

ESCUELA SUPERIOR POLITÉCNICA DEL LITORAL

FACULTAD DE INGENIERÍA EN ELECTRICIDAD Y

COMPUTACIÓN

**“DESARROLLO DE UN SISTEMA IoT PARA LA PREDICCIÓN DE
INCENDIOS Y LA GESTIÓN DE RIESGOS EN AREAS INDUSTRIALES
URBANAS”**

EXAMEN COMPLEXIVO

Previa la Obtención del Título de:

MAGISTER EN TELECOMUNICACIONES

AUTOR:

FREDDY ANDRES MACIAS AGUILAR

GUAYAQUIL – ECUADOR

Año: 2025

DEDICATORIA

Lo dedico a Dios, quien me ha guiado y fortalecido en cada paso de mi camino, le expreso mi más profunda gratitud. A mi familia, que ha sido mi motivación, les dedico este logro con todo mi amor.

A mi querido abuelito Jacinto, que desde el cielo me observa con orgullo, te agradezco por las lecciones de vida y el amor que me brindaste. Este logro es también tuyo, y espero que estés sonriendo desde arriba.

Freddy Macias

AGRADECIMIENTOS

Agradezco a Dios por siempre darme el camino y ser parte fundamental de mi vida. Agradezco profundamente a mi familia, que ha sido mi motivación durante todo este camino. Mi papá, el Máster Freddy Macías, quien se graduó en esta misma universidad, gracias por ser un ejemplo y por demostrarme que la perseverancia y la dedicación pueden llevarnos a alcanzar nuestros sueños. A mi madre, la Lcda. Jackeline Aguilar, gracias por tu amor incondicional y por ser siempre una fuente de aliento y apoyo. Tu presencia en mi vida ha sido fundamental para mi crecimiento y desarrollo.

También quiero expresar mi gratitud a mis hermanos. A mi linda hermana, la Máster Chrystel Macías, gracias por tu alegría y tu entusiasmo, que siempre me han inspirado a seguir adelante. Y a mi hermano, el Máster Daniel Macías, con quien compartí tantas clases y momentos universitarios, gracias por ser mi compañero de curso y mi amigo, por tus consejos y tu apoyo.

Me siento profundamente orgulloso de haber alcanzado este objetivo, que he soñado desde que era pequeño. Es un honor y un privilegio haber podido realizar mis estudios de maestría en la ESPOL, la mejor universidad del país y una institución que guardo en mi corazón.

Freddy Macias

DECLARACIÓN EXPRESA

Yo Freddy Andrés Macias Aguilar acuerdo y reconozco que: La titularidad de los derechos patrimoniales de autor del proyecto de graduación corresponderá al autor, sin perjuicio de lo cual la ESPOL recibe en este acto una licencia gratuita de plazo indefinido para el uso no comercial y comercial de la obra con facultad de sublicenciar, incluyendo la autorización para su divulgación, así como para la creación y uso de obras derivadas. En el caso de usos comerciales se respetará el porcentaje de participación en beneficios que corresponda a favor del autor o autores. El o los estudiantes deberán procurar en cualquier caso de cesión de sus derechos patrimoniales incluir una cláusula en la cesión que proteja la vigencia de la licencia aquí concedida a la ESPOL.

La titularidad total y exclusiva sobre los derechos patrimoniales de patente de invención, modelo de utilidad, diseño industrial, secreto industrial, secreto empresarial, derechos patrimoniales de autor sobre software o información no divulgada que corresponda o pueda corresponder respecto de cualquier investigación, desarrollo tecnológico o invención realizada por mí durante el desarrollo del proyecto de graduación, pertenecerán de forma total, exclusiva e indivisible a la ESPOL, sin perjuicio del porcentaje que me corresponda de los beneficios económicos que la ESPOL reciba por la explotación de mi/nuestra innovación, de ser el caso.

En los casos donde la Oficina de Transferencia de Resultados de Investigación (OTRI) de la ESPOL comunique al autor que existe una innovación potencialmente patentable sobre los resultados del proyecto de graduación, no se realizará publicación o divulgación alguna, sin la autorización expresa y previa de la ESPOL.

Guayaquil, 29 de enero del 2025.

Freddy Andrés Macías Aguilar

Evaluadores

Ing. María Antonieta Álvarez, PhD.

Evaluador

Ing. Eduardo Chancay, Mgtr.

Evaluador

RESUMEN

Este proyecto propone un sistema inteligente de detección de incendios basado en el Internet de las Cosas (IoT) y el aprendizaje automático (Machine Learning), enfocado en prevenir y mitigar incendios en zonas urbanas e industriales. Utilizando una red de sensores IoT, se recopilarán datos ambientales clave, como temperatura, humedad, niveles de gases combustibles y partículas en el aire. Estos datos serán analizados en tiempo real mediante algoritmos de Machine Learning entrenados para identificar patrones asociados a incendios, permitiendo una detección precisa y oportuna. Las alertas generadas se enviarán automáticamente a través de aplicaciones móviles o plataformas web, garantizando una respuesta inmediata.

La combinación de IoT y Machine Learning proporciona una solución innovadora que no solo detecta incendios en sus primeras etapas, sino que también predice su ocurrencia, reduciendo tiempos de respuesta y minimizando daños. Este sistema inteligente contribuye significativamente a la gestión de riesgos, la seguridad pública y la protección ambiental, posicionándose como un avance clave en la prevención de incendios en entornos críticos.

Palabras Clave: IoT, CNN, DNN, Detección de Incendio

ABSTRACT

This project proposes an intelligent fire detection system based on the Internet of Things (IoT) and Machine Learning, aimed at preventing and mitigating fires in urban and industrial areas. Using an IoT sensor network, key environmental data such as temperature, humidity, levels of combustible gases, and airborne particles will be collected. This data will be analyzed in real-time using Machine Learning algorithms trained to identify patterns associated with fires, enabling precise and timely detection. The generated alerts will be automatically sent via mobile applications or web platforms, ensuring an immediate response.

The combination of IoT and Machine Learning provides an innovative solution that not only detects fires in their early stages but also predicts their occurrence, reducing response times and minimizing damage. This intelligent system significantly contributes to risk management, public safety, and environmental protection, positioning itself as a key advancement in fire prevention for critical environments.

Keywords: Noise pollution, Urban noise, Machine Learning, Internet of Things

INDICE GENERAL

RESUMEN	¡Error! Marcador no definido.
ABREVIATURAS	11
ÍNDICE DE FIGURAS	11
ÍNDICE DE TABLAS	11
1. INTRODUCCIÓN	13
1.1 ANTECEDENTES	15
1.2 DESCRIPCIÓN DEL PROBLEMA	16
1.3 JUSTIFICACIÓN DE LA PROPUESTA	17
1.4 DELIMITACIÓN	18
1.4.1 DELIMITACIÓN TEMPORAL	18
1.4.2 DELIMITACIÓN ESPACIAL	19
1.5 OBJETIVOS	19
1.5.1 OBJETIVO GENERAL	19
1.5.2 OBJETIVOS ESPECÍFICOS	19
1.6 MARCO TEÓRICO	20
1.6.1 TECNOLOGIA DE SENSORES PARA LA ADQUISICIÓN DE DATOS	22
1.6.2 ESTADO DEL ARTE EN SISTEMAS DE PREDICCIÓN DE INCENDIOS	22
1.6.3 DETECCIÓN SIMULTANEA DE INCENDIOS	23
1.6.4 IDENTIFICACIÓN DE INCENDIOS USANDO MACHINE LEARNING	23
1.6.5 MACHINE LEARNING Y EDGE COMPUTING	24
1.6.6 DESCRIPCIÓN DE LOS MODELOS DE DATOS UTILIZADOS ..	¡Error! Marcador no definido.
1.6.7 REDES NEURONALES DENSAS (DNN)	25
1.6.8 REDES NEURONALES CONVOLUCIONALES (CNN)	26
1.6.9 DESCRIPCIÓN DE LA PLATAFORMA DE PREDICCIÓN	26
2. DISEÑO	26
2.1 COMPONENTES DEL SISTEMA DE SENSADO DE PARAMETROS	26
2.2 DISCUSIÓN SOBRE LA ELECCIÓN DE LOS MODELOS Y LA PLATAFORMA	29
3. ANALISIS DE RESULTADOS	30
3.1 ANÁLISIS PRELIMINAR DE LOS DATOS	30
3.2 ANÁLISIS DE LA DISTRIBUCIÓN	33
3.3 ANÁLISIS DE RENDIMIENTO DEL MODELO DE MACHINE LEARNING	35
3.4 RESULTADOS DEL MODELO DE CLASIFICACIÓN	36
4. CONCLUSIONES Y RECOMENDACIONES	38

4.1	CONCLUSIONES.....	38
4.2	RECOMENDACIONES	39
5.	BIBLIOGRAFÍA.....	40
6.	APÉNDICES.....	42

ABREVIATURAS

SVM	Máquina de Soporte Vectorial
RNN	Red Neuronal Replicadora
CNN	Red Neuronal Convolucional
DNN	Red Neuronal Profunda
ML	Aprendizaje de Máquina
IoT	Internet de las Cosas
ROC	Curva Característica Operativa del Receptor
EPA	Agencia de Protección Ambiental
IAQ	Calidad del Aire en Ambiente Interior
FTT	Transformada Rápida de Fourier
ANSI	Instituto Nacional Americano de Estándares
MEMS	Sistemas Microelectromecánicos
RBM	Máquina de Boltzmann Restringida
GMM	Modelo Gaussiano Mixto
PCA	Análisis de Componentes Principales

ÍNDICE DE FIGURAS

Figura 1	<i>Ubicación de la Unidad Educativa "Fragata Guayas"</i>	19
Figura 2	<i>Triángulo de Fuego</i>	20
Figura 3	<i>Partes del Fuego en Movimiento</i>	21
Figura 4	<i>Prototipo de Recolección de Datos</i>	27
Figura 5	<i>Resume Estadístico</i>	30
Figura 6	<i>Diagrama de Dispersión Temperatura / Humedad</i>	31
Figura 7	<i>Diagrama de Dispersión de Presencia de CO₂ / Hora</i>	32
Figura 8	<i>Diagrama de Barra de Nivel de Humo</i>	33
Figura 9	<i>Matriz de Correlación</i>	34
Figura 10	<i>Resultados del Entrenamiento</i>	35
Figura 11	<i>Resultado con el Conjunto de Datos de Prueba</i>	37

ÍNDICE DE TABLAS

Tabla 1	<i>Características de Edge Impulse</i>	26
Tabla 2	<i>Infraestructura Utilizada</i>	27

1. INTRODUCCIÓN

Los incendios representan una amenaza persistente tanto para las personas como para el entorno natural. A nivel global, es necesario lidiar con estos eventos en repetidas ocasiones, aunque su frecuencia varía según la región. De tal manera, los incendios se pueden caracterizar de varias formas dependiendo de su tipo, porque no es igual un incendio ocurrido en un campo abierto que un incendio en zona urbana, o situaciones de mayor temperatura como lo es en verano [1].

Un gran consecuente que dejan los incendios a su paso son la destrucción de los enseres de los propietarios que dependiendo de la magnitud del incendio puede ser una pérdida irreparable. Tomar una decisión rápida asistida por elemento de censado perenne pueden ayudar a los socorristas en minimizar las consecuencias. En un inicio, las llamas son alimentadas por el contacto directo del fuego con material combustible disponible y a medida que el incendio gana fuerza debido al aumento de la temperatura y el viento que alimenta la llama [2].

En ciertas situaciones, intervenir durante las etapas iniciales de la propagación del fuego se considera la única oportunidad para extinguirlo, dado que al alcanzar una alta intensidad extiende en toda el área en segundos, el conato de incendio puede volverse imposible de controlar. No es nada fácil analizar y comprender el proceso físico que determina el desarrollo del fuego.

Esto se debe a que el fuego actúa de distintas formas dependiendo de varios factores que el entorno nos provee, estos factores se agrupan en condiciones climáticas, combustible, topografía. Las condiciones climáticas que influyen en el incendio son el viento, la temperatura, la humedad, la precipitación reciente.

El viento es especialmente relevante, ya que define la dirección y velocidad con la que se desplaza el fuego, incluso es capaz de moldear su forma. Por otro lado, la temperatura y humedad no actúan directamente sobre las llamas, pero sí influyen en el nivel de inflamabilidad del material combustible.

El combustible puede variar ampliamente y se clasifica según su densidad, tamaño de partículas y nivel de humedad. Con características como el volumen de combustible, el porcentaje de humedad del sitio tienen un impacto directo en la propagación del fuego. En cuanto a la topografía, el comportamiento del fuego cambia dependiendo de si el terreno es plano o presenta desniveles, ya que la llama se desplaza con mayor rapidez [3].

Diferentes disposiciones del terreno favorecer, dificultan o incluso bloquear el avance del fuego. Como sucede con la presencia de un río puede actuar como una barrera natural que limite su avance. La evaluación del comportamiento del fuego busca anticipar su alcance y expansión, lo que permite diseñar planes de contingencia orientados a controlar el incendio, prevenir su propagación y extinguirlo, reduciendo al máximo sus impactos negativos.

Es importantes entender las diferentes características del fuego para ser efectivos al momento de responder a una situación de emergencia. El fuego puede clasificarse en clase A, B, C, D, E, F/K, dependiendo del tipo de material combustible su comportamiento varía entre ellos. En las soluciones actuales existen distintos dispositivos diseñados para prever y contener el avance de un incendio, pero la mayoría de ellos tiene un serio problema: solo son aplicables a un entorno concreto. Es decir, no han sido adaptado para todas las situaciones posibles que pueden darse [4].

El objetivo de la propuesta de proyecto es crear un marco para el comportamiento del fuego y modelarlo de manera que permita una acción proactiva con respecto al comportamiento que no esté limitado por el entorno en casi cualquier tipo de superficie. Cualquier restricción para hacer una predicción en una superficie específica no se deberá limitar al modelo con un alto grado de exactitud.

1.1 ANTECEDENTES

En los últimos años, los incendios provocados en las cercanías de la Unidad Académica Naval “Fragata Guayas” han despertado una preocupación cada vez mayor por la salud y la protección de los alumnos, maestros, y empleados burocráticos. Los incendios son principalmente ocasionados por manejo inapropiado de desechos sólidos inflamables por parte de los empleados que operan en la zona industrial cercana. Estas fábricas desechan materiales inflamables de manera irresponsable, quemando los desechos sin seguir un procedimiento acorde a los lineamientos estatales de conservación del medio ambiente, lo que aumenta significativamente la probabilidad de generar un incendio forestal o en la zona urbana cercana.

Además de la destrucción material y ambiental, estos incendios producen una gran cantidad de humo tóxico que afecta directamente la calidad del aire disponible. Las partículas finas y los gases emitidos durante la combustión que son peligrosos para la salud humana, especialmente en ambientes cerrados como las aulas de clase. La cercanía de estos focos de incendio a la unidad académica agrava la situación, ya que los estudiantes y docentes se ven expuestos a estos

contaminantes de manera reiterada, lo que puede provocar problemas respiratorios y complicaciones a largo plazo.

La falta de regulación efectiva y la supervisión deficiente por parte de las potestades cualificadas en el trámite de los desechos industriales han contribuido a la reincidencia de estos incidentes. A pesar de los esfuerzos de sensibilización ambiental y las normativas sobre manejo de residuos, no se ha logrado que se sigan las normas establecidas. Es por ello, que el estudio propuesto sentara las basase para ajustar la regular y minimizar la cantidad de incidentes que ocurren.

1.2 DESCRIPCIÓN DEL PROBLEMA

La cuestión de los incendios en zonas urbanas industriales es compleja y multifacética. Finalmente, tiene consecuencias graves en términos de seguridad y del medio ambiente, así como de la economía. Dado que es común el almacenamiento a largo plazo de productos inflamables y el uso de impresoras y otros dispositivos de alta potencia en la industria, el riesgo de incendios es notable. Los incendios no solo afectan la infraestructura de las fábricas y almacenes, sino que también pueden extenderse rápidamente a zonas residenciales cercanas, amenazando la vida de los habitantes del sector [5].

En este contexto, una falta de mecanismos de monitoreo y detección temprana dificulta la capacidad de reacción ante incendios. Los sistemas de respuesta tradicionales suelen ser insuficientes, ya que muchas veces los incendios se detectan cuando ya han alcanzado una fase avanzada, complicando los esfuerzos de mitigación. Además, la contaminación resultante producto del incendio, libera

gases tóxicos y partículas dañinas para la salud, afectando a las comunidades y en especial a las unidades educativas que colindan en el sector [6].

El uso de tecnologías emergentes, como el Internet de las Cosas (IoT), representa una solución prometedora para esta problemática. Estos sistemas pueden monitorear en tiempo real parámetros como temperatura, humedad y la presencia de gases, de tal forma que se pueda detectar con anticipación los incendios y evitar que se extiendan y provoque un desastre. Aunque la implementación de sistemas IoT en entornos industriales urbanos presenta sus propios desafíos, incluyendo la necesidad de infraestructura de red adecuada, costos de implementación, y la integración de estos sistemas con las estrategias de gestión de riesgos existentes [7].

Abordar esta problemática requiere un enfoque integral, que combine la tecnología IoT con modelos predictivos y estrategias de seguridad para reducir tanto la ocurrencia como el impacto de los incendios en zonas urbanas industriales [8].

1.3 JUSTIFICACIÓN DE LA PROPUESTA

Dada la problemática de los incendios en las cercanías de la unidad educativa, se propone el desarrollo de un dispositivo IoT para la creación de modelos de clasificación para la gestión de riesgos contra incendios en zonas urbanas. Como primer paso los sensores se pretenden instalar en áreas propensas a incidentes que se puedan monitorear en tiempo real, variables como la temperatura, aumento CO₂ y la presencia de otros gases inflamables. Esta información se procesaría mediante algoritmos predictivos basados en inteligencia artificial, permitiendo identificar patrones de riesgo y alertar a las autoridades locales de manera temprana [9].

Finalmente se propone gestionar de forma conjunta con organismos como el Servicio Nacional de Gestión de Riesgos y Emergencias (SNGRE) impulsan planes como la identificación de zonas críticas y la realización de simulacros comunitarios. De tal forma que estas nuevas tecnologías puedan convertirse en un pilar clave para la correcta gestión de políticas de prevención de incendios en zonas urbanas y sectores industriales [10].

A continuación, se describen los pasos para llevar a cabo toda la implementación:

1. Configuración de dispositivos IoT provistos de sensores que serán capaces de recolectar la información de las variables de análisis para la predicción del fuego.
2. Diseño de un sistema de gestión para procesar los datos recolectados por los sensores.
3. Desarrollo de un modelo de predicción de Machine Learning para la detección de un posible incendio.
4. Desarrollo de un sistema de generación de alertas que avisarán a los encargados de gestión de riesgos de poner los planes de mitigación en acción.

1.4 DELIMITACIÓN

1.4.1 DELIMITACIÓN TEMPORAL

Se estableció un periodo de 4 meses para llevar a cabo todo este estudio. Durante este período, todas las condiciones relacionadas con el problema se documentan mediante mediciones de ruido y vibración para conocer las probables causas del ruido.

1.4.2 DELIMITACIÓN ESPACIAL

“La investigación se llevará a cabo en una Unidad Educativa “Fragata Guayas” en la ciudadela Los Helechos, frente a Primavera 2 en la provincia del Guayas, cantón Durán”




Figura 1 Ubicación de la Unidad Educativa "Fragata Guayas"

1.5 OBJETIVOS

1.5.1 OBJETIVO GENERAL

Desarrollo de un plan de prevención de incendios basado en Internet de las Cosas (IoT) y aprendizaje automático que permita la predicción temprana de incendios en zonas industriales urbanas.

1.5.2 OBJETIVOS ESPECÍFICOS

1. Diseñar una red de sensores IoT en entornos industriales urbanas para el monitorear en tiempo real variables como temperatura, humo y gases inflamables.

2. Desarrollar un modelo predictivo de Machine Learning utilizando datos de los sensores IoT para identificar patrones que preceden incendios.
3. Implementar un sistema emitirá alertas a responsables de seguridad, indicando condiciones críticas que puedan derivar en un incendio.

1.6 MARCO TEÓRICO

En la **Figura 2** se presenta los elementos que componen el fuego a través de un triángulo equilátero en el cual cada lado se refiere a un elemento de la combustión que son necesarios para la activación del fuego. Entonces es una condición necesaria para la creación y mantenimiento del fuego, si una de ellas faltara el fuego se extinguiría inmediatamente [11].




Figura 2 Triángulo de Fuego

El combustible suele ser material sólido proveniente de desechos industriales, como cartón, papel o fundas plásticas. El comburente corresponde al oxígeno del aire, mientras que la energía puede originarse de una chispa, alta temperatura u otra llama. Si se elimina alguno de estos elementos, el triángulo queda incompleto y la llama no se genera o se extingue.

La combustión es un proceso de oxidación rápida a altas temperaturas que produce cenizas, un residuo compuesto principalmente de sales minerales. Este proceso se divide en tres etapas: precalentamiento, combustión de gases y fase sólida. En la etapa de precalentamiento, el calor eleva la temperatura del combustible. Al alcanzar los 100°C, el material comienza a liberar humedad en forma de vapor, y cerca de los 200°C, los compuestos volátiles de las resinas se evaporan. Luego, en la etapa de combustión de gases, al llegar a temperaturas de 300°C a 400°C, se inicia la ignición del material. La temperatura sigue aumentando hasta los 500°C o 600°C, momento en que la combustión se mantiene de forma autónoma, incluso sin la fuente de calor, liberando gases no quemados, vapor de agua y humo. Por último, en la fase sólida, el combustible arde con una llama azulada, emitiendo poco humo y una baja cantidad de gases de carbono [12].




Figura 3 Partes del Fuego en Movimiento

Los incendios que se propagan sin control en terrenos donde crecen especies vegetales como árboles, arbustos, matorrales o hierbas, ya sea de forma natural o cultivada. Aunque los incendios pueden adoptar diversas formas, el ejemplo que se presenta en la **Figura 3** resume las partes que componen un incendio en movimiento.

- Lugar de origen
- Cola
- Flancos (derecho / izquierdo)
- Dedos o Lenguas
- Cabeza o Frente

1.6.1 TECNOLOGIA DE SENSORES PARA LA ADQUISICIÓN DE DATOS

Se describe en detalle la infraestructura utilizada, los modelos de Machine Learning elegidos, así como la metodología para la adquisición del sistema de predicción. Cada componente se seleccionó en función de su idoneidad para procesar llevar a cabo todos nuestros objetivos propuestos. Debido a la creciente penetración del Internet de las cosas (IoT) y de las computadoras sofisticadas, este tipo de equipos se han vuelto fundamentales para monitorear y controlar los ambientes en interiores. Un enfoque de gran alcance para desarrollar un sistema de pronóstico basado en aprendizaje automático diseñado específicamente para monitorear la temperatura, la humedad y los niveles de humo como indicadores para evaluar posibles incendios [13].

1.6.2 ESTADO ACTUAL DE LOS SISTEMAS DE PREDICCIÓN DE INCENDIOS

En los últimos diez años, ha habido un enorme avance en la predicción de incendios basada en el aprendizaje automático. Estudios recientes han demostrado el uso de una serie de estrategias, particularmente en dos áreas importantes. Según investigaciones recientes, los sistemas basados en redes neuronales pueden beneficiarse de una serie de estrategias, particularmente en

dos áreas importantes, las arquitecturas híbridas en la cual nos centraremos es la gestión de series temporales.

En el ámbito del Edge Computing, se han evaluado la integración exitosa con sistemas IoT, en el que se han concentrado en mejorar los recursos tecnológicos, y se han examinado el proceso distribuido como un medio para aminorar la latencia en los procesos ambientales [14].

1.6.3 DETECCIÓN SIMULTANEA DE INCENDIOS

La detección de incendios forestales se realiza mediante sensores inalámbricos. Estos sensores inalámbricos son bastante costosos en comparación con los sensores cableados. El mecanismo puede ser más complejo si se diseñó con sensores inalámbricos. Existen muchas dificultades técnicas al usar los sensores, especialmente al usar este tipo de sensores en las zonas urbanas, lo hace más sencillo. En este caso, los nodos sensores se implementan en un área urbana. Estos sensores están interconectados y utiliza una técnica de red neuronal. Estos nodos sensores implementados acumularán la información medida. La información medida que se almacenara en el nodo principal. Este procesará la información recopilada de los sensores, y la información recopilada se almacenaría con un intervalo de tiempo específico. Esto reducirá el procesado en el nodo, pero en una situación de emergencia como humo o fuego la información se enviaría con una frecuencia más alta.

1.6.4 IDENTIFICACIÓN DE INCENDIOS USANDO MACHINE LEARNING

Existen muchos algoritmos o métodos de aprendizaje automático que se pueden utilizar en la detección de incendios forestales. Básicamente, los algoritmos de aprendizaje automático tienen un uso multipropósito. Estos algoritmos se pueden

aplicar en casi todos los dominios. La detección de incendios forestales también es uno de ellos. La máquina de vectores de soporte, el algoritmo de Random Forest y Redes Neuronales son algoritmos y métodos que se pueden utilizar para detectar incendios. Inicialmente, el conjunto de datos se recopila de mediciones que se realizaran. Los datos recopilados no se pueden utilizar tal como se dan, hay que preprocesarla. El preprocesamiento se realiza con la ayuda del software Anaconda y Spyder. El conjunto de datos se proporciona a todos estos algoritmos para probar la precisión, la velocidad y el tiempo de respuesta. Se probará con diferentes tipos de datos. Después de analizar los resultados de la prueba, el algoritmo Redes Neuronales se tiene la mayor velocidad, precisión y tiempo de respuesta en comparación con otros algoritmos. Por lo tanto, se recomienda utilizar este algoritmo para detectar incendios forestales [15].

1.6.5 MACHINE LEARNING Y EDGE COMPUTING

El modelo en mención, junto al arte de aprendizaje automático, posee particularidades únicas que respaldan este diseño:

- a. **Perfeccionamiento de Modelos:** Se pueden adecuar tipos engorrosos a aparatos con atributos limitados gracias a enfoques de cuantificación y recorte [16].
- b. **Construcciones Híbridas:** La utilización de las ventajas de cada arquitectura se facilita combinando múltiples tipos de redes neuronales [17].

1.6.6 RESUMEN DE LOS MODELOS DE DATOS APLICADOS

Se eligieron los modelos de este sistema de pronóstico porque es necesario procesar series de tiempo complejas que contienen mucha inconstancia ambiental. Al combinar las fortalezas de las redes neuronales densas y

convolucionales (DNN y CNN), la arquitectura híbrida propuesta crea un sistema confiable y adaptable.

1.6.7 REDES NEURONALES DENSAS (DNN)

Son fundamentales gracias a la eficacia en la clasificación binaria y el manejo de datos temporales. Hay múltiples capas completamente interconectadas en la estructura implementada. Por lo cual es capaz de identificar patrones complejos en las secuencias del dato en cuestión. La elección de este modelo es por su talento para extraer patrones enmarañados, haciéndolo idóneo para pronosticar secuencias temporales como niveles de CO₂ y ruido [18].

La estructura DNN particular para este sistema incluye:

a. Capa de Ingreso

- Dimensiones: $n_features$ (no. sensores + variables de contexto)
- La normalización de datos a través del método min-max
- Dropout (0.2) para evitar el exceso de ajuste.

b. Capas Ocultas

- Primera capa: 128 neuronas que están activadas con ReLU
- En la segunda capa: 64 neuronas activadas por ReLU.
- Tercer nivel: 32 neuronas activadas por ReLU
- Normalización Batch entre capas de niveles
- Incremental descenso (0.2-0.4)

c. Capade Egreso

- 1 neurona activada de manera sigmoide
- La optimización a través de Adam
- Función de desecho: Cross-Entropy Binario

1.6.8 REDES NEURONALES CONVOLUCIONALES (CNN)

Estás también son ideales para manejar este tipo de situaciones; dado a su eficiencia en el manejo de estas características a lo largo de intervalos de tiempo [19].

1.6.9 DESCRIPCIÓN DE LA PLATAFORMA DE PREDICCIÓN

Simboliza un progreso considerable para aparatos electrónicos de borde. Esta plataforma online fusiona habilidades de desarrollo, capacitación y ejecución en un ambiente consolidado, simplificando la aplicación en Inteligencia Artificial en aparatos con recursos escasos. Fue elegida la plataforma por su habilidad para poner en práctica soluciones de aprendizaje automático en dispositivos de computación a distancia. La plataforma ofrece un ambiente unificado que simplifica:

Tabla 1 Características de Edge Impulse

Manejo de datos de carácter temporal	Elaboración de modelos conceptuales
Adaptabilidad de las ventanas de tiempo.	Desarrollo optimizado de DNN y CNN.
Automatización de la normalización de señales.	Sistemas de validación incorporados.
Manejo eficaz de las frecuencias de muestreo	Valores de desempeño en tiempo real.

2. DISEÑO

2.1 COMPONENTES DEL SISTEMA DE SENSADO DE PARAMETROS

Este sistema está diseñado para ser proactivo en la prevención de incendios, utilizando múltiples sensores y aprendizaje automático para detectar condiciones de riesgo antes de que se produzca un incendio. La estructura por fases permite

primero recolectar datos suficientes para entrenar el modelo, y luego usar ese modelo para la detección en tiempo real.




Figura 4 Prototipo de Recolección de Datos

La **Tabla 2** especifica el método de recopilación de datos, los sensores empleados y algunas particularidades del software utilizado.

Tabla 2 Infraestructura Utilizada

Software y configuración	Sensores y componentes	Hardware
Python	Sensor de monóxido de carbono	Raspberry pi 4
Frecuencia de muestreo: 5 min	DHT11 para medición de humedad y temperatura	Procesador: Cortex-A72
Formato de almacenamiento: CSV		Memoria RAM: 8 GB
Análisis de señales en tiempo real.		Sistema operativo: Raspbian

Para la aplicación de este enfoque es obligatorio una base fuerte que pueda funcionar consistentemente en coyunturas cambiantes. La selección de componentes para sistemas informáticos remotos debe lograr un equilibrio entre

confiabilidad, consumo de energía y rendimiento de procesamiento. En este marco, nuestra infraestructura ha sido diseñada con base en los fundamentos de repetición y eficacia definidos por el IEEE.

La elección del hardware se basa en sus características de fábrica, que las hace ideal para este tipo de enfoques. El procesador de este equipo proporciona una utilidad óptima porque mantiene un consumo de energía moderado de 3,5 W en condiciones de carga típicas. La configuración de RAM de 8 GB permite manejar múltiples flujos de datos a la vez.

El despliegue de este tipo de red simboliza una estrategia global para la observación medioambiental. El sistema de detección de CO₂ utiliza un sistema de alta precisión. Lo cual es primordial para nuestro fin. Para proporcionar mediciones precisas y confiables, la graduación del sensor se realiza de acuerdo con las pautas establecidas por la Environmental Protection Agency (EPA).

La arquitectura distribuida que sustenta la estructura de mensajes definida prioriza la solidez de la transferencia de información. El sistema interactúa con sensores locales a través de un bus I2C y emplea una combinación de MQTT y HTTP REST para comunicarse con sistemas externos. La diligencia de energía se ha desarrollado teniendo en cuenta las mejores prácticas para sistemas de monitoreo continuo. El establecimiento de un sistema de alimentación constante (UPS) ayudo al continuo almacenamiento de información.

Ampliar la potencia de procesamiento y agregar más sensores es posible gracias al diseño con capacidad de crecimiento de la infraestructura. La arquitectura modular permite el mantenimiento y la renovación sin cambiar el funcionamiento

del sistema. Un mecanismo de actualización automatizado es fundamental para llevar a cabo el propósito del trabajo [10].

2.2 DISCUSIÓN SOBRE LA ELECCIÓN DE LOS MODELOS Y LA PLATAFORMA

Se elige este tipo de sistemas, dado a una serie de factores deseables. El análisis del uso de este tipo de sistemas mejora sustancialmente en este tipo de situaciones. Los resultados empíricos demuestran que, esta metodología híbrida mejora los resultados hasta un 15 %. Gracias a sus propiedades de no linealidades, las DNN se han incorporado como un componente crucial del sistema. Se seleccionó Edge Impulse como plataforma de desarrollo e implementación. En su análisis comparativo de varias plataformas informáticas de áreas remotas, encontraron que la elegida era particularmente notable. Edge Impulse puede optimizar automáticamente los modelos, lo que disminuye en un 40% el desarrollo, en comparación con los métodos tradicionales de desarrollo de ML. La reducción de costos y tiempo de implementación, dos componentes cruciales de los proyectos de monitoreo ambiental son un resultado directo de este desarrollo exitoso [17].

La observación financiera del sistema implementado muestra una relación costo-beneficio ventajosa en comparación con otras opciones. El menor coste del procesamiento y transmisión de datos en la nube compensa los costes iniciales de implementación. En el diseño y ejecución del sistema se ha considerado la sostenibilidad. Las resoluciones concentradas tradicionales, estos sistemas pueden reducir hasta en un 30% la huella de carbono [20].

3. ANALISIS DE RESULTADOS

3.1 ANÁLISIS PRELIMINAR DE LOS DATOS

En la **Figura 5** adjunta muestra un resumen estadístico del conjunto de datos obtenidos a través de las mediciones.

	Nivel de Humo	Temperatura (C)	Humedad (%)
count	1812.000000	1812.000000	1812.000000
mean	0.300773	29.722406	40.811258
std	0.458721	1.711586	8.870485
min	0.000000	24.000000	22.000000
25%	0.000000	28.000000	35.000000
50%	0.000000	30.000000	40.000000
75%	1.000000	31.000000	46.000000
max	1.000000	33.000000	72.000000

Figura 5 Resume Estadístico

El valor medio del humo es de 0.3, lo que indica que, en promedio, se observó humo en cerca del 30% de las observaciones. El promedio de temperatura fue de 29.72°C, lo que corresponde a un clima cálido. El bajo desviación estándar (1.71) señala que las temperaturas no experimentaron grandes fluctuaciones alrededor de este promedio. La media de humedad alcanzó el 40.81%, lo que señala un grado de humedad moderado. La desviación estándar más elevada (8.87) indica una mayor fluctuación en los niveles de humedad respecto a la temperatura.

El gráfico de dispersión presentado en la **Figura 6** expone la correlación entre: la temperatura (medida en grados Celsius) y la humedad relativa (medida en porcentaje). Los puntos del gráfico son una percepción personal, evidenciando la temperatura y humedad correspondiente en un instante concreto.




Figura 6 Diagrama de Dispersión Temperatura / Humedad

La mayor parte de la información se concentra en un rango de temperatura que va de 28°C a 30°C, con una humedad relativa que varía entre el 30% y el 50%. Hay una notable dispersión de los datos, en particular en el eje de la humedad. Esto sugiere que, para una temperatura determinada, puede haber una gran variación en los niveles de humedad. A primera impresión, no se percibe una correlación lineal evidente y sólida entre la temperatura y la humedad. Aunque no existe una correlación lineal clara, podrían presentarse otras formas de relaciones, como una relación no lineal o una concentración de los datos en determinados intervalos. Para profundizar en esto, serían necesarios análisis estadísticos más exhaustivos.

Las temperaturas registradas parecen tener una humedad relativa bastante fluctuante, lo que indica que otros elementos, además de la temperatura, podrían estar afectando los niveles de humedad. La correlación entre la temperatura y la

humedad no es tan simple como una relación directa lineal. Podría haber otras variables o elementos no tomados en cuenta en este estudio.

En la **Figura 7** muestra una correlación entre dos factores: la hora del día en el eje y y la existencia de CO₂ (en una escala de 0 a 1) en el eje x . Cada punto en el diagrama simboliza una observación personal, señalando la hora y el nivel de CO₂ correspondiente en dicho instante.




Figura 7 Diagrama de Dispersión de Presencia de CO₂ / Hora

Los datos están muy concentrados en líneas verticales, lo que sugiere que para cada nivel de CO₂ hay una gran diversidad de horas del día en las que se registró dicho nivel. No se percibe una tendencia evidente entre el aumento o la reducción sistemática del CO₂ durante el día. No hay una relación evidente entre las horas y la presencia de humo. Los puntos están dispersos. Parece que los niveles de CO₂ no dependen de la hora del día, al menos de acuerdo con los datos mostrados en este diagrama. La fluctuación en los niveles de CO₂ podría ser afectada por otros elementos no contemplados en este estudio, tales como la

actividad humana en la zona, las condiciones meteorológicas, o la ventilación del espacio en el que se realizaron las mediciones.

3.2 ANÁLISIS DE LA DISTRIBUCIÓN

La imagen presentada en la **Figura 8** muestra un análisis de la relación entre el nivel de humo y las demás variables.




Figura 8 Diagrama de Barra de Nivel de Humo

Alrededor del 70% de las observaciones se asocian a un nivel de humo de 0, lo que indica que en la mayor parte de las mediciones no se registró humo o que los niveles eran extremadamente bajos. Solo el 30% de los reportes señalan un nivel de humo de 1, lo que podría indicar condiciones con una mayor concentración de partículas en el aire. El grado de humo parece tener una fuerte correlación con el año y el mes, lo que indica que podría haber patrones de presencia de humo a lo largo del año. Hay una correlación moderada entre la cantidad de humo y la hora del día, lo que sugiere que la hora podría afectar los niveles de polución.

Usualmente, se ilustran las matrices de correlación utilizando un mapa de calor. Las tonalidades cálidas (rojos) señalan una correlación positiva, las tonalidades frías

(azules) una correlación negativa, y las tonalidades próximas al blanco señalan una correlación mínima o nula, tal como se muestra en la **Figura 9**.

La mayor parte de las celdas exhiben valores próximos a cero, lo que señala que las conexiones lineales entre las variables son escasas o no existen. Algunas correlaciones sobresalen por su mayor intensidad en relación con las demás. La correlación entre la variable humo y la mayoría de las demás variables es muy baja. El vínculo más significativo se encuentra con la hora del día, lo que indica que podría haber un patrón temporal en los niveles de humo. La relación con la humedad es positiva, aunque muy limitada, señalando una leve inclinación a que los niveles de humo se incrementen con la humedad.




Figura 9 Matriz de Correlación

La temperatura presenta una correlación negativa mínima con el horario diurno, lo que podría sugerir que las temperaturas suelen descender durante determinadas horas del día. La humedad presenta una correlación moderadamente positiva con el día y la hora, lo que indica que la humedad podría incrementarse conforme el día progresa.

3.3 ANÁLISIS DE RENDIMIENTO DEL MODELO DE MACHINE LEARNING

La ilustración de la **Figura 10** muestra un resumen de los logros alcanzados en la fase final de entrenamiento de un modelo de aprendizaje automático. Estos hallazgos son esenciales para valorar la eficacia del modelo y su habilidad para extenderse a datos nuevos.




Figura 10 Resultados del Entrenamiento

El accuracy señala el porcentaje total de las predicciones acertadas que ha hecho el modelo. En esta situación, el modelo cuenta con una precisión del 71%, lo que implica que logró acertar en el 71% de las proyecciones. Loss es un indicador de la adecuación del modelo a los datos de entrenamiento. Un valor más reducido señala un ajuste óptimo. En este escenario, la pérdida es de 0.60, lo que indica un ajuste moderado. La matriz de confusión presenta un contraste entre las proyecciones del modelo y los datos reales, siendo la diagonal principal (100% y 97.3%) la representación de las predicciones acertadas, mientras que los valores más allá de la diagonal simbolizan las predicciones equivocadas. En este escenario, el modelo presenta una tasa muy baja de falsos positivos (0%), lo que indica que el modelo no presenta falsos positivos. F1-Score es un indicador de exactitud que toma en cuenta tanto la exactitud como el RECALL. Un valor elevado señala un adecuado balance entre ambos. El F1-Score para la clase 0 es altamente positivo (0.83), en cambio, para la clase 1 es reducido (0.05). Esto implica un desequilibrio en el desempeño del modelo para diversas clases. Sector bajo la curva ROC, evalúa la habilidad del modelo para diferenciar entre clases, un índice de 0.51 señala un desempeño medio.

3.4 RESULTADOS DEL MODELO DE CLASIFICACIÓN

La **Figura 11** ilustra los hallazgos de la evaluación de un modelo de clasificación. Estas medidas nos ofrecen una perspectiva global del rendimiento del modelo en la labor de categorizar datos en diversas categorías.



Figura 11 Resultado con el Conjunto de Datos de Prueba

Para obtener más información sobre el efecto individual que estos parámetros tienen en tu modelo, puedes consultar esta documentación. Esto podría requerir algo de prueba y error para encontrar la configuración óptima. La exactitud señala que el modelo ha categorizado adecuadamente el 58.69% de las muestras en su totalidad. No obstante, este valor puede resultar fraudulento si las clases se encuentran desbalanceadas. El AUC evalúa la habilidad del modelo para diferenciar entre los grupos positivos y negativos. Un valor de 0.5 señala un desempeño aleatorio, en cambio, un valor próximo a 1 señala un rendimiento sobresaliente. En esta situación, el AUC es de 0.49, lo que indica que el modelo no es suficientemente eficaz en este trabajo. La precisión ponderada evalúa el porcentaje de pronósticos positivos que resultan acertados. Un valor reducido señala que gran parte de las proyecciones positivas del modelo son erróneas. El RECALL ponderado determina la proporción de casos positivos que se

identificaron correctamente. Un valor elevado señala que el modelo es eficaz para detectar los casos positivos. El F1-score representa la media armónica de la exactitud y el RECALL, ofreciendo una evaluación equilibrada de ambas. Un valor superior señala un rendimiento global superior. La matriz de confusión presenta un contraste entre las estimaciones del modelo y los valores verdaderos. La mayor parte de los pronósticos acertados están situados en la diagonal principal. La categoría "UNCERTAIN" indica que el modelo no tiene certeza en su pronóstico en ciertas situaciones.

4. CONCLUSIONES Y RECOMENDACIONES

4.1 CONCLUSIONES

El gráfico de dispersión de la **Figura 6** sugiere que la humedad en el lugar de estudio es bastante variable y no está estrechamente relacionada con la temperatura de manera lineal.

El diagrama de dispersión mostrado en la **Figura 7** indica que la hora del día no juega un papel crucial en los niveles de CO₂ en este grupo de estudio.

La mayoría de las mediciones indican niveles bajos de humo. La matriz de correlación indica que las conexiones entre las variables son intrincadas y no pueden ser explicadas solo mediante correlaciones lineales sencillas.

Según la **Figura 11**, se podría afirmar que el modelo muestra un rendimiento superior en la predicción de la clase 0 en relación con la clase 1. Esto podría ser resultado de un desequilibrio en los datos de entrenamiento o de rasgos inherentes a las clases.

Según los hallazgos mostrados en la figura 6, se puede deducir que el valor reducido de AUC y la precisión general señalan que el modelo tiene problemas para diferenciar entre las clases.

4.2 RECOMENDACIONES

Como se ha notado una variabilidad significativa en la humedad y una aparente autonomía de los niveles de CO₂ en relación con la hora del día, se sugiere llevar a cabo análisis más exhaustivos para entender de manera más profunda estas relaciones. Esto podría comprender:


- Investigar si hay alguna correlación no lineal entre las variables mediante técnicas como el análisis de correlación de Spearman o mediante representaciones como esquemas de dispersión con líneas de suavizado.
- Tomar en cuenta factores como la velocidad del viento, la presión atmosférica o la radiación solar, dado que estos podrían tener un impacto considerable en los niveles de humedad y CO₂.
- Analizar si hay patrones estacionales en los datos, dado que elementos como la estación del año pueden influir de manera considerable en las condiciones del medio ambiente.
- Efectuar una elección meticulosa de las características empleadas para entrenar el modelo, descartando aquellas que no sean pertinentes o que posean una alta correlación.
- Explorar varios valores de los hiper parámetros del modelo con el objetivo de mejorar su desempeño.

5. BIBLIOGRAFÍA

- [1] A. G. Medewar, A. D. Sawarkar, and U. V. Kshirsagar, "A Review on Fire and Smoke Detection With Intelligent Control for Enhanced Safety Using Machine Learning (ML) and Internet of Things (IoT)," *Cureus J.*, Sep. 2024, doi: 10.7759/10.
- [2] C. Santelices and M. Felipe, "APLICACIÓN DE TÉCNICAS DE MACHINE LEARNING PARA PREDECIR EL TAMAÑO DE INCENDIOS FORESTALES," 2017.
- [3] L. D. F. Licero, E. M. R. Fontalvo, and J. D. A. Quiroga, "Desarrollo de un Modelo de Estimación para la Prevención de Incendios Forestales," 2024.
- [4] A. Sharma *et al.*, "Fire Detection in Urban Areas Using Multimodal Data and Federated Learning," *Fire*, vol. 7, no. 4, p. 104, Mar. 2024, doi: 10.3390/fire7040104.
- [5] F. J. Kelly and J. C. Fussell, "Improving indoor air quality, health and performance within environments where people live, travel, learn and work," *Atmos. Environ.*, vol. 200, pp. 90–109, Mar. 2019, doi: 10.1016/j.atmosenv.2018.11.058.
- [6] M. S. Aslanpour, S. S. Gill, and A. N. Toosi, "Performance evaluation metrics for cloud, fog and edge computing: A review, taxonomy, benchmarks and standards for future research," *Internet Things*, vol. 12, p. 100273, Dec. 2020, doi: 10.1016/j.iot.2020.100273.
- [7] Y. Kang, L. Aye, T. D. Ngo, and J. Zhou, "Performance evaluation of low-cost air quality sensors: A review," *Sci. Total Environ.*, vol. 818, p. 151769, Apr. 2022, doi: 10.1016/j.scitotenv.2021.151769.
- [8] T. Peng and W. Ke, "Urban fire emergency management based on big data intelligent processing system and Internet of Things," *Optik*, vol. 273, p. 170433, Feb. 2023, doi: 10.1016/j.ijleo.2022.170433.
- [9] K. J. O. Camargo and L. F. C. Castro, "PROTOTIPO DE UN SISTEMA DE MONITOREO PARA DETECCIÓN DE INCENDIOS EN ÁREAS PROTEGIDAS DEL DEPARTAMENTO DE SANTANDER CON LA GENERACIÓN DE ALERTAS EN TIEMPO REAL POR MEDIO DE DRONES," 2019.
- [10] E. Lule, C. Mikeka, A. Ngenzi, and D. Mukanyiligira, "Design of an IoT-Based Fuzzy Approximation Prediction Model for Early Fire Detection to Aid Public Safety and Control in the Local Urban Markets," *Symmetry*, vol. 12, no. 9, p. 1391, Aug. 2020, doi: 10.3390/sym12091391.
- [11] N. Vidakis, M. A. Lasithiotakis, and E. Karapidakis, "Environmental monitoring through embedded system and sensors," in *2017 52nd International Universities Power Engineering Conference (UPEC)*, Aug. 2017, pp. 1–7. doi: 10.1109/UPEC.2017.8231913.
- [12] R. Voltas, "Creación de un modelo de predicción de riesgos de incendios forestales usando una red neuronal convolucional sobre datos históricos de meteorología de California," 2021.
- [13] "An Integrated System for Regional Environmental Monitoring and Management Based on Internet of Things | IEEE Journals & Magazine | IEEE Xplore." Accessed: Jan. 26, 2025. [Online]. Available: https://ieeexplore.ieee.org/abstract/document/6725615?casa_token=wjQZhHFXDYUAAAAA:6tL9IO-CifbEkCqB6a_QpdkbVy_g8UjgAJRAfqI9hIh0eNlv9V9VhytZFWxSUbOI8VAcCKTxBd-L_w
- [14] A. Akanbi and M. Masinde, "A Distributed Stream Processing Middleware Framework for Real-Time Analysis of Heterogeneous Data on Big Data Platform: Case of Environmental Monitoring," *Sensors*, vol. 20, no. 11, Art. no. 11, Jan. 2020, doi: 10.3390/s20113166.
- [15] J. Salamon and J. P. Bello, "Deep Convolutional Neural Networks and Data Augmentation for Environmental Sound Classification," *IEEE Signal Process. Lett.*, vol. 24, no. 3, pp. 279–283, Mar. 2017, doi: 10.1109/LSP.2017.2657381.

- [16] "Communication protocols for wireless sensor networks: A survey and comparison: Heliyon." Accessed: Jan. 26, 2025. [Online]. Available: [https://www.cell.com/heliyon/fulltext/S2405-8440\(18\)34019-2](https://www.cell.com/heliyon/fulltext/S2405-8440(18)34019-2)
- [17] A. Rehman, D. Kim, and A. Paul, "Convolutional Neural Network Model for Fire Detection in Real-Time Environment," *Comput. Mater. Contin.*, vol. 77, no. 2, pp. 2289–2307, 2023, doi: 10.32604/cmc.2023.036435.
- [18] R. Chellappa, S. Theodoridis, and A. van Schaik, "Advances in Machine Learning and Deep Neural Networks," *Proc. IEEE*, vol. 109, no. 5, pp. 607–611, May 2021, doi: 10.1109/JPROC.2021.3072172.
- [19] J. C. B. Gamboa, "Deep Learning for Time-Series Analysis," Jan. 07, 2017, *arXiv*: arXiv:1701.01887. doi: 10.48550/arXiv.1701.01887.
- [20] H. Fleischmann, J. Kohl, and J. Franke, "A Modular Architecture for the Design of Condition Monitoring Processes," *Procedia CIRP*, vol. 57, pp. 410–415, Jan. 2016, doi: 10.1016/j.procir.2016.11.071.

6. APÉNDICES



CODIGO PARA EL MUESTREO DE DATOS

```
// Definición de constantes

CONST INTERVALO_MUESTREO = 5 // minutos
CONST DURACION_RECOLECCION = 30 // días
CONST UMBRAL_ALARMA_CRITICA = 0.8 // probabilidad
CONST UMBRAL_ALARMA_ADVERTENCIA = 0.6
CONST UMBRAL_ALARMA_PRECAUCION = 0.4


// Definición de estructuras de datos
ESTRUCTURA DatosSensor

    timestamp: DateTime
    temperatura: Float
    humedad: Float
    presion: Float
    nivelLuz: Float
    nivelGas: Float
FIN_ESTRUCTURA


// Variables globales
VAR baseDatos: Lista<DatosSensor>
VAR modeloIA: ModeloPrediccion
VAR estadoAlarma: Entero // 0: Normal, 1: Precaución, 2: Advertencia, 3: Crítica


// Función principal
PROCEDIMIENTO main()

    INICIAR

        configurarSensores()
        inicializarBaseDatos()


        // Fase 1: Recolección de datos
        MIENTRAS (duracionRecoleccion < DURACION_RECOLECCION) HACER

            nuevosDatos = recolectarDatosSensores()
            almacenarDatos(nuevosDatos)
            esperar(INTERVALO_MUESTREO)
        FIN_MIENTRAS


        // Fase 2: Entrenamiento del modelo
```

```

preprocesarDatos()

entrenarModelo()

// Fase 3: Monitoreo continuo
MIENTRAS (verdadero) HACER
    datoActual = recolectarDatosSensores()
    riesgoIncendio = evaluarRiesgo(datoActual)
    gestionarAlarmas(riesgoIncendio)
    esperar(INTERVALO_MUESTREO)
FIN_MIENTRAS
FIN_INICIAR

// Funciones de recolección de datos
FUNCION recolectarDatosSensores() RETORNA DatosSensor
    INICIAR
        datos = NUEVO DatosSensor
        datos.timestamp = obtenerTiempoActual()
        datos.temperatura = leerSensorTemperatura()
        datos.humedad = leerSensorHumedad()
        datos.presion = leerSensorPresion()
        datos.nivelLuz = leerSensorLuz()
        datos.nivelGas = leerSensorGas()
    RETORNAR datos
FIN_INICIAR

// Funciones de procesamiento de datos
PROCEDIMIENTO preprocesarDatos()
    INICIAR
        eliminarValoresAtipicos()
        normalizarDatos()
        generarCaracteristicas()
    FIN_INICIAR

// Funciones de IA y predicción
FUNCION evaluarRiesgo(datos: DatosSensor) RETORNA Float
    INICIAR
        datosProcesados = procesarDatosEntrada(datos)

```

```

        probabilidadIncendio = modeloIA.predecir(datosProcesados)

    RETORNAR probabilidadIncendio

FIN_INICIAR

// Código usado

-- coding: utf-8 --

import RPi.GPIO as GPIO import time import csv from datetime import datetime import
board import adafruit_dht import os

Configuración de GPIO

SENSOR_SONIDO_PIN = 17 # Cambia esto según tu conexión SENSOR_HUMO_PIN = 27 #
Cambia esto según tu conexión LED_ACTIVO_PIN = 22 # Pin para el LED que indica que
el programa está activo LED_GUARDADO_PIN = 23 # Pin para el LED que indica que los
datos se han guardado sensor = adafruit_dht.DHT11(board.D4) # Cambia a DHT11 si es
necesario

GPIO.setmode(GPIO.BCM) GPIO.setup(SENSOR_SONIDO_PIN, GPIO.IN)
GPIO.setup(SENSOR_HUMO_PIN, GPIO.IN) GPIO.setup(LED_ACTIVO_PIN, GPIO.OUT) #
Configurar el pin del LED activo como salida GPIO.setup(LED_GUARDADO_PIN, GPIO.OUT)
# Configurar el pin del LED de guardado como salida

Variables para el control del tiempo

noise_detected = False start_time = None threshold_time = 300 # 5 minutos en
segundos

Archivo CSV para almacenar los datos

csv_file = '/home/aja/Desktop/Tesina/datos_sensores.csv'

Función para inicializar el archivo CSV

def init_csv(): # Verificar si el archivo ya existe if not
os.path.exists(csv_file): with open(csv_file, mode='w', newline='') as file: writer
= csv.writer(file) writer.writerow(['Fecha y Hora', 'Nivel de Sonido', 'Nivel de
Humo', 'Temperatura (C)', 'Humedad (%)']) print(f"Archivo {csv_file} creado y
encabezados escritos.") else: print(f"El archivo {csv_file} ya existe. No se
crearon encabezados.")

Función para leer los sensores

def leer_sensores(): global noise_detected, start_time # Declarar las variables
como globales nivel_sonido = GPIO.input(SENSOR_SONIDO_PIN) nivel_humo =
GPIO.input(SENSOR_HUMO_PIN)

temperature_c = None
humidity = None

for attempt in range(5): # Intentar hasta 5 veces
    try:
        # Lee la temperatura y la humedad
        temperature_c = sensor.temperature
        humidity = sensor.humidity
        print(f"Leyendo sensor DHT: temperatura: {temperature_c} y humedad:
{humidity}")
        if temperature_c is not None and humidity is not None:
            break # Salir del bucle si la lectura es exitosa
    except RuntimeError as error:
        print(f"Error de lectura del sensor DHT")

```

```

        time.sleep(2.0) # Esperar antes de reintentar
    except Exception as error:
        print(f'Ocurrió un error inesperado: {error}')
        sensor.exit()
        raise error

if temperature_c is None or humidity is None:
    print("No se pudo obtener datos del sensor DHT después de varios intentos.")
    temperature_c = float('nan') # Asignar NaN para representar un valor no válido
    humidity = float('nan')

# Lectura del sensor de Humo
if SENSOR_HUMO_PIN == GPIO.LOW:
    print("Concentración de CO alta detectada!")
    nivel_humo = 1
else:
    print("Concentración de CO normal.")
    nivel_humo = 0

#Lectura del Ruido
if SENSOR_SONIDO_PIN == GPIO.HIGH:
    if not noise_detected:
        noise_detected = True
        start_time = time.time() # Iniciar el temporizador
        print("Ruido detectado!")
    else:
        # Verificar si el ruido ha estado presente por más de 5 minutos
        elapsed_time = time.time() - start_time
        if elapsed_time >= threshold_time:
            print("Ruido alto durante más de 5 minutos.")
            nivel_sonido = 1
else:
    if noise_detected:
        noise_detected = False
        start_time = None # Reiniciar el temporizador
        print("Ruido normal.")
    nivel_sonido = 0
    print("Sin Ruido")

return nivel_sonido, nivel_humo, temperature_c, humidity
Inicializar el archivo CSV

init_csv()

Encender el LED que indica que el programa está activo

GPIO.output(LED_ACTIVO_PIN, GPIO.HIGH)

try: while True: # Leer los sensores nivel_sonido, nivel_humo, nivel_temperatura,
nivel_humedad = leer_sensores()

    # Obtener la fecha y hora actual
    fecha_hora = datetime.now().strftime('%Y-%m-%d %H:%M:%S')

    # Almacenar los datos en el archivo CSV
    with open(csv_file, mode='a', newline='') as file:
        writer = csv.writer(file)
        writer.writerow([fecha_hora, nivel_sonido, nivel_humo, nivel_temperatura,
nivel_humedad])

    # Encender el LED de guardado
    GPIO.output(LED_GUARDADO_PIN, GPIO.HIGH)
    GPIO.output(LED_ACTIVO_PIN, GPIO.LOW)
    time.sleep(2) # Mantener el LED encendido por 0.5 segundos
    GPIO.output(LED_GUARDADO_PIN, GPIO.LOW) # Apagar el LED de guardado
    GPIO.output(LED_ACTIVO_PIN, GPIO.HIGH)

    # Esperar un intervalo antes de la próxima lectura

```

```
time.sleep(300) # Leer cada 60 segundos (puedes ajustar este valor)

except KeyboardInterrupt: print("Deteniendo el programa...") finally:
GPIO.output(LED_ACTIVO_PIN, GPIO.LOW) # Apagar el LED activo al finalizar
GPIO.cleanup()
```