



UNIVERSIDAD AUTÓNOMA DEL
ESTADO DE MORELOS

UNIVERSIDAD AUTÓNOMA DEL ESTADO DE MORELOS

FACULTAD DE CONTADURÍA, ADMINISTRACIÓN E INFORMÁTICA
MAESTRÍA EN OPTIMIZACIÓN Y CÓMPUTO APLICADO

IMPLEMENTACIÓN DE TÉCNICAS DE IA PARA CLASIFICAR PARAMETROS EN PROTOTIPO DE CAPTACION DE AGUA CON CELDAS PELTIER.

T E S I S

QUE PARA OBTENER EL GRADO DE
MAESTRÍA EN OPTIMIZACIÓN Y CÓMPUTO APLICADO

PRESENTA

ALEXIS ANGELES ROBLES

DIRECTOR DE TESIS

DR. OUTMANE OUBRAM

CO-DIRECTOR

DR. ROY LÓPEZ SESENES

REVISORES:

DR. OUTMANE OUBRAM

DR. ROY LÓPEZ SESENES

DR. JOSÉ ALBERTO HERNÁNDEZ AGUILAR

DRA. LORENA DÍAZ GONZÁLEZ

DR. FEDERICO ALONSO PECINA



Facultad de Contaduría,
Administración e Informática

CUERNAVACA, MORELOS.

ABRIL, 2026

Dedicatoria

Este trabajo está dedicado a: Principalmente a Dios, por haberme dado la vida y permitirme el haber llegado hasta este momento tan importante de mi formación profesional. A mis padres que con su amor y paciencia me han llegado a permitir cumplir un objetivo más, gracias por inculcar en mí el ejemplo de esfuerzo y valentía, de no temer a las adversidades.

Agradecimientos

Quisiera comenzar expresando mi más sincero agradecimiento a mis directores de tesis, el Dr. Outmane Oubram y Dr. Roy López Sesenes, cuya experiencia, paciencia y apoyo constante fueron fundamentales para la realización de este trabajo. Su guía no solo me proporcionó claridad académica, sino también motivación en momentos de duda. Su confianza en mí me impulsó a seguir adelante y superar los desafíos. A mi familia, especialmente a mis padres, les agradezco profundamente su amor incondicional y su apoyo constante. Su fe en mí ha sido el motor que me permitió completar este camino. A la Secretaría de Ciencia, Humanidades, Tecnología e Innovación por brindarme la ayuda económica para poder llevar a cabo el inicio de mi carrera en la ciencia y a la Universidad Autónoma de Morelos, gracias por brindarme la oportunidad de crecer académica y profesionalmente. Mi gratitud también va a mi comité tutorial, la Dra. Lorena Díaz González, el Dr. Federico Alonso Pecina y el Dr. José Alberto Hernández Aguilar, cuyo apoyo y disposición fueron esenciales para la culminación de esta tesis. Aprecié profundamente su confianza en mi trabajo y el ambiente de aprendizaje que me ofrecieron. A mis amigos y compañeros, gracias por su compañía y apoyo en los momentos de estrés y alegría. Su amistad me ayudó a mantener el ánimo en los momentos más duros. Cada uno de ustedes contribuyó a que este proceso fuera más llevadero y finalmente, agradezco a todos los colegas y colaboradores que participaron en esta investigación en especial a mis compañeros de tesis Alejandro Yair Alejandro Gutiérrez Álvarez y Marco Antonio Ramírez Rubio. Por su ayuda en la recopilación de datos, revisión de mi trabajo y valiosos comentarios enriquecieron este proyecto de maneras que jamás imaginé. Esta tesis es el resultado de un esfuerzo colectivo, y su colaboración fue crucial para su realización. A todos, gracias.

RESUMEN

El medio ambiente ha experimentado afectaciones significativas derivadas del estilo de vida humano, una situación que se hizo evidente en México con la reducción del 20% de las lluvias en 2023 respecto a 2022, lo que repercutió en la temporada de sequía de 2024 al impedir que las presas, especialmente en los estados del norte, alcanzaran su máxima capacidad. Ante este escenario, se propone un dispositivo alternativo para la obtención de agua mediante la captación de humedad atmosférica con celdas *Peltier*, optimizado con técnicas de inteligencia artificial para maximizar la captación con un consumo energético reducido.

El dispositivo consiste en cuatro celdas *Peltier* con disipadores de calor en sus lados frío y caliente. Incorpora un sistema de monitoreo de temperaturas mediante una cámara térmica de bajo costo MLX90640, que utiliza un algoritmo desarrollado para estimar la sensación térmica promedio en cada disipador.

Sensores adicionales registran la temperatura ambiente, la humedad y la cantidad de agua recabada cada tres minutos. Los resultados obtenidos del algoritmo mostraron buenas estimaciones para las temperaturas en la zona fría, que se mantuvieron más constantes, a diferencia de las temperaturas en la zona caliente. En los modelos de clasificación, la regresión logística superó a las redes neuronales artificiales, entrenándose ambos con el 80% de los datos. El estudio sugiere que la calidad de los datos es crucial para la clasificación; la minoría de datos en la Clase 1 (captación de agua), provocó un desbalanceo que, aunque se resolvió con la creación de instancias sintéticas, subraya la importancia de recabar más datos reales de esta clase para el correcto funcionamiento de las técnicas de *Machine Learning* y Visión por Computadora.

CONTENIDO

CAPÍTULO 1.	DESCRIPCIÓN DEL PROYECTO	
	Introducción.....	3
1.1	Planteamiento de la hipótesis.....	6
1.2	Objetivos del trabajo de investigación.....	6
1.2.1	General.....	6
1.2.2	Específicos.....	6
1.3	Justificación.....	7
1.4	Alcances y Limitaciones.....	7
1.5	Planteamiento del problema.....	8
CAPÍTULO 2.	MARCO TEÓRICO	
2.1	Redes neuronales artificiales.....	10
2.2	Regresión logística.....	11
2.3	Visión artificial.....	11
CAPÍTULO 3.	ESTADO DEL ARTE	
	Redes neuronales para clasificación binaria.....	13
	Visión por computadora.....	17
	Captación de agua con celdas Peltrier.....	22
CAPÍTULO 4.	DESARROLLO	
4.1	Metodología.....	25
4.2	Diagrama de bloques.....	26
4.3	Adquisición de datos.....	26
CAPÍTULO 5.	RESULTADOS	
5.1	Construcción del dataset.....	39
5.2	Preprocesamiento de los datos.....	40
5.3	Escalamiento de los datos.....	47
5.5	Construcción del modelo de clasificación.....	49
CAPÍTULO 6.	CONCLUSIONES	
6.1	contribuciones.....	61

Lista de figuras

Figura 1.1: Proyección global del estrés hídrico para el año 2040.....	4
Figura 1.2: Métodos de extracción de agua a partir del aire húmedo, mediante tecnologías de condensación, absorción y captura pasiva.....	5
Figura 1.3: Niveles de almacenamiento en presas de México al 12 de junio de 2023, con disminución del 20 % en lluvias.....	8
Figura 1.4: Evolución mensual de las condiciones de sequía en México durante 2023, según categorías de severidad.....	9
Figura 2.1: Red neuronal con 3 entradas, 3 capas ocultas con 4 neuronas cada una y una neurona de salida [7].....	10
Figura 3.1: Red neuronal feedforward con capas de entrada, oculta y salida, ilustrando el flujo de información para clasificación o predicción [8].....	14
Figura 3.2: Precisión de cinco modelos de redes neuronales en tres conjuntos de datos (diabetes, hígado e ionosfera),	16
Figura 3.3: Configuración experimental que muestra la RaspberryPi.....	18
Figura 3.4: Comparación temporal de lecturas de temperatura entre sensores TPMx75, MLX90640 y ambiente.....	19
Figura 3.5: Reconocimiento facial en imágenes térmicas:	20
Figura 3.6: Distribución térmica del rostro humano a distintas distancias (50–100 cm).....	21
Figura 3.7: Detección facial en imágenes térmicas a distintas distancias (50–100 cm), con delimitación automática.....	21
Figura 3.8: Esquema de condensación de agua con energía solar.....	22
Figura 3.9 Diagrama psicrométrico que relaciona la temperatura de bulbo seco, la humedad relativa y la temperatura de rocío.....	24
Figura 4.1 Metodología seguida para desarrollar el proyecto.....	26
Figura 4.2 Prototipo desarrollado para la obtención de agua mediante la humedad relativa en la atmósfera.....	27
Figura 4.3 Diagrama electrónico de conexiones.....	28
Figura 4.4 Vista alzada del prototipo.....	29
Figura 4.5 Diagrama de conexión de cámara térmica de bajo costo MLX90640 [39]..	30

Figura 5.1 Fotografía RGB de celda Peltier conectado a los disipadores de temperatura, así mismo con un sensor termopar.....	30
Figura 5.2 fotografía térmica tomada con la cámara MLX90640 y sumada con la Figura 3.6.....	31
Figura 5.3 Imagen resultante convertida a escala de grises para poder obtener el histograma.....	32
Figura 5.4 Histograma obtenido.....	34
Figura 5.5 Resultados en la detección de bordes.....	35
Figura 5.6 Resultado de la segmentación de imágenes en capas de colores RGB...35	
Figura 5.7 Resultado de la estimación promedio de la temperatura en la zona fría y caliente de la celda Peltier.....	38
Figura 5.8 Prototipo conteo de agua (tesis en desarrollo).....	39
Figura 5.9 Conjunto de datos sin valores nulos por variable.....	40
Figura 5.10 Distribución por columna de los datos con intervalos de 3 minutos entre cada medición registrada.....	44
Figura 5.11 Coeficiente de correlación de las variables independientes con respecto a la variable dependiente.....	47
Figura 5.12 Distribución de clases antes y después de aplicar SMOTE.....	48
Figura 5.13 Configuración del modelo regresión logística.....	50
Figura 5.14 Código del modelo redes neuronales.....	50
Figura 5.15 Arquitectura de red neuronal.....	51
Figura 5.16 Desempeño del modelo durante el entrenamiento.....	52
Figura 5.17 validación cruzada con 5 <i> folds</i>	54
Figura 5.18 validación cruzada con 5 <i> folds de redes neuronales</i>	55
Figura 5.19 Resultado de la comparativa redes neuronales y regresión logística con técnica ROC.....	56
Figura 5.20 Grafico SHAP del modelo entrenado con redes neuronales.....	58
Figura 5.21 Simulación de red neuronal con activación sigmoide en C++.....	60

Lista de tablas

Tabla 3.1: Comparación de lecturas de temperatura y niveles de ruido (RMS) en sensores TMPx75 y MLX90640 bajo distintas tasas de muestreo (FPS).....	19
Tabla 3.2 Comparación de estudios sobre generación de agua mediante módulos termoeléctricos.....	23
Tabla 5.1 Nombres de las variables incluidas en el conjunto de datos.....	40
Tabla 5.2 Comparativa de varianza original vs. varianza con datos imputados.....	45
Tabla 6.1 Comparación de métricas promedio entre los modelos de red neuronal y regresión logística.....	61

CAPÍTULO 1. DESCRIPCIÓN DEL PROYECTO

INTRODUCCION.

En el año 2023 en todo el territorio mexicano existió un aumento en la sequía en comparación con el año 2022 [1], lo que trajo bastantes problemas para las comunidades y ciudades que dependen de la lluvia para el consumo de agua. Esto no es solo un problema regional si no que se estima que para el año 2040 el estrés hídrico se convierta en un problema global, se prevé un aumento significativo de la escasez de agua en diversas partes del mundo, como resultado del cambio climático y el crecimiento demográfico.

Se anticipa que países que ya enfrentan niveles críticos de estrés hídrico verán un empeoramiento de la situación, lo que podría amenazar la seguridad alimentaria y el acceso al agua potable. Regiones vulnerables, como el Cuerno de África y el suroeste de Estados Unidos, son particularmente susceptibles. Para mitigar este problema, es fundamental que se implementen estrategias efectivas de gestión del agua y se fortalezcan las políticas de adaptación climática, garantizando así un suministro sostenible de agua para las futuras generaciones en 2040 (ver Figura 1.1) [2].

Water Stress by Country: 2040

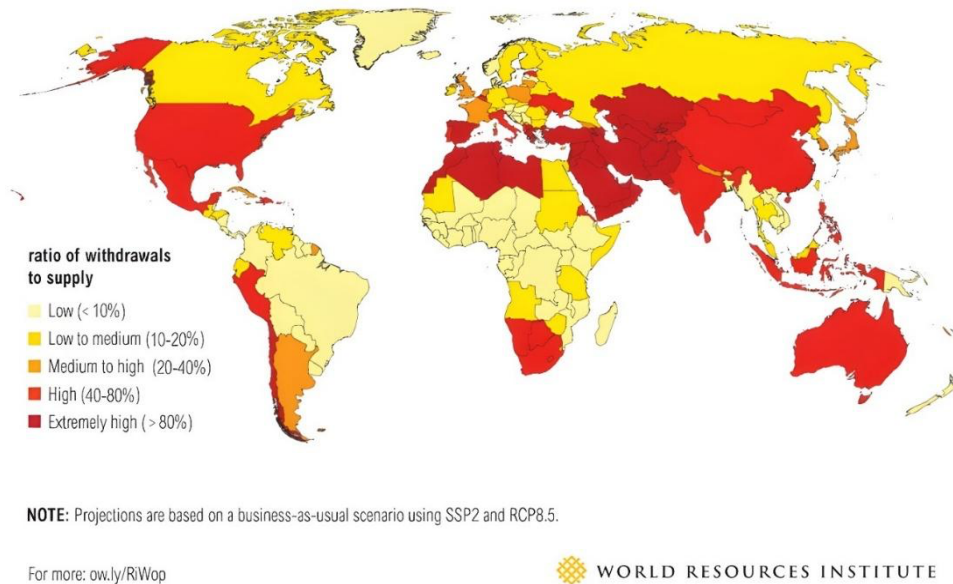


Figura 1.1: Proyección global del estrés hídrico en 2040, mostrando el cociente entre extracciones y disponibilidad de agua por país en cinco niveles de riesgo [2].

A medida que la tecnología avanza se crean nuevas técnicas para la solución de los problemas globales, tal como es el caso del estrés hídrico en algunas regiones del mundo, para ello existen varias técnicas de captación de agua a través de la humedad que existe en el aire de la atmosfera por ejemplo la técnica más antigua la cual consiste en colocar una malla con un diseño especial para poder extraer el agua que se encuentra cerca de las nubes, para ello es colocada en zonas altas donde existe una humedad alta para poder funcionar.

Así mismo algunos insectos y plantas especialmente que habitan en zonas áridas, tienen la capacidad de extraer agua y almacenarla mediante su estructura biológica. En la Figura 1.2 [2], se observan distintas técnicas de extracción de agua, unas más sofisticadas que otras, es por ello por lo que para fines de esta investigación se utiliza la tecnología de celdas *Peltier*. Las cuales tienen un funcionamiento básico el cual consiste en enfriar un lado de la celda y calentar el otro, de manera reciproca, de esta manera podemos extraer el agua que existe en el aire de la atmósfera y condensar el agua para poder ser utilizada. Aunado a ello se agregan técnicas de Inteligencia

Artificial [3], tecnología que se encuentra en auge en los últimos años, esto con la finalidad de hacer eficiente la recolección de datos, el procesamiento de estos y la captación de agua en litros.

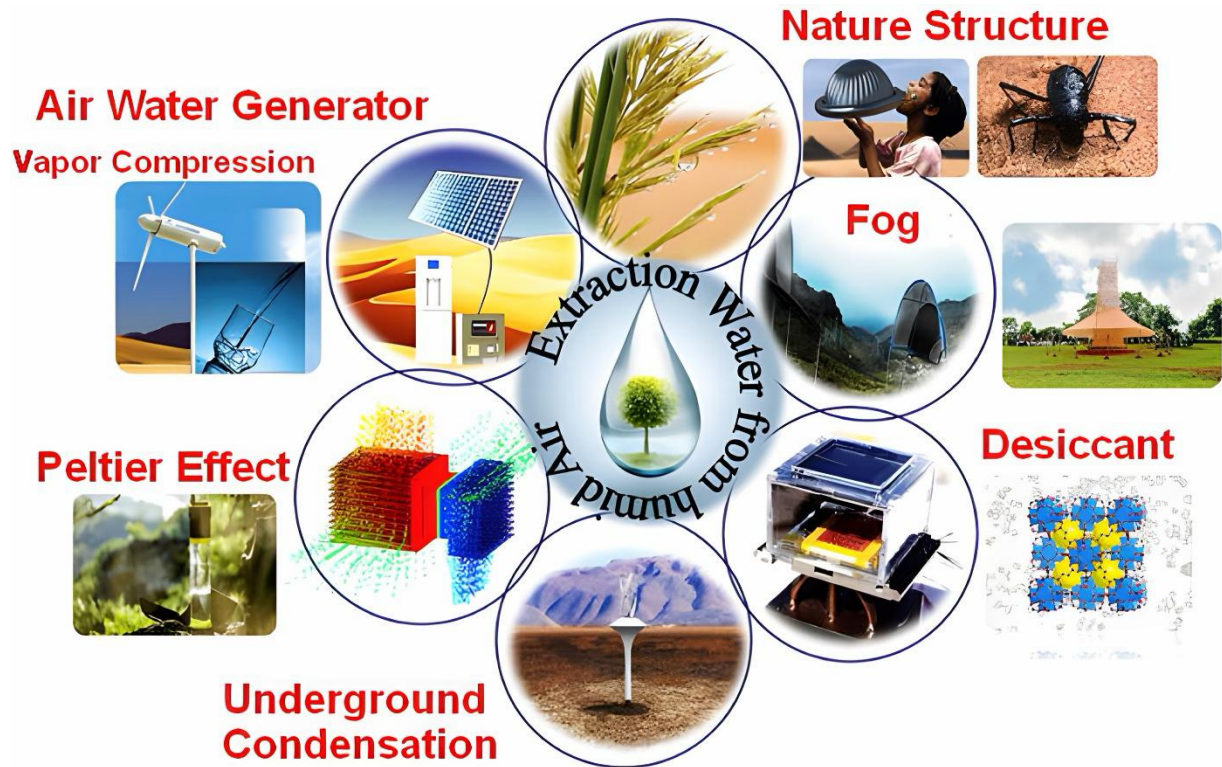


Figura 1.2: Tecnologías de captación de agua atmosférica: condensación, absorción y captura pasiva [4].

La inteligencia artificial tiene varias aplicaciones las más comunes son la predicción y la clasificación de datos, por ejemplo, en esta investigación se utilizan modelos de clasificación, los modelos más comunes de clasificación son regresión logística y redes neuronales artificiales [5].

Así mismo técnicas de clasificación de datos para determinar si nuestro prototipo tiene un buen o un mal desempeño en la captación de agua. De esta manera podemos tomar decisiones en la implementación de acciones para mejorar el desempeño del prototipo.

1.1 Planteamiento de la hipótesis

- H0: Las Redes Neuronales son la técnica que mejor precisión y menor error tendrán para el proceso de clasificación en parámetros para captación de agua.
- H1: Las Redes Neuronales no son la mejor opción en términos de precisión y error para clasificar parámetros en captación de agua.

1.2 Objetivos del trabajo de investigación

1.2.1 General

Desarrollar una metodología para clasificar datos del prototipo de captación de agua a partir de la atmósfera utilizando celdas *Peltier*.

1.2.2 Específicos

- Adquirir datos de los diferentes sensores del prototipo.
 - Obtener información de diferentes zonas de interés del prototipo mediante imágenes térmicas.
 - Construir el conjunto de datos con la información recibida de los sensores y de las imágenes térmicas.
 - Aplicar diferentes técnicas de preprocesamiento de datos.
 - Utilizar técnicas de *Machine Learning* para clasificar parámetros en captación de agua.
-

1.3 Justificación

En los últimos años, la escasez de agua ha ido en aumento debido a fenómenos naturales derivados de nuestro estilo de vida. En México, en el año 2023, se registró un 20% menos de lluvias en comparación con 2022 [1]. Este no es solo un problema regional.

1.4 Alcances y Limitaciones

1.4.1 Alcances

- Se utilizará una cámara de bajo costo, modelo MLX90640, para capturar imágenes térmicas.
 - Se conformará una base de datos donde se registrará la información captada por los diferentes sensores.
 - Se pondrá a prueba durante un tiempo el prototipo de captación de agua, con el modelo de IA entrenado para comprobar el desempeño.
-

1.5 Planteamiento del problema

La demanda de agua en lugares de difícil acceso o en lugares con poca lluvia ha seguido aumentando día a día. Tan solo en 2023 se registró un 20% menos lluvia con respecto al año anterior [1]. Esto significa una reducción del suministro de agua en presas y ríos de algunas zonas, lo que no es suficiente para consumo humano. Actualmente existen diferentes métodos de captación de agua en la atmósfera, pero muy pocas aplican tecnologías de cómputo. Hacer eficiente el proceso de recolección de agua se convierte en un objetivo primordial en esta investigación.




Figura 1.3: Niveles de almacenamiento en presas de México al 12 de junio de 2023, con disminución del 20 % en lluvias. Se muestra la distribución por categoría de llenado y la variación semanal en volumen almacenado [6].

Según el reporte anual de la Comisión Nacional de Agua [1], el año 2023 se caracterizó por ser especialmente seco y caluroso. De acuerdo con los registros de precipitación y temperatura, se le considera el año más seco desde 1941 y el más cálido desde 1953. Esto ha llevado a un aumento en las zonas afectadas por sequía en todo el país;

en septiembre de 2023, se registró la mayor área con sequía moderada a excepcional para ese mes.




Figura 1.4: Evolución mensual de las condiciones de sequía en México durante 2023, según categorías de severidad. Se observa un incremento sostenido de áreas con sequía extrema y excepcional hacia el segundo semestre del año [1].

A pesar de las lluvias que se registraron a finales de mayo, los cuatro meses siguientes (de junio a septiembre) se caracterizaron por escasas precipitaciones y altas temperaturas. Durante este tiempo, junio y septiembre fueron considerados como los más secos desde 1941, mientras que los meses de junio, julio, agosto y septiembre se convirtieron en los más cálidos desde 1953. Esta situación llevó a un aumento gradual de las áreas afectadas por sequía en el país durante el verano. Por esta razón, es crucial buscar o desarrollar nuevas tecnologías, incluida la inteligencia artificial, para obtener agua apta para el consumo humano. Este análisis permitirá determinar los patrones en las variables que influyen en este desarrollo y, así, poder tomar las medidas correspondientes para abordarlas de manera efectiva.

2.1 Redes neuronales artificiales

Las redes neuronales artificiales representan uno de los avances más significativos dentro del campo de la inteligencia artificial, pues buscan emular el funcionamiento del cerebro humano mediante estructuras matemáticas capaces de aprender y generalizar a partir de datos. Estas redes se componen de capas de nodos interconectados que transmiten señales ponderadas y ajustables, lo que les permite modelar relaciones no lineales y complejas.

A través de procesos de entrenamiento se observa una arquitectura de red neuronal en la Fig.2.1, como la retropropagación, los pesos de las conexiones se optimizan para minimizar el error en las predicciones, logrando que el sistema pueda reconocer patrones, clasificar información y realizar tareas de predicción en ámbitos tan diversos como la física, la química, la medicina y la movilidad urbana. La evolución de estas arquitecturas ha dado lugar a variantes como las redes convolucionales, que han revolucionado el procesamiento de imágenes, y las redes recurrentes, diseñadas para manejar secuencias temporales, lo que ha permitido avances notables en visión por computadora y análisis de datos masivos.




Figura 2.1: Red neuronal con 3 entradas, 3 capas ocultas con 4 neuronas cada una y una neurona de salida [7].

2.2 Regresión logística

En paralelo, la regresión logística constituye una técnica estadística fundamental para la clasificación de eventos binarios, ya que transforma una combinación lineal de variables independientes en una probabilidad entre cero y uno mediante la función sigmoidea. A diferencia de la regresión lineal, que predice valores continuos, la regresión logística se centra en estimar la probabilidad de ocurrencia de un fenómeno categórico, lo que la convierte en una herramienta ampliamente utilizada en ciencias sociales, medicina y economía. En el contexto del aprendizaje automático, se considera un algoritmo supervisado de clasificación que, además de su simplicidad, ofrece interpretaciones claras sobre la influencia de cada predictor en el resultado, siendo un modelo base que ha servido como punto de partida para el desarrollo de técnicas más complejas como las redes neuronales.

2.3 Visión artificial

La visión artificial, también llamada visión por computadora, se erige como un campo multidisciplinario cuyo objetivo es dotar a las máquinas de la capacidad de percibir e interpretar el mundo visual. Se fundamenta en el procesamiento digital de imágenes y videos capturados por sensores y en la aplicación de algoritmos que permiten extraer información relevante de dichas representaciones. Este campo abarca desde etapas de bajo nivel, como la mejora de la calidad de las imágenes y la segmentación de regiones, hasta etapas de alto nivel, orientadas al reconocimiento de objetos, clasificación de escenas y comprensión semántica. Sus aplicaciones son vastas y abarcan desde la detección de tumores en radiografías, la inspección automática de piezas industriales, el desarrollo de vehículos autónomos, hasta sistemas de seguridad y herramientas de interacción humano-computadora [7]. La integración de redes neuronales convolucionales ha potenciado de manera extraordinaria la visión artificial, permitiendo que las máquinas alcancen niveles de precisión cercanos a los humanos en la identificación de patrones visuales.

En conjunto, las redes neuronales, la regresión logística y la visión artificial conforman un entramado conceptual que sustenta gran parte de los avances actuales en inteligencia artificial. La regresión logística puede considerarse un antecedente metodológico que introdujo la idea de clasificación probabilística, mientras que las redes neuronales representan la evolución hacia modelos más flexibles y poderosos capaces de manejar grandes volúmenes de datos y relaciones no lineales. La visión artificial, por su parte, constituye un campo de aplicación privilegiado donde estas técnicas se integran para resolver problemas prácticos de gran impacto social y tecnológico, demostrando que la sinergia entre modelos estadísticos, arquitecturas neuronales y procesamiento visual es clave para el desarrollo de sistemas inteligentes capaces de transformar la manera en que interactuamos con el entorno.

CAPÍTULO 3. ESTADO DEL ARTE

Se realizó una búsqueda de en la literatura sobre sistemas de captación de agua a través del aire en la atmosfera, se encontraron artículos relacionados sin embargo no se encontraron similitudes para optimizar el funcionamiento de estos estudios o prototipos con técnicas de inteligencia artificial, es por ello por lo que este trabajo es pionero en la utilización de las técnicas de inteligencia artificial para mejorar la eficiencia energética y de captación de agua en prototipos con celdas *Peltier*. Esta búsqueda se divide en tres categorías y métodos de clasificación con redes neuronales artificiales, técnicas de visión computacional para imágenes térmicas y captación de agua a través de la atmosfera. Para una visión más completa de la literatura se muestra más información en el anexo c.

3.1 Redes neuronales para clasificación binaria

El problema de clasificación constituye una tarea fundamental de toma de decisiones en la que numerosos investigadores han centrado sus esfuerzos, desarrollando diversas técnicas para abordar este desafío. Entre ellas, las redes neuronales destacan como una de las herramientas más utilizadas dentro de la inteligencia artificial, con múltiples aplicaciones exitosas en problemas de clasificación.

En este contexto, el presente trabajo realiza una comparación de diferentes técnicas de redes neuronales aplicadas a la clasificación binaria. Se evalúa el rendimiento de cinco tipos de redes: la Red Neuronal de Retropropagación (BPNN), la Red Neuronal de Función de Base Radial (RBFNN), la Red Neuronal de Regresión General (GRNN), la Red Neuronal Probabilística (PNN) y la Red Neuronal Complementaria (CMTNN). La comparación se lleva a cabo utilizando tres conjuntos de datos de referencia obtenidos del repositorio de aprendizaje automático de la UCI, y los resultados indican que las CMTNN suelen ofrecer un desempeño superior en problemas de clasificación binaria [8].

La Red Neuronal de Retropropagación (BPNN), también conocida como red neuronal de retropropagación y retroalimentación, funciona mediante un proceso de entrenamiento en el que los datos se introducen en la capa de entrada y se propagan hacia las capas oculta y de salida en un paso denominado hacia adelante. En esta fase, cada nodo ajusta los pesos entre conexiones y genera un valor de salida. Posteriormente, los valores obtenidos se comparan con los valores objetivo, y el error resultante se retropropaga hacia la capa oculta para actualizar los pesos, en un proceso conocido como paso hacia atrás o aprendizaje. Este ciclo se repite hasta alcanzar un error aceptable. Una vez entrenada, la red puede utilizarse para clasificar nuevos datos sin modificar sus matrices de ponderación, ya que durante la fase de prueba únicamente se realiza propagación hacia adelante basada en el conocimiento adquirido [8].




Figura 3.1: Red neuronal feedforward con capas de entrada, oculta y salida, ilustrando el flujo de información para clasificación o predicción [8].

Por su parte, la Red Neuronal de Función de Base Radial (RBFNN) es una red multicapa que se diferencia de la BPNN principalmente en su algoritmo de

entrenamiento. Su estructura consta de una capa de entrada, una capa *kernel* u oculta y una capa de salida. Puede considerarse una variante especial del perceptrón multicapa, ya que combina modelos estadísticos paramétricos con algoritmos no paramétricos. En la capa *kernel* se emplean funciones de base radial, y la salida final se obtiene como una combinación lineal de dichas funciones. La RBFNN supera algunas limitaciones de la BPNN, pues puede modelar funciones no lineales utilizando una sola capa oculta, lo que permite un entrenamiento más rápido sin perder capacidad de mapeo. Estas características la convierten en una alternativa eficiente para problemas de clasificación [8].

La Red Neuronal de Regresión General (GRNN) es una red de propagación hacia adelante diseñada para datos supervisados y basada en funciones de regresión no lineal. Al igual que la BPNN, está compuesta por una capa de entrada, una capa oculta y una capa de salida; sin embargo, difiere en su mecanismo de aprendizaje. Mientras que la BPNN utiliza parámetros como la tasa de aprendizaje y el momento, la GRNN emplea un factor de suavizado que se ajusta para optimizar la función de transferencia en todos los nodos. Además, realiza un entrenamiento de una sola pasada, lo que reduce significativamente la complejidad computacional y acelera el proceso de aprendizaje [7].

La Red Neuronal Probabilística (PNN), considerada un tipo de red de base radial, se fundamenta en la regla de decisión bayesiana y en los estimadores de densidad de *Parzen*, aplicándose principalmente en clasificación *Bayes-Parzen* [9]. Combina elementos del reconocimiento estadístico de patrones con características de la BPNN. Es una red supervisada de propagación hacia adelante compuesta por tres capas y entrenada mediante un algoritmo de una sola pasada. La PNN puede trabajar con conjuntos de datos dispersos y clasificar entradas en categorías específicas. Entre sus ventajas destacan su menor tiempo de cálculo en comparación con la BPNN, su robustez al ruido y la simplicidad de su entrenamiento [8].

Finalmente, la Red Neuronal Complementaria (CMTNN) ha demostrado ser eficaz tanto en clasificación binaria como multiclase. En el caso de la clasificación binaria, se

emplea un par de redes neuronales para estimar los grados de pertenencia verdadera y falsa. Además, se utiliza la técnica de *bagging* [10], sobre un conjunto de pares de redes para mejorar el rendimiento respecto a un solo par. La diferencia entre los valores de pertenencia verdadera y falsa permite representar la incertidumbre en la clasificación, lo que aporta mayor precisión y estabilidad al proceso [8].




Figura 3.2: Precisión de cinco modelos de redes neuronales en tres conjuntos de datos (diabetes, hígado e ionosfera), mostrando variabilidad según la arquitectura [8].

3.2 Visión por computadora

La visión computacional permite extraer información relevante a partir de imágenes digitales, independientemente de su resolución o tipo (binaria, en escala de grises o RGB), mediante técnicas avanzadas de procesamiento de imágenes. Estas técnicas facilitan el desarrollo de algoritmos matemáticos y métodos de aprendizaje automático capaces de aprovechar características, patrones y texturas presentes en las imágenes. En este contexto, se han desarrollado múltiples investigaciones que emplean visión computacional para tareas de detección, clasificación y análisis térmico.

En el ámbito de la captura de imágenes térmicas, existe una amplia variedad de cámaras con diferentes características, resoluciones y rangos de precio. Para aplicaciones que requieren bajo costo y facilidad de integración, una opción común es el uso de cámaras térmicas compactas controlables mediante microcontroladores. Un ejemplo de este tipo de dispositivos es la cámara MLX90640, que ofrece una resolución de 32×24 píxeles y permite visualizar imágenes térmicas en pantallas a color, páginas web o plataformas de análisis como Matlab y Python. Dentro de la literatura se han reportado desarrollos de dispositivos no invasivos para el monitoreo y seguimiento de temperatura mediante algoritmos de aprendizaje automático.

En estos sistemas se emplean plataformas embebidas, como microcomputadoras de bajo consumo, junto con cámaras térmicas y cámaras RGB para la adquisición simultánea de información visual y térmica. La configuración típica incluye una unidad de procesamiento, módulos de captura y un sistema de retención o soporte para mantener la alineación entre cámaras, como se observa en la Figura 3.3.




Figura 3.3: Configuración experimental que muestra la *RaspberryPi* y las dos cámaras [11].

Uno de los algoritmos más utilizados en este tipo de aplicaciones es *Haar Cascade* [112], implementado en *OpenCV*. Este método es ampliamente empleado para la detección de rostros y rasgos faciales específicos, como ojos, frente o nariz, aunque también puede aplicarse a la identificación de objetos como vehículos o animales. En diversos estudios se presentan ensambles de cámaras RGB y térmicas que permiten comparar la variación de temperatura con sensores de referencia, como termopares, observándose generalmente una ligera diferencia entre ambos sistemas.

La configuración experimental de estos dispositivos suele incluir pruebas relacionadas con la influencia de los cuadros por segundo (FPS) en el ruido RMS, así como la evaluación del tiempo de estabilización de la cámara infrarroja. Estas pruebas permiten determinar la precisión térmica y el comportamiento dinámico del sensor, como se ilustra en las Figura 3.4 y Tabla 3.1.




Figura 3.4: Comparación temporal de lecturas de temperatura entre sensores TPMx75, MLX90640 y ambiente. Se observa estabilidad en las mediciones y diferencias consistentes entre sensores activos y pasivos [10].

Tabla 3.1: Lecturas de temperatura y niveles de ruido (RMS) en sensores TMPx75 y MLX90640 bajo distintas tasas de muestreo, mostrando incremento del ruido con mayor frecuencia [11].

FPS	TMPx75 (°C)	MLX90640 (°C)	Noise RMS (°C)
1	49,25	50,91	0,56
2	49,31	50,91	0,61
4	49,16	50,97	0,65
8	49,06	51,05	0,66
16	49,25	50,82	0,74
32	49,31	50,68	1,10
64	49,38	51,25	1,17

Una técnica comúnmente utilizada para mejorar la calidad de imágenes térmicas de baja resolución consiste en la fusión o suma de imágenes. Este procedimiento permite obtener representaciones térmicas más claras del objeto observado, especialmente cuando se trabaja con sensores de baja densidad de píxeles. En la Figura 3.5 se muestra un ejemplo de este proceso.




Figura 3.5: Reconocimiento facial en imágenes térmicas: (a) detección en imagen visible; (b) mapa térmico de la escena; (c) identificación automática en infrarrojo [10].

En estudios relacionados, se presenta la detección de regiones faciales en imágenes RGB y su posterior correspondencia con imágenes térmicas. En la Figura 3.5 (a) se observa la detección de rostros en una fotografía; en la Figura 3.5 (b), la imagen térmica correspondiente; y en la Figura 3.5 (c), la fusión de ambas. Asimismo, se han realizado pruebas a diferentes distancias para evaluar la detección de zonas de interés, tanto en imágenes visibles como térmicas, como se aprecia en la Figura 3.6. La Figura 3.7 muestra los resultados finales de la fusión, logrando una identificación clara de las regiones faciales y su información térmica asociada.

Este tipo de técnicas resulta especialmente útil cuando se emplean cámaras térmicas de bajo costo, como la MLX90640, ya que permiten mejorar la claridad y precisión en la detección de zonas de interés a pesar de las limitaciones de resolución del sensor.




Figura 3.6: Distribución térmica del rostro humano a distintas distancias (50–100 cm), mostrando variación espacial en la emisión infrarroja [11].




Figura 3.7: Detección facial en imágenes térmicas a distintas distancias (50–100 cm), con delimitación automática y valores de confianza [11].

3.3 Captación de agua con celdas *Peltier*

Dentro del estudio de tecnologías para la captación de agua atmosférica, se han desarrollado diversos sistemas que emplean el efecto *Peltier* como mecanismo de enfriamiento para inducir la condensación del vapor de agua presente en el ambiente. Estos sistemas suelen alimentarse mediante energía solar, lo que permite su operación autónoma y de bajo consumo energético. En la Figura 3.8 se muestra un diagrama básico de un sistema de captación que utiliza una celda *Peltier* y un condensador cónico para dirigir el flujo de aire y favorecer el proceso de condensación.

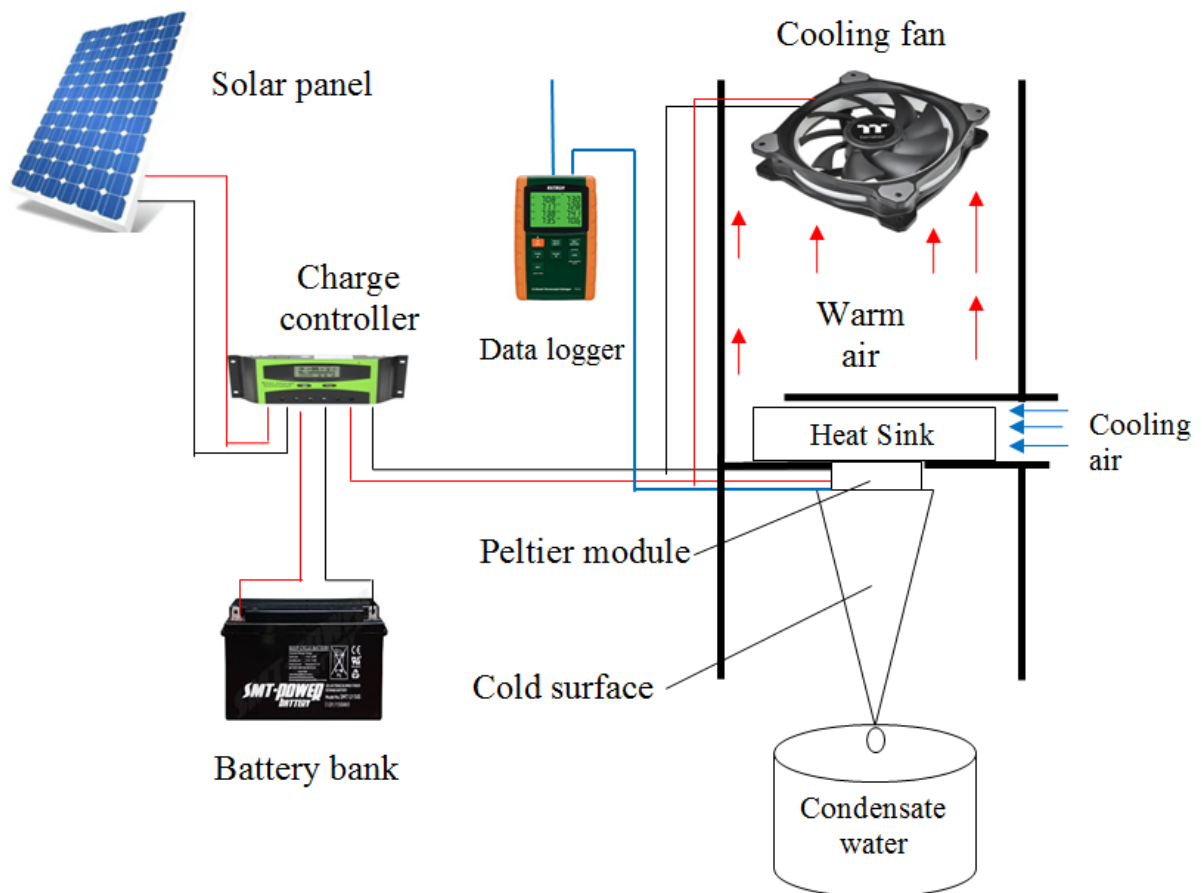


Figura 3.8: Esquema de condensación de agua con energía solar, donde el panel fotovoltaico alimenta un módulo Peltier para enfriar el aire y recoger el agua condensada, con disipación de calor y registro de datos [13].

En estudios experimentales se han evaluado variables como la cantidad de agua recolectada, el consumo energético, la temperatura ambiente, la humedad relativa y el número de celdas *Peltier* utilizadas. La Tabla 3.2 presenta resultados obtenidos durante un día de operación, donde se observa que la recaudación de agua aumenta cuando la humedad relativa del ambiente se incrementa, mientras que las demás variables permanecen relativamente constantes. Este comportamiento es consistente con los principios termodinámicos que rigen la condensación del vapor de agua.

Tabla 3.2: Comparación de tasas de generación de agua con módulos termoeléctricos bajo condiciones constantes, mostrando variación según la humedad relativa [13].

Estudio	Tasa de generación de agua (mL/h)	Consumo de energía (W)	Temperatura ambiente (°C)	Humedad relativa (%)	Número de celdas termoeléctricas
Estudio actual	8.1	70	31	60	Una
	10.1	70	31	65	
	16	70	31	70	
	20	70	31	75	

Para determinar las condiciones de operación del sistema, se calcularon las temperaturas del punto de rocío utilizando la tabla psicrométrica, como se muestra en la Figura 3.9. El análisis se realizó para un rango de temperaturas del aire seco entre 24 °C y 31 °C, con humedades relativas entre 65% y 75%. Se observó que el punto de rocío aumenta conforme se incrementa la humedad relativa del aire. Como consecuencia, la diferencia entre la temperatura del aire seco y la temperatura del punto de rocío disminuye a medida que la humedad relativa aumenta, lo que facilita el proceso de condensación.




Figura 3.9 Diagrama psicrométrico que relaciona la temperatura de bulbo seco, la humedad relativa y la temperatura de rocío. Se muestran dos condiciones ambientales (24 °C y 31 °C) con sus respectivas intersecciones sobre las curvas de humedad, permitiendo estimar los puntos de condensación relevantes para el diseño del sistema termoeléctrico [13].

Los resultados muestran que, para una temperatura del aire seco de 24 °C, el punto de rocío se incrementó de 15.8 °C a 19.3 °C cuando la humedad relativa aumentó del 60% al 75%. De manera similar, para una temperatura del aire seco de 31 °C, el punto de rocío se elevó de 22.3 °C a 26 °C bajo las mismas condiciones de humedad. Estos valores evidencian la relación directa entre la humedad relativa y la eficiencia potencial de los sistemas de captación de agua atmosférica basados en enfriamiento termoeléctrico.

CAPÍTULO 4. DESARROLLO

4.1 Metodología

Se tiene prevista la recopilación de imágenes térmicas mediante una cámara térmica de bajo costo MLX90640, estratégicamente ubicada en la vista superior del prototipo. Este dispositivo capturará fotografías térmicas de la sensación térmica de todo el sistema en general y sus variaciones con respecto al tiempo. Con un algoritmo desarrollado se delimitarán de manera automática las zonas frías y calientes de las cuatro zonas *Peltier* y se estimará la sensación térmica promedio de cada zona de las celdas *Peltier*. Así mismo, se utilizarán otros sensores para medir la humedad, temperatura ambiente, velocidad del viento y captación de agua.

Se pretende obtener registros de goteo de agua para nuestro conjunto de datos, el cual estará en un repositorio público para poder acceder a la información de una manera más eficaz. Una vez obtenido el conjunto de datos, se procederá a realizar un tratamiento de los datos para identificar valores atípicos y faltantes.

Posteriormente, se realizará un entrenamiento de redes neuronales y regresión lineal con el objetivo de predecir la cantidad de agua que se capta con el prototipo. Para la clasificación de los datos, se realizará un entrenamiento con las técnicas Redes neuronales artificiales y regresión logística, para clasificar si tenemos goteo o no con el prototipo en la captación de agua. Posteriormente, los valores obtenidos de los modelos mencionados anteriormente se introducirán a un microcontrolador para poder modificar el suministro de corriente que ingresa al prototipo, esto con la finalidad de mejorar el desempeño en la captación de agua.

4.2 Diagrama de bloques

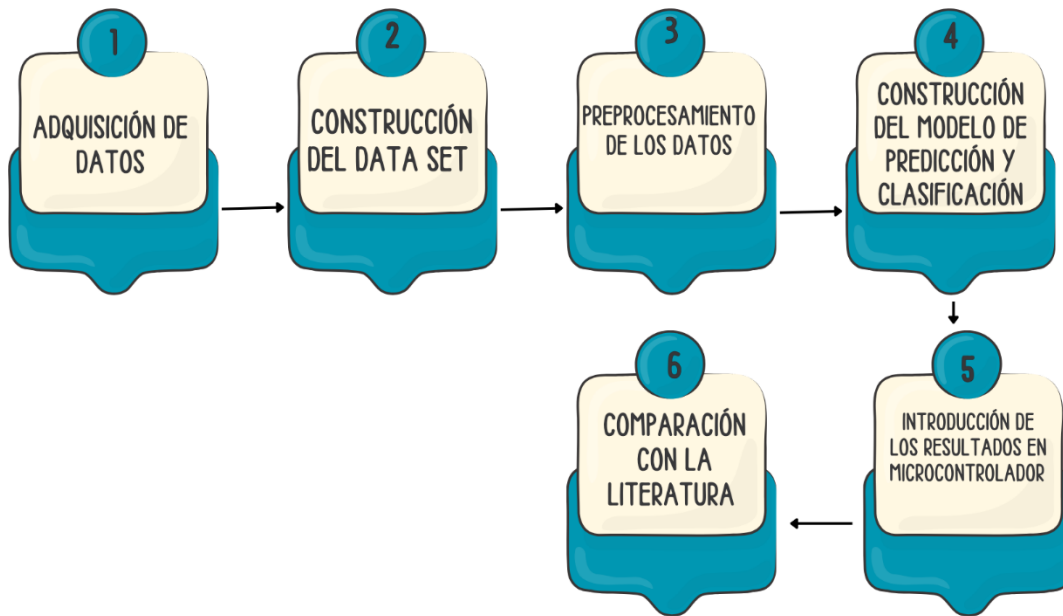


Figura 4.1 Metodología seguida para desarrollar el proyecto.

4.3 Adquisición de datos

Los datos son un pilar fundamental en el área de inteligencia artificial puesto que, en los datos se tiene información importante de cada área disciplinar, por ejemplo: clima, biología, física, fotografía, etc. Para este trabajo en particular los datos son referentes a información de variables cuantitativas como temperaturas en gados Celsius de 4 celdas *Peltier*, temperatura ambiente, humedad relativa, cantidad de agua, punto de rocío.

Para recabar esta información es importante elaborar un dispositivo con sensores analógicos y digitales. Es por ello por lo que en la Figura 4.2 se observa el dispositivo elaborado el cual consiste en extraer el agua que se encuentra en la humedad del ambiente entorno al prototipo.



Figura 4.2 Prototipo desarrollado para la obtención de agua mediante la humedad relativa en la atmosfera [14].

En la Figura 4.3 se observa el diagrama electrónico de las conexiones de los diferentes sensores, reguladores de voltaje, microcontrolador y placas *Peltier* del prototipo. En la Figura 4.4 se observa la vista superior del prototipo donde se alcanza a observar las placas *Peltier* conectadas a los disipadores de temperatura y así mismo los ventiladores que nos ayudaran a extraer el calor interno del prototipo, esto con la finalidad de regular la temperatura interna. En la parte interna de color azul es la zona donde se almacena el agua, recolectada por el prototipo. Esta cantidad de temperatura que se recolecta por hora es variable debido a la humedad relativa del ambiente.




Figura 4.3 Diagrama electrónico de conexiones [14].




Figura 4.4 Vista alzada del prototipo [14].

Los sensores termopares son dispositivos demasiado sensibles y propensos a censar valores erróneos o atípicos con respecto a la tendencia de los valores reales, es por ello por lo que se tiene planeado la implementación de una cámara térmica de bajo costo, precisamente el modelo MLX90640, esta cámara tiene una resolución baja de 32 por 24 pixeles lo cual es ideal para capturar la información térmica del prototipo, debido a la baja resolución de la cámara, tenemos un bajo costo computacional en el procesamiento de las imágenes. En la Figura 4.3 se observa el diagrama de conexiones de la cámara térmica con un microcontrolador *Raspberry Pi 3*.

Como parte de la recolección de información se decide utilizar una Raspberry y un Arduino mega, con la finalidad de tener un mejor desempeño, puesto que el Arduino no cuenta con la capacidad de procesar las imágenes y correr modelos de Inteligencia Artificial, esto debido a sus limitantes en la arquitectura de *hardware*.

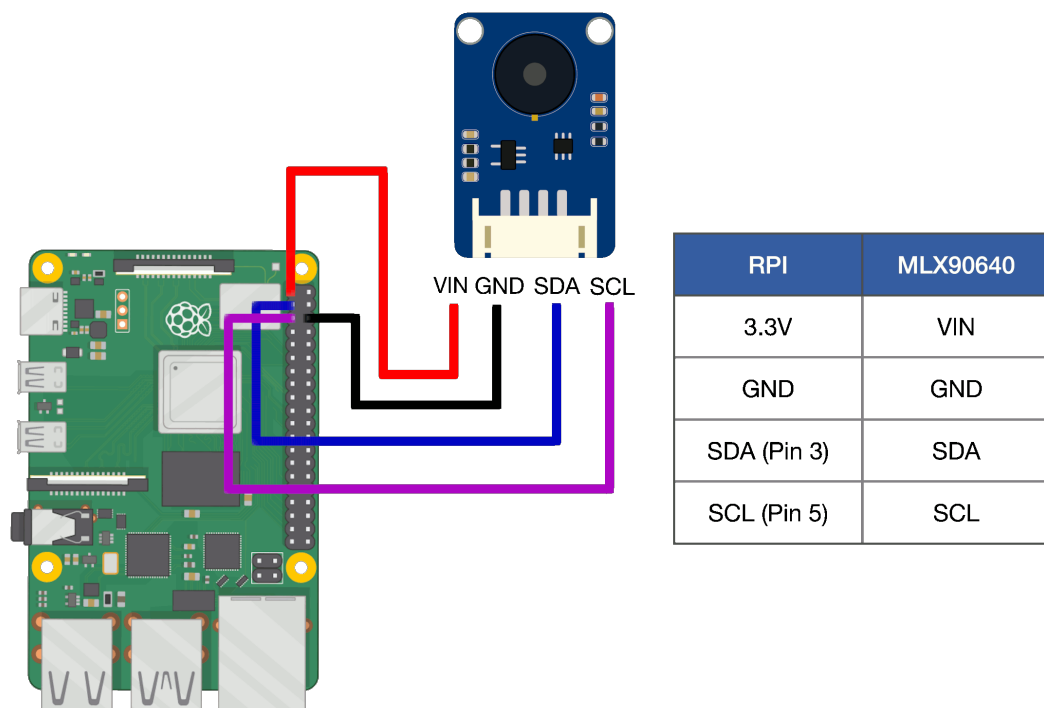


Figura 4.5 Diagrama de conexión de cámara térmica de bajo costo MLX90640 [15].

Para poder visualizar las imágenes se integra una pantalla *LED (Light Emitting Diode Display)* a color con conexión *HDMI (High-Definition Multimedia Interface)*.

CAPÍTULO 5. RESULTADOS

En la Figura 5.1 se observa la imagen RGB de una celda *Peltier* con los disipadores conectados y en la Figura 5.2 se observa la imagen térmica de la Figura 5.1 para la obtención de las temperaturas puesto que solo necesitamos la información que se encuentran en las zonas de interés, para este caso nos interesa lo zona fría y caliente de cada celda *Peltier*.




Figura 5.1 Fotografía RGB de celda *Peltier* conectado a los disipadores de temperatura, así mismo con un sensor termopar.




Figura 5.2 fotografía térmica tomada con la cámara MLX90640 y sumada con la Figura 5.1.

A continuación, se explica el algoritmo desarrollado para la estimación de la temperatura. El prototipo cuenta con 4 celdas *Peltier*, por tal motivo la fotografía original que se toma de la vista superior como se observa en el Figura 4.4, las cuales son nombradas con la fecha y hora de captura. Respectivamente, dichas imágenes son guardadas en la placa Raspberry Pi 3, donde son subidas a un repositorio en

GitHub para poder realizar un *dataset* de imágenes térmicas con celdas *Peltier*. Esto con la finalidad de evitar una duplicación de imágenes.




Figura 5.3 Imagen resultante convertida a escala de grises para poder obtener el histograma.

Posteriormente se toma una imagen y procedemos a realizar un histograma Figura 5.3, de todos los valores de la imagen convertida a escala de grises previamente Figura 5.4, la finalidad de dicho histograma es establecer un umbral con el valor de píxel con el que se cuenta mayor frecuencia en la imagen a escala de grises. Con el objetivo de convertir a una imagen binaria, esto se logra convirtiendo todos los valores de píxel que están por debajo del valor umbral en 0 y por encima del mismo en 1. Para el procedimiento de limitación de contornos en imágenes se establecieron áreas en la

imagen binaria, uno por cada zona de interés, puesto que la imagen binaria tiene zonas de interés aisladas de las zonas de calor que se pretenden analizar, se calcula la distancia de los píxeles de dichas áreas con la siguiente fórmula:

$$d = \sqrt{(x_2 - x_1)^2 + (y_2 - y_1)^2} \quad (1)$$

Donde:

- d : *Distancia euclidiana entre los dos píxeles.*
- x_1 : *posición horizontal (columna) del píxel de la primera zona de interés.*
- y_1 : *posición vertical (fila) del mismo píxel.*
- x_2 : *posición horizontal (columna) del píxel de la segunda zona de interés.*
- y_2 : *posición vertical (fila) del mismo píxel.*

Esto se calcula con respecto a los píxeles de las zonas térmicas y se adjuntan a las zonas más cercanas, dando como resultado un área más unificada en la propagación de calor. Se realizó un establecimiento de áreas mínimas y máximas, por cada zona fría y caliente, esto se logró determinar por el simple hecho que la zona fría es más pequeña que la caliente.




Figura 5.4 Histograma obtenido de la Figura 3.8.

Una vez establecidas las áreas de cada zona, se realiza el dibujado del contorno de cada una de las zonas, con la técnica *thresholding* [16] sin el cálculo del gradiente Figura 5.5 (a), el cual fue reemplazado con el umbral de la imagen para convertir en binaria la Figura 5.4, posterior a ello se dibuja el contorno en color verde por encima de la imagen original a color, y se procede a recortar la imagen a color con contornos dibujados, en dos imágenes resultantes, zona fría y zona caliente Fig 5.5 (b).




Figura 5.5 Resultados en la detección de bordes.




Figura 5.6 Descomposición de la imagen en escala de grises (a) y en sus canales de color: rojo (b), verde (c) y azul (d), mostrando la distribución relativa de intensidades cromáticas en la composición.

Utilizamos técnicas de segmentación de imágenes para acceder a la información de las imágenes zona fría y zona caliente, para ellos, se dividen las imágenes en cada una de sus capas *RGB* [17], a las cuales se denominan canal rojo, canal verde y canal azul. En la Figura 5.6. se observa la segmentación de dichas capas, partiendo de que se tiene la información analógica de 0 a 255 en valor de píxeles, tenemos que encontrar un píxel promedio por capa, para poder ser promediado con los píxeles promedios de cada capa *RGB*, esto con la finalidad de obtener un píxel promedio de toda la zona de interés, en este caso de muestra en la Figura 5.6, la zona caliente. Al estar hablando

de valores promedio en figuras amorfas se toma la opción de utilizar el siguiente método:

$$\int_{x_1}^{x_2} \int_{y_1}^{y_2} C(x, y) dy dx \quad (2)$$

La presente formula representa una integración doble sobre las coordenadas espaciales (x) y (y) en un rango dado, en este caso desde

$$\begin{aligned} x_1 &\leq x \leq x_2 \\ y_1 &\leq y \leq y_2 \end{aligned}$$

Donde:

- x_1, x_2 : Límites de integración en el eje horizontal.
- y_1, y_2 : Límites de integración en el eje vertical.
- $C(x, y)$: Función de intensidad o característica en el punto (x,y).
- dy, dx : Diferenciales de área.

El doble integrando $C(x, y)$ corresponde a la imagen, como el canal y permite calcular una medida global de una propiedad sobre una región específica y cada una de las capas ignorando los pixeles de color negro. Una vez obtenidas las áreas, se realiza el promedio de las 3 capas dando como resultado un valor *pixel* y se introduce a una estandarización donde se tiene establecido el valor *pixel* de la temperatura en grados Celsius, tomando como referencia los valores máximos y mínimos de los sensores termopares, de esta manera se garantiza tener un error mínimo con respecto a los valores reales.

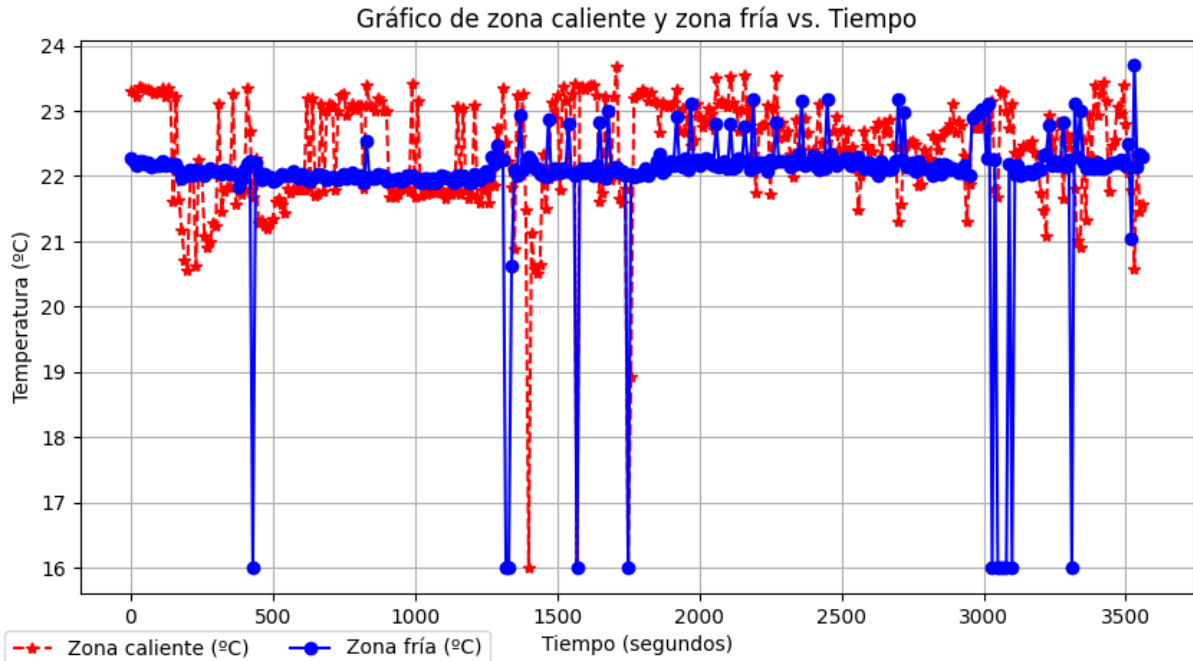


Figura 5.7 Resultado de la estimación promedio de la temperatura en la zona fría y caliente de la celda *Peltier*.

En la Figura 5.7 se observa el resultado de un conjunto con 350 imágenes térmicas de celda *Peltier*, las cuales fueron tomadas con una variación de 10 segundos cada una, en la línea azul se observa la temperatura fría y la línea roja, la temperatura caliente, como se observa podemos deducir que el algoritmo desarrollado tiene una buena predicción con la temperatura fría, mientras que con la temperatura caliente es menos estable, esto es porque la celda *Peltier* estaba conectada con una fuente de voltaje que no suministraba la suficiente corriente eléctrica para el correcto funcionamiento, lo que provocaba es que no se tuviera un suministro constante. Aún falta una etapa más rigurosa de comprobación con respecto a los valores suministrados por el algoritmo y los valores reales.

Con respecto al conteo de la cantidad de agua se plantearon diferentes maneras de tener la información cuantificable sin embargo se optó por el siguiente método. El conteo de cantidad de agua que se recolecta en determinado tiempo es de suma importancia puesto que es lo que pretendemos predecir con ayuda de nuestros modelos de *machine learning* en cuanto a clasificación. Mediante una búsqueda en la literatura optamos por fabricar un prototipo el cual consiste en el conteo de gotas con

tamaño uniforme, de esta manera podemos obtener la cantidad de gotas de agua que se obtienen cada 3 minutos, este tiempo se estableció porque es el mismo tiempo que se obtiene las mediciones de los demás parámetros, debido a que no se tiene bastante cambio en los parámetros en un tiempo más corto. En la Figura 5.8 se observa una pantalla que muestra la cantidad de agua contada.




Figura 5.8 Prototipo conteo de agua (tesis en desarrollo) [18].

5.1 Construcción del *Dataset*




Figura 5.9 Conjunto de datos sin valores nulos por variable.

En la Figura 5.9 se observa la construcción del conjunto de datos procesados que son lo que se integraran como entradas para los modelos de *Machine Learning*. Dicho conjunto de datos fue recabado de los sensores que se muestran en la Figura 4.3, En la tabla 5.1 se muestra el nombre de cada una de las columnas de los datos que fue recabado para la construcción de dicho conjunto de datos.

Tabla 5.1 Nombres de las variables incluidas en el conjunto de datos.

Variables del <i>Dataset</i>
Temperatura (°C) celda 1 lado caliente
Temperatura (°C) celda 1 lado frio
Temperatura (°C) celda 2 lado caliente
Temperatura (°C) celda 2 lado frio
Temperatura (°C) celda 3 lado caliente
Temperatura (°C) celda 3 lado frio
Temperatura (°C) celda 4 lado caliente
Temperatura (°C) celda 4 lado frio
Humedad
TempAmbiente
PuntoRocioGeneral
Punto de rocío celda 1 (°C)
Punto de rocío celda 2 (°C)
Punto de rocío celda 3 (°C)
Punto de rocío celda 4 (°C)
Gotas

5.2 Preprocesamiento de los datos

La etapa del preprocesamiento de datos es una de las etapas más importantes para el entrenamiento y el buen desempeño de los modelos de inteligencia artificial, puesto que si tenemos datos de mala calidad tendremos como resultado malos desempeños en cuanto a modelos de clasificación, regresión y generación de datos sintéticos. La base de datos recabada por el prototipo de la Figura 5.9 se tienen datos nulos, datos erróneos por motivos variados que afectan a los sensores, debido a la alta sensibilidad y el requerimiento de calibración constantemente, es por ello por lo que se idea un plan de acción para mejorar los datos recabados.

El paso más importante es definir el entorno de trabajo para ello, utilizamos el entorno online de *Google Colab*, puesto que permite una opción gratuita de programación con *GPU (Graphics Processing Unit)* y *CPU (Central Processing Unit)*, ya que para programar utilizando el recurso de *GPU* es necesario contar con un equipo con tarjeta gráfica dedicada, que ayuda al procesamiento de los datos mediante las *GPU*. Debemos tener en cuenta el tipo de datos con los que contamos en nuestro *dataset*, es por ello por lo que se aplica la función, *dtype* para conocer el tipo de variables en los datos por columna, para este caso la función muestra que contamos solamente con variables numéricas.

Por lo que se omite un plan de acción para reemplazar variables categóricas. Sin embargo, contamos con diferentes tipos de datos numéricos flotantes y enteros, para resolver este problema es conveniente convertir a un mismo tipo de datos numéricos, por lo que se toma la decisión de convertir en valores de tipo flotante (*Float*).

El graficado de los valores numéricos por columna, nos permite tener un panorama más concreto de los intervalos de valores por columna, recordando la Figura 4.3 observamos que tenemos sensores termopares que registran la temperatura, lo cual significa que son muy sensibles a diferentes perturbaciones que generan mediciones erróneas. En la Figura 5.10 se observa dicha distribución de los datos, podemos observar que en la columna (Temperatura (°C) celda 3 lado frío) contamos con valores atípicos en la medición de la temperatura fría, esto podemos confirmar tras analizar la base de datos, debido a que los sensores termopares envían valores de -120°C , cuando registran mediciones erróneas, entonces procedemos a eliminar esos registros dando un total de 1896 registros originales a 1708 registros imputados.

Distribución de Datos por Columna

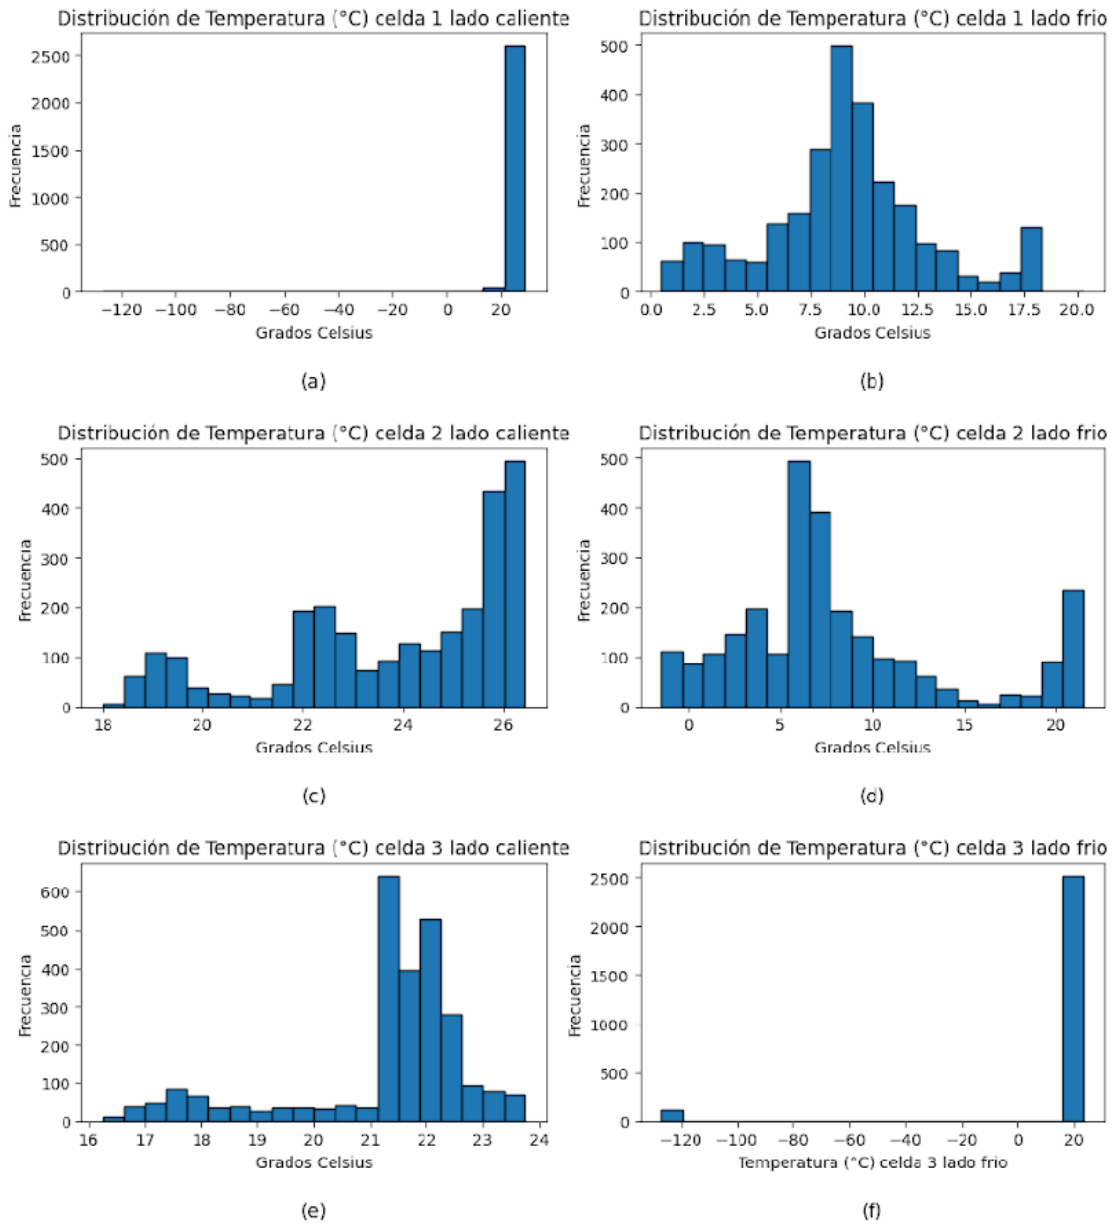


Figura 5.10 Distribución por columna de los datos con intervalos de 3 minutos entre cada medición registrada.

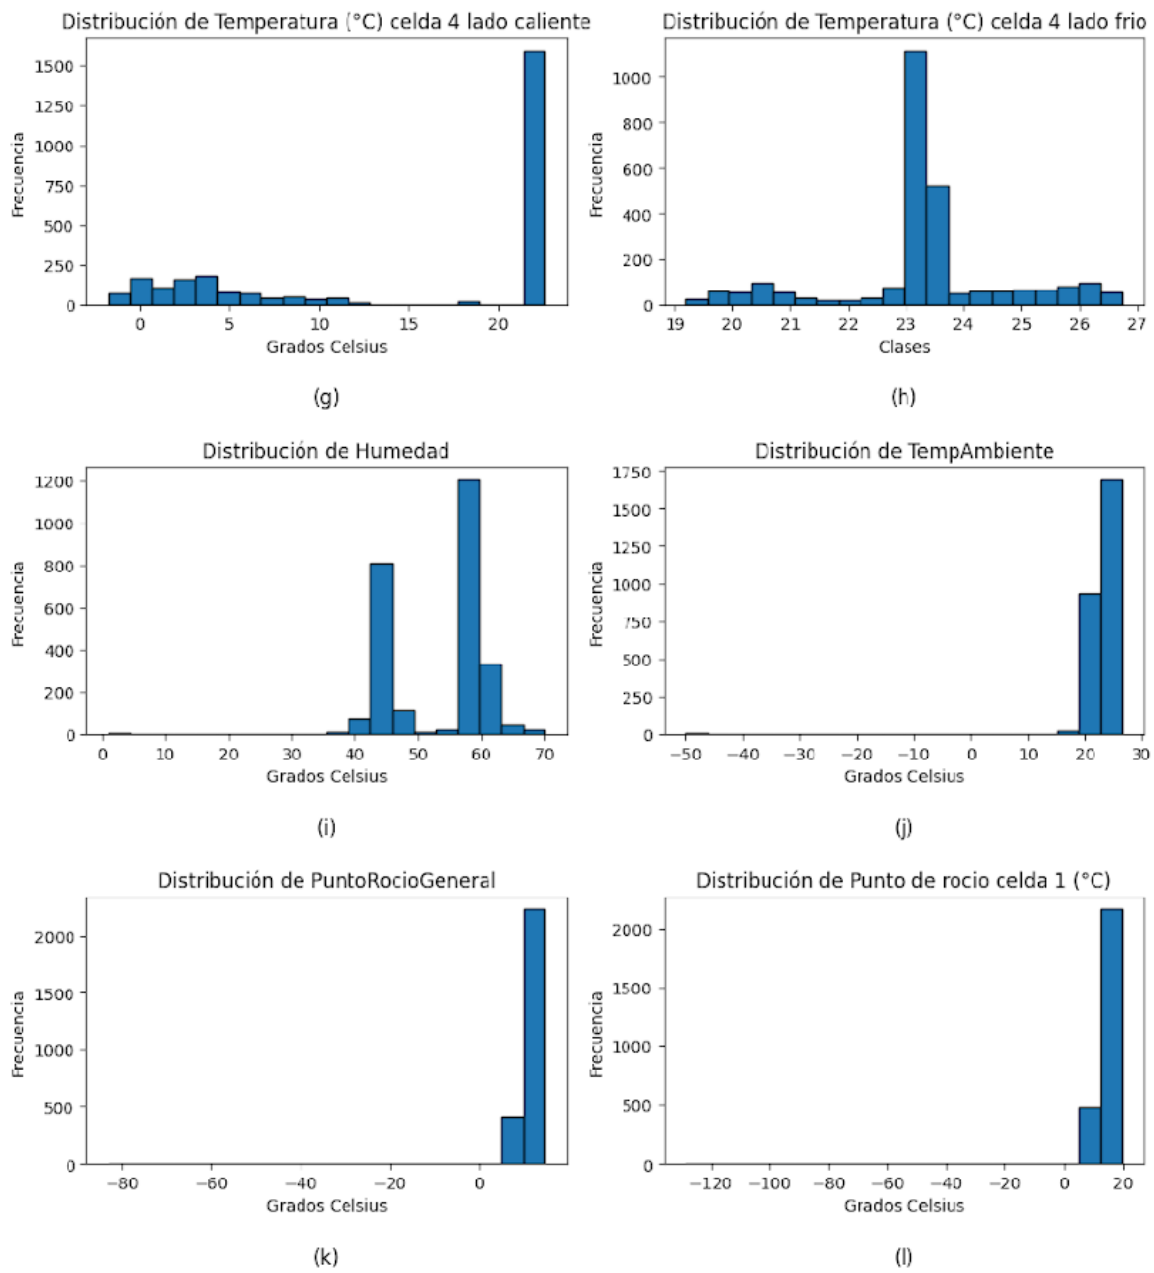


Figura 5.10 Distribución por columna de los datos con intervalos de 3 minutos entre cada medición registrada.

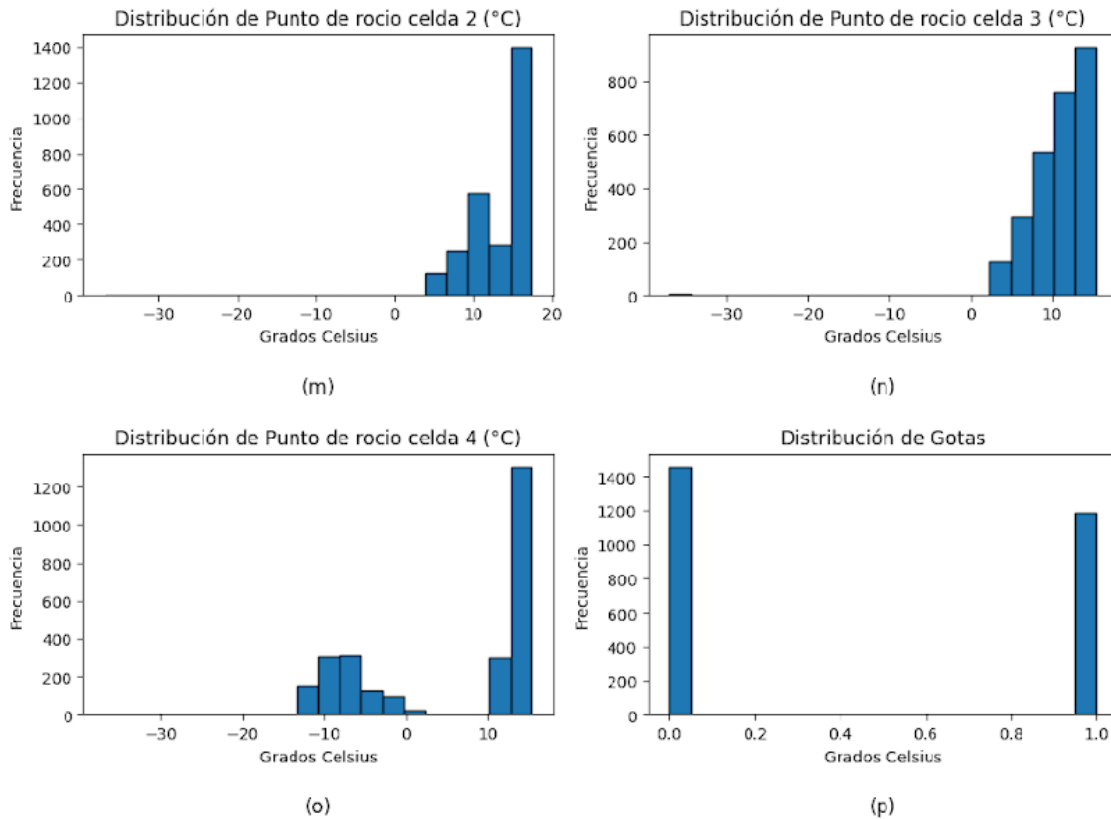


Figura 5.10 Distribución por columna de los datos con intervalos de 3 minutos entre cada medición registrada.

Para garantizar la calidad de los datos y evitar que valores atípicos distorsionen los análisis posteriores, se aplicó un procedimiento de detección y eliminación de valores atípicos, basado en el rango intercuartílico (IQR) [18].

Sea $X = x_1, x_2, \dots, x_n$ el conjunto de observaciones no nulas de dicha variable. Se denoten los siguientes cuartiles:

- Q_1 : primer cuartil (percentil 25), tal que el 25% de los datos son menores o iguales a Q_1 .
- Q_3 : tercer cuartil (percentil 75), tal que el 75% de los datos son menores o iguales a Q_3 .
- $IQR = Q_3 - Q_1$: rango intercuartílico.

Se considera que una observación x_i es atípica si:

$$x_i < Q_1 - 1.5 \cdot IQR \quad \text{o} \quad x_i > Q_3 + 1.5 \cdot IQR \quad (4)$$

Por lo tanto, se conserva únicamente el subconjunto filtrado:

$$X_{filtrado} = \{ Q_1 - 1.5 \cdot IQR \leq x_i \leq Q_3 + 1.5 \cdot IQR \} \quad (5)$$

Este procedimiento permite eliminar valores atípicos sin asumir una distribución específica de los datos, siendo especialmente útil en contextos experimentales donde pueden existir errores de medición o condiciones anómalas. Como se observa en la tabla 5.2 se redujo la dispersión en los datos, siendo la columna de la temperatura fría en la celda 3, la que tiene una reducción más significativa.

Tabla 5.2 Comparativa de varianza original vs. varianza con datos imputados.

Parámetro	Varianza original	Varianza con datos imputados
Temperatura celda 1 lado caliente (°C)	17.11	16.47
Temperatura celda 1 lado frío (°C)	7.72	4.23
Temperatura celda 2 lado caliente (°C)	3.00	2.45
Temperatura celda 2 lado frío (°C)	31.12	26.02
Temperatura celda 3 lado caliente (°C)	0.21	0.10
Temperatura celda 3 lado frío (°C)	1300.82	0.03
Temperatura celda 4 lado caliente (°C)	0.21	0.08
Temperatura celda 4 lado frío (°C)	14.11	0.02
Humedad (%)	14.11	8.68
Temperatura ambiente (°C)	11.88	6.66
Punto de rocío general (°C)	20.10	11.17
Punto de rocío celda 1 (°C)	19.92	17.20
Punto de rocío celda 2 (°C)	6.97	4.25
Punto de rocío celda 3 (°C)	5.92	3.49
Punto de rocío celda 4 (°C)	5.88	3.45
Gotas	0.07	0.06

El conocer cómo afectan cada una de las variables, de nuestro conjunto de datos, es de suma importancia debido a que podemos garantizar que todas las variables que van a ser introducidas al modelo de regresión o clasificación tienen un impacto directo en la predicción de la variable objetivo. En este caso, en la Figura 3.16 se observa el resultado de un análisis de correlación donde se observa que la variable Temperatura

(°C) celda 4 lado frío es la que tiene mayor impacto en la predicción de nuestra variable objetivo, es decir, que si la variable Temperatura (°C) celda 4 lado frío aumenta, tenemos una reducción en la variable objetivo. Esto no es del todo correcto, debido a que la variable Temperatura (°C) celda 4 lado frío muestra que tiene más temperaturas con valores cercanos a la temperatura ambiente, lo que significa que no fue suministrado el suficiente voltaje para poder condensar agua.

Es por ello por lo que podemos asegurar que el disipador de la celda 4 en la zona fría no tuvo una alimentación de voltaje constante, o el disipador no estuvo de manera directa conectado a la celda *Peltier* 4. Para calcular la relación lineal entre cada variable independiente y la variable objetivo, se utilizó el coeficiente de correlación de Pearson. Matemáticamente, este coeficiente se define como:

$$r_{X,Y} = \frac{\sum_{i=1}^n (x_i - \underline{x})(y_i - \underline{y})}{\sqrt{\sum_{i=1}^n (x_i - \underline{x})^2} \cdot \sqrt{\sum_{i=1}^n (y_i - \underline{y})^2}} \quad (6)$$

Donde:

- x_i y y_i son los valores individuales de las variables X e Y respectivamente.
- \underline{x} y \underline{y} son las medias de las variables X e Y .
- n es el número total de observaciones. Este coeficiente toma valores en el intervalo $[-1, 1]$, donde:
 - $r = 1$ indica una correlación positiva perfecta.
 - $r = -1$ indica una correlación negativa perfecta.
 - $r = 0$ indica ausencia de correlación lineal.

En nuestro caso, se observa que la variable Temperatura (°C) celda 4 lado frío presenta una correlación negativa con la presencia de gotas, lo cual sugiere que, a mayor temperatura en esa zona, menor probabilidad de condensación. Sin embargo, esta correlación debe interpretarse con cautela, ya que no necesariamente implica causalidad. El hecho de que esta variable tenga valores cercanos a la temperatura ambiente indica que el sistema de enfriamiento no

estuvo operando correctamente. Posiblemente por falta de voltaje o por una desconexión física entre el disipador y la celda *Peltier*.

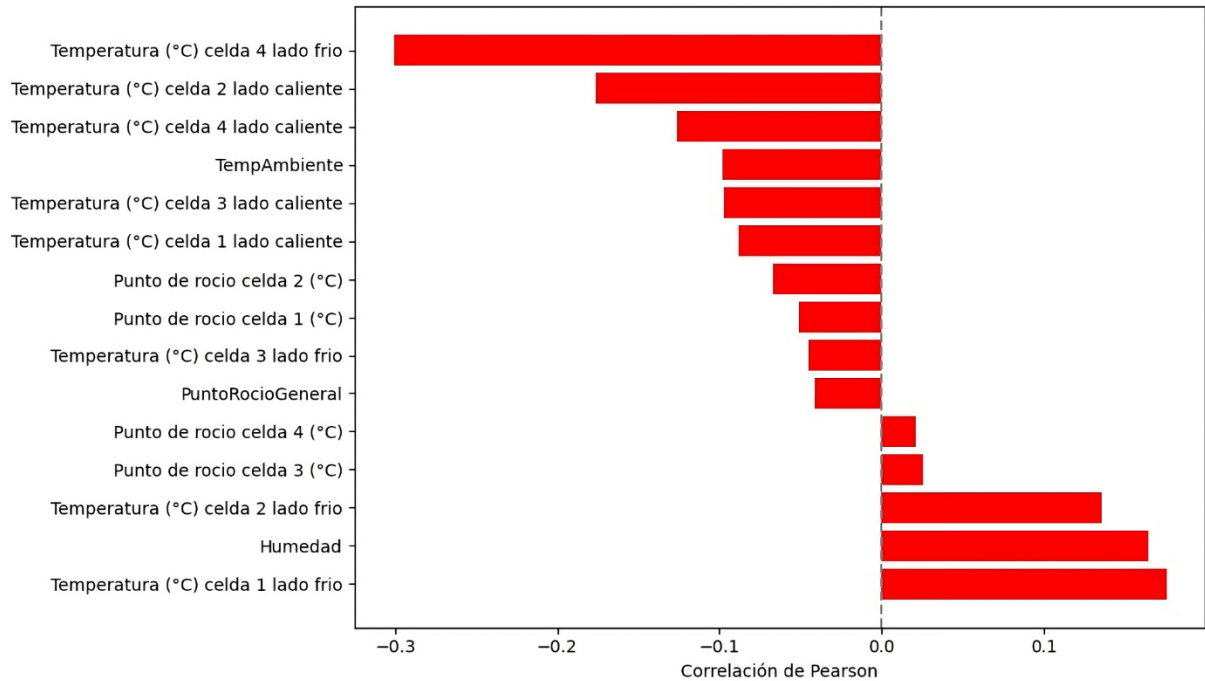


Figura 5.11 Coeficiente de correlación de las variables independientes con respecto a la variable dependiente.

5.3. Escalamiento de datos

El escalamiento de los datos es de suma importancia debido a que nos permite normalizar las variables numéricas, especialmente cuando cada columna de nuestra base de datos presenta rangos distintos. Esta variabilidad puede representar un riesgo al momento de utilizar dichos valores como entradas en modelos de *Machine Learning*, ya que los algoritmos pueden verse sesgados hacia características con mayor magnitud. Para este proyecto se optó por utilizar la técnica de escalamiento estándar, conocida como *Standard Scaler*, la cual transforma los datos para que cada característica tenga media cero y desviación estándar unitaria. Matemáticamente, esta transformación se expresa como:

$$X_{escalado} = \frac{X - \mu}{\sigma} \quad (7)$$

Donde:

- X : Es el valor original de la variable.
- μ : Es la media de la variable.
- σ : Es la desviación estándar.

De esta manera, se garantiza que todas las variables contribuyan de forma equitativa al modelo, sin importar su escala original.

En problemas de clasificación binaria, es común encontrar conjuntos de datos con clases desbalanceadas, lo cual puede sesgar el entrenamiento del modelo hacia la clase mayoritaria. La Figura 5.12 muestra la distribución de clases antes y después de aplicar la técnica SMOTE (Synthetic Minority Over-sampling Technique) [19].




Figura 5.12 Distribución de clases antes y después de aplicar SMOTE, Clase 0: No se obtuvieron registros de goteo de agua y clase1: se obtuvieron registros de goteo de agua.

Antes de aplicar SMOTE, la clase 1 (minoritaria) contaba con aproximadamente 100 instancias, mientras que la clase 0 tenía cerca de 1400. Esta desproporción puede provocar que el modelo aprenda a predecir mayoritariamente la clase 0, ignorando patrones relevantes de la clase 1. Después de aplicar *SMOTE*, ambas clases presentan una cantidad equilibrada de instancias, lo que mejora la capacidad del modelo para generalizar y detectar correctamente ambas clases. *SMOTE* genera

nuevas instancias sintéticas de la clase minoritaria mediante interpolación lineal entre ejemplos existentes.

Dado un vector de características $X_i \in R^d$ perteneciente a la clase minoritaria, se selecciona aleatoriamente uno de sus k vecinos más cercanos X_{nn} , y se genera una nueva instancia sintética X_{new} como:

$$x_{new} = x_i + \delta \cdot (x_{nn} - x_i) \quad (8)$$

Donde:

- $\delta \sim U(0,1)$ es un valor aleatorio extraído de una distribución uniforme.

Este proceso se repite hasta alcanzar el número deseado de instancias sintéticas, logrando así un conjunto de datos balanceado.

5.4 División del conjunto de datos

Dividir el conjunto de datos con el que se cuenta, es de suma importancia debido a que nos permite tener un porcentaje de información con la que se entrena el modelo, otro porcentaje, para hacer pruebas con información que nunca han visto nuestros modelos y por último otro porcentaje de información para validación y poder conocer el desempeño del modelo, para este caso se tomó la decisión de tener el 80% para entrenamiento, el 20% para prueba y para validación. Con una semilla aleatoria de 400, lo cual indica que siempre que se ejecute el código se tendrán los mismos datos en cada conjunto.

5.5 Construcción del modelo de clasificación

5.5.1. Modelos de Clasificación

Elegir el modelo más adecuado para este proyecto de tesis, no es tarea fácil debido a que existe muy poca literatura utilizando técnicas de inteligencia artificial, en este tipo de problemas con celdas *Peltier*. Es por ello por lo que se toma la decisión de hacer la comparativa entre dos modelos de inteligencia artificial (regresión logística y redes neuronales artificiales). Para el primer modelo se utiliza regresión logística, con el

framework *Scikitlearn*, el cual es un modelo simple, que se ajusta de manera adecuada al comportamiento de los datos en este problema debido a que la tasa de cambio de los datos es lineal con el tiempo. En la Figura 5.13 se observa la construcción del modelo y la métrica *recall*, utilizada de primera instancia para medir

```
# Entrenar regresión logística
from sklearn.linear_model import LogisticRegression
from sklearn.metrics import confusion_matrix,
classification_report, accuracy_score

# Crear el modelo con parámetros definidos
modelo_log = LogisticRegression(max_iter=1000,
random_state=42)

# Entrenar el modelo con datos re-muestreados
modelo_log.fit(X_train_resampled, y_train_resampled)

# Realizar predicciones sobre los datos de prueba escalados
y_pred = modelo_log.predict(X_test_scaled)

# Evaluar el rendimiento del modelo
print("\nMatriz de confusión:")
print(confusion_matrix(y_test, y_pred))

print("\nReporte de clasificación:")
print(classification_report(y_test, y_pred))

print(f"\nAccuracy: {accuracy_score(y_test, y_pred):.4f}")
```

Figura 5.13 Configuración del modelo Regresión logística

la capacidad del modelo para identificar correctamente todos los casos positivos reales. Es especialmente importante cuando los falsos negativos son costosos o peligrosos.

El segundo modelo es redes neuronales artificiales, debido a que es un modelo que se ajusta a los parámetros que se requieren del problema. En la Figura 5.14 se observa la construcción del modelo el cual consiste en 11 neuronas como entradas, dos capas ocultas con 64 y 32 neuronas respectivamente y una capa de salida con una neurona con función de activación Sigmoide en la capa de salida y las demás capas con función

de activación lineal esto con la finalidad de lograr hacer una clasificación binaria en la salida, ya que en función sigmoide se establece un umbral donde, si se supera el umbral, se puede catalogar que pertenece a un grupo y si no se supera significa que pertenece al otro grupo de datos, entonces podemos decir que estamos ante un problema de clasificación binaria supervisado, debido a que todos los datos tienen sus respectivas etiquetas en cada una de las variables del *dataset*.

En la Figura 5.15 se observa el diagrama de la configuración de la red neuronal, donde se puede observar la arquitectura utilizada y resaltando que se toman todas las variables de entrada como un vector de 1 por 11, de esta manera tenemos una mejor clasificación en la capa de salida, debido a que este proceso resultó ser mejor durante la transmisión de los datos en la red neuronal, se ajustaron de mejor manera los pesos y los sesgos de la misma red neuronal.

```
# Definir arquitectura de la red neuronal
from tensorflow.keras.models import Sequential
from tensorflow.keras.layers import Dense, Dropout
from tensorflow.keras.regularizers import l2

model = Sequential([
    Dense(64, activation='relu',
input_shape=(X_train_scaled.shape[1],),
kernel_regularizer=l2(0.001)),
    Dropout(0.3),
    Dense(32, activation='relu',
kernel_regularizer=l2(0.001)),
    Dropout(0.3),
    Dense(1, activation='sigmoid')
])
```

Figura 5.14 Código del modelo Redes neuronales.

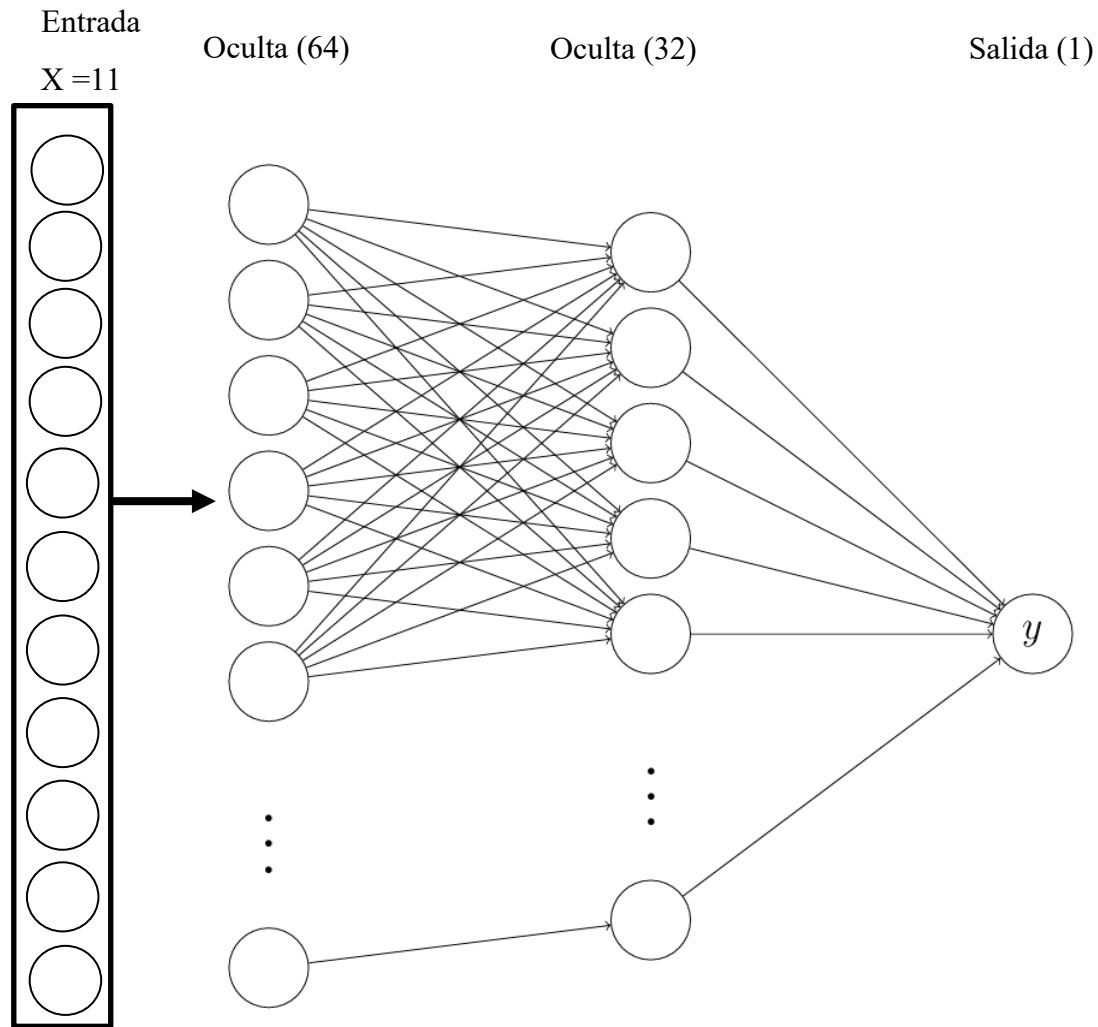


Figura 5.15 Arquitectura de red neuronal para clasificación binaria, con 11 entradas, dos capas oculta de 64 y 32 neuronas y una salida sigmoideal.

Dicho modelo tiene un compilador configurado con el optimizador *Adam* a 0.001 para garantizar un ajuste más no en la magnitud de pérdida con respecto a las épocas, dichas épocas se establecieron en 100. Así mismo se agregaron penalizaciones en los pesos grandes con la técnica de regresión rige, para prevenir el sobre ajuste, en la Figura 3.21 se observa de manera gráfica la magnitud de perdidas por época.




Figura 5.16 Desempeño del modelo durante el entrenamiento:
(a) Evolución de la pérdida (binary_crossentropy) en entrenamiento y validación, alcanzando un mínimo de 0.423.
(b) Evolución de la precisión, con una mejora sostenida hasta un máximo de 0.809, reflejando una convergencia efectiva del modelo.

5.6. Validación de los modelos de predicción

La validación de los modelos es algo muy importante debido a que se requiere tener certeza que los modelos son funcionales con datos que no ha visto durante su entrenamiento, es por ello por lo que en la etapa división del conjunto de datos, el 10% de los datos se separaron justamente para ser utilizados en la etapa de validación, dichos datos se toman de manera aleatoria para realizar la prueba. Para ello se utiliza la técnica validación cruzada donde se toman 5 conjuntos de datos del conjunto, para ser comparados con los datos predichos del modelo, en la Figura 5.17 se observa la comparativa de la validación cruzada en la matriz de confusión obtenida, de los dos modelos de clasificación (regresión logística y redes neuronales).

Como se observa en la Figura 5.17, no se cuenta con buenos resultados en el modelo de regresión logística, por lo que se descarta dicho modelo y se opta por redes neuronales, evaluadas mediante la técnica de la curva *ROC*. Esta curva permite visualizar el rendimiento de un clasificador binario al variar el umbral de decisión aplicado sobre la salida de la función de activación. En el caso de las redes neuronales, se utiliza la función sigmoide como activación en la capa de salida, definida como:

$$\sigma(z) = \frac{1}{1 + e^{-z}} \quad (9)$$

donde z representa la combinación lineal de las activaciones de la capa anterior. Esta función produce una salida continua en el intervalo $[0,1]$, interpretada como la probabilidad de pertenencia a la clase positiva.




Figura 5.17 validación cruzada con *5 folds*, para el modelo de regresión logística donde la clase 1 significa que existió goteo de agua y clase 0 donde no existió conteo de agua.

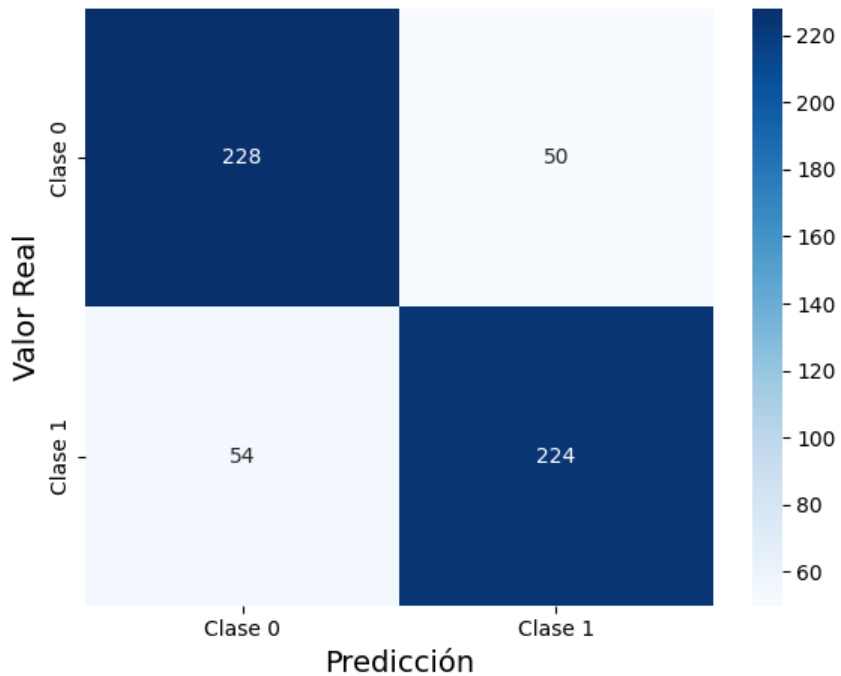


Figura 5.18 validación cruzada con 5 *folds*, para el modelo de redes neuronales donde la clase 1 significa que existió goteo de agua y clase 0 donde no existió conteo de agua.

Para construir la curva ROC, se evalúan todos los posibles umbrales de decisión $t \in [0, 1]$, y para cada uno se calcula:

- La Tasa de verdaderos positivos (TPR):

$$TPR(t) = \frac{TP(t)}{TP(t) + FN(t)} \quad (10)$$

- La Tasa de falsos positivos (FPR):

$$FPR(t) = \frac{FP(t)}{FP(t) + TN(t)} \quad (11)$$

donde TP , FP , FN y TN son los conteos de verdaderos positivos, falsos positivos, falsos negativos y verdaderos negativos, respectivamente, al aplicar el umbral t . La curva ROC se construye trazando $TPR(t)$ contra $FPR(t)$ para cada valor de t . El área bajo la curva (AUC) cuantifica el rendimiento general del modelo: cuanto más cerca esté de 1, mejor será la capacidad de discriminación.

En la Figura 5.19 se observa que la red neuronal alcanza un AUC de 0.86, superior al 0.74 obtenido con regresión logística, lo que indica una mejora significativa en la clasificación.

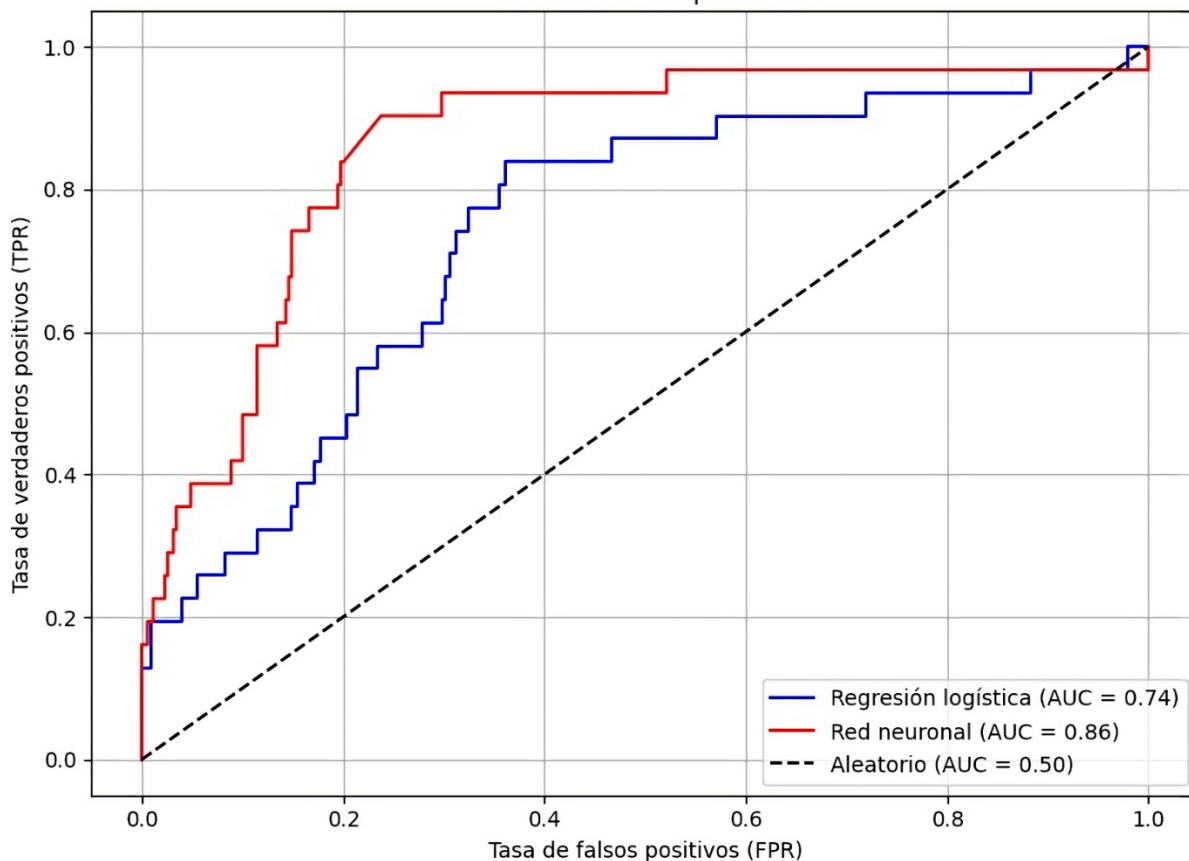


Figura 5.19 Resultado de la comparativa redes neuronales y regresión logística con técnica ROC.

El gráfico de resumen SHAP (*SHapley Additive Explanations*) [19], presentado en la Figura 5.20, permite visualizar la importancia relativa de cada variable en las predicciones del modelo de clasificación binaria. Cada punto representa un valor SHAP para una instancia específica, donde su posición horizontal indica el impacto en la salida del modelo: valores a la derecha (positivos) impulsan la predicción hacia la clase positiva, mientras que a la izquierda (negativos) la alejan. El color de cada punto codifica el valor original de la característica: azul para valores bajos y rosa para valores altos.

Este análisis revela patrones clave de direccionalidad y dispersión:

- Correlación Directa e Inversa: Variables como *Temperatura (°C) celda 4 lado caliente* muestran una correlación positiva (puntos rosas a la derecha), indicando que valores altos incrementan la probabilidad de la clase positiva. En contraste, el *Punto de rocío celda 1 (°C)* muestra un impacto inverso.
- Poder Discriminativo: Las variables superiores presentan una mayor dispersión horizontal, confirmando su alto peso en la decisión final, mientras que variables como *TempAmbiente* muestran una alta densidad cerca del cero, indicando una influencia marginal en la mayoría de los casos.
- Detección de Casos Críticos: Se identifican impactos extremos en valores específicos, como en la *Temperatura (°C) celda 3 lado frío*, donde valores muy bajos (puntos azules aislados) ejercen un efecto negativo desproporcionado en la predicción.

Esta visualización no solo jerarquiza las variables, sino que valida la coherencia empírica del sistema al mostrar cómo cada rango de valores afecta la decisión del modelo, guiando futuras estrategias de ingeniería de características.

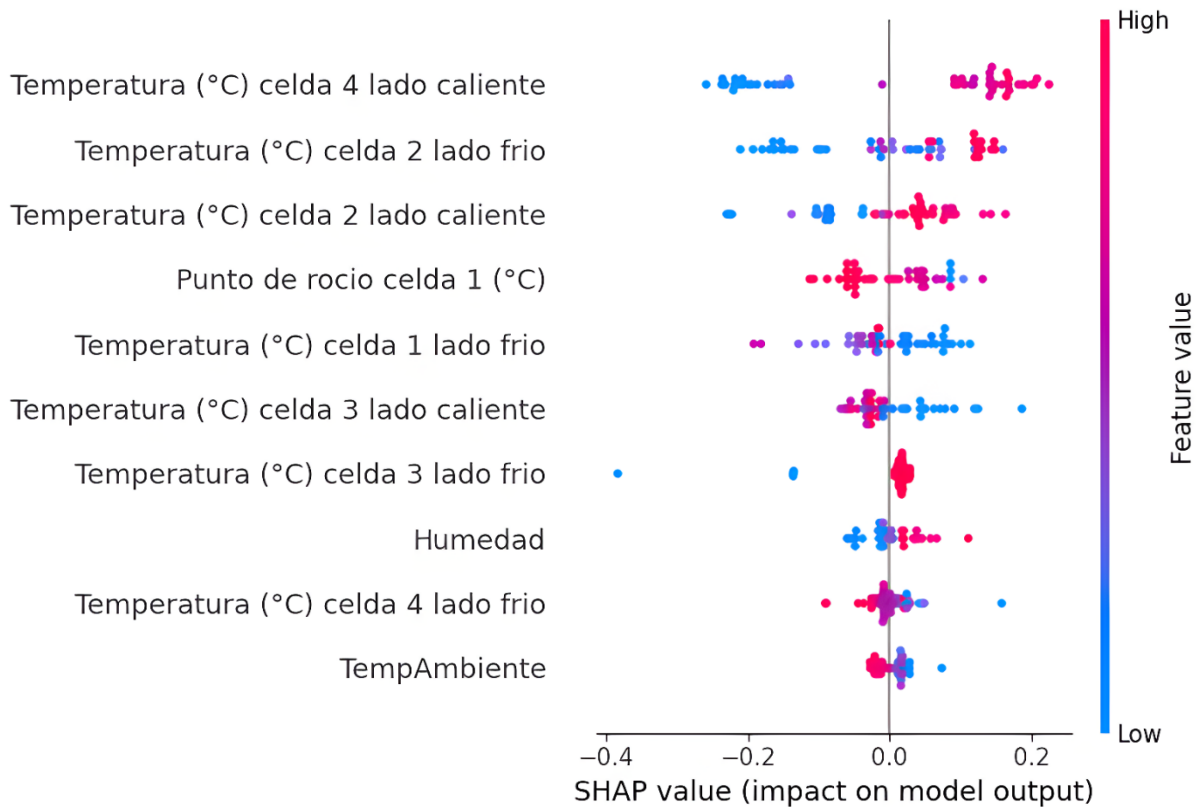


Figura 5.20 Grafico SHAP del modelo entrenado con redes neuronales.

5.7. Introducción de los resultados en el microcontrolador

El último proceso es la introducción de la ecuación obtenida del modelo utilizado, en este caso redes neuronales con función de activación sigmoide en la capa de salida. Para esto se requiere un análisis de sensibilidad que permita obtener los pesos en la capa de salida, como se observa en el siguiente código: se trata de un tensor con los pesos que actúan en la capa de salida más el sesgo de la última capa. Con esta información es más que suficiente para replicar el modelo ya entrenado con menos recursos computacionales, puesto que los microcontroladores cuentan con recursos muy limitados, incluso con kilobytes disponibles para almacenamiento.

La salida de la red neuronal en la última capa se define como:

$$\hat{y} = \sigma(w^T \cdot a^{(L-1)} + b) \quad (12)$$

donde:

w es el vector de pesos de la capa de salida.

$a^{(L-1)}$ son las activaciones de la capa anterior.

b es el sesgo de la capa de salida.

$\sigma(z) = \frac{1}{1+e^{-z}}$ es la función sigmoide.

Así, la salida \hat{y} puede interpretarse como una probabilidad en el intervalo $[0,1]$.

Es por ello por lo que se presenta a continuación la simulación del modelo de redes neuronales en lenguaje C++, el cual incluye la función de activación sigmoide para realizar el proceso de clasificación:

```

#include <cmath>
#include <vector>
#include <cstdio>

int main() {
    // Entradas simuladas (12 valores de ejemplo)
    std::vector<float> x = {
        0.5, -0.2, 0.1, 0.7, -0.3, 0.0,
        0.9, -0.5, 0.4, 0.2, -0.1, 0.6
    };

    // Pesos de la capa de salida
    std::vector<float> w = {
        -1.3169221, 0.31789774,
        0.87327147, 0.79329956, 0.50520283, 0.7212907,
        -1.0186042, 0.40676844,
        0.9459163, 0.5296269, 0.7161179, -1.8045915,
        0.9655434, -1.6124474, -
        1.3534809, 1.2550455, -0.8226437, 1.0710626,
        -1.5096995, -1.2897682, -
        1.0417376, -1.0136194, 1.1318973, -
        1.9530044,
        0.5322932, -
        1.323224, 0.6846763, 0.5117881, -
        1.350615, 0.7218342,
        0.47676626, 0.7769485
    };

    // Sesgo de la capa de salida
    float b = -0.07447436;

    // Cálculo de la salida
    float z = 0.0;
    for (int i = 0; i < 32; i++) {
        z += w[i] * x[i];
    }
    z += b;

    // Activación sigmoide
    float y = 1.0 / (1.0 + exp(-z));

    // Salida
    printf("Salida de la red neuronal: %.6f\n", y);

    return 0;
}

```

Figura 5.21 Simulación de red neuronal con activación sigmoide en C++.

CAPITULO 6. CONCLUSIONES

las redes neuronales muestran una menor precisión y un mejor *recall* en comparación con la regresión logística, deduzco que la hipótesis se cumple, ya que con las redes neuronales se obtiene un mejor desempeño. Por ello decidimos quedarnos con este modelo, pues resulta sencillo simular las ecuaciones suministradas por la capa de salida y adaptarlas para introducirlas en un microcontrolador.

Podemos afirmar que se cumplieron parcialmente los objetivos planteados, tanto el general como los específicos, logrando buenos resultados en las métricas de los modelos de clasificación desarrollados. Esto deja claro que siempre existe espacio para mejorar, tanto en el *hardware* como en el *software*, con el fin de alcanzar métricas superiores en la captación de agua con celdas Peltier y en la clasificación de parámetros mediante técnicas de inteligencia artificial.

Tabla 6.1 Comparación de métricas promedio entre los modelos de red neuronal y regresión logística.

Modelo	Accuracy	Precisión	Recall	F1-score
Red neuronal	0.815	0.821	0.850	0.813
Regresión logística	0.692	0.671	0.753	0.709

6.1 Contribuciones

Podemos concluir que este trabajo refleja una opción alternativa a los sistemas de control PID, donde reemplazamos los controladores que utilizan funciones matemáticas derivadas, por algoritmos como las redes neuronales artificiales, pero también una alternativa para usar estos modelos de inteligencia artificial ya entrenados, con menos recursos para ser introducidos en placas programables como los microcontroladores,

que tienen recursos limitados en comparación con equipos con tarjetas gráficas y procesadores más potentes, de esta manera podemos ejecutar los modelos ya entrenados con menos recursos y con la misma facilidad. Para trabajo futuro se espera recolectar más datos reales del sistema de captación de agua en diferentes ubicaciones y con diferentes variables ambientales que no podemos controlar como temperatura ambiente, altitud, etc. De esta manera tendremos un mejor panorama de como estas variables afectan a la captación de agua del sistema.

REFERENCIAS

- [1] Servicio Meteorológico Nacional. (2024). *Reporte del clima en México: Anual 2023*. Comisión Nacional del Agua. <https://smn.conagua.gob.mx/tools/DATA/Climatología/Diagnóstico%20Atmosférico/Reporte%20del%20Clima%20en%20México/Anual2023.pdf>
- [2] World Resources Institute. (2025). *Ranking of the world's most water-stressed countries by 2040*. <https://www.wri.org>
- [3] Nativo. (2024). *Reporte IA 2024: ¿Cómo es la IA en México?* <https://trends.nativo.company/storage/01JKBEH8S02X47MMVHA88CP96C>
- [4] Salehi, A. A., Ghannadi-Maragheh, M., Torab-Mostaedi, M., Torkaman, R., & Asadollahzadeh, M. (2020). A review on the water-energy nexus for drinking water production from humid air. *Renewable and Sustainable Energy Reviews*, 120, Artículo 109627. <https://doi.org/10.1016/j.rser.2019.109627>
- [5] Flórez López, R., & Fernández Fernández, J. M. (2005). *Las redes neuronales artificiales*. Netbiblo. <https://books.google.com.mx/books?id=X0uLwi1Ap4QC>
- [6] El Economista. (2023, 13 de junio). *Llueve 20.1% menos en 2023 que el promedio histórico*. <https://www.economista.com.mx/politica/Llueve-20.1-menos-en-2023-que-promedio-historico-20230613-0132.html>
- [7] Richaud, A. (2024, 18 de octubre). *Redes perceptrón multicapa (MLP): ¿Qué son, cómo funcionan y cuándo utilizarlas? (o no)*. <https://antonio-richaud.com/blog/archivo/publicaciones/41-redes-perceptron-multicapa.html>
- [8] Jeatrakul, P., & Wong, K. W. (2009). Comparing the performance of different neural networks for binary classification problems. En *2009 Eighth International Symposium on Natural Language Processing* (pp. 111–115). IEEE. <https://doi.org/10.1109/SNLP.2009.5340932>
- [9] Fukunaga, K., & Hummels, D. M. (1987). Bayesian error estimation using Parzen and k-NN procedures. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 9(5), 634–643. <https://doi.org/10.1109/TPAMI.1987.4767969>
- [10] Dong, X., Qian, L., & Huang, L. (2017). A CNN-based machine learning approach for short-term load forecasting in smart grids. En *2017 IEEE SmartWorld, Ubiquitous Intelligence & Computing, Advanced & Trusted Computing, Scalable Computing & Communications, Cloud & Big Data Computing, Internet of People and Smart City Innovation* (pp. 1–6). IEEE. <https://doi.org/10.1109/UIC-ATC.2017.8397447>

- [11] Mery, D. (2004). *Visión por computador*. Departamento de Ciencia de la Computación, Pontificia Universidad Católica de Chile. <https://mialdeatdo.com/wp-content/uploads/2021/01/LIBRO-MAQUETACION.pdf>
- [12] Soo, S. (2014). *Detección de objetos mediante el clasificador en cascada Haar*. Instituto de Ciencias de la Computación, Universidad de Tartu. https://comserv.cs.ut.ee/home/files/Soo_ComputerScience_2014.pdf
- [13] Kadhim, T. J., Abbas, A. K., & Kadhim, H. J. (2020). Experimental study of atmospheric water collection powered by solar energy using the Peltier effect. *IOP Conference Series: Materials Science and Engineering*, 671(1), Artículo 012155. <https://doi.org/10.1088/1757-899X/671/1/012155>
- [14] Gutiérrez Álvarez, Y. A. (en preparación). *Sistema autónomo para la captación de agua mediante aire atmosférico*[Tesis doctoral en preparación]. Universidad Autónoma del Estado de Morelos.
- [15] Hrisiko, J. (2020, 8 de junio). *High-resolution thermal camera with Raspberry Pi and MLX90640*. Maker Portal. <https://makersportal.com/blog/2020/6/8/high-resolution-thermal-camera-with-raspberry-pi-and-mlx90640>
- [16] Sahoo, P. K., Soltani, S. A. K. C., & Wong, A. K. (1988). A survey of thresholding techniques. *Computer Vision, Graphics, and Image Processing*, 41(2), 233–260. [https://doi.org/10.1016/0734-189X\(88\)90022-9](https://doi.org/10.1016/0734-189X(88)90022-9)
- [17] Lalinde, J. D. H., Castro, F. E., Rodríguez, J. E., Rangel, J. G. C., Sierra, C. A. T., Torrado, M. K. A., ... & Pirela, V. J. B. (2018). Sobre el uso adecuado del coeficiente de correlación de Pearson: definición, propiedades y suposiciones. *Archivos Venezolanos de Farmacología y Terapéutica*, 37(5), 587–595.
- [18] Wan, X., Wang, W., Liu, J., & Tong, T. (2014). Estimating the sample mean and standard deviation from the sample size, median, range and/or interquartile range. *BMC Medical Research Methodology*, 14, Artículo 135. <https://doi.org/10.1186/1471-2288-14-135>
- [19] Chawla, N. V., Bowyer, K. W., Hall, L. O., & Kegelmeyer, W. P. (2002). SMOTE: Synthetic minority over-sampling technique. *Journal of Artificial Intelligence Research*, 16, 321–357. <https://doi.org/10.1613/jair.95>
- [20] Mosca, E., Szigeti, F., Tragianni, S., Gallagher, D., & Groh, G. (2022, octubre). Métodos de explicación basados en SHAP: una revisión de la interpretabilidad del PLN. En *Actas de la 29.ª Conferencia Internacional sobre Lingüística Computacional* (pp. 4593–4603).
- [21] Bilal, M., Sultan, M., Morosuk, T., Den, W., Sajjad, U., Aslam, M. M. A., Shahzad, M. W., & Farooq, M. (2022). Adsorption-based atmospheric water harvesting: A review

of adsorbents and systems. *International Communications in Heat and Mass Transfer*, 136, Artículo 106164. <https://doi.org/10.1016/j.icheatmasstransfer.2022.106164>

[22] Wang, M., Liu, E., Jin, T., Zafar, S. U., Mei, X., Fauconnier, M., & De Clerck, C. (2023). Towards a better understanding of atmospheric water harvesting (AWH) technology. *Water Research*, 242, Artículo 120080. <https://doi.org/10.1016/j.watres.2023.120080>

[23] Felles Isidro, C. L., La Rosa Trinidad, D. M., Cisneros Tejeira, M., Guere Salazar, F. V., Valencia Reyes, Z. L., Benites-Alfaro, E., & Armas Blancas, A. S. (2023). Generation of water with Peltier cells from the humidity of the air. *Chemical Engineering Transactions*, 100, 313–318. <https://doi.org/10.3303/CET2310053>

[24] Shafeian, N., Ranjbar, A., & Gorji, T. B. (2022). Progress in atmospheric water generation systems: A review. *Renewable and Sustainable Energy Reviews*, 162, Artículo 112441. <https://doi.org/10.1016/j.rser.2022.112441>

[25] Ali, D. (2023). Harvesting of water from atmospheric air using electrospun PVP-PVC nanofibers with TEC atmospheric generator. *Journal of Water Research*, 1(1), 12–23.

[26] Liu, X., Beysens, D., & Bourouina, T. (2022). Water harvesting from air: Current passive approaches and outlook. *ACS Materials Letters*, 4(6), 1133–1148. <https://doi.org/10.1021/acsmaterialslett.2c00171>

[27] El-Sharkawy, I. I., Gado, M. G., Sabouni, H., Abd-Elhady, M. M., Radwan, A., Abo Khalil, A. G., & Dawoud, B. (2024). Material characteristics and selection criteria for adsorption-based atmospheric water harvesting: An overview. *Solar Energy*. <https://doi.org/10.1016/j.solener.2024.112543>

[28] Wang, J., Yang, Z., Li, Z., Fu, H., & Chen, J. P. (2024). Comprehensive review on atmospheric water harvesting technologies. *Journal of Water Process Engineering*, 58, Artículo 104845. <https://doi.org/10.1016/j.jwpe.2024.104845>

[29] Gado, M. G., Nasser, M., Hassan, A. A., & Hassan, H. (2022). Adsorption-based atmospheric water harvesting powered by solar energy: Comprehensive review on desiccant materials and systems. *Process Safety and Environmental Protection*, 160, 660–683. <https://doi.org/10.1016/j.psep.2022.02.054>

[30] Hu, Y., Yao, H., Liao, Q., Lin, T., Cheng, H., & Qu, L. (2022). The promising solar-powered water purification based on graphene functional architectures. *EcoMat*, 4(1), Artículo e12166. <https://doi.org/10.1002/eom2.12166>

[31] Ansari, E., Elwadood, S. N. A., Balakrishnan, H., Sapkaite, I., Munro, C. J., Karanikolos, G. N., Askar, K., Arafat, H. A., Mao, S. S., & Dumée, L. F. (2024). Sorption-based atmospheric water harvesters: Perspectives on materials design and

innovation. *Journal of Environmental Chemical Engineering*, 12(2), Artículo 111234. <https://doi.org/10.1016/j.jece.2024.111234>

[32] Baggio, G., Adamowski, J., Hyde, V. J., & Qadir, M. (2023). Small-scale desalination and atmospheric water provisioning systems in water-scarce vulnerable communities: Status and perspectives. *International Journal of Water Resources Development*, 39(6), 897–923. <https://doi.org/10.1080/07900627.2022.2146262>

[33] Cai, R., & Que, H. (2024). Brain-like contour detector following Retinex theory and Gestalt perception grouping principles. *Neural Computing and Applications*. <https://doi.org/10.1007/s00521-024-09889-4>

[34] Humphreys, J., & Secco, E. L. (2023). A low-cost thermal imaging device for monitoring electronic systems remotely. En *Lecture Notes in Networks and Systems* (Vol. 651, pp. 151–161). Springer. https://doi.org/10.1007/978-3-031-37703-7_13

[35] Sadhukhan, D., Peri, S., Sugunaraj, N., Biswas, A., Selvaraj, D. F., Koiner, K., Rosener, A., Dunlevy, M., Goveas, N., Flynn, D., & Ranganathan, P. (2020). Estimating surface temperature from thermal imagery of buildings for accurate thermal transmittance (U-value): A machine learning perspective. *Journal of Building Engineering*, 32, Artículo 101637. <https://doi.org/10.1016/j.jobe.2020.101637>

[36] Yang, W., Chen, X.-D., Wang, H., & Mao, X. (2023). Edge detection using multi-scale closest neighbor operator and grid partition. *The Visual Computer*, 39(12), 5517–5533. <https://doi.org/10.1007/s00371-022-02669-x>

[37] Cai, Z., Yang, R., Fan, Y., & Wu, W. (2023). A contour detection method based on the projective coding model of the visual cortex information flow. *IEEE Transactions on Cognitive and Developmental Systems*, 15(4), 1321–1332. <https://doi.org/10.1109/TCDS.2023.3245678>

[38] Sun, R., Lei, T., Chen, Q., Wang, Z., Du, X., Zhao, W., & Nandi, A. K. (2022). Survey of image edge detection. *Frontiers in Signal Processing*, 2, Artículo 1000473. <https://doi.org/10.3389/frsip.2022.1000473>

[39] Li, S., Shen, Y., Wang, Y., Zhang, J., Li, H., Zhang, D., & Li, H. (2024). PiDiNet-TIR: An improved edge detection algorithm for weakly textured thermal infrared images based on PiDiNet. *Infrared Physics & Technology*, 138, Artículo 105257. <https://doi.org/10.1016/j.infrared.2023.105257>

[40] Li, S., Shen, Y., Wang, Y., Zhang, J., Li, H., Zhang, D., & Li, H. (2024). PiDiNet-TIR: An improved edge detection algorithm for weakly textured thermal infrared images based on PiDiNet. *Infrared Physics & Technology*, 138, Artículo 105257.

- [41] Zhou, L., Lin, C., Pang, X., Yang, H., Pan, Y., & Zhang, Y. (2023). Learning parallel and hierarchical mechanisms for edge detection. *Frontiers in Neuroscience*, 17, Artículo 1194713. <https://doi.org/10.3389/fnins.2023.1194713>
- [42] Jing, J., Liu, S., Wang, G., Zhang, W., & Sun, C. (2022). Recent advances on image edge detection: A comprehensive review. *Neurocomputing*, 500, 846–872. <https://doi.org/10.1016/j.neucom.2022.04.118>
- [43] Li, M., Chen, D., & Liu, S. (2023). Beta network for boundary detection under non-deterministic labels. *Knowledge-Based Systems*, 263, Artículo 110206. <https://doi.org/10.1016/j.knsys.2023.110206>
- [44] Lin, C., Pang, X., & Hu, Y. (2023). Bio-inspired multi-level interactive contour detection network. *Digital Signal Processing*, 137, Artículo 103901. <https://doi.org/10.1016/j.dsp.2023.103901>
- [45] Crespo, R. G., Verdú, E., Khari, M., & Garg, A. K. (2019). Gesture recognition of RGB and RGB-D static images using convolutional neural networks. *International Journal of Interactive Multimedia and Artificial Intelligence*, 5(7), 22–27. <https://doi.org/10.9781/ijimai.2019.07.004>
- [46] Guo, Y., Guo, M., Su, J., Yang, Z., Zhu, M., Li, H., ... & Liu, S. S. (2024). *Bias in large language models: Origin, evaluation, and mitigation*. arXiv. <https://doi.org/10.48550/arXiv.2411.10915>
- [47] Méndez Girón, A. M., López Quiroz, M., Loranca Domínguez, Y., Gallegos Benítez, M. A., Zavala Fajardo, A. G., Gómez Camacho, J., Farías Núñez, O. A., López Trujillo, J. A., López, H. R., & Lunagomez Cruz, D. P. (2023). *Reporte anual del clima en México 2023*. Servicio Meteorológico Nacional. <https://smn.conagua.gob.mx>
- [48] Nikkhah, H., Wan Azmi, W. M. B. W., Nikkhah, A., Najafi, A. M., Babaei, M. M., Fen, C. S., Nouri, A., Mohammad, A. W., Ang, W. L., Yong, N. L., & Mahmoudi, E. (2023). A comprehensive review on atmospheric water harvesting technologies: From thermodynamic concepts to mechanism and process development. *Journal of Water Process Engineering*, 56, Artículo 103728. <https://doi.org/10.1016/j.jwpe.2023.103728>
- [49] Kwan, T. H., Yuan, S., Shen, Y., & Pei, G. (2022). Comparative meta-analysis of desalination and atmospheric water harvesting technologies based on the minimum energy of separation. *Energy Reports*, 13, 610–623. <https://doi.org/10.1016/j.egyr.2022.07.175>
- [50] Tashtoush, B., & Alshoubaki, A. Y. (2023). Atmospheric water harvesting: A review of techniques, performance, renewable energy solutions, and feasibility. *Energy*, 281, Artículo 128186. <https://doi.org/10.1016/j.energy.2023.128186>
- [51] Kahvecioğlu, B., Avinç, G. M., & Selçuk, S. A. (2024). Biomimetic adaptive building façade modeling for sustainable urban freshwater ecosystems: Integration of nature's

water-harvesting strategy into sun-breakers. *Biomimetics*, 9(9), Artículo 569. <https://doi.org/10.3390/biomimetics9090569>

[52] Ahrestani, Z., Sadeghzadeh, S., & Banna Motejadded Emrooz, H. (2023). An overview of atmospheric water harvesting methods: The inevitable path of the future in water supply. *RSC Advances*, 13(23), 15610–15627. <https://doi.org/10.1039/D2RA07733G>

[53] Hassan, A. A., Ezzeddine, M., Kordy, M. G. M., & Awad, M. M. (2024). Application of various MOF designs in adsorption-based atmospheric water harvesting. En *Elsevier eBooks* (pp. 1245–1256). Elsevier. <https://doi.org/10.1016/B978-0-323-95486-0.00030-2>

[54] Ansari, E., Ferber, N. L., Milošević, T., Barron, J., Karanikolos, G. N., AlMarzooqi, F., Dumée, L. F., & Calvet, N. (2022). Atmospheric water generation in arid regions: A perspective on deployment challenges for the Middle East. *Journal of Water Process Engineering*, 49, Artículo 103163. <https://doi.org/10.1016/j.jwpe.2022.103163>

[55] Hassan, A. A., Ezzeddine, M., Kordy, M. G. M., & Awad, M. M. (2023). Techno-economic assessment of atmospheric water harvesting (AWH) technologies. En *Water Science and Technology Library* (Vol. 106, pp. 151–171). Springer. https://doi.org/10.1007/978-3-031-21746-3_8

[56] Brambilla, A., Gasparri, E., Zolfaghari, L., Keshavarzi, R., & Andaloro, A. (2022). On the applicability of atmospheric water harvesting technologies on building facades: A critical review. *Journal of Cleaner Production*, 366, Artículo 132809. <https://doi.org/10.1016/j.jclepro.2022.132809>

[57] Li, R., & Wang, P. (2023). Sorbents, processes and applications beyond water production in sorption-based atmospheric water harvesting. *Nature Water*, 1(8), 696–706. <https://doi.org/10.1038/s44221-023-00099-0>

[58] Wang, X., Han, W., Luo, N., Luo, H. Q., Zhou, X., Qin, B., Mei, Y., & Zhang, Y. (2024). Smart materials and micro/nano architectonics for water harvesting: From fundamental mechanism to advanced application. *Composites Part A: Applied Science and Manufacturing*, 177, Artículo 108241. <https://doi.org/10.1016/j.compositesa.2024.108241>

[59] Gao, S., Wang, Y., Zhang, C., Jiang, M., Wang, S., & Wang, Z. (2023). Tailoring interfaces for atmospheric water harvesting: Fundamentals and applications. *Matter*, 6(5), 1365–1392. <https://doi.org/10.1016/j.matt.2023.04.008>

[60] Zeng, W., Tian, Y., & Wu, W. (2024). Passive atmospheric water harvesting: Materials, devices, and perspectives. *Nano Energy*, 120, Artículo 109572. <https://doi.org/10.1016/j.nanoen.2024.109572>

- [61] Bai, Z., Wang, P., Xu, J., Wang, R. Z., & Li, T. (2023). Progress and perspectives of sorption-based atmospheric water harvesting for sustainable water generation: Materials, devices, and systems. *Science Bulletin*, 68(24), 2824–2846. <https://doi.org/10.1016/j.scib.2023.12.018>
- [62] Wasti, T. Z., Sultan, M., Aleem, M., Sajjad, U., Farooq, M., Raza, H. M. U., Khan, M. U., & Noor, S. (2022). An overview of solid and liquid materials for adsorption-based atmospheric water harvesting. *Advances in Mechanical Engineering*, 14(3), Artículo 16878132221082768. <https://doi.org/10.1177/16878132221082768>
- [63] Entezari, A., Esan, O. C., Yan, X., Wang, R. Z., & An, L. (2023). Sorption-based atmospheric water harvesting: Materials, components, systems, and applications. *Advanced Materials*, 35(16), Artículo 2210957. <https://doi.org/10.1002/adma.202210957>
- [64] Yu, Z., Zhu, T., Zhang, J., Ge, M., Fu, S., & Lai, Y. (2022). Fog harvesting devices inspired from single to multiple creatures: Current progress and future perspective. *Advanced Functional Materials*, 32(25), Artículo 2200359. <https://doi.org/10.1002/adfm.202200359>
- [65] Zhang, C., Guo, H., Li, C., Wang, F., Guo, X., Li, A., Gong, S., Zhang, H., Zhang, X., & Qin, X. (2023). Atmospheric water extraction – A review from materials to devices. *Journal of Materials Chemistry A*, 11(43), 23146–23186. <https://doi.org/10.1039/D3TA04380K>
- [66] Agrawal, A., & Kumar, A. (2024). A comprehensive review of fresh water production from atmospheric air – Techniques, challenges and opportunities. *Environment, Development and Sustainability*. <https://doi.org/10.1007/s10668-024-05211-2>
- [67] Ahmad, M., Nighojkar, A., & Plappally, A. (2023). A review of the methods of harvesting atmospheric moisture. *Environmental Science and Pollution Research*, 30(50), 108381–108404. <https://doi.org/10.1007/s11356-023-30727-x>
- [68] Thavalengal, M. S., Jamil, M. A., Mehroz, M., Xu, B. B., Yaqoob, H., Sultan, M., Imtiaz, N., & Shahzad, M. W. (2023). Progress and prospects of air water harvesting system for remote areas: A comprehensive review. *Energies*, 16(6), Artículo 2686. <https://doi.org/10.3390/en16062686>
- [69] Pang, X., Lin, C., Li, F., & Pan, Y. (2023). Bio-inspired XYW parallel pathway edge detection network. *Expert Systems with Applications*, 232, Artículo 121649. <https://doi.org/10.1016/j.eswa.2023.121649>
- [70] Pan, S., Wang, R., & Lin, C. (2022). Bio-inspired feature cascade network for edge detection. *The Visual Computer*, 39(6), 2541–2557. <https://doi.org/10.1007/s00371-022-02581-4>

- [71] Lin, C., Zhang, Z., & Hu, Y. (2022). Bio-inspired feature enhancement network for edge detection. *Applied Intelligence*, 52(21), 24194–24208. <https://doi.org/10.1007/s10489-022-03202-2>
- [72] Wang, C., Dai, D., Xia, S., Liu, Y., & Wang, G. (2022). One-stage deep edge detection based on dense-scale feature fusion and pixel-level imbalance learning. *IEEE Transactions on Artificial Intelligence*, 4(2), 245–256. <https://doi.org/10.1109/TAI.2022.3223893>
- [73] Zhang, X., & Lin, C. (2022). Multi-decoding network with attention learning for edge detection. *Neural Processing Letters*, 55(2), 1547–1564. <https://doi.org/10.1007/s11063-022-11070-7>
- [74] Zhou, C., Yuan, C., Wang, H., Li, L., Oehmcke, S., Liu, J., & Peng, J. (2023). Multi-scale pseudo labeling for unsupervised deep edge detection. *Knowledge-Based Systems*, 279, Artículo 111057. <https://doi.org/10.1016/j.knosys.2023.111057>
- [75] Wang, F., Geng, S., Zhang, D., Zhou, M., Li, L., & Nian, W. (2022). Image extraction of Thangka line drawings with Transformer. En *2022 5th International Conference on Advanced Communication Technology and Electronic Information (ICACTE)* (pp. 281–285). IEEE. <https://doi.org/10.1109/ICACTE55855.2022.9943668>
- [76] Lin, C., Qiao, Y., & Pan, Y. (2022). Bio-inspired interactive feedback neural networks for edge detection. *Applied Intelligence*, 52(14), 16049–16063. <https://doi.org/10.1007/s10489-022-04316-3>
- [77] Pu, M., Huang, Y., Liu, Y., Guan, Q., & Ling, H. (2022). EDTER: Edge detection with Transformer. En *2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)* (pp. 1459–1468). IEEE. <https://doi.org/10.1109/CVPR52688.2022.00146>
- [78] Yang, D., Peng, B., Al-Huda, Z., Malik, A., & Zhai, D. (2022). An overview of edge and object contour detection. *Neurocomputing*, 512, 19–35. <https://doi.org/10.1016/j.neucom.2022.02.079>
- [79] Luo, Z., Lin, C., Li, F., & Pan, Y. (2023). BLEDNet: Bio-inspired lightweight neural network for edge detection. *Engineering Applications of Artificial Intelligence*, 125, Artículo 106530. <https://doi.org/10.1016/j.engappai.2023.106530>
- [80] Lin, C., Zhang, Z., Peng, J., Li, F., Pan, Y., & Zhang, Y. (2024). A lightweight contour detection network inspired by biology. *Complex & Intelligent Systems*, 10(3), 2733–2746. <https://doi.org/10.1007/s40747-024-01393-4>
- [81] Chen, Y., Lin, C., & Qiao, Y. (2022). DPED: Bio-inspired dual-pathway network for edge detection. *Frontiers in Bioengineering and Biotechnology*, 10, Artículo 1008140. <https://doi.org/10.3389/fbioe.2022.1008140>

[82] Kaiser, M. S., Xie, J., & Rathore, V. S. (Eds.). (2024). *Intelligent strategies for ICT: Proceedings of ICTCS 2024*(Vol. 5). Springer Nature. <https://books.google.com.mx/books?id=4-x0EQAAQBAJ>

ANEXO A. Código de cámara MLX90640

```
import time
import board
import busio
import numpy as np
import adafruit_mlx90640
import matplotlib.pyplot as plt
from matplotlib.backends.backend_tkagg import FigureCanvasTkAgg
import tkinter as tk

def initialize_sensor():
    i2c = busio.I2C(board.SCL, board.SDA)
    mlx = adafruit_mlx90640.MLX90640(i2c)
    mlx.refresh_rate = adafruit_mlx90640.RefreshRate.REFRESH_4_HZ
    return mlx

def setup_plot():
    fig, ax = plt.subplots(figsize=(12, 7))
    therm1 = ax.imshow(np.zeros((24, 32)), vmin=0, vmax=60,
                       cmap='jet', interpolation='bilinear') # Usando 'jet'
    cbar = Figura colorbar(therm1)
    cbar.set_label('Temperature [°C]', fontsize=14)
    plt.title('Thermal Image')
    return fig, ax, therm1

def update_display(canvas, therm1, data_array):
    therm1.set_data(np.fliplr(data_array))
    therm1.set_clim(vmin=np.min(data_array), vmax=np.max(data_array))
    canvas.draw()

def save_image(fig, count):
    filename = f'capture_{count}.png'
    Figura savefig(filename)
    print(f'Imagen guardada: {filename}')
```

```
def main():
    mlx = initialize_sensor()
    fig, ax, therm1 = setup_plot()

    # Inicialización de la ventana Tkinter
    root = tk.Tk()
    root.wm title("Thermal Camera")
```

```

# Integrar Matplotlib con Tkinter
canvas = FigureCanvasTkAgg(fig, master=root)
canvas_widget = canvas.get_tk_widget()
canvas_widget.pack(side=tk.TOP, fill=tk.BOTH, expand=1)

frame = np.zeros((24*32,))
t_array = []
max_retries = 5

        last_save_time = time.monotonic() # Para controlar cuando
guardar imágenes
        image_counter = 0 # Contador para el nombre de los
archivos de imagen
while True:
    t1 = time.monotonic()
    retry_count = 0
    while retry_count < max_retries:
        try:
            mlx.getFrame(frame)
            data_array = np.reshape(frame, (24, 32))
            update_display(canvas, therm1, data_array)
            t_array.append(time.monotonic() - t1)
            print('Sample Rate: {0:2.1f}fps'.format(len(t_array) /
np.sum(t_array)))
            break
        except ValueError:
            retry_count += 1
        except RuntimeError as e:
            retry_count += 1
    if retry_count >= max_retries:
        print(f"Failed after {max_retries} retries with error: {e}")
        break

current_time = time.monotonic()
if current_time - last_save_time >= 10:
    save_image(fig, image_counter)
    last_save_time = current_time
    image_counter += 1

root.update_idletasks() # Para actualizar la interfaz de Tkinter
root.update() # Para mantener la interfaz responsiva

```

Figura A.1 Código Python para captura de imagen térmica

ANEXO B. Código obtención de la temperatura promedio en la zona fría y caliente.

```
from PIL import Image
import matplotlib.pyplot as plt
import numpy as np
import pandas as pd
import os
import cv2

def recortar_imagen_centro(ruta_imagen, lado_cuadrado):
    # Cargar la imagen
    imagen = Image.open(ruta_imagen)

    # Obtener dimensiones de la imagen
    ancho, alto = imagen.size

    # Calcular las coordenadas del área a recortar
    izquierda = (ancho - lado_cuadrado) // 2
    superior = (alto - lado_cuadrado) // 2
    derecha = (ancho + lado_cuadrado) // 2
    inferior = (alto + lado_cuadrado) // 2

    # Recortar la imagen
    imagen_recortada = imagen.crop((izquierda, superior, derecha,
    inferior))

    return imagen_recortada

# Preparar el DataFrame para guardar resultados
results = []

# Procesar imágenes desde capture_20 hasta capture_29
lado_cuadrado = 400 # Define el tamaño del recorte cuadrado

for i in range(20, 30):
    ruta_imagen = f'/content/capture_{i}.png' # Ruta de la imagen

    imagen_recortada = recortar_imagen_centro(ruta_imagen,
    lado_cuadrado)

    # Cargar la imagen
    imagen = np.array(imagen_recortada)
    imagen = cv2.cvtColor(imagen, cv2.COLOR_RGB2BGR)
    reducidaC = cv2.resize(imagen, (int(imagen.shape[1] * 0.1),
    int(imagen.shape[0] * 0.1)))

    # Convertimos la imagen a grises
    RC_gray = cv2.cvtColor(reducidaC, cv2.COLOR_BGR2GRAY)
```

```

# Histograma
plt.hist(RC_gray.ravel(), bins=256, range=(0, 255),
edgecolor='black')
plt.xlabel('Valor de gris')
plt.ylabel('Frecuencia')
plt.title('Histograma de escala de grises')
plt.show()

# Convertimos la imagen en una imagen binaria
_, threshC = cv2.threshold(RC_gray, 145, 255,
cv2.THRESH_BINARY_INV)
contoursC, _ = cv2.findContours(threshC, cv2.RETR_LIST,
cv2.CHAIN_APPROX_SIMPLE)

# Filtrar contornos
area_min = 70
area_max = 1000
contours_filteredC = [c for c in contoursC if
cv2.contourArea(c) >= area_min and cv2.contourArea(c) <= area_max]

# Crear una máscara binaria del contorno
mask = np.zeros(RC_gray.shape, dtype=np.uint8)
cv2.drawContours(mask, contours_filteredC, -1, (255), -1)

# Aplicar la máscara a la imagen original
RC_cropped = cv2.bitwise_and(reducidaC, reducidaC, mask=mask)

# Calcular el promedio de p\ 'ixeles no cero para cada capa
r, g, b = cv2.split(RC_cropped)
avg_red0 = np.mean(r[r > 0]) if np.sum(r > 0) > 0 else 0
avg_green0 = np.mean(g[g > 0]) if np.sum(g > 0) > 0 else 0
avg_blue0 = np.mean(b[b > 0]) if np.sum(b > 0) > 0 else 0
# Calcular promedio solo si hay valores válidos
sumaC = 0
contador = 0

if avg_red0 > 0:
sumaC += avg_red0
contador += 1
if avg_green0 > 0:
sumaC += avg_green0
contador += 1
if avg_blue0 > 0:
sumaC += avg_blue0
contador += 1

promedioC1 = sumaC / contador if contador > 0 else 0

```

```

# Calcular el promedio de la otra imagen
_, thresh = cv2.threshold(RC_gray, 140, 255, cv2.THRESH_BINARY_INV)
contours, _ = cv2.findContours(thresh, cv2.RETR_LIST,
cv2.CHAIN_APPROX_SIMPLE)

area_min = 20
area_max = 53
contours_filtered = [c for c in contours if
cv2.contourArea(c) >= area_min and cv2.contourArea(c) <= area_max]

# Crear una máscara binaria del contorno
mask = np.zeros(RC_gray.shape, dtype=np.uint8)
cv2.drawContours(mask, contours_filtered, -1, (255), -1)

# Aplicar la máscara a la imagen original
R0_cropped = cv2.bitwise_and(reducidaC, reducidaC, mask=mask)

# Calcular promedios para la segunda imagen
r, g, b = cv2.split(R0_cropped)
avg_red0F = np.mean(r[r > 0]) if np.sum(r > 0) > 0 else 0
avg_green0F = np.mean(g[g > 0]) if np.sum(g > 0) > 0 else 0
avg_blue0F = np.mean(b[b > 0]) if np.sum(b > 0) > 0 else 0

# Calcular promedio solo si hay valores válidos
sumaF = 0
contadorF = 0

if avg_red0F > 0:
sumaF += avg_red0F
contadorF += 1
if avg_green0F > 0:
sumaF += avg_green0F
contadorF += 1
if avg_blue0F > 0:
sumaF += avg_blue0F
contadorF += 1

promedioCF = sumaF / contadorF if contadorF > 0 else 0

# Convertir los promedios a temperatura
def pixel_to_temperature(pixel_value, min_temp=-5, max_temp=50,
min_pixel=0, max_pixel=255):
temperature = (pixel_value - min_pixel) / (max_pixel - min_pixel) *
(max_temp - min_temp) + min_temp
return temperature

C1 = pixel_to_temperature(promedioC1)

```

```
# Crear un DataFrame a partir de los resultados
df = pd.DataFrame(results)

# Guardar o agregar resultados al archivo CSV existente sin crear
columnas nuevas
csv_file_path = 'resultados_temperatura.csv'

if os.path.exists(csv_file_path):
# Cargar el archivo existente
df_existente = pd.read_csv(csv_file_path)

# Concatenar nuevos resultados
df_nuevo = pd.concat([df_existente, df], ignore_index=True)
else:
# Si no existe, crear un nuevo DataFrame
df_nuevo = df

# Guardar el DataFrame actualizado en el archivo CSV
df_nuevo.to_csv(csv_file_path, index=False)

print("Resultados guardados en 'resultados_temperatura.csv'")
```

Figura B.1 Código Python para estimación de sensación térmica promedio,

ANEXO C. Tabla de trabajos que se analizaron para la realización de esta tesis.

Título y autores del Artículo	Revista / Conferencia (Año)	Descripción
<i>Adsorption-based atmospheric water harvesting powered by solar energy: Review on desiccant materials.</i> <i>Gado et al. [21]</i>	<i>Process Safety and Environmental Protection</i> (2022)	Evalúa el impacto ambiental y la seguridad de los sistemas de cosecha de agua solares, analizando la estabilidad a largo plazo de los materiales desecantes utilizados.
<i>The promising solar-powered water purification based on graphene functional architectures.</i> <i>Hu et al. [22]</i>	<i>EcoMat</i> (2022)	Investiga el uso de estructuras funcionales de grafeno para la purificación solar de agua, aprovechando su alta capacidad de absorción de luz y conductividad térmica para procesos de evaporación-condensación.
<i>Sorption-based atmospheric water harvesters: Perspectives on materials design and innovation.</i> <i>Ansari et al. [23]</i>	<i>Journal of Environmental Chemical Engineering</i> (2024)	Se enfoca en la innovación de materiales de sorción, específicamente estructuras metal-orgánicas (MOF) que pueden capturar agua incluso en condiciones de humedad extremadamente baja (<20%).
<i>Small-scale desalination and atmospheric water provisioning systems in water-scarce communities.</i> <i>Baggio et al. [24]</i>	<i>Int. Journal of Water Resources Development</i> (2023)	Analiza la implementación social y técnica de sistemas AWH a pequeña escala en comunidades con estrés hídrico, evaluando su viabilidad económica frente a la desalinización tradicional.

<p><i>Brain-like contour detector following Retinex theory and Gestalt perception grouping principles.</i></p> <p><i>Cai & Que [25]</i></p>	<p><i>Neural Computing and Applications (2024)</i></p>	<p>Propone un detector de contornos que imita la percepción visual humana (teoría Retinex) para mejorar la identificación de objetos en condiciones de iluminación variable o poco favorables.</p>
<p><i>Estimating surface temperature from thermal imagery of buildings for accurate thermal transmittance.</i></p> <p><i>Sadhukhan et al. [27]</i></p>	<p><i>Journal of Building Engineering (2020)</i></p>	<p>Desarrolla una metodología para calcular el valor de transmitancia térmica en edificios usando cámaras térmicas e IA, permitiendo detectar fugas de calor o frío con alta precisión.</p>
<p><i>Edge detection using multi-scale closest neighbor operator and grid partition.</i></p> <p><i>Yang et al. [28]</i></p>	<p><i>The Visual Computer (2023)</i></p>	<p>Presenta un nuevo operador de "vecino más cercano" para detectar bordes en imágenes digitales, reduciendo el ruido computacional y mejorando la nitidez de las líneas detectadas.</p>
<p><i>Survey of image edge detection.</i></p> <p><i>Sun et al. [30]</i></p>	<p><i>Frontiers in Signal Processing (2022)</i></p>	<p>Realiza un estado del arte sobre técnicas de detección de bordes, comparando métodos clásicos (Canny, Sobel) con los nuevos enfoques basados en aprendizaje profundo (Deep Learning).</p>
<p><i>PiDiNet-TIR: An improved edge detection algorithm for weakly textured thermal infrared images based on PiDiNet.</i></p> <p><i>Li et al. [31]</i></p>	<p><i>Infrared Physics & Technology (2024)</i></p>	<p>Presenta PiDiNet-TIR, una red diseñada específicamente para imágenes infrarrojas térmicas. Supera la dificultad de detectar bordes en objetos que tienen temperaturas muy similares a su entorno.</p>

<i>Learning parallel and hierarchical mechanisms for edge detection.</i> <i>Zhou et al. [33]</i>	<i>Frontiers in Neuroscience (2023)</i>	Explora cómo los mecanismos cerebrales de atención pueden ser replicados en algoritmos de visión para filtrar información irrelevante en la detección de bordes complejos.
<i>Recent advances on image edge detection: A comprehensive review.</i> <i>Jing et al. [34]</i>	<i>Neurocomputing (2022)</i>	Revisa los avances en segmentación de imágenes y detección de bordes, subrayando la importancia de las conexiones de salto (skip connections) en las redes neuronales modernas.
<i>Beta network for boundary detection under non-deterministic labels.</i> <i>Li et al. [35]</i>	<i>Knowledge-Based Systems (2023)</i>	Introduce la "Red Beta", un modelo para detectar límites de objetos cuando las etiquetas de entrenamiento son imprecisas o probabilísticas (etiquetas no deterministas).
<i>Bio-inspired multi-level interactive contour detection network.</i> <i>Lin et al. [36]</i>	<i>Digital Signal Processing (2023)</i>	Propone una arquitectura bio-inspirada que utiliza retroalimentación multinivel para refinar la detección de contornos, eliminando texturas falsas que confunden a los algoritmos tradicionales.
<i>Gesture recognition of RGB and RGB-D static images using convolutional neural networks.</i> <i>Crespo et al. [39]</i>	<i>Int. Journal of Interactive Multimedia and AI (2019)</i>	Utiliza CNNs para reconocer gestos humanos en imágenes que combinan datos de color (RGB) y profundidad (D), mejorando la interacción hombre-máquina.

<p><i>Estimating the sample mean and standard deviation from the sample size, median, and range.</i> Wan et al. [40]</p>	<p><i>BMC Medical Research Methodology (2014)</i></p>	<p>Proporciona fórmulas matemáticas para estimar estadísticas poblacionales cuando solo se dispone de datos de resumen (mediana, rango), útil para meta-análisis técnicos.</p>
<p><i>A comprehensive review on atmospheric water harvesting technologies.</i> Nikkhah et al. [46]</p>	<p><i>Journal of Water Process Engineering (2023)</i></p>	<p>Detalla la transición de la termodinámica teórica al diseño industrial de sistemas AWH, analizando la eficiencia de los ciclos de enfriamiento frente a los de desecante sólido.</p>
<p><i>Comparative meta-analysis of desalination and atmospheric water harvesting technologies.</i> Kwan et al. [47]</p>	<p><i>Energy Reports (2022)</i></p>	<p>Un meta-análisis que utiliza la termodinámica estadística para comparar cuánta energía cuesta realmente separar una molécula de agua del aire frente a separarla de la sal del mar.</p>
<p><i>Atmospheric water harvesting: A review of techniques and renewable energy solutions.</i> Tashtoush et al. [48]</p>	<p><i>Energy (2023)</i></p>	<p>Revisa soluciones de energía renovable integradas para AWH, concluyendo sobre la factibilidad económica de estos sistemas en regiones remotas de Oriente Medio y África.</p>
<p><i>An overview of atmospheric water harvesting methods: The inevitable path of the future.</i> Ahrestani et al. [50]</p>	<p><i>RSC Advances (2023)</i></p>	<p>Argumenta que la cosecha de agua atmosférica será un pilar inevitable de la seguridad hídrica global debido al agotamiento de acuíferos y el cambio climático.</p>

<p><i>Application of various MOF designs in adsorption-based atmospheric water harvesting.</i> <i>Hassan et al. [51]</i></p>	<p><i>Elsevier eBooks / Art. Inv. (2024)</i></p>	<p>Analiza el diseño de estructuras MOF específicas para adsorción, optimizando la porosidad del material para maximizar la captura de moléculas de agua.</p>
<p><i>Sorbents, processes and applications beyond water production in sorption-based AWH.</i> <i>Li & Wang [55]</i></p>	<p><i>Nature Water (2023)</i></p>	<p>Explora cómo los sistemas de sorción AWH pueden usarse dualmente para control de humedad en interiores y enfriamiento de espacios, aumentando su valor económico.</p>
<p><i>Smart materials and micro/nano architectonics for water harvesting.</i> <i>Wang et al. [56]</i></p>	<p><i>Composites Part A (2024)</i></p>	<p>Estudia materiales compuestos a nanoescala que cambian sus propiedades hidrofílicas/hidrofóbicas con la temperatura para facilitar la liberación del agua capturada.</p>
<p><i>Tailoring interfaces for atmospheric water harvesting: Fundamentals and applications.</i> <i>Gao et al. [57]</i></p>	<p><i>Matter (2023)</i></p>	<p>Se enfoca en la ingeniería de interfaces, analizando cómo el diseño de la superficie a nivel atómico puede acelerar la velocidad a la que el agua se condensa y se desprende.</p>
<p><i>Passive atmospheric water harvesting: Materials, devices, and perspectives.</i> <i>Zeng et al. [58]</i></p>	<p><i>Nano Energy (2024)</i></p>	<p>Revisa dispositivos de nanoenergía aplicados a la cosecha pasiva, integrando materiales fototérmicos que calientan el adsorbente usando solo luz solar.</p>

<p><i>Progress and perspectives of sorption-based atmospheric water harvesting.</i> Bai et al. [59]</p>	<p><i>Science Bulletin (2023)</i></p>	<p>Evalúa el rendimiento de sistemas de adsorción multietapa que permiten reciclar el calor latente de condensación para mejorar la eficiencia global del ciclo.</p>
<p><i>An overview of solid and liquid materials for adsorption-based atmospheric water harvesting.</i> Wasti et al. [60]</p>	<p><i>Advances in Mechanical Engineering (2022)</i></p>	<p>Compara materiales desecantes sólidos frente a higroscópicos líquidos, analizando sus ventajas en términos de mantenimiento y capacidad de carga de agua.</p>
<p><i>Sorption-based atmospheric water harvesting: Materials, components, systems.</i> Entezari et al. [61]</p>	<p><i>Advanced Materials (2023)</i></p>	<p>Una revisión de alto impacto que cubre desde la química de los materiales de sorción hasta la ingeniería de sistemas comerciales de gran escala.</p>
<p><i>Fog harvesting devices inspired from single to multiple creatures.</i> Yu et al. [62]</p>	<p><i>Advanced Functional Materials (2022)</i></p>	<p>Investiga superficies biomiméticas inspiradas en cactus y escarabajos del desierto para recolectar niebla de manera eficiente mediante estructuras de micro-picos.</p>
<p><i>Atmospheric water extraction – A review from materials to devices.</i> Zhang et al. [63]</p>	<p><i>Journal of Materials Chemistry A (2023)</i></p>	<p>Analiza la cadena completa del sistema AWH: desde la captura de moléculas, pasando por la condensación, hasta el almacenamiento de agua segura para consumo.</p>

<p><i>A comprehensive review of fresh water production from atmospheric air.</i> <i>Agrawal & Kumar [64]</i></p>	<p><i>Env., Development and Sustainability (2024)</i></p>	<p>Evalúa los desafíos logísticos y oportunidades de mercado para las tecnologías AWH como solución descentralizada a la crisis del agua.</p>
<p><i>A review of the methods of harvesting atmospheric moisture.</i> <i>Ahmad et al. [65]</i></p>	<p><i>Environmental Science and Pollution Res. (2023)</i></p>	<p>Revisa métodos de cosecha de humedad, comparando la eficiencia de la refrigeración mecánica frente a los métodos químicos de absorción.</p>
<p><i>Progress and prospects of air water harvesting system for remote areas.</i> <i>Thavalengal et al. [66]</i></p>	<p><i>Energies (2023)</i></p>	<p>Se centra en la aplicación de estos sistemas en áreas rurales y remotas donde no hay infraestructura de tuberías, usando energía eólica o solar local.</p>
<p><i>Bio-inspired XYW parallel pathway edge detection network.</i> <i>Pang et al. [67]</i></p>	<p><i>Expert Systems with Applications (2023)</i></p>	<p>Propone la red XYW, que separa la información de bordes en diferentes canales espaciales para mejorar la precisión en la visión artificial industrial.</p>
<p><i>Bio-inspired feature cascade network for edge detection.</i> <i>Pan et al. [68]</i></p>	<p><i>The Visual Computer (2022)</i></p>	<p>Introduce una red de cascada de características que ayuda a la IA a detectar tanto bordes gruesos como detalles finos en una misma imagen de manera simultánea.</p>
<p><i>Bio-inspired feature enhancement network for edge detection.</i> <i>Lin et al. [69]</i></p>	<p><i>Applied Intelligence (2022)</i></p>	<p>Describe una red de mejora de características que utiliza mecanismos de atención para resaltar los bordes de objetos en imágenes con mucho ruido o baja resolución.</p>

<p><i>One-stage deep edge detection based on dense-scale feature fusion.</i></p> <p><i>Wang et al. [70]</i></p>	<p><i>IEEE Transactions on Artificial Intelligence (2022)</i></p>	<p>Aborda el problema del desbalance de píxeles (donde hay pocos píxeles de borde frente a muchos de fondo) mediante un aprendizaje de imbalance a nivel de píxel.</p>
<p><i>Multi-decoding network with attention learning for edge detection.</i></p> <p><i>Zhang & Lin [71]</i></p>	<p><i>Neural Processing Letters (2022)</i></p>	<p>Utiliza un aprendizaje de atención multidecodificación para que la red neuronal "aprenda" qué partes del contorno son más importantes para definir la forma de un objeto.</p>
<p><i>Multi-scale pseudo labeling for unsupervised deep edge detection.</i></p> <p><i>Zhou et al. [72]</i></p>	<p><i>Knowledge-Based Systems (2023)</i></p>	<p>Presenta un método de aprendizaje no supervisado (sin necesidad de que un humano etiquete las imágenes) para detectar bordes usando etiquetas generadas automáticamente.</p>
<p><i>Bio-inspired interactive feedback neural networks for edge detection.</i></p> <p><i>Lin et al. [74]</i></p>	<p><i>Applied Intelligence (2022)</i></p>	<p>Propone redes de retroalimentación que imitan la forma en que el ojo humano vuelve a mirar una zona de la imagen para confirmar si hay un borde o no.</p>
<p><i>EDTER: Edge detection with Transformer.</i></p> <p><i>Pu et al. [75]</i></p>	<p><i>IEEE/CVF (CVPR) (2022)</i></p>	<p>Presenta EDTER, un modelo que utiliza la arquitectura Transformer para capturar relaciones de larga distancia entre píxeles, logrando la detección de bordes más precisa hasta la fecha.</p>
<p><i>An overview of edge and contour detection.</i></p> <p><i>Yang et al. [76]</i></p>	<p><i>Neurocomputing (2022)</i></p>	<p>Ofrece una visión panorámica de la evolución de la detección de contornos, desde algoritmos matemáticos simples hasta redes neuronales profundas.</p>

<p><i>BLEDNet: Bio-inspired lightweight neural network for edge detection.</i></p> <p><i>Luo et al. [77]</i></p>	<p><i>Engineering Apps. of Artificial Intelligence (2023)</i></p>	<p>Introduce BLEDNet, una red neuronal diseñada para ser extremadamente ligera y rápida, ideal para ser instalada en microcontroladores de dispositivos AWH portátiles.</p>
<p><i>A lightweight contour detection network inspired by biology.</i></p> <p><i>Lin et al. [78]</i></p>	<p><i>Complex & Intelligent Systems (2024)</i></p>	<p>Desarrolla una red de contornos ligera optimizada para dispositivos con poca memoria, manteniendo una alta precisión inspirada en procesos biológicos de visión.</p>
<p><i>DPED: Bio-inspired dual-pathway network for edge detection.</i></p> <p><i>Chen et al. [79]</i></p>	<p><i>Frontiers in Bioengineering Biotech. (2022)</i></p>	<p>Propone DPED, una red de doble vía que procesa información local y global por separado para luego fusionarlas, imitando las vías visuales del cerebro.</p>

Cuernavaca, Morelos a 14 de abril del 2026.

MTRO. ELMER IVÁN SÁNCHEZ RABADÁN
ENCARGADO DE DESPACHO DE LA DIRECCIÓN DE LA FACULTAD
DE CONTADURÍA, ADMINISTRACIÓN E INFORMÁTICA
PRESENTE

En mi carácter de revisor de tesis, hago de su conocimiento que he leído con interés la tesis para obtener el grado de la Maestría en Optimización y Cómputo Aplicado, del estudiante **Alexis Angeles Robles**, con matrícula **10074239**, con el título **IMPLEMENTACIÓN DE TÉCNICAS DE IA PARA CLASIFICAR PARAMETROS EN PROTOTIPO DE CAPTACION DE AGUA CON CELDAS PELTIER**. por lo cual, me permito informarle que después de una revisión cuidadosa de dicha tesis, me permito expresar mi **VOTO APROBATORIO** por lo que de mi parte no existe inconveniente para que el estudiante continúe con los trámites que la Universidad Autónoma del Estado de Morelos tenga establecidos para obtener el grado mencionado.

Atentamente
Por una humanidad culta

Dra. LORENA DÍAZ GONZÁLEZ
Profesor- investigador
Centro de Investigación en Ciencias



UNIVERSIDAD AUTÓNOMA DEL
ESTADO DE MORELOS

Se expide el presente documento con firma electrónica UAEM, soportada por el certificado vigente a la fecha de su elaboración y con efectos plenos de conformidad con los LINEAMIENTOS EN MATERIA DE FIRMA ELECTRÓNICA PARA LA UNIVERSIDAD AUTÓNOMA DEL ESTADO DE MORELOS PUBLICADOS en el ÓRGANO INFORMATIVO UNIVERSITARIO "ADOLFO MENÉNDEZ SAMARÁ" número 117 de fecha 20 de abril de 2021.

Sello electrónico

LORENA DIAZ GONZALEZ | Fecha:2026-04-14 10:49:06 | FIRMANTE

oaW+zyHODiK0xxb1bU+pLujkDnlPeWWcU0mVEhlUWTHDjQPRUVrZyDDiLQjHmTn9Y2vJv14jbfJv409fYndEvEIV/IAQZK7GgJciYXBFivUoxrjUBBUqn/nOF6rokrDxSaEO0aXhEGzBzcn2zesQPO4NNdvzeinET542OMzP87LTorEqV+kpbgAYXytzEkizrFOFv6oo5aJdxoN0Zy0s6myjlVCE1a6wWSGuB/O0jvveDWFZZmKO4N/f8oHj8wEDXnk4FrLi0PRJZF/lr487eg2591n6g2oCvVBJJ41JBexJIRIfOmPz6poiMSuVMzDc7pmr+gaC6bCnOBx/GeGoA==

Puede verificar la autenticidad del documento en la siguiente dirección electrónica o escaneando el código QR ingresando la siguiente clave:



[4Jkh2YrNs](#)

<https://efirma.uaem.mx/noRepudio/Ei8LwjTqpcPgXz5jjMLUzTuF5zu69GaJ>



UAEM
RECTORÍA
2023-2029

Cuernavaca, Morelos a 14 de abril del 2026.

MTRO. ELMER IVÁN SÁNCHEZ RABADÁN
ENCARGADO DE DESPACHO DE LA DIRECCIÓN DE LA FACULTAD
DE CONTADURÍA, ADMINISTRACIÓN E INFORMÁTICA
PRESENTE

En mi carácter de revisor de tesis, hago de su conocimiento que he leído con interés la tesis para obtener el grado de la Maestría en Optimización y Cómputo Aplicado, del estudiante **Alexis Angeles Robles**, con matrícula **10074239**, con el título **IMPLEMENTACIÓN DE TÉCNICAS DE IA PARA CLASIFICAR PARAMETROS EN PROTOTIPO DE CAPTACION DE AGUA CON CELDAS PELTIER**. por lo cual, me permito informarle que después de una revisión cuidadosa de dicha tesis, me permito expresar mi **VOTO APROBATORIO** por lo que de mi parte no existe inconveniente para que el estudiante continúe con los trámites que la Universidad Autónoma del Estado de Morelos tenga establecidos para obtener el grado mencionado.

Atentamente
Por una humanidad culta

Dr. Roy López Sesenes
Profesor- investigador
Facultad de Ciencias Químicas e Ingeniería



UNIVERSIDAD AUTÓNOMA DEL
ESTADO DE MORELOS

Se expide el presente documento con firma electrónica UAEM, soportada por el certificado vigente a la fecha de su elaboración y con efectos plenos de conformidad con los LINEAMIENTOS EN MATERIA DE FIRMA ELECTRÓNICA PARA LA UNIVERSIDAD AUTÓNOMA DEL ESTADO DE MORELOS PUBLICADOS en el ÓRGANO INFORMATIVO UNIVERSITARIO "ADOLFO MENÉNDEZ SAMARÁ" número 117 de fecha 20 de abril de 2021.

Sello electrónico

ROY LOPEZ SESENES | Fecha:2026-04-14 10:50:22 | FIRMANTE

erjxLl5URSeEePioMkuiPejZYh3pS8tMvGdgPo6cC9DK9i1zWIk7JLep5c8oWRWc90b1ZNxAghf9XQHUSseVXrNIWXgr9SOZ8Dha2pH+Y2W+owMOQdHIODFXlwp2F9dPETlyT+e7CgvUaMyIH1TDxqYDGPST7IOUfuokuuA7zP4XPcBTEoRDC/qFycmeog0rQh0CFEm1Z5Wtky7eE/xqtUgLiQxZnnhrCtkNKz1YPEQlrcWorGHJKdL2ZnFE3ZVX0uFy1+ScEfHMq3XCuxABNHBx11xi+O83xmUllkm4hSu+kl623ujey3nanzvEI5AwlCOuUcWwZCmewezhNEQuEeQ==

Puede verificar la autenticidad del documento en la siguiente dirección electrónica o escaneando el código QR ingresando la siguiente clave:



[DcuNA1sEL](#)

<https://efirma.uaem.mx/noRepudio/Lq76V3Nlqpykx382Ossd4C6ndMHb47s>



UAEM
RECTORÍA
2023-2029

Cuernavaca, Morelos a 14 de abril del 2026.

MTRO. ELMER IVÁN SÁNCHEZ RABADÁN
ENCARGADO DE DESPACHO DE LA DIRECCIÓN DE LA FACULTAD
DE CONTADURÍA, ADMINISTRACIÓN E INFORMÁTICA
PRESENTE

En mi carácter de revisor de tesis, hago de su conocimiento que he leído con interés la tesis para obtener el grado de la Maestría en Optimización y Cómputo Aplicado, del estudiante **Alexis Angeles Robles**, con matrícula **10074239**, con el título **IMPLEMENTACIÓN DE TÉCNICAS DE IA PARA CLASIFICAR PARAMETROS EN PROTOTIPO DE CAPTACION DE AGUA CON CELDAS PELTIER**. por lo cual, me permito informarle que después de una revisión cuidadosa de dicha tesis, me permito expresar mi **VOTO APROBATORIO** por lo que de mi parte no existe inconveniente para que el estudiante continúe con los trámites que la Universidad Autónoma del Estado de Morelos tenga establecidos para obtener el grado mencionado.

Atentamente
Por una humanidad culta

Dr. José Alberto Hernández Aguilar
Profesor- investigador
Facultad de Contaduría, Administración e Informática



UNIVERSIDAD AUTÓNOMA DEL
ESTADO DE MORELOS

Se expide el presente documento con firma electrónica UAEM, soportada por el certificado vigente a la fecha de su elaboración y con efectos plenos de conformidad con los LINEAMIENTOS EN MATERIA DE FIRMA ELECTRÓNICA PARA LA UNIVERSIDAD AUTÓNOMA DEL ESTADO DE MORELOS PUBLICADOS en el ÓRGANO INFORMATIVO UNIVERSITARIO "ADOLFO MENÉNDEZ SAMARÁ" número 117 de fecha 20 de abril de 2021.

Sello electrónico

JOSE ALBERTO HERNANDEZ AGUILAR | Fecha:2026-04-14 11:32:57 | FIRMANTE

IOcOGVGgQsMHCKsWmP73JWBlgBUllotCEt34oMVucndI2TqMRDUv2jiVcFkVvxWzS1JgwTFveh0gFSRM9LNOS87XW2uxlk9Xn1FoiKpNiQFwfFJhMlj1VdGPW3vPwpiAEimv
hTTbBbYFf1N++rLmkbZ7xCeKe2cLEJ3C8vLASECJQ6RkArj6+aEOKOQbaRi7d7TQHosotgTYh2C3xrD42DWEE2akUjTtxO4VfzFOT8CeOce+H2UxpBQA9MG/kwBaK8x4nGSc
REgZQSi4pmUhB9DP38Cu5oSvnofrRIDpJa+MdluVv+ihPWzWF5xxqhZB+2/Gw5eo5LjSovS5/RGQ==

Puede verificar la autenticidad del documento en la siguiente dirección electrónica o
escaneando el código QR ingresando la siguiente clave:



kMH6csB7W

<https://efirma.uaem.mx/noRepudio/9slpFOFO1kcuOGBFdZsyR7yu7NiYLKru>



UAEM
RECTORÍA
2023-2029

Cuernavaca, Morelos a 14 de abril del 2026.

MTRO. ELMER IVÁN SÁNCHEZ RABADÁN
ENCARGADO DE DESPACHO DE LA DIRECCIÓN DE LA FACULTAD
DE CONTADURÍA, ADMINISTRACIÓN E INFORMÁTICA
PRESENTE

En mi carácter de revisor de tesis, hago de su conocimiento que he leído con interés la tesis para obtener el grado de la Maestría en Optimización y Cómputo Aplicado, del estudiante **Alexis Angeles Robles**, con matrícula **10074239**, con el título **IMPLEMENTACIÓN DE TÉCNICAS DE IA PARA CLASIFICAR PARAMETROS EN PROTOTIPO DE CAPTACION DE AGUA CON CELDAS PELTIER**. por lo cual, me permito informarle que después de una revisión cuidadosa de dicha tesis, me permito expresar mi **VOTO APROBATORIO** por lo que de mi parte no existe inconveniente para que el estudiante continúe con los trámites que la Universidad Autónoma del Estado de Morelos tenga establecidos para obtener el grado mencionado.

Atentamente
Por una humanidad culta

Dr. Outmane Oubram
Profesor- investigador
Facultad de Ciencias Químicas e Ingeniería



UNIVERSIDAD AUTÓNOMA DEL
ESTADO DE MORELOS

Se expide el presente documento con firma electrónica UAEM, soportada por el certificado vigente a la fecha de su elaboración y con efectos plenos de conformidad con los LINEAMIENTOS EN MATERIA DE FIRMA ELECTRÓNICA PARA LA UNIVERSIDAD AUTÓNOMA DEL ESTADO DE MORELOS PUBLICADOS en el ÓRGANO INFORMATIVO UNIVERSITARIO "ADOLFO MENÉNDEZ SAMARÁ" número 117 de fecha 20 de abril de 2021.

Sello electrónico

OUTMANE OUBRAM | Fecha:2026-04-14 13:33:49 | FIRMANTE

lsXaEp+5EcvWvQZKXSYgjdGkylSSwY/w3gadJbvAzHd4aLB7pbkLEAJOaD4uF5MPjL4hB/r7rzhQc/WiCCF0dJ+SOYkNJXxOkoeKLSNKO7RQpvoPG0/ywmeTwwxsQR1wYF1Vz
nLbq8rXAHBpL4LqXuUJLVaJFKj/IW1AAIVRdl1VwYMEzeX5C5NPp3L67s9XssINSrNSPj+EqOP8DbSLg6dCPVb32cXGMFRGg/pwhsZSSy5H2DxFiuCwTe3rfbQbHhJr0C1pt7vu
gPV8M+0/CwoIChRh8WuKo59fcX3qBVXNny+GRVVt4utMTXsGcpdOjqGEGbaEZO5JkN6GyLrBA==

Puede verificar la autenticidad del documento en la siguiente dirección electrónica o
escaneando el código QR ingresando la siguiente clave:



[ZndTAr0Mw](#)

<https://efirma.uaem.mx/noRepudio/MtkfKgJSiKrRwgpbvroyd7YoCNWqL6d0>



UAEM
RECTORÍA
2023-2029

Cuernavaca, Morelos a 14 de abril del 2026.

MTRO. ELMER IVÁN SÁNCHEZ RABADÁN
ENCARGADO DE DESPACHO DE LA DIRECCIÓN DE LA FACULTAD
DE CONTADURÍA, ADMINISTRACIÓN E INFORMÁTICA
PRESENTE

En mi carácter de revisor de tesis, hago de su conocimiento que he leído con interés la tesis para obtener el grado de la Maestría en Optimización y Cómputo Aplicado, del estudiante **Alexis Angeles Robles**, con matrícula **10074239**, con el título **IMPLEMENTACIÓN DE TÉCNICAS DE IA PARA CLASIFICAR PARAMETROS EN PROTOTIPO DE CAPTACION DE AGUA CON CELDAS PELTIER**. por lo cual, me permito informarle que después de una revisión cuidadosa de dicha tesis, me permito expresar mi **VOTO APROBATORIO** por lo que de mi parte no existe inconveniente para que el estudiante continúe con los trámites que la Universidad Autónoma del Estado de Morelos tenga establecidos para obtener el grado mencionado.

Atentamente
Por una humanidad culta

Dr. Federico Alonso Pecina
Profesor Investigador de Tiempo Completo
Facultad de Contaduría, Administración e Informática



UNIVERSIDAD AUTÓNOMA DEL
ESTADO DE MORELOS

Se expide el presente documento con firma electrónica UAEM, soportada por el certificado vigente a la fecha de su elaboración y con efectos plenos de conformidad con los LINEAMIENTOS EN MATERIA DE FIRMA ELECTRÓNICA PARA LA UNIVERSIDAD AUTÓNOMA DEL ESTADO DE MORELOS PUBLICADOS en el ÓRGANO INFORMATIVO UNIVERSITARIO "ADOLFO MENÉNDEZ SAMARÁ" número 117 de fecha 20 de abril de 2021.

Sello electrónico

FEDERICO ALONSO PECINA | Fecha:2026-04-14 22:45:43 | FIRMANTE

Tm9nvHkQhSukeLgbDM/UwyKDh1sLEWdbjVGxxzusSXjT1U88+tGdT7TtaKjxRNS7SqcOWQU/+xq2/9EodQ37i3QLA6g87dSRVyCOg5FNE6Zq4yFPIn1xeN3NUaUc9kcPdP6si
Q/3cARa6e4kbalhrWDgxSrUik3Z3fNUxCPZwqMM+gdiKWlx4seJhERDYYPX3jJHEkRhha/oqKNusOdtWSp4evNom+mt+9s/OhZ2ytVxISg+emPLTS7jYgOQw/VVr1DjihCQI1u
aTGMrDee26we35Qm8VFe+QYrRzjZcCjr2ML/p6C//YIQycRYnZ2SSl60l9mJWjtbinp0jV+A==

Puede verificar la autenticidad del documento en la siguiente dirección electrónica o
escaneando el código QR ingresando la siguiente clave:



[HfbCAYq25](#)

<https://efirma.uaem.mx/noRepudio/rsXpJpfkwmUxIZnt6KU2sLbdQyq6DgKb>



UAEM
RECTORÍA
2023-2029