

Recibido 18 Nov. 2022

ReCIBE, Año 12 No.1, May. 2023

Aceptado 30 Nov. 2022

Sistema de Identificación de Incendios en Espacios Interiores

Fire Identification System in Interior Spaces

Héctor Caballero Hernández¹

Marco Antonio Ramos Corchado¹

Vianney Muñoz Jiménez¹

¹Universidad Autónoma del Estado de México

RESUMEN

Los incendios en espacios cerrados se caracterizan por ser detonados cuando alguna instalación eléctrica está provocando un cortocircuito o por una fuente que genera una chispa en dichos espacios, además, hay presencia de combustibles como gases y materiales sólidos o líquidos altamente flamables. Esta investigación se enfoca en presentar un sistema híbrido de prevención y detección de incendios en lugares cerrados, como casa-habitación, edificios corporativos, laboratorios, entre otros. Se ha propuesto la implementación de sensores para la detección de distintos tipos de gases flamables, así como la detección de gases no flamables que son producto de un proceso de combustión, aunado a esto, se cuenta con un sistema de detección por visión de computadora, el cual emplea una red neuronal profunda para la detección de fuego y humo basada en el modelo YOLO (You Only Look Once). Las variables obtenidas por el dispositivo, denominado como DRI3 (Dispositivo de reconocimiento de incendios), tiene la capacidad de almacenar los registros en un servidor local, así como subir los datos obtenidos por los sensores en la plataforma ThingSpeak para el respaldo y análisis de la información. De acuerdo con los resultados obtenidos, el sistema tuvo una capacidad de detección de gases flamables y humo en un 100%, mientras que, la red convolucional empleada para detectar fuego en imágenes digitales tuvo una capacidad de detección del 93%, adicionalmente, la emisión de alertas mediante el envío de mensajes de alerta a celulares se gestionó de forma correcta.

Palabras clave: Detección de incendios, redes neuronales convolucionales, prevención

ABSTRACT

Fires in closed spaces are characterized by being detonated when an electrical installation is causing a short circuit or by a source that causes a spark in said spaces, in addition, there is the presence of fuels such as gases and highly flammable solid or liquid materials. This research focuses on presenting a hybrid system for the prevention and detection of fires in closed places, such as a homeroom, corporate buildings, laboratories, among others. The implementation of sensors for the detection of different types of flammable gases has been proposed, as well as the detection of non-flammable gases that are the product of a combustion process, in addition to this, there is a computer vision detection system, the which uses a deep neural network for fire and smoke detection based on the You Only Look Once (YOLO) model. The variables obtained by the device, called IRD3 (Image Recognition Device), can store the records on a local server, as well as upload the data obtained to the ThingSpeak platform for information backup and analysis. According to the results obtained, the system had a 100% detection capacity of flammable gases and smoke, while the convolutional network used to detect fire in digital images had a detection capacity of 93%, additionally, the emission of alerts by sending alert messages to cell phones was managed correctly.

KEYWORDS: Fire detection, convolutional neural networks, prevention

1. INTRODUCCIÓN

El presente trabajo muestra el desarrollo de un sistema híbrido para la detección de incendios en espacios cerrados mediante reconocimiento de evento en imágenes digitales y la detección de gases y elementos que son productos de la combustión. Este documento está compuesto de las siguientes secciones, la primera sección está dedicada a mostrar un panorama general sobre la temática de incendios, la sección 2 trata sobre definiciones y conceptos básicos referentes a la temática central de sistemas clasificadores, incendios, redes de sensores, entre otros, la sección 3, describe las investigaciones que abordan el tratamiento de incendios forestales, la sección 4 se enfoca en la presentación de la metodología a seguir para construir un sistema de detección de incendios en

interiores, la sección 5 aborda el desarrollo de la propuesta general de un sistema híbrido de detección de incendios, la sección 6 presenta las pruebas y resultados que se obtuvieron para validar el sistema de detección de incendios, en las secciones 7 y 8 se desglosa el curso a seguir para la presente investigación así como las conclusiones obtenidas tras la ejecución de las pruebas y resultados, finalmente, se presentan las referencias empleadas en este trabajo.

Uno de los peligros más grandes que se presentan en lugares cerrados, como casa habitación, sitios comerciales, edificios corporativos, laboratorios, entre otros lugares, es la generación de un incendio sin control cuando existe presencia de objetos flamables en estado sólido, líquido o gaseoso y una deficiente instalación eléctrica o algún otro elemento que cause un corto circuito o temperaturas elevadas, debido a que destruyen una gran cantidad de bienes materiales, así como poner en peligro la vida de seres humanos (CONAPCI, 2022). Se estima que de cada 100 incendios que se presentan en zonas urbanas de México, el 55.6% son de casa habitación, el 34.1% en lugares de comercio o uso mixto para la vivienda, mientras que el resto se ubica en hoteles, edificios industriales y otro tipo de infraestructura. En México, aproximadamente cada año 128,000 personas sufren quemaduras de distintos grados en el cuerpo, de los casos totales el 30% son niños (Gómez, 2022), dichas lesiones condicionan su integración a la sociedad, dejando secuelas físicas y emocionales que deterioran su calidad de vida. Los casos de quemaduras graves son de aproximadamente 13,000 personas por año, de las cuales el 8% corresponde a infantes (Secretaría de Salud, 2021).

Los incendios en espacios interiores generalmente son causados por una serie de descuidos con respecto a un uso incorrecto o almacenamiento de materiales flamables, entre los que se encuentran, los gases de tipo LP, metano y butano, el uso de solventes, alcoholes, formaldehidos, resinas y otros tipos de derivados del petróleo (principalmente gasolina y diésel) (Pavez, 2021). Se tiene que una de las principales causas de los incendios es por la fuga de gas en tubería o de cilindros, los cuales no han recibido un mantenimiento rutinario de forma correcta. Según la Organización Mundial de la Salud (OMS) fallecen aproximadamente 180,000 personas a nivel mundial (OMS, 2018) por incendios.

Debido a la complejidad de los incendios en interiores existen distintas propuestas para atender la prevención y detección de estos, mediante el uso de sistemas de visión por computadora empleando redes preentrenadas (como YOLO) para detección de eventos (Park & Ko, 2020), uso de redes de dispositivos IoT (Internet of Things) en la predicción de incendios en ciudades inteligentes mediante la detección de variables como gases procedentes de combustión, entre otros elementos (Zang et al., 2021), (Lule et al., 2020), así como la combinación de visión por computadora y dispositivos IoT (Arshad et al., 2019), (Sharma et al., 2020). Siendo que los sistemas híbridos (dedicados a combinar distintas técnicas de detección de incendios), los más utilizados actualmente, por su capacidad de detectar distintas variables que indican la presencia de un incendio. En siguiente sección se presentan los elementos fundamentales de las tecnologías que se utilizan mayoritariamente para la detección de eventos en espacios interiores, por otra parte, en la sección 3 se citan trabajos actuales sobre propuestas que tratan la prevención y la detección oportuna de incendios en espacios interiores.

2. FUNDAMENTO TEÓRICO

Los sistemas de detección de eventos están basados en distintas propuestas para determinar la presencia de un fenómeno. Generalmente, los sistemas de detección de incendios se basan en el monitoreo de variables como humo y temperatura, mientras que las propuestas más modernas llegan a emplear reconocimiento visual y mediante emisión de ondas infrarrojas para clasificar la fuente calor que está generando un posible problema.

Un sensor se define como un dispositivo capaz de detectar materiales y señales para enviar una señal y permitir que se realice un proceso o continúe con este (Thomazini & de Albuquerque, 2020). Una de las aplicaciones más novedosas que existen de sensores en espacios cerrados y abiertos, es el uso de redes de sensores, las cuales son un conjunto de sensores que están interconectados mediante una pasarela para el intercambio de información a una estación de trabajo para su recolección y tratamiento (Mendoza et al., 2020), como se puede apreciar en la figura 1. Las redes de sensores pueden transmitir la información de forma alámbrica o de forma inalámbrica (RIS).




Figura 1. Esquema general de una red de sensores
Fuente: (Campaña Bastidas, 2019)

Por otra parte, en el reconocimiento de objetos y eventos, se tiene el uso de redes neuronales, específicamente, el uso de redes neuronales convolucionales (en inglés Convolutional Neural Network, CNN), las cuales son algoritmos que están basados en el reconocimiento de patrones específicos, mediante la formación de un kernel que indica una serie de características que se pueden presentar en una imagen digital (Cetinic, Lipic & Grgic, 2020).

Existen distintos tipos de CNN preentrenadas, entre las más comunes se tiene a R-CNN (Girshick et al., 2013), YOLO (Redmon, 2016), SSD (Liu et al. 2015) y VGG (Simonyan & Zisserman, 2014). En la figura 2 se encuentra la estructura básica de una red neuronal convolucional, en donde los datos de entrada pasan por un proceso de convolución, posteriormente los datos son expuestos a un proceso de mezclado y finalmente se realizan las operaciones de procesamiento en la capa de clasificación para obtener una salida.




Figura 2. Estructura de una red neuronal convolucional
Fuente: Elaboración propia

Algunas de las métricas de evaluación más importantes que se utilizan en el entrenamiento de redes neuronales son las siguientes (Sze, 2020).

Accuracy. Indica la proporción de aciertos que ha tenido el modelo. Es el porcentaje de TP y TN respecto al total.

$$\text{Accuracy} = \frac{\text{TN} + \text{TP}}{\text{TN} + \text{TP} + \text{FN} + \text{FP}} \quad (1)$$

Precision. Indica el porcentaje de los elementos válidos respecto a los predichos como verdaderos.

$$\text{Precision} = \frac{TP}{TP + FP} \quad (2)$$

Recall. Indica la capacidad del modelo para identificar un suceso.

$$\text{Recall} = 2 * \frac{TP}{TP + FN} \quad (3)$$

F1-score. Es la media armónica entre Recall y Precision. Se emplea cuando se necesita saber la relación entre los errores de falsos positivos y falsos negativos.

$$\text{F1 - score} = 2 * \frac{\text{Precision} * \text{Recall}}{\text{Precision} + \text{Recall}} \quad (4)$$

Donde:

True Positives (TP)
True Negatives (TN)
False Positives (FP)
False Negatives (FN)

En la siguiente sección se presentan trabajos relevantes relacionados con la detección de incendios en espacios interiores.

3. ESTADO DEL ARTE

Con los avances obtenidos en ciencias computacionales y la electrónica, ha sido posible la implementación de avanzados modelos matemáticos que permitan la detección y predicción de eventos, como es el caso de incendios en lugares donde habitan personas para evitar mayores percances. En el trabajo de Rzaïj y Al-Obaidi (2022) desarrollaron un análisis de 12 parámetros para verificar el riesgo que existe de presentar en edificios, algunos de los parámetros contemplados son, tipo de construcción, alarmas de incendios, salidas de emergencias, entre otros. Una propuesta interesante para el control de incendios está expuesta en Wang et al. (2022), donde emplean imágenes digitales para realizar una predicción de incendios, tomando en cuenta la evolución del humo que se está detectando, y en una evaluación de más de 1800 escenarios de incendios simulados, las imágenes son analizadas por una red neuronal convolucional. El factor clave que los autores analizan es el HRR (potencia del fuego), debido a que establece una relación entre la cantidad de fuego presente y el humo que se desprende en tiempo real, en la investigación los autores obtuvieron una tasa de error menor al 20% en su fase experimental. En Kou et al. (2021) presentan un modelo para detectar y predecir la intensidad del fuego en edificios con la implementación de un GRU, con la aplicación de redes neuronales que permiten identificar elementos de un incendio, la base de entrenamiento está construida por una base de imágenes de incendios. El modelo presentado tiene una precisión de localización del fuego en un 0.954 (de 1), aunque tiene limitaciones cuando el fuego es constante y el escenario simple.

Un trabajo interesante en la evaluación de riesgos de incendios basado en aprendizaje automático y estadístico es el trabajo de Choi & Jun (2020), los autores comparan su modelo contra el KFRI, en los resultados experimentales obtuvieron una precisión del 0.7514, lo cual representa un gran esfuerzo debido a que la periodicidad con que se presentan los incendios en interiores, así como los factores que intervienen en ellos son altamente difíciles de estudiar.

En las investigaciones de Iqbal et al. (2020), Mwedzi et al. (2019) y Muhammad et al. (2018) presentan propuestas similares basadas en redes neuronales convolucionales para la detección de incendios en interiores de edificios, siendo el más avanzado el trabajo Muhammad et al. (2018), debido a que

desarrolló un framework de vigilancia contra incendios para edificios y casa habitación, incendios forestales e incendios en vehículos, la red convolucional propuesta está basada en GoogleNet, consta de 100 capas con dos redes convolucionales principales y 4 pools, la base de entrenamiento está en imágenes digitales de una profundidad de 24 bits de 224 x 224 píxeles en 64 núcleos, la novedad contra otras propuestas es que está aplicado en vídeo y tiene una efectividad de detección promedio del 94.43% en el mejor de los casos y un 80% en escenarios de alta complejidad.

Algunas investigaciones se han concentrado en el análisis de imágenes digitales desde el punto de vista de su intensidad calorífica, usando tecnología infrarroja, tal es el caso de las investigaciones de Rostami et al. (2022), Wang et al. (2018), Yang et al. (2018), Yang et al. (2020), Saponara et al. (2021) entre lo que destaca el uso de modelos avanzados de reconocimiento de imágenes digitales con imágenes normales de tipo RGB (Red Green Blue) y de imágenes digitales tomadas con cámaras infrarrojas. En otros trabajos como en Nazir et al. (2022), realizan una experimentación detallada sobre los componentes que existen espacios cerrados y analizan factores como la temperatura, la concentración de gases como CO₂, para medir los niveles de alerta que se pueden presentar.

En los trabajos de Meidelfi et al. (2022), Albassam y Khan (2019) y Kothandapani et al. (2021) emplearon sensores como MQ6 y MQ5 para ser utilizados en dispositivos móviles con Android y detectar humo. En trabajos como Raj et al. (2021) y Guo et al. (2019), en este último trabajo desarrollaron un sistema el cual consta de dos partes: terminal sensor y servidor central, y tiene un módulo receptor del sistema de posición global (GPS), un módulo de servicio general de paquetes de radio (GPRS) y un módulo de alimentación. Las redes de sensores inalámbricos móviles consisten en terminales de sensores móviles y terminales de sensores estacionarios, permiten un monitoreo de fugas.

Los sistemas de detección de fuego hacen uso de distintas herramientas para poder identificar elementos, tales como, fuentes posibles de materiales que puedan ocasionar un incendio, como lo son: gases como el butano, propano, metano, entre otros. Varias de las propuestas modernas en la identificación de incendios están basadas en el uso de análisis visual mediante CNN, así como modelos predictivos que indican el comportamiento destructivo del fuego en interiores si se llegase a presentar, algunas otras propuestas se centran en emplear redes de sensores para detectar la presencia de elementos que indicarían la presencia de humo y gas. Debido a la complejidad que representa un incendio en espacios interiores es necesaria la combinación distintas tecnologías que permitan precisar con certeza este tipo de eventos.

En base a la revisión de los trabajos anteriormente descritos, se ha diseñado una propuesta para la detección de incendios en espacios interiores la cual se describe a continuación.

4. METODOLOGÍA

En la detección de incendios es importante identificar los elementos que presentan cambios en el ambiente, entre las variables más importante se tienen la temperatura y la humedad, mientras que, la detección de presencia de elementos como gases inflamables, son elementales para prevenir un incidente, por otro lado, la detección de elementos como el humo o flama indicarían que existe un proceso de combustión, el cual debe de detenerse antes de que se expanda sin control. Tomando en consideración los elementos anteriores, se ha propuesto la metodología expresada en la figura 3, en la cual se indican 4 fases para la identificación de incendios o fuentes potenciales que pueden provocar un incendio en interiores.




Figura 3. Metodología propuesta para la detección de incendios en interiores
Fuente: Elaboración propia

Las fases de la metodología propuesta se explican en los siguientes párrafos.

- Monitoreo del ambiente interior. Se detectan los valores de las variables como temperatura y humedad, así como la verificación de presencia de gases flamables, humo y flama. Es la fase de mayor importancia, debido a que permite obtener datos que tienen como función principal evitar la generación de un incendio o la expansión de este.

- Almacenamiento de datos en servidores. Los datos obtenidos en la fase anterior son almacenados en dispositivos locales o en la nube, para realizar un análisis a corto y mediano plazo para la caracterización del microclima y poder realizar ajustes de temperatura y humedad.


- Clasificación de los elementos del ambiente. El valor de los elementos al ser obtenidos y almacenados, son comparados con umbrales para determinar si se exceden los valores que se considerarían como estables, tanto el valor de la temperatura ambiente y la humedad, siendo prioritarios la presencia de gas flamable, humo y presencia de flama para realizar un análisis mediante visión por computadora.

- Activación de alertas. En la cuarta fase se envían alertas cuando los sistemas de detección obtuvieron presencia de gas, humo o fuego, como acción de alerta y acción para los usuarios vinculados con el espacio interior.

Las fases de la metodología desarrollada son aplicadas para la construcción de un sistema de detección de incendios, con el propósito de generar una propuesta que se adapte a distintos contextos, permitiendo flexibilidad y adaptabilidad a distintos entornos de interiores. En la sección 5 se presenta una propuesta general sobre la metodología planteada.

5. PROPUESTA GENERAL

En base a la metodología anterior se ha diseñado una propuesta que englobe la detección de variables físicas mediante sensores que registren humedad, temperatura ambiente, presencia de humo y fuego, así como un análisis de imágenes digitales. En la figura 4, se muestra el diseño general de un sistema híbrido denominado como DRI3 (Dispositivo de Reconocimiento de Incendios), el cual tiene la capacidad de obtener la lectura de las variables anteriormente mencionadas, y cuenta con la capacidad de captura imágenes para comprobaciones visuales de la presencia de fuego. Se ha propuesto que el DRI3 registre todos los elementos que son obtenidos por los sensores en una base de datos local, así como una conexión a internet, mediante una conexión a una red local, cualquier evento que se supere los umbrales predeterminados (límites a los que pueden llegar las variables físicas), iniciarían un proceso de alarma acústica, así como la activación de un aviso mediante la emisión de alertas acústicas y vía mensajes SMS.






Figura 4. Propuesta general de prevención y atención a incendios en espacios interiores
Fuente: Elaboración propia

Los datos que se transmiten en la red local, son codificarlos mediante el uso de la base 64. Cuando los datos llegan al servidor local son decodificados y almacenados en la base de datos, posteriormente, se envían a la plataforma en la nube para realizar proceso de graficación de la información que se está almacenando. La información registrada por los sensores puede ser directamente cargada a la plataforma que se encuentra en la nube, pero si la conexión es inestable se perderían los datos, además depende de las circunstancias que se presenten en el entorno, por esta razón está diseñado para almacenar de forma prioritaria en un base de datos local.

En la figura 5 se muestra la estructura de bloques del DRI3 indicando los componentes con los que está conformado, el cual contiene una configuración donde el dispositivo IoT realiza la lectura de los sensores (monóxido de carbono, gas flamable, temperatura, humedad y humo), mientras que el analizador imágenes dispone de otro hardware, como puede ser un Tablet PC o PC, junto con una cámara para la captura de imágenes y un módulo de comunicación Wifi para la transmisión de información. Los dispositivos que concentran el procesamiento están conectados por un gateway, el cual es el mecanismo para la transmisión de la información, esta gateway puede ser mediante un medio inalámbrico o alámbrico para lograr la comunicación entre el dispositivo IoT y la computadora.




Figura 5. Componentes del dispositivo de reconocimiento de incendios para espacios interiores (DRI3)

Fuente: Elaboración propia

Los umbrales son determinados con respecto las características técnicas de los sensores, pero la lógica de activación de las alertas es la siguiente.

- 1.- Los sensores de gas y humo tienen prioridad al superar su umbral, activan directamente las alarmas disponibles y el análisis visual.
- 2.- Si cualquiera de los sensores de temperatura o flama superan su umbral, se activa el análisis visual.
- 3.- Si el análisis visual no detecta presencia de fuego, genera una alerta de inspección.
- 4.- Todas las lecturas de los sensores son almacenadas en una base datos sin importar que no se rebase el umbral.

La propuesta del DRI3 está diseñada cubrir distintas áreas de espacios cerrados, debido a que el concepto de comunicación IP permite conectar varios dispositivos de acuerdo con la capacidad de administración de conexión que provee punto de acceso. En la figura 6 se muestra una distribución hipotética del DRI3, en donde cada uno de los dispositivos tendría asignada una IP única, sirviendo para indicar el área en donde se está desarrollando un determinado evento.




Figura 6. Distribución de DRI3 en distintos espacios
Fuente: Elaboración propia

La configuración del DRI3 depende de las necesidades específicas del ambiente en el que estaría trabajando, por esta razón se ha diseñado de la forma más flexible posible para trabajar en entornos con o sin conexión a internet, así como la cantidad de sensores que puede incluir.

6. PRUEBAS Y RESULTADOS

Las pruebas se desarrollaron en espacios interiores con dos escenarios de evaluación, ambos tomando en cuenta una casa habitación. En el primer escenario, denominado A, se libera gas LP de forma controlada para medir la capacidad de detección del DRI3. En el segundo escenario, denominado B, se produce un incendio controlado, en donde se busca detectar la presencia de humo y la activación del sistema de visión por computadora para determinar la capacidad de reconocimiento visual, teniendo en cuenta que el objeto a detectar es fuego. Los datos que se obtienen por el sistema son almacenados en las bases de datos local y en la nube, teniendo prioridad la primera. En ambos escenarios se

empieza con el proceso de detección de los datos del ambiente los cuales se tomarán como parámetros normales de operación.

La configuración del DRI3 está conformada por una placa IoT Wemos D1, la cual cuenta con una tarjeta inalámbrica ESP8266 integrada, que trabaja a una frecuencia de 2.4 GHz, a la tarjeta controladora se han conectado los sensores HI 01 (detección de flama), MQ-9 (detector de humo y gas) y DHT11 (sensor de temperatura ambiental y humedad). Por otra parte, el analizador de imágenes se montó en una tableta Chuwi Hi10 Go, la cual cuenta con un procesador Intel Celeron N5100, 6 GB de memoria RAM, con 128 GB de almacenamiento en disco SSD y doble cámara (frontal y trasera). La elección de la tableta electrónica se debe a su tamaño compacto y además que incluye cámara integrada, pero el sistema puede trabajar con cualquier otro tipo de hardware que permita capturar vídeo e imagen. La transmisión de datos entre la placa Wemos D1 y la tableta se ha realizado vía Wifi mediante un dispositivo de doble banda que trabaja a 2.4 GHz y a 5 GHz. La configuración de la gateway está dada por la conexión inalámbrica que provee el punto de acceso. Los sensores han pasado por un proceso de depuración, el cual ha consistido en la conexión de dichos dispositivos durante un periodo de 12 horas ininterrumpidas, puesto que, al momento de realizar el proceso de lectura sin una depuración previa los datos que se registran son erróneos.

La figura 7 muestra la distribución de los componentes del DRI3 de forma esquemática, en la parte de la izquierda se ubican los sensores, la tarjeta de adquisición de datos y la unidad de alimentación, mientras que en la segunda parte se presenta el dispositivo de empleado para el análisis visual. Las dos secciones del DRI3 no tienen conexión física, debido a que la comunicación se realiza de forma inalámbrica, siendo el flujo de información de forma unidireccional, el cual parte de la placa de adquisición de datos a la tableta electrónica.




Figura 7. Esquema de los componentes del DRI3
Fuente: Elaboración propia

El modelo de reconocimiento de imágenes para detección de fuego se basó en la red convolucional YOLO v5, específicamente utilizando el modelo preentrenado yolov5l6. La base de datos utilizada para el entrenamiento de la red se construyó con imágenes digitales provenientes de internet, tomando 7000 imágenes del tipo RGB con una resolución 640 x 640 píxeles. El entrenamiento se llevó a cabo en el entorno de Google Colab, mediante una GPU Nvidia TESLA de 16 GB de RAM, empleando 100 ciclos de entrenamiento (épocas). Los resultados obtenidos del proceso de entrenamiento, que se muestran en la figura 8, presentan resultados de las métricas mPA50 y mPA95, con puntajes de 0.8 y 0.6 respectivamente. Mientras que, la métrica precision obtuvo un puntaje de 0.67 y recall obtuvo un puntaje de 0.82, indicando que los objetos detectados van a tener más de un 80% de precisión al momento de que el software realice el etiquetado de área de los objetos reconocidos.





Figura 8. Resultados obtenidos del entrenamiento del modelo de CNN de detección de fuego del modelo preentrenado yolov5l6
Fuente: Elaboración propia


Una vez obtenido el modelo de reconocimiento de fuego, se sometió a un proceso de evaluación empleando imágenes del dataset Kaggle (Gamaleldin et al. 2018), con un total de 750 imágenes digitales con presencia explícita de fuego, para validar la efectividad del modelo, del total de imágenes se pudo detectar con éxito el 93% de las imágenes digitales, por otra parte se evaluaron 240 imágenes digitales en las cuales no existía presencia de fuego, de las cuales el 100% fueron clasificadas sin la presencia de la clase buscada.

Por otra parte, la placa de adquisición WEMOS D1 con los sensores conectados fueron puestos a prueba a 100 ciclos, para detectar la presencia de gas, humo y emisión de fuego, sin que se presentara un falso positivo o un falso negativo.

La figura 9 muestra la vista física del dispositivo DRI3 que se ha utilizado en el proceso de pruebas, como se puede observar en la imagen contenida en la figura 8 inciso a, en la parte inferior se ubican los sensores junto con la placa Wemos D1, en la sección de la derecha superior se ubica la tableta que realiza el procesamiento de visión por computadora, finalmente, en la sección de la izquierda superior se ubica el espacio para colocar las baterías que alimenten a los sensores. En las pruebas experimentales se utilizó una conexión directa a un tomacorriente, no se utilizó una batería durante estas pruebas, es por ello por lo que se observa el espacio vacío en la sección de baterías. En la figura 8 inciso b se expone la cara inferior del prototipo, en donde se aprecian los sensores y la cámara digital de la tableta electrónica, finalmente en la figura 8 inciso c se muestra una vista del prototipo en una perspectiva frontal y superior.



a) Vista del superior del prototipo en funcionamiento



b) Cara inferior del prototipo



c) Vista frontal y superior del prototipo

Figura 9. Diferentes vistas del prototipo para detección de incendios en interiores
Fuente: Elaboración propia

6.2 Escenario A

En la ejecución de la prueba del escenario A se ha podido obtener correctamente la lectura de gas LP, mediante la simulación de una fuga de este tipo de gas. En la figura 10 se presenta el mensaje que ha recibido el usuario al momento de que se detectó un evento de fuga de gas, para que pueda tomar una acción inmediata. Dentro de este proceso se ha activado la alarma acústica para alertar a las personas que se encuentren en el área afectada. El sistema de detección de incendios, al momento que se ha detectado la fuga de gas, almacena los datos en la tableta electrónica en una base datos construida en SQLite y posteriormente activa el servicio de SMS de la plataforma Twilio.




Figura 10. Mensaje recibido de la plataforma Twilio en un evento de detección de gas
Fuente: Elaboración propia

6.3 Escenario B


En el segundo escenario se activó el sistema de detección visual al momento de que se presentó la fase de incendio, el software fue capaz de detectar correctamente cuando se estaba produciendo el proceso de combustión. Se ha podido observar que el tiempo de reacción del sistema de reconocimiento visual oscila entre unos 10 y 15 segundos después de que el módulo de detección de gases se ha activado y por lo tanto ha emitido la alerta de activación de la comprobación visual. En la figura 11, se presentan los ejemplos de las imágenes que se capturaron al momento de la activación del sistema de detección de incendios, en los incisos a y b de la figura 11, se exponen las capturas de las tomas de los objetos en donde se detectó la presencia de fuego, enmarcando las secciones en donde se encuentran los objetos que se están incendiando. La activación del sistema de reconocimiento fue mediante la presencia de humo que detectó el sensor MQ9. El sistema de envío de datos para las alertas al usuario con mensajes SMS ha funcionado de manera correcta (plataforma Twilio), como se puede observar en la figura 11 c).



a) Detección de fuego 1




b) Detección de fuego 2



c) Mensaje de alerta de presencia de humo y fuego

Figura 11. Resultados obtenidos por el sistema de detección visual
Fuente: Elaboración propia

Los datos adquiridos por los sensores conectados a la placa WEMOS D1 fueron almacenados en la base de datos contenida en la tableta electrónica, como respaldo local, para posteriormente ser enviados al servicio en la nube ThingSpeak (de MathWorks) mediante un script de Python. Las variables almacenadas en el servicio en la nube son temperatura ambiente (figura 12 a), humedad relativa (figura 12 b), PPM de gas y humo (figura 12 c) y evento de flama (figura 12 d), para poder tener el registro de las condiciones normales del espacio en el DRI3 se encuentra trabajando.



c) Gráfica de lectura de PPM gas y humo d) Gráfica de lectura de evento de flama

Figura 12. Graficas de datos almacenados en la plataforma ThingSpeak
Fuente: Elaboración propia

De acuerdo con los resultados obtenidos tras la ejecución de las pruebas del DRI3, se puede observar que la propuesta es altamente efectiva para reconocer distintos factores que indican un suceso en una etapa temprana de incendios, así como en una etapa avanzada, puesto que, al tratarse de un sistema híbrido que emplea las ventajas del reconocimiento de fuego mediante visión por computadora, así como el uso de sensores electroquímicos, permite analizar distintas perspectivas al momento de indicar que se está presentando un evento de incendio, con una respuesta efectiva menor a un 1 minuto, desde el momento que los datos obtenidos son verificados, hasta que el usuario final recibe la alerta vía SMS y sonora.

La propuesta desarrollada tiene la ventaja de trabajar con la arquitectura del protocolo IP, lo cual le permite desplegar, de manera teórica, una gran cantidad de dispositivos en interiores para cubrir distintos puntos estratégicos, así como el uso de distintos tipos de hardware para realizar la lectura de gases, temperatura, humedad y flama, aprovechando la arquitectura de hardware abierto que proveen plataformas como Arduino y sus derivados, por otra parte, el software empleado para el reconocimiento visual puede implementarse en distintos tipos de hardware que corran con los sistemas operativos Windows o Linux, siendo que DRI3 está concebido para adaptarse a los entornos donde debe desempeñarse, sin estar limitado a un tipo específico de hardware y de tipo de sistema operativo. Una de las cualidades de DRI3 sobre propuestas del estado del arte, anteriormente analizadas, es que, al capturar los datos del ambiente de los sitios en donde se encuentra desplegado, permite evitar errores por fluctuaciones de elementos como la temperatura y la humedad, debido a que no permanecen constantes en todos los edificios, así como el clima en donde se encuentra puede variar, sin que ello indique que se esté presentando un incendio.

Los sistemas híbridos de detección de fuego tienen la ventaja de obtener información desde distintas perspectivas, debido a que en este caso particular, se realiza una detección empleando visión por computadora para analizar las formas del fuego, y por otra parte, el uso de sensores electroquímicos permite detectar variables como humo, fuego y temperaturas elevadas, para dar una respuesta complementaria al análisis de visión por computadora, sumando que no hay restricciones con un respecto al uso de hardware específico y la adecuación previa al clima en donde se encuentra el DRI3.

7. TRABAJO A FUTURO

De acuerdo con los resultados obtenidos del funcionamiento del DRI3, es posible ver que la detección de elementos como gas y humo, así como la detección de fuego vía imágenes digitales, ha cumplido satisfactoriamente su objetivo primario, pero existen limitaciones con respecto a la distancia de transmisión del dispositivo ESP8206, debido a que en ambientes con objetos densos la transmisión de datos oscila entre 15 y 25 metros, mientras que en espacios donde no existen obstáculos para las señales inalámbricas puede superar los 30 metros de transmisión, por lo tanto, se propone analizar la adquisición de otros dispositivos de transmisión de datos que incrementen la distancia de comunicación. El software de análisis visual trabajó de forma exitosa, pero se ha considerado incluir la clase que contemple la detección de humo, para analizar situaciones en las que no exista visiblemente presencia de fuego.

Por otra parte, se considera la conexión del DRI3 a dispositivos de control de incendios, como pueden ser aspersores de agua y de espuma antincendios, así como la activación de extractores de gases para eliminar la concentración de gases inflamables en interiores.

Finalmente, en investigaciones futuras se tiene contemplado realizar el despliegue de varios DRI3 en diversas zonas para verificar su eficacia práctica, en la presente investigación no fue posible realizarlo por las limitaciones presupuestales con las que se contaban.

8. CONCLUSIONES

Las propuestas dedicadas a la prevención y detección de incendios en espacios cerrados han tenido un gran avance, debido a que las modernas implementaciones en redes neuronales convolucionales permiten el reconocimiento de factores como el fuego, humo, así como identificación de zonas de

riesgo. Por otra parte, las redes de sensores han tenido una evolución lo suficientemente razonable para poder incorporar una gran cantidad de elementos que ayuden a detectar el cambio de variables en el entorno que indiquen un posible incendio o la presencia de uno.

De acuerdo con los resultados obtenidos, es posible visualizar que la propuesta inicial resultó efectiva para la detección de fuego en su etapa temprana, así como la detección de formas como son llamas, el modelo basado en la red convolucional YOLOv5, durante la fase de validación del modelo obtuvo una precisión del 93 % con respecto a las imágenes que pudo clasificar correctamente del dataset Kaggle.

Durante la ejecución del módulo de visión artificial se observó que el uso constante de este genera un alto costo de consumo energético y de recursos computacionales (tiempo en CPU), debido a que suele demandar grandes cantidades de tiempo en procesar la información adquirida.

Uno de los grandes retos a los que se enfrentan este tipo de propuestas es el costo de los dispositivos para realizar el procesamiento adecuado, debido a que el análisis por computadora de imágenes digitales demanda altas tasas de consumo en procesador, y, por otra parte, los sensores deben de utilizarse en puntos estratégicos que permitan monitorear gases como el CO, CO2 y los niveles de temperatura cuando se elevan de forma drástica.

El modelo que emplea el DRI3 le permite combinar hardware de distintas características, para adaptarse a situaciones del entorno en el cual se va a desplegar, así como la consideración de condiciones ambientales, las cuales son almacenadas de forma local o mediante un servicio en la nube para tomar los parámetros de referencia, esta última característica generalmente no es tomada en cuenta en las propuestas del estado del arte.

Agradecimientos

Agradecemos al Consejo Mexiquense de Ciencia y Tecnología por el apoyo otorgado para la realización del de este proyecto de investigación.

REFERENCIAS

- Albassam, N., & Khan, J. (2019). Autonomous fire safety system for gas leak detection. doi:10.47611/JSR.VI.898.
- Arshad, B., Ogie, R., Barthelémy, J., Pradhan, B., Verstaavel, N., & Perez, P. (2019). Computer vision and IoT-based sensors in flood monitoring and mapping: A systematic review. *Sensors*, 19(22), 5012.
- Campaña Bastidas, S. E., Cabrera Meza, H. E., Cervelion Bastidas, A. J., & Aguirre Cabrera, A. (2019). Capítulo 1: Las redes de sensores inalámbricas, arquitectura y aplicaciones.
- Cetinic, E., Lipic, T., & Grgic, S. (2020). Learning the principles of art history with convolutional neural networks. *Pattern Recognition Letters*, 129, 56-62.
- Choi, Myoung-Young & Jun, Sunghae. (2020). Fire Risk Assessment Models Using Statistical Machine Learning and Optimized Risk Indexing. *Applied Sciences*, 10(4), 4199. doi: 10.3390/app10124199.
- CONAPCI. (10 de septiembre 2020). Incendios urbanos en México [en línea]. <https://conapci.org/incendios-urbanos-en-mexico/>
- Di Pietro, R., Guarino, S., Verde, N. V., & Domingo-Ferrer, J. (2014). Security in wireless ad-hoc networks – A survey. *Computer Communications*, 51, 1-20. <https://doi.org/10.1016/j.comcom.2014.06.003>.
- Gamaleldin, A., Atef, A., Saker, H., & Shaheen, A. (2018). Fire Dataset. Outdoor-fire images and non-fire images for computer vision tasks. Kaggle. <https://www.kaggle.com/datasets/phylake1337/fire-dataset> [available].

Girshick, R., Donahue, J., Darrell, T., & Malik, J. (2013). Rich feature hierarchies for accurate object detection and semantic segmentation. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*.

Gómez Mena, C. (27 de abril 2022). Quemaduras, tercer lugar como causa de muerte de niños en México [en línea]. <https://www.jornada.com.mx/notas/2022/04/27/sociedad/ocupan-las-quemaduras-el-tercer-lugar-de-muertes-en-infantes-en-el-pais/>.

Guo, K., Yang, P., Guo, D., & Liu, Y. (2019). Gas leakage monitoring with mobile wireless sensor networks. *Procedia Computer Science*, 154, 430-438. doi: 10.1016/j.procs.2019.06.061.

Iqbal, M., Setianingsih, C., & Irawan, B. (2020). Deep Learning Algorithm for Fire Detection. *10th Electrical Power, Electronics, Communications, Controls and Informatics Seminar (EECCIS)*, 237-242, doi: 10.1109/EECCIS49483.2020.9263456.

Kothandapani, V., Teja, V., Kumar, S., Divya, P., & D., B. (2021). Smart gas leak detection. *International Journal of Scientific Research in Science and Technology*, 8, 952-956.

Kou, L., Wang, X., Guo, X., Zhu, J., & Zhang, H. (2021). Deep learning based inverse model for building fire source location and intensity estimation. *Fire Safety Journal*, 121. <https://doi.org/10.1016/j.firesaf.2021.103310>.

Liu, W., Anguelov, D., Erhan, D., Szegedy, C., & Reed, S. (2015). SSD: Single shot multibox detector.

López-Molina, A., Vázquez-Román, R., & Díaz-Ovalle, C. (2012). Aprendizajes del Accidente de San Juan Ixhuatepec-México. *Información tecnológica*, 23(6), 121-128. <https://dx.doi.org/10.4067/S0718-07642012000600013>.

Lule, E., Mikeka, C., Ngenzi, A., & Mukanyiligira, D. (2020). 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*, 12(9), 1391.

Meidelfi, D., Moodutor, H., Sukma, F., & Adnin, S. (2022). Android based spark and gas leak detection and monitoring. *Journal of Computer Networks, Architecture and High Performance Computing*, 4, 148-157. doi: 10.47709/cnahpc.v4i2.1489.

Mendoza, E., Fuentes, P., Benítez, I., Reina, D., & Núñez, J. (2020). Red de sensores inalámbricos multisalto para sistemas domóticos de bajo costo y área extendida. *Revista Iberoamericana de Automática e Informática industrial*, 17(4), 412-423.

Muhammad, K.; Ahmad, J.; Mehmood, I.; Rho, S.; and Baik, S. W. (2018). Convolutional Neural Networks Based Fire Detection in Surveillance Videos. *IEEE Access*, vol. 6, 18174-18183, doi: 10.1109/ACCESS.2018.2812835.

Mwedzi, N. A., Nwulu, N. I., and Gbadamosi, S. L. (2019). Machine Learning Applications for Fire Detection in a Residential Building. *2019 IEEE 6th International Conference on Engineering Technologies and Applied Sciences (ICETAS)*, 1-4, doi: 10.1109/ICETAS48360.2019.9117318.

Nazir, A.; Mosleh, H.; Takruri, M.; Jallad, A.-H.; Alhebsi, H. (2022) Early Fire Detection: A New Indoor Laboratory Dataset and Data Distribution Analysis. *Fire*, 5(11). <https://doi.org/10.3390/fire5010011>.

Park, M., & Ko, B. C. (2020). Two-step real-time night-time fire detection in an urban environment using Static ELASTIC-YOLOv3 and Temporal Fire-Tube. *Sensors*, 20(8), 2202.

Pavez, F. A. (2021). Manual de autoprotección contra incendios para un emprendimiento unipersonal de producción artesanal(Bachelor's thesis).

Raj, S., Ankit, T., Rishabh, S., & Saurabh, S. (2021). Gas leak detection and smart alerting using IOT. *I-manager's Journal on Information Technology*, 10 (12). doi: 10.26634/jit.10.3.15052.

Redmon, J., Divvala, S., Girshick, R., & Farhadi, A. (2016). You only look once: Unified, real-time object detection. *IEEE 2016 conference on computer vision and pattern recognition (CVPR)*, p. 779-788. 10.1109/CVPR.2016.91.

Rostami, A.; Shah-Hosseini, R.; Asgari, S.; Zarei, A.; Aghdami-Nia, M.; Homayouni, S. (2022) Active Fire Detection from Landsat-8 Imagery Using Deep Multiple Kernel Learning. *Remote Sensors*, 14 (992). <https://doi.org/10.3390/rs14040992>.

Rzaij, W. & Al-Obaidi, B. (2022). Evaluation of a fire safety risk prediction model for an existing building. *Journal of the Mechanical Behavior of Materials*, 31(1), 64-70. <https://doi.org/10.1515/jmbm-2022-0007>.

Saponara, S., Elhanashi, A., & Gagliardi, A. (2021). Real-time video fire/smoke detection based on CNN in antifire surveillance systems. *J Real-Time Image Proc*, 18, 889–900. <https://doi.org/10.1007/s11554-020-01044-0>.

Secretaría de Salud (27 de abril 2021). Cuenta México con centro de alta especialidad para atender quemaduras graves [en línea]. <https://www.gob.mx/salud/prensa/170-cuenta-mexico-con-centro-de-alta-especialidad-para-atender-quemaduras-graves>.

Simonyan, K., & Zisserman, A. (2014). Very deep convolutional networks for large-scale image recognition. *arXiv* 1409.1556.

Sharma, A., Singh, P. K., & Kumar, Y. (2020). An integrated fire detection system using IoT and image processing technique for smart cities. *Sustainable Cities and Society*, 61, 102332.

Sze, V., Chen, Y. H., Yang, T. J., & Emer, J. S. (2020). Efficient processing of deep neural networks. *Synthesis Lectures on Computer Architecture*, 15(2), 1-341.

Thomazini, D., & de Albuquerque, P. U. B. (2020). *Sensores industriais: fundamentos e aplicações*. Saraiva Educação SA.

Wang, K.; Zhang, Y.; Wang, J.; Zhang, Q.; Chen, B. and Liu, D. (2018). Fire Detection in Infrared Video Surveillance Based on Convolutional Neural Network and SVM. 2018 IEEE 3rd International Conference on Signal and Image Processing (ICSIP), 162-167, doi: 10.1109/SIPROCESS.2018.8600510.

Wang, Z., Zhang, T., Wu, X., & Huang, X. (2022). Predicting transient building fire based on external smoke images and deep learning. *Journal of Building Engineering*, 47. <https://doi.org/10.1016/j.jobbe.2021.103823>.

Yang, Z.; Bu, L. T., Wang, J., Ouyang, P., & Yuan, P. (2018). Fire Alarm for Video Surveillance Based on Convolutional Neural Network and SRU. 2018 5th International Conference on Information Science and Control Engineering (ICISCE), 232-236, doi: 10.1109/ICISCE.2018.00056.

Yang, Z.; Bu, L.; Wang, T.; Yuan, P.; Jineng, O. (2020). Indoor Video Flame Detection Based on Lightweight Convolutional Neural Network. *Pattern Recognition and Image Analysis*, 30, 551-564. doi: 10.1134/S1054661820030293.

Zhang, Y., Geng, P., Sivaparthipan, C. B., & Muthu, B. A. (2021). Big data and artificial intelligence based early risk warning system of fire hazard for smart cities. *Sustainable Energy Technologies and Assessments*, 45, 100986.



Esta obra está bajo una licencia de Creative Commons
Atribución-NoComercial-CompartirIgual 4.0 Internacional.