- [46] Martín Quintín Martín and Paz Santana, Yanira del Rosario de, *Aplicación de las redes neuronales artificiales a la regresión*. Madrid: Editorial La Muralla, 2007.
- [47] Díez Raúl Pino, Gómez Alberto Gómez, and de Abajo Martínez Nicolás, *Introducción a la inteligencia artificial: sistemas expertos, redes neuronales artificiales y computación evolutiva*.

Oviedo: Servicio de Publicaciones, Universidad de Oviedo, 2001.

[48] P. Joshi, *Artificial intelligence with Python: build real-world artificial intelligence applications with Python to intelligently interact with the world around you*. Birmingham, UK: Packt Publishing Ltd., 2017.

[49] F. Nieborowski, "Coupled Computational Fluid Dynamics (CFD) and Artificial Neural Network (ANN) for Prediction of Traffic-related Air Pollution Infiltration Effects in Hong Kong," 2020.

[50] B. Vaferi, "Application of Artificial Neural Networks for Accurate Prediction of Thermal and Rheological Properties of Nanofluids," *IntechOpen*, 27-May-2020. [Online]. Available: <https://www.intechopen.com/books/deterministic-artificial-intelligence/application-of-artificial-neural-networks-for-accurate-prediction-of-thermal-and-rheological-propert>. [Accessed: 06-Jun-2020].

[51] G. Franco-Sepúlveda, J. C. D. Rio-Cuervo, and M. A. Pachón-Hernández, "State of the art about metaheuristics and artificial neural networks applied to open pit mining," *Resources Policy*, vol. 60, pp. 125–133, 2019.

[52] G. N. Kouziokas, "Long Short-Term Memory (LSTM) Deep Neural Networks in Energy Appliances Prediction," 2019 Panhellenic Conference on Electronics & Telecommunications (PACET), 2019.

[53] G. S. Handelman, H. K. Kok, R. V. Chandra, A. H. Razavi, S. Huang, M. Brooks, M. J. Lee, and H. Asadi, "Peering Into the Black Box of Artificial Intelligence: Evaluation Metrics of Machine Learning Methods," *American Journal of Roentgenology*, vol. 212, no. 1, pp. 38–43, 2019.

[54] D. V. Carvalho, E. M. Pereira, and J. S. Cardoso, "Machine Learning Interpretability: A Survey on Methods and Metrics," *Electronics*, vol. 8, no. 8, p. 832, 2019.

[55] A. Lu, P. Frazier, and O. Kislev, "Surge Pricing Moves Ubers Driver Partners," *SSRN Electronic Journal*, 2018.

[56] A. E. P. Villa, P. Masulli, and P. R. A. Javi, *Artificial neural networks and machine learning - ICANN 2016: 25th International Conference on Artificial Neural Networks*, Barcelona, Spain, September 6-9, 2016, proceedings. Switzerland: Springer, 2016.

[57] UNE-EN ISO 7730: ergonomía del ambiente térmico: determinación analítica e interpretación del bienestar térmico mediante el cálculo de los índices PMV y PPD y los criterios de bienestar térmico local: (ISO 7730:2005). Madrid: AENOR, 2006.

[58] P. Roelofsen, "A comparison of the dynamic thermal sensation between the modified Stolwijk model and the Fiala thermal physiology and comfort (FPC) model," *Intelligent Buildings International*, pp. 1–11, Sep. 2019.

[59] "Home," *Home*. [Online]. Available: <https://www.ashrae.org/>. [Accessed: 06-Jun-2020].

[60] A. Zhang, Q. Huang, Y. Du, Q. Zhen, and Q. Zhang, "Agent-Based Modelling of Occupants' Clothing and Activity Behaviour and Their Impact on Thermal Comfort in Buildings," *IOP Conference Series: Earth and Environmental Science*, vol. 329, p. 012022, Nov. 2019.

[61] M. Piasecki, M. Fedorczak-Cisak, M. Furtak, and J. Biskupski, "Experimental Confirmation of the Reliability of Fanger's Thermal Comfort Model—Case Study of a Near-Zero Energy Building (NZEB) Office Building," *Sustainability*, vol. 11, no. 9, p. 2461, 2019.

- [62] "ASHRAE 55-2017," ASHRAE 55-2017 | ASHRAE Store. [Online]. Available: [https://www.techstreet.com/ashrae/standards/ashrae-552017?product\\_id=1994974&ashrae\\_auth\\_token=](https://www.techstreet.com/ashrae/standards/ashrae-552017?product_id=1994974&ashrae_auth_token=). [Accessed: 06-Jun-2020].
- [63] UNE-EN 15251:2008, Web UNE. [Online]. Available: <https://www.une.org/encuentra-tu-norma/busca-tu-norma/norma?c=N0041732>. [Accessed: 06-Jun-2020].
- [64] UNE-EN ISO 7730:2006 Web UNE. [Online]. Available: <https://www.une.org/encuentra-tu-norma/busca-tu-norma/norma?c=N0037517>. [Accessed: 06-Jun-2020].
- [65] "Soluciones de Eficiencia Energética," Revista Mundo HVAC&R, 25-Jul-2014. [Online]. Available: <https://www.mundohvacr.com.mx/2010/10/soluciones-de-eficiencia-energetica/>. [Accessed: 06-Jun-2020].
- [66] D. Marín-García, D. Bienvenido-Huertas, E. Nieto-Julián, J. J. M. Campos, M. J. Oliveira, and F. Farinha, "Analysis of the Regulations that Affect Energy Efficiency with Respect to Consumption of HVAC System for Residential Buildings in Southern Spain and Portugal," INCREaSE 2019, pp. 478–486, 2019.
- [67] R. C. Tesiero, N. Nassif, B. Gokaraju, and D. A. Doss, "Intelligent Approaches for Modeling and Optimizing HVAC Systems' Energy Use," ASME 2017 11th International Conference on Energy Sustainability, 2017.
- [68] A. E. Castillo, L. S. Peña, and G. P. Guardián, "Hogares y energía eléctrica en México," Revista Espinhaço | UFVJM. [Online]. Available: <http://revistaespinhaco.com/index.php/journal/article/view/132>. [Accessed: 07-Jun-2020].
- [69] K. Zorn, L. Weerakkodey, Logan, S. Alston, B. Layton, Wang, D. Carter, Karen, Ahmad, Lynn, Oka, Ahmed, Devon, Ruben, Frank, Ovat, Ilyas, Brian, D. English, E. Heredia, and Maa, "Air Conditioning BTU's: What Are They & What Do They Mean?," Compact Appliance, 14-Mar-2018. [Online]. Available: <https://learn.compactappliance.com/air-conditioning-btus/>. [Accessed: 07-Jun-2020].
- [70] T. Review, "10 Emerging Technologies That Will Change the World," MIT Technology Review. [Online]. Available: <http://www2.technologyreview.com/news/401775/10-emerging-technologies-that-will-change-the-2/>. [Accessed: 25-Jul-2020]
- [71] YANG, S. (2016). WIRELESS SENSOR NETWORKS(1st ed.). London: Springer-Verlag. doi:<https://doi.org/10.1007/978-1-4471-5505-8>
- [72] A. Watt, M. Phillips, C.-A. Campbell, I. Wells, and S. Hole, "Wireless Sensor Networks for monitoring underwater sediment transport," Science of The Total Environment, vol. 667, pp. 160–165, 2019.
- [73] J. Dizdarević, F. Carpio, A. Jukan, and X. Masip-Bruin, "A Survey of Communication Protocols for Internet of Things and Related Challenges of Fog and Cloud Computing Integration," ACM Computing Surveys, vol. 51, no. 6, pp. 1–29, 2019.
- [74] Y. Niu, J. Zhang, A. Wang, and C. Chen, "An Efficient Collision Power Attack on AES Encryption in Edge Computing," IEEE Access, vol. 7, pp. 18734–18748, 2019.
- [75] Nakamoto, S. Bitcoin Whitepaper. 2008. Available online: <https://bitcoin.org/bitcoin.pdf> (accessed on 17 July 2019).

- [76] M. Niranjnamurthy, B. N. Nithya, and S. Jagannatha, "Analysis of Blockchain technology: pros, cons and SWOT," *Cluster Computing*, vol. 22, no. S6, pp. 14743–14757, 2018.
- [77] R. A. Canessane, N. Srinivasan, A. Beuria, A. Singh, and B. M. Kumar, "Decentralised Applications Using Ethereum Blockchain," 2019 Fifth International Conference on Science Technology Engineering and Mathematics (ICONSTEM), 2019.
- [78] A. Kristof, "Autonomous Finance," *Handbook of Blockchain, Digital Finance, and Inclusion*, Volume 2, pp. 471–479, 2018.
- [79] V. J. Morkunas, J. Paschen, and E. Boon, "How blockchain technologies impact your business model," *Business Horizons*, vol. 62, no. 3, pp. 295–306, 2019.
- [80] A. Allan, "The Raspberry Pi 3 Does Not Halt and Catch Fire: Make:" *Make*, 07-Mar-2016. [Online]. Available: <https://makezine.com/2016/03/02/raspberry-pi-3-not-halt-catch-fire/#:~:text=The official operating temperature limit,performance around 82°C>. [Accessed: 20-Jul-2020].
- [81] "Visualization with Python¶," *Matplotlib*. [Online]. Available: <https://matplotlib.org/>. [Accessed: 07-Jun-2020].
- [82] "ECOSYSTEM," *NumPy*. [Online]. Available: <https://numpy.org/>. [Accessed: 07-Jun-2020].
- [83] "pandas documentation¶," *pandas documentation - pandas 1.0.4 documentation*. [Online]. Available: <https://pandas.pydata.org/docs/>. [Accessed: 07-Jun-2020].
- [84] "Testing and Validation," *EnergyPlus*. [Online]. Available: <https://energyplus.net/testing>. [Accessed: 07-Jun-2020].
- [85] SENER, "Comparativo de eficiencia energética de sistemas de aire acondicionado con tecnologías on-off e Inverte4," [Online]. Available: [https://www.gob.mx/cms/uploads/attachment/file/346457/Bolet\\_n\\_03\\_EE\\_Aire\\_Acondicionado.pdf](https://www.gob.mx/cms/uploads/attachment/file/346457/Bolet_n_03_EE_Aire_Acondicionado.pdf) [Accessed: 25-Jul-2020].
- [86] "AlphaStar: Mastering the Real-Time Strategy Game StarCraft II," *Deepmind*. [Online]. Available: <https://deepmind.com/blog/article/alphastar-mastering-real-time-strategy-game-starcraft-ii>. [Accessed: 26-Jul-2020].



# Anexos Anexo I Examen de inglés



UNIVERSIDAD AUTÓNOMA DE QUERÉTARO  
FACULTAD DE LENGUAS Y LETRAS

A QUIEN CORRESPONDA:

La que suscribe, Directora de la Facultad de Lenguas y Letras, hace **C O N S T A R** que

**GUERRERO SANCHEZ ALMA ELIZA**

Presentó el **Examen de Manejo de la Lengua** efectuado el día veinte de febrero de dos mil veinte, en el cual obtuvo la siguiente calificación:

**8**

Se extiende la presente a petición de la parte interesada, para los fines escolares y legales que le convengan, en el Campus Aeropuerto de la Universidad Autónoma de Querétaro, el día veintisiete de febrero de dos mil veinte.



Atentamente,  
"Enlazar Culturas por la Palabra"

**LIC. LAURA PÉREZ TÉLLEZ**

**LPT/jals\*CL\*FLL-C.-284**

**SOMOS UAQ**  
EDUCAR CRECER CONSOLIDAR

Campus Aeropuerto, Anillo Vial Fray Junípero Serra S/N, Querétaro, Qro. C.P. 76140  
Tel. 442 192 12 00 Dirección Ext. 61010, Secretaría Administrativa Ext.61300, Posgrado Ext. 61140,  
Licenciatura Ext.61070, Centro de Lenguas Ext.61050, Secretaría Académica Ext.61100 y Planeación Es

## Anexo II Publicación Congreso Internacional.



# Anexo III Poster Coloquio Facultad de Ingeniería

Número de Submission: 37

## COLOQUIO

La Ingeniería y el equilibrio global

Comparación de modelo de regresión lineal múltiple y aprendizaje

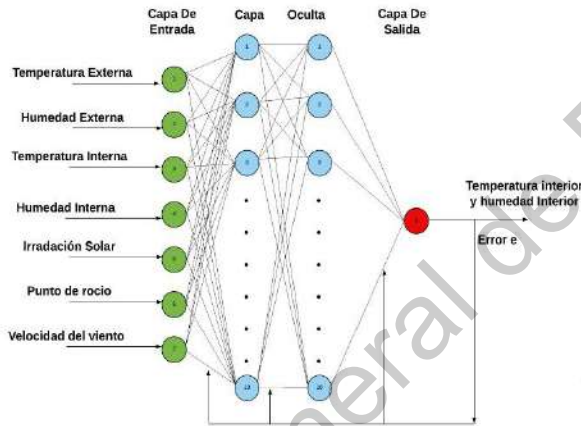
automático para la predicción del comportamiento termal en edificios

Ing. Alma Guerrero Sánchez; Doctor Edgar Rivas Araza; Doctor Saúl Tovar Arriaga. Maestría en Ciencias Inteligencia Artificial.

13<sup>o</sup>

### Introducción

El análisis del comportamiento térmico dentro de un edificio es importante para encontrar las condiciones térmicas ideales para la comodidad de los usuarios. Como respuesta a la demanda de confort termal, consumo energético, productividad, así como la calidad del aire, métodos más avanzados son propuestos para proveer condiciones termales adecuadas. La aplicación de estrategias de control predictivo se han aplicado en edificios de oficinas y en edificios residenciales obteniendo una reducción de energía significativa.



### Materiales y métodos

#### Modelo de Regresión Lineal Múltiple (Modelo Lineal Generalizado)

- El Modelado de Regresión Lineal Múltiple (MRLM) es uno de los métodos más usados en series de datos y es una versión más flexible del modelo de regresión lineal.

- El modelo relacional (X-Y) es definido por la ecuación:

$$g(E(Y)) = X\beta + O, y \sim F$$

- Donde  $g(\bullet)$  es la función de enlace seleccionada, O es la variable de desplazamiento, F es el modelo de distribución de  $y$ , X es el predictor, y es la variable de respuesta y  $\beta$  es el coeficiente de regresión

#### Redes Neuronales Artificiales (RNA)


- La estructura de las RNA es biológicamente similar al sistema nervioso central.
- La red neuronal de propagación hacia atrás (BPNN, back-propagation neural network) es ampliamente usada debido a que mientras avanza el entrenamiento recalcula los pesos basándose en la magnitud del error, de esta forma los pesos se ajustan de manera autónoma y precisa, mejorando el tiempo de convergencia hacia un mínimo error. La función de activación que se usa para cada neurona que trabaja en las capas ocultas es la función Sigmoide. 
$$f(x) = \frac{1}{1 + e^{-x}}$$

#### Base de datos

- El repositorio de datos público perteneciente a UCI Machine Learning, recolectó los datos usados medidos con sensores de temperatura y humedad en un edificio y se tomaron datos de variables ambientales de una estación meteorológica de Chievres, Bélgica.


### Resultados

#### Modelo de Regresión Lineal Múltiple



MSE 0.11447  
RMSE 0.12347

#### Redes Neuronales Artificiales



MSE  $1.8102 \times 10^{-3}$   
RMSE  $1.23490 \times 10^{-3}$

### Conclusiones

- La predicción del comportamiento térmico de un edificio es importante para la satisfacción de la demanda del confort térmico de los usuarios en edificios.
- En las métricas de evaluación MSE y RMSE, se observa que las redes neuronales artificiales tienen un mejor desempeño y una predicción más acertada en comparación al modelo de regresión lineal múltiple.
- Esta aportación es una parte de una investigación que se desarrolla en la Maestría en Ciencias de la Inteligencia Artificial, enfocada en el ahorro energético a partir del control inteligente en las secuencias de presión según el comportamiento termal en edificios inteligentes.



## Anexo IV Publicación Revista Indexada Sensors



 **sensors**  
an Open Access Journal by MDPI

**CERTIFICATE OF ACCEPTANCE**

Indexed in:  
 **PubMed**

Indexed in:  
 **EI Compendex**

CITESCORE  
**3.72**  
SCOPUS

IMPACT  
FACTOR  
**3.031**

Certificate of acceptance for the manuscript (sensors-760146) titled:  
**Blockchain Mechanism and Symmetric Encryption in a Wireless Sensor Network**

Authored by:  
Alma Eliza Guerrero-Sánchez; Edgar Rivas-Araiza; Jose Luis González-Córdoba; Manuel Toledano-Ayala; Andras Takacs

has been accepted in *Sensors* (ISSN 1424-8220) on 06 May 2020

 **MDPI** | Academic Open Access Publishing  
since 1996  
Basel, May 2020