

Recibido 22 Mar 2026

ReCIBE, Año 15 No. 2, mayo 2026

Aceptado 24 May 2026

Sistema de Alerta Temprana de Incendios para Personas con Discapacidad Auditiva Basado en IoT y Señales Hápticas

Early Fire Warning System for People with Hearing Disabilities Based on IoT and Haptic Signals

Héctor Caballero Hernández²

nv_addstar@hotmail.com

German Becerril Donato¹

2021150480104@tesjo.edu.mx

Vianney Muñoz Jiménez²

vmunozj@uaemex.mx

Marco Antonio Ramos Corchado²

correo4@academicos.udg.mx

1 Tecnológico de Estudios Superiores de Jocotitlán, México

2 Universidad Autónoma del Estado de México, México

Resumen

El presente trabajo describe el desarrollo de un sistema de seguridad IoT híbrido diseñado para la detección temprana de incendios mediante la integración de sensores de temperatura, humedad (DHT11) y CO (MQ-7) conectados a un ESP32 que reenvía la información a un smartwatch y un smartphone (SMS/Telegram) para alertar a usuarios con discapacidad auditiva en tiempo real. La metodología empleada consta de una etapa de adquisición de datos (placa ESP32) y una etapa de procesamiento con motor de inferencia difusa implementado en un TicWatch E3 con Wear OS 3.5 utilizando el lenguaje Kotlin para analizar las variables de entrada y determinar el nivel de riesgo (Bajo, Medio, Alto y Extremo). El sistema determina automáticamente entre amenazas por humo o fuego activo apoyado de confirmación visual mediante el algoritmo Yolov8s, cuyos resultados de detección son enviados a través de un mensaje de Telegram. Los resultados demuestran que la aplicación es capaz de activar retroalimentación háptica y reproducir vídeo con señas de alertamiento en lengua de señas mexicana en el smartwatch al superar los umbrales de seguridad. Durante la etapa de pruebas, se obtuvieron resultados sobresalientes al aplicar las métricas de precisión y exactitud, con un resultado del 97%, mientras que MAE (Mean Absolute Error) presentó un puntaje de 0.0327 en una simulación Monte Carlo de 3000 casos para validar el motor difuso, mientras que, en las pruebas en entorno real, el sistema reaccionó de forma precisa, con una aceptación favorable por parte de los usuarios que participaron en los experimentos.

Español: IoT, lógica difusa, Wear OS, detección de incendios, computación vestible.

Abstract

This paper describes the development of a hybrid IoT security system designed for early detection of fires. It integrates temperature and humidity (DHT11) and CO (MQ-7) sensors connected to an ESP32, which sends the information to a smartwatch and a smartphone (SMS/Telegram) to alert users with hearing impairments in real time. The method consists of a data acquisition stage (ESP32 board) and a processing stage using a fuzzy inference engine implemented on a TicWatch E3 with Wear OS 3.5. The Kotlin programming language is used to analyze the input variables and figure out the risk level (Low, Medium, High, and Extreme). The system automatically distinguishes between smoke and active fire threats, supported by visual confirmation using the Yolov8s algorithm. Detection results are sent via a Telegram message. The results show that the application can activate haptic feedback and play a video with Mexican Sign Language alerts on the smartwatch when safety thresholds are exceeded. During the testing phase, outstanding results were obtained when applying the precision and accuracy metrics, with a result of 97%, while MAE (Mean Absolute Error) presented a score of 0.0327 in a Monte Carlo simulation of 3000 cases to validate the fuzzy engine, while in the tests in the real environment, the system reacted accurately, with a favorable acceptance by the users who participated in the experiments.

English: IoT, fuzzy logic, Wear OS, fire detection, wearable computing.

1 Introducción

En la actualidad, los incendios en diversos entornos se han convertido en una amenaza de gran impacto para la seguridad humana, así como en los sectores económicos y entornos ecológicos. De acuerdo con reportes recientes del Servicio de Vigilancia de la Atmósfera de Copernicus (Copernicus, 2024), la temporada de incendios 2023-2024 fue devastadora a nivel mundial, con un total de 2.1 millones de kilómetros cuadrados de área quemada y un 16% más de emisiones de CO_2 en relación con el promedio histórico, alcanzando las 8.6 mil millones de toneladas. Por otra parte, en el periodo de 2024-2025 se registraron pérdidas por 215 mil millones de dólares por exposición al riesgo de incendios (CRED, 2025). Estos registros reflejan que, a pesar del impacto devastador de

los incendios, existe una brecha importante en la implementación de sistemas de prevención y extinción de incendios para mitigar su impacto, previniendo pérdidas, tanto materiales como humanas. Los detectores actuales de incendios suelen trabajar con sistemas binarios simples, lo cual los convierte en dispositivos ineficientes, de acuerdo con la Agencia Federal para el Manejo de Emergencias (FEMA, 2025), indica que los detectores de humo pueden fallar o no dar una alerta temprana en hasta un 35% en caso de incendios. Las falsas alarmas en estos dispositivos pueden ser por presencia de polvo, vapor, entre otros, lo cual genera que los usuarios en un 19% de los casos lleguen a desconectarlo, incrementando la vulnerabilidad (Ahrens, 2021; Istre et al., 2020). Otra de las limitaciones que presentan los sistemas de detección de incendios, que se instalan en techo y paredes es que el método de avisar sobre humo o fuego es mediante alarmas sonoras, lo cual genera que personas con discapacidad auditiva no puedan percibir dicha alerta, además de que no existe confirmación visual para el estado actual del área donde se ha alertado el incidente, siendo un área de oportunidad importante por abordar (Ahrens, 2021; NFPA, 2024).

En este mismo contexto, se han desarrollado diversas soluciones basadas en la integración del internet de las cosas (IoT) e inteligencia artificial (IA) para la detección de incendios. Algunas investigaciones basadas en el uso de IoT para la detección de incendios, como se puede observar en los trabajos de Arifia & Mulyana (2025) y Cahyadi & Teary (2026) demostraron la factibilidad de sistemas basados en ESP32 con sensores DHT22, - y MQ-7, con la capacidad de transmitir información y generar alertas en tiempo real empleando servicios como Telegram. En Mahbub et al. (2021) integraron sistemas de iluminación, monitoreo ambiental y detección de emergencias en una plataforma centralizada de bajo costo. En Pincott et al. (2022) propusieron el uso de R-CNN Inception V2 y SSD MobileNetV2 para mejorar la detección en interiores y vincularla con sistemas HVAC. Asimismo, en Nazir et al. (2022) propusieron nodos LoRaWAN (Long Range Wide Area Network) para detectar incendios de combustión lenta mediante sensores eCO₂ y TVOC. Por otra parte, en Mukhiddinov et al. (2022) desarrollaron un sistema para personas con discapacidad visual que, mediante una cámara acoplada y un servidor que emplea algoritmos de IA, con una alerta acústica para avisar sobre la presencia de fuego. Los trabajos de Rachman & Hendrantoro (2020) y Vaegae et al. (2024) demostraron que la implementación de múltiples sensores mediante lógica difusa reduce significativamente los falsos positivos y mejora la fiabilidad operativa en interiores y entornos urbanos inteligentes.

Por otra parte, la visión artificial permite validar visualmente las señales de incendio, el modelo FireNetCNN de Alam et al. (2025), reportó una exactitud del 99.05%, superando arquitecturas como VGG16. El trabajo de El-Madafri et al. (2024) presenta un modelo ligero basado en MobileNetV3 que utiliza extracción de conocimiento para detectar incendios forestales en tiempo real y en dispositivos de bajos recursos, la métrica de especificidad de elementos de confusión (CES), el sistema logró una precisión del 93.36% al distinguir eficazmente fuego real de falsos positivos como humo o niebla. Sin embargo, el alto costo computacional de las CNN limita su implementación en IoT, favoreciendo arquitecturas híbridas donde la inferencia se ejecuta en equipos externos. En Ahn et al. (2023) entrenaron un modelo EFDM (early fire detection model) con más de 10,000 imágenes, alcanzando altos índices de precisión. La investigación de Li et al. (2023) presenta el diseño de una arquitectura onestage comparable a Yolo (you only look once), pero con una décima parte del tamaño del modelo. En el trabajo de Deng et al. (2023) fusionaron datos de distintos sensores con una CNN ligera logrando un 99.1% de

precisión. En tareas de segmentación semántica, Hou et al. (2023) superaron el 90% de precisión global y 80% de mIoU. La investigación de An et al. (2023) presenta la combinación de suavizado exponencial y fusión multisensorial con una precisión del 98%. En Ali & Ghodrat (2025) introdujeron una red 3D con atención espacial y temporal (90.46% de precisión). Finalmente, Peng & Kim (2025) propusieron YOLOHF, entrenado con un dataset especializado en incendios domésticos mejorando el rendimiento en un 4.2% con respecto a métodos previos.

Las investigaciones anteriores presentan una tendencia en el uso del IoT y de la IA en soluciones basadas en visión artificial mediante redes CNN. La implementación de microcontroladores de bajo costo, redes de comunicación y la aplicación de lógica difusa han permitido optimizar la obtención de datos de múltiples sensores en tiempo real, reduciendo el ruido ambiental y los falsos positivos. Los modelos basados en CNN han alcanzado el 99% de precisión de detección visual de fuego, aunque el costo computacional es elevado, por lo tanto, en otras investigaciones han optado por sistemas híbridos con modelos ligeros para la detección de incendios para equilibrar la eficacia de la detección con el costo computacional. En la presente propuesta se plantea un sistema híbrido de detección de incendios el cual integra una solución con una arquitectura cliente-servidor donde un nodo IoT basado en una placa ESP32 que obtiene variables ambientales como temperatura y humedad, donde el procesamiento de la decisión de determinar un incendio reside en un smartwatch con Wear OS 3.5 dirigido principalmente para población vulnerable con problemas de audición (CNDIPD, 2017), tomando en cuenta la investigación Aksüt y Eren (2025) que marca la utilidad de los dispositivos wearables para cuestiones de salud y de seguridad.

2 Metodología

La propuesta metodológica considera los puntos analizados en la sección anterior para presentar un sistema con la capacidad de detección de incendios en espacios interiores para indicar la presencia de un incendio, enfocándose a personas que sufren discapacidad auditiva. A continuación, se presenta la Figura 1 con el flujo de trabajo con el que se construyó el sistema de alerta temprana (SAT), así como la descripción de cada una de las etapas del proceso de construcción del SAT.



Figura 1. Diagrama del desarrollo del SAT

- **Diseño y planificación conceptual.** En esta etapa se seleccionaron los componentes principales (ESP32, sensores, protocolos de comunicación) y se definió la arquitectura de procesamiento, con la ejecución de YOLOv8s (Jocher et al., 2023) en una PC. Se establecieron las vistas y contenedores arquitectónicos

bajo la referencia IEEE 2413 (Institute of Electrical and Electronics Engineers [IEEE], 2020).

- Prototipado e implementación de hardware. Se integraron físicamente los dispositivos como ESP32 con sensores DHT11 y MQ-7 sobre una proto tarjeta. Se ejecutaron tareas de verificación eléctrica, la estabilidad en la alimentación eléctrica y estabilización de los sensores.
- Desarrollo de software y lógica. En esta etapa se implementaron un servicio API REST y Yolov8s con Python 3.12. Tomando en cuenta que el servicio de detección de imágenes se ejecuta mediante una PC, y la detección de variables físicas por la placa ESP32 siguiendo el estándar IEEE 2413.
- Integración y pruebas unitarias. Las pruebas unitarias se basaron en establecer la unión de los subsistemas y la validación individual del flujo de datos sensores → ESP32 → servidor → inferencia → decisión → notificación, verificando la interoperabilidad mediante IEEE 2413.
- Validación del sistema. La validación del sistema se dividió en 3 subetapas: la primera consiste en validar el desempeño del motor de inferencia difuso mediante simulación Monte Carlo (Kroese et al., 2011) tomando 3000 casos, y realizando la medida de MAE (Mean Absolute Error), así como métricas de exhaustividad, precisión y puntuación F1 siguiendo el algoritmo 1. La segunda subetapa es la validación del modelo de Yolov8s, finalmente, la subetapa 3 consistió en verificar el desempeño de propuesta en un entorno real.

Para evaluar la respuesta del proceso de simulación Monte Carlo se han empleado las siguientes métricas de desempeño (Rusell y Norving, 2021).

Exactitud. Mide la proporción de predicciones positivas sobre el número total de predicciones, ecuación (1).

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

Precisión. Mide la proporción de instancias clasificadas como positivas, ecuación (2).

$$\text{Precisión} = \frac{VP}{VP + FP} \quad (2)$$

Puntuación F1. Es la media armónica de la precisión y la exhaustividad, proporciona una medida que equilibra ambas métricas, ecuación (3).

$$F1 = 2 \times \frac{\text{Precisión} \times \text{Exhaustividad}}{\text{Precisión} + \text{Exhaustividad}} \quad (3)$$

Exhaustividad. Mide la capacidad del modelo para encontrar todos los casos positivos reales, ecuación (4)

$$\text{Exhaustividad} = \frac{VP}{VP + FN} \quad (4)$$

MAE (Mean Square Error): Mide la magnitud promedio de los errores en un conjunto de predicciones, sin tener en cuenta su dirección (James et al., 2013), ecuación (5).

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (5)$$

Donde:

Verdadero positivo (VP). El modelo predijo correctamente la clase positiva.

Falso positivo (FP). El modelo predijo incorrectamente la clase positiva.

Falso negativo (FN). El modelo predijo incorrectamente la clase negativa.

Verdadero negativo (VN). El modelo predijo correctamente la clase negativa.

n es el número total de observaciones

y_i es el valor real

$\hat{y}_i$ es el valor predicho por el modelo

$|y_i - \hat{y}_i|$ es el valor absoluto de la diferencia

Despliegue y mantenimiento. Finalmente, en esta etapa se procedió con la instalación del prototipo en un entorno real para determinar su efectividad de detección de las variables de humo, fuego y fuego con el sistema de reconocimiento visual.

Algoritmo 1. Validación del motor de inferencia difusa empleando simulación Monte Carlo

Inicio

Definir iteraciones $N = 300$

Iniciar contadores de aciertos y errores en 0.

Iniciar ciclo de Simulación N

Lanzar una probabilidad para elegir uno de los 5 escenarios.

Generar un valor aleatorio para *Temperatura*.

Generar un valor aleatorio para *Humedad*.

Generar un valor aleatorio para *Gas*.

Fórmula: Valor = Min + (Max - Min) × Random(0,1)

Ingresar ($T_{sim}, H_{sim}, G_{sim}$) al algoritmo de fusificación

Obtener la predicción del sistema: $P_{sistema}$ (ALTO).

Consultar la "Etiqueta" del escenario

Obtener la etiqueta real: E_{real} .

Si $P_{sistema} == E_{real} \rightarrow$ Sumar 1 Acierto.

Si $P_{sistema} \neq E_{real} \rightarrow$ calcular el error

Fin del Ciclo:

Calcular MAE

Generar Matriz de Confusión.

Calcular precisión, exactitud y puntajes F1.

Fin

3 Diseño

En esta sección se presenta el proceso del diseño del SAT para la detección de incendios en entornos de casa-habitación y su asistencia a personas con discapacidad auditiva. La Figura 2 ilustra el diagrama de funcionamiento general de la propuesta. El

proceso de detección de incendios inicia con la adquisición de datos ambientales a través del ESP32, el cual monitorea temperatura, humedad y concentración de gases (monóxido de carbono, CO); estos valores son procesados mediante lógica difusa. Al detectarse cambios en el ambiente, el sistema activa la validación temporal, durante este intervalo de tiempo, el verificador de vídeo procede a analizar los frames en tiempo real mediante el algoritmo Yolov8s para detectar la presencia de fuego o humo. Solo si existe coincidencia entre la detección realizada por los sensores y el análisis por visión artificial, se emite una alerta de incendio. Esta notificación se transmite al usuario mediante señales hápticas en un *smartwatch* y alertas de mensajes SMS y de Telegram en tiempo real empleando un *smartphone*.




Figura 2. Diagrama general del sistema

A continuación, el Algoritmo 2 describe la lógica de control implementada en el ESP32, para el monitoreo continuo de variables ambientales, este algoritmo evalúa las lecturas en tiempo real y, al detectar una concentración de CO superior al umbral predefinido, inicia con una de validación por de siete segundos, enviando al mismo tiempo una solicitud de verificación al servicio de visión artificial.

Algoritmo 2. Gestión de alertas y puente de datos

```

1;
  Entrada: Lecturas de sensores MQ-7 ( $S_{gas}$ ), DTH11 ( $S_{temp}, S_{hum}$ )
  Salida: Objeto JSON {tem, hum, gas, fuegoYolo, esperandoYolo}
2  fuegoYolo  $\leftarrow$  falso;
3  esperandoYolo  $\leftarrow$  falso;
4   $T_{inicio} \leftarrow 0$ ;
5  Mientras verdadero hacer
6     $S_{temp}, S_{hum}, S_{gas} \leftarrow$  LeerSensores();
7    Si  $S_{gas} > 1100$  and esperandoYolo and  $\neg$  fuegoYolo entonces
8      esperandoYolo  $\leftarrow$  verdadero;
9       $T_{inicio} \leftarrow$  TiempoActual();
10     HTTP_POST(ServidorPython, "trigger-true");
11     Si esperandoYolo and ( TiempoActual() –  $T_{inicio} > 7s$ ) entonces
12       esperandoYolo  $\leftarrow$  falso;
13     Si  $S_{gas} < 600$  and fuegoYolo entonces
14       fuegoYolo  $\leftarrow$  falso
15     devolver JSON( $S_{temp}, S_{hum}, S_{gas}, fuegoYolo, esperandoYolo$ );
  
```

Por otra parte, el Algoritmo 3 presenta el funcionamiento del servicio de verificación visual basado en Yolov8s, el cual es activado por la detección de concentraciones las variables temperatura, humedad y CO. Durante el intervalo de verificación, el servicio analiza los frames de video y evalúa la confianza de las predicciones del modelo con el motor de lógica difusa. Si la certeza supera el umbral configurado, se confirma el evento de incendio y se notifica al ESP32 mediante una petición HTTP, cerrando así el lazo de control para terminar con la validación de los sensores aplicada en la ventana de tiempo asignada.

Algoritmo 3. Flujo de trabajo de validación visual Yolov8s	
	Entrada: Señal de activación (Ttrigger), Flujo de video (Vstream)
	Salida: Notificación HTTP POST al ESP32
1	Umbralcerteza β 0.70;
2	Si Ttrigger – verdadero entonces
3	// Definir ventana de tiempo de 7 segundos
4	Tventana β TiempoActual() + 7s;
	confirmado β falso
5	Mientras TiempoActual() Tventana and $\neg$ confirmado
	Hacer
6	Img β CapturarFrame(Vstream);
	// Inferencia del modelo entrenado fire.pt
7	BBoxes,Conf β Yolo_Inference(Img);
11	Si $\max(\text{Conf}) \geq \text{Umbralcerteza}$ entonces
12	Confirmado β verdadero;
	//Enviar alerta única para evitar saturacion
13	HTTP_POST(ESP32_ip/yolo_alert);
15	Break à Finalizar detección;

La Figura 3 muestra el diagrama de contexto del SAT, donde se identifican los actores, dispositivos y servicios externos involucrados en el proceso integral de detección y verificación de incendios en interiores. En este diagrama la cámara envía video en tiempo real a la aplicación del servidor de clasificación de vídeo, que ejecuta la verificación visual mediante el modelo Yolov8s, mientras que el ESP32 transmite continuamente las variables de temperatura, humedad y CO, permitiendo realizar el análisis para determinar el nivel de riesgo mediante el motor de lógica difusa. Una vez que el servidor confirma una situación de incendio con base en los datos ambientales y la evidencia visual, el SAT genera alertas hápticas y visuales con un vídeo de señas LSM al usuario mediante el *smartwatch*. Por otra parte, además el sistema puede enviar notificaciones automáticas a servicios externos, como APIs de mensajería, Telegram y Twilio, para informar a contactos de emergencia empleando el *smartphone* del usuario y ampliar la capacidad de respuesta del sistema.




Figura 3. Contexto del SAT

La Figura 4 presenta la arquitectura lógica del SAT organizada mediante contenedores, en esta vista, el ESP32 opera como contenedor de adquisición física, limitándose a capturar variaciones en la temperatura, humedad y presencia de CO en el aire, y transmitir datos mediante protocolos HTTP/JSON con una red WiFi 2.4 GHz. El servicio actúa como el contenedor de procesamiento, donde se ejecuta el API REST, el proceso de detección de fuego corre a cargo de YoloV8s y los resultados de la verificación visual proveniente de la cámara. El *smartwatch* con Wear OS actúa como el contenedor responsable de ejecutar el motor de lógica difusa y generar la notificación háptica y visual al usuario final, mientras los mensajes enviados al *smartphone* permiten realizar una comprobación visual del evento de incendio con el mensaje de Telegram, y un mensaje redundante enviado vía SMS. Finalmente, los servicios externos operan como contenedores independientes para transmitir la alerta a los destinatarios del SAT.




Figura 4. Componentes principales del SAT

La Figura 5 representa la topología física y los enlaces de comunicación en la red local. En este caso, el ESP32 trabaja como servidor HTTP en la red LAN, conectado a un AP (Access Point) que opera a una frecuencia de 2.4 GHz. El servidor se ubica en el mismo flujo de datos para recibir el video de la cámara y consultar periódicamente el estado del ESP32. Cuando se confirma un evento de incendio, el servidor envía una petición POST a /yolo_alert para posteriormente notificar al *smartwatch* y activar la alerta remota a través de Twilio y Telegram mediante el protocolo HTTPS, enviando mensajes SMS y con la captura de la escena en donde se ha detectado la presencia de humo o fuego, respectivamente.




Figura 5. Despliegue de topología física y de red del SAT

Las ecuaciones (6), (7) y (8) presentan los rangos de la operación del motor de inferencia, en la ecuación (6) y (7), se toman el rango de valores de 50 % al 10 %, mediante una función triangular, finalmente la ecuación (8) representa la función de pertenencia para CO de tipo triangular, que va de 200 a 450 ppm (partes por millón).

$$\mu_{Calor}(T) = \begin{cases} 0 & si\ T \leq 30 \\ \frac{T-30}{20} & si\ 30 < T < 50 \\ 0 & si\ T \geq 50 \end{cases} \quad (6)$$

$$\mu_{Seco}(H) = \begin{cases} 1 & si\ H \leq 10 \\ \frac{50-H}{40} & si\ 10 < H < 50 \\ 0 & si\ H \geq 50 \end{cases} \quad (7)$$

$$\mu_{Gas}(G) = \begin{cases} 0 & si\ G \leq 200 \\ \frac{x-200}{250} & si\ 200 < G < 450 \\ 1 & si\ G \geq 450 \end{cases} \quad (8)$$

El cálculo de los riesgos parciales se realiza a través de las ecuaciones (9) y (10), mientras que la ecuación (11) se presenta función de agregación.

$$\alpha_{Fuego} = \min(\mu_{Calor}(T), \mu_{Seco}(H)) \quad (9)$$

$$\alpha_{Humo} = \mu_{Gas}(G) \quad (10)$$

$$Z = \max(\alpha_{Fuego}, \alpha_{Humo}) \quad (11)$$

La ecuación (12) presenta la defusificación por umbrales para la toma de decisiones sobre las salidas del sistema.

$$L(Z) = \begin{cases} Bajo & si\ Z \leq 0.10 \\ Medio & si\ 0.10 < Z < 0.41 \\ ALTO & si\ 0.41 \leq Z < 0.80 \\ Extremo & si\ Z \geq 0.80 \end{cases} \quad (12)$$


Por otra parte, en la Figura 6 a) se muestra el inicio de la aplicación, donde está la opción de consejos para actuar al presentarse un incendio, así como la operación de la aplicación, por otra parte, la Figura 6 b) presenta el indicador de nivel de peligro, basado en la concentración de CO (ppm), utiliza códigos de color y tipografía especial para que el usuario interprete la información presentada de manera rápida. La Figura 6 c) presenta el panel de monitoreo en tiempo real, donde se visualizan las variables críticas (temperatura, humedad y CO) con actualización continua, las cuales está siendo monitoreadas a través del ESP32 y cuyos datos viajan mediante una red WiFi. Finalmente, en la Figura 6 d) se muestra la prototarjeta del Wemos con los sensores DHT11 y el MQ-7 conectados para realizar la detección de las variables en el entorno.




a) Inicio de la aplicación



b) Indicador de riesgo



c) Obtención de resultados



d) Sensores conectados al ESP32

Figura 6. Interfaz final de la aplicación de aviso de detección de incendios

4. Pruebas y Validación

En esta sección se presentan los resultados obtenidos al evaluar el SAT con asistencia para personas con discapacidad auditiva. El proceso de pruebas se basó en obtener la respuesta del motor de inferencia difusa mediante una simulación Monte Carlo, y la respuesta del sistema en la detección de incendios en un escenario real controlado, para la verificación de la detección oportuna de incendios, así como la respuesta del usuario con respecto a la usabilidad de la aplicación y del *smartwatch*.

Con respecto a la configuración del módulo de visión artificial, se ha configurado con un algoritmo de Yolov8s, la red de detección de fuego se basó en un dataset con 1000 imágenes sobre el contexto de fuego, empleando los hiperparámetros por defecto del framework, con una configuración de 300 épocas, tamaño de lote de 16 y una resolución de entrada de 640×640 píxeles utilizando el optimizador SGD. En la Tabla 1 se presentan los elementos tanto de hardware y software, así como condiciones para la ejecución del detector de incendios.

Tabla 1. Elementos de hardware, software y condiciones para obtener los resultados de ejecución del SAT


Elementos	Descripción
Software de desarrollo	Android Studio Panda 2025.3.1 con Kotlin Entorno de desarrollo de Arduino para la codificación del ESP32 Editor HTML y Javascript Python 3.13.3 Dataset personalizado de 1000 imágenes sobre fuego y humo.
Hardware empleado	- Computadora portátil HP Pavilion con Sistema operativo Windows 10, 12 GB de RAM y 500 GB de almacenamiento. - Reloj inteligente Movoi TicWatch E3, con procesador Qualcomm Snapdragon Wear 4100, 1GB de RAM y 8GB de ROM. Pantalla LCD de 1.3 pulgadas (360x360 pixeles), GPS integrado, NFC para pagos, sensores de SpO2 y frecuencia cardíaca. - Placa ESP32 integra procesador Dual-Core (240 MHz), conectividad Dual (Wi-Fi + Bluetooth BLE), 18 canales ADC de 12 bits, 30 pines GPIO (entradas/salidas) y modo de ultra bajo consumo. - Sensor de temperatura y humedad DTH11 y MQ-7 detector de presencia de monóxido de carbono. - Smartphone Xiaomi POCO M3 Pro 5G con procesador MediaTek Dimensity 700, con pantalla FHD+ de 6.5" a 90Hz, batería de 5000mAh con carga rápida de 18W y cámara triple de 48MP.
Sujetos de pruebas	10 de personas con discapacidad auditiva moderada

La simulación de Monte Carlo fue ejecutada sobre un conjunto de 3000 escenarios estocásticos que abarcaron condiciones normales hasta eventos de incendios, se empleó para dar validez al motor de inferencia difusa, teniendo en cuenta que se alcanzó una exactitud global del 97.57%, Tabla 2, y un MAE de 0.0327, lo que demuestra una desviación mínima entre la predicción y un evento real de incendio. El sistema demostró un comportamiento con una zona de amortiguamiento para los casos de “alto” y “extremo” con respecto a la probabilidad de un incendio, manteniendo una exhaustividad del 98% en la categoría extremo (garantizando que prácticamente ningún conato de incendio real fuera ignorado), y obteniéndose un equilibrio entre un aviso oportuno y la reducción de probabilidades de falsas alarmas.

Tabla 2. Resultados obtenidos al evaluar el motor de inferencia difusa

Nivel de Riesgo	Precisión	Exhaustividad	Puntaje F1	Casos detectados
Bajo	0.98	0.99	0.99	1244
Medio	0.96	1.00	0.98	598
Alto	0.60	0.43	0.50	76
Extremo	1.00	0.98	0.99	1082
Promedio ponderado	0.97	0.98	0.97	3000

La matriz de confusión presentada en la Figura 7, permite observar el desempeño del motor de inferencia para los distintos casos hipotéticos planteados, en la categoría de “extremo” se obtuvieron 1060 aciertos y solo 22 casos donde se clasificó como “alto”, esto indica que ningún incendio se grave fue clasificado como bajo o medio, garantizando una alerta oportuna de incendio en un escenario real. Por otra parte, las categorías de “bajo” y “medio” obtuvieron 1236 y 598 aciertos respectivamente, con mínimos errores, lo cual garantiza que el sistema indicó condiciones de operación normal que evitan errores en la generación de falsas alarmas. Es de notarse que se presentó un solapamiento en la clase “alto”, debido a las características de transición de la lógica difusa, pero sin comprometer la capacidad del sistema para dejar pasar una alerta de incendio.

**Figura 7.** Matriz de confusión para la detección de incendios empleando lógica difusa

La Figura 8 a) ilustra la respuesta del sistema al momento de realizar una consulta sobre el estado actual del interior, en este sentido el sistema obtiene los datos proporcionados por el ESP32 y el motor de inferencia incorporado en el TicWatch E3, en este caso no hay riesgo de incendio. Por otra parte, la Figura 8 b) presenta la evidencia de las pruebas en un escenario real realizadas con un voluntario de 50 años diagnosticado con hipoacusia conductiva, el fuego se ha generado de manera controlada para activar al sistema, de tal forma que se envíen las alertas de humo y fuego con su respectiva señal en LSM de estos elementos, así como la ejecución de la vibración del E3 para alertar al usuario (señal háptica). Finalmente, las Figuras 8 c) y 8 d) muestran la respuesta del SAT

al momento enviar los resultados de detección visual en donde se ha detectado un evento de fuego, mediante YOLOv8s, y la alerta empleando SMS dirigido desde el servicio Twilio y con el servicio de Telegram para la confirmación visual. Este escenario reproduce una escena cotidiana, donde se puede presentar un incendio en una ubicación donde generalmente se manejan fuentes de energía (cocina) y existen combustibles disponibles. De acuerdo con la respuesta del SAT la alerta de incendio se presenta en tiempo real. Estas pruebas validan la hipótesis de respuesta inmediata y con baja incertidumbre en los eventos acaecidos, donde el sistema logra comunicar la situación de presencia de un incendio de forma efectiva sin depender del canal auditivo, garantizando el alertamiento a personas con discapacidad auditiva.



a) Interfaz recibiendo datos del ESP32



b) Uso del smartwatch por el usuario



- c) Envío de imagen mediante Telegram para notificar la alerta al usuario para comprobar la gravedad del incendio.
- d) Envío de SMS mediante Twilio para alertar al usuario sobre la presencia de fuego/humo en el interior.

Figura 8. Resultados obtenidos en la prueba de entorno físico

Durante las pruebas de entorno real a los usuarios se les realizaron cuestionamientos sobre la practicidad del SAT, a lo cual respondieron positivamente sobre la practicidad relativa al uso del TicWatch E3 y del *smartphone*, siendo elemento con los cuales pueden convivir en el día a día sin interferir en unas actividades cotidianas.

5 Discusión de resultados

De acuerdo con los resultados obtenidos durante la etapa de pruebas se pueden observar distintos aspectos importantes. El primer aspecto es que la simulación Monte Carlo permitió comprobar la eficacia del motor de lógica difusa bajo condiciones difícilmente reproducibles en entornos con pruebas reales, garantizando la estabilidad del sistema para evitar generar falsas alarmas, siendo este uno de los puntos más importantes que se han buscado reducir con respecto a sistemas de detección de incendios que trabajan con una lógica convencional, en estas pruebas cabe destacar las métricas precisión, exhaustividad y puntuación F1 superaron los 0.97 puntos en todos los casos, mientras que el MAE estuvo por debajo de los 0.038 puntos. El segundo aspecto es, como se mencionó anteriormente, las personas con discapacidad auditiva tienen problemas para percibir alertas sonoras, ya sea por su grado de hipoacusia o por el lugar en donde se encuentran ubicadas las alarmas, mientras que con el *smartwatch* al contar con una respuesta de vibración garantiza que el usuario haga uso del sistema en tiempo real con una comprensión total de lo que está ocurriendo. Durante las pruebas de entorno real, los usuarios reconocieron la efectividad del SAT en la generación de las alarmas, tanto a nivel visual con los mensajes en LSM desplegados en el TicWatch E3, como las desplegadas en Telegram con comprobación visual del área afecta, así como el envío de mensajes SMS vistos desde el *smartphone*. El tercer aspecto es que la ergonomía por otorgada por el TicWatch E3 permite que los usuarios lo utilicen a lo largo del día para cuestiones multipropósito, garantizando que no se deje de utilizar por falta de practicidad, o en un caso específico por la generación de falsas alarmas. Por otra parte, la integración del servicio de comprobación visual mediante la captura de imagen y posterior clasificación con Yolov8s, cuyos resultados son enviados por Telegram, permiten al usuario tener certeza de lo que está aconteciendo, para poder tomar una decisión lo más pronto posible sobre el evento presentado. En este mismo contexto, mediante el envío de mensajes SMS que alerten sobre un incendio en curso permite tener redundancia para el

SAT, en caso de que el usuario no tenga acceso a internet en su smartphone para recibir el mensaje de Telegram, reduciendo el riesgo de que el usuario no actúe de forma oportuna por no recibir una alerta a tiempo.

En esta propuesta se consideró el equilibrio entre el costo económico y la efectividad en la detección de incendios en espacios interiores tomando en cuenta los dispositivos de detección de las variables de humedad, temperatura y CO/humo mediante los sensores conectados a la placa ESP32, la PC destinada a la captura de imágenes para su posterior clasificación y los *smartwatch* y *smartphone* destinados a la presentación de los resultados del monitoreo. Si bien es cierto que el objetivo principal de esta investigación fue generar un sistema para alertar a personas con problemas auditivos moderados, también puede extenderse a personas sin discapacidad auditiva, considerando diversos espacios de casa-habitación. Al comparar nuestra propuesta con otras investigaciones como la de Vaegae et al. (2024), Rachman & Hendratoro (2020) y Peng & Kim (2025), podemos destacar la inclusión de la respuesta háptica para asistir en la detección de incendios a personas con discapacidad auditiva, empleando mensajes con la LSM, lo cual permite al usuario entender con mayor detalle lo que está sucediendo en su entorno. En las investigaciones analizadas en el estado del arte no se fue posible encontrar propuestas que permitieran incluir en sus mecanismos de alertamiento a sectores de la población con alguna limitación sensorial, siendo este trabajo una propuesta prometedora para este sector de la población que en distintas ocasiones no es considerada para el uso de herramientas tan importantes como es un sistema de alerta de incendios en interiores.

Es importante señalar que los objetivos de detección temprana de fuego o de presencia de humo y gas CO se lograron adecuadamente, así como la respuesta háptica de forma adecuada en TicWatch E3, existen puntos importantes por tratar, como el reconocimiento visual de fuego empleando solo IoT (Raspberry) o servicios de cómputo en la nube, para reducir tanto complejidad de integración del hardware como el consumo energético de los dispositivos.

6 Conclusiones

Los resultados obtenidos durante la ejecución de las pruebas de validación tanto del motor de lógica difusa mediante la simulación Monte Carlo y las pruebas en el escenario real demostraron que el sistema de híbrido de detección de incendios fue ampliamente efectivo para alertar a los usuarios con discapacidad auditiva que la presencia de fuego y humo en un ambiente de casa habitación, donde el algoritmo Yolov8s y el envío de mensajes por SMS y Telegram permitieron reducir la incertidumbre de una falsa alarma y verificar el evento que se estaba presentando.

La efectividad de la respuesta del motor de lógica difusa se pudo comprobar en los resultados obtenidos en la simulación Monte Carlo, como se puede observar en la aplicación de las métricas de precisión exhaustividad, y puntaje F1 alcanzando puntajes de 0.97, 0.98 y 0.97 respectivamente, lo cual permitió que no se clasificara un evento de incendio como falso positivo o negativo.

La implementación de la respuesta háptica y visual mediante vídeos en LSM desplegada en el TicWatch E3 permitió que los usuarios entendieran con claridad y en tiempo real lo que estaba pasando sobre el evento de incendio, sin la necesidad del uso de alarmas sonoras, siendo uno de los principales objetivos que se alcanzaron con éxito a lo largo de la presente investigación. Es importante señalar que la ejecución de los

eventos de envío de comprobación de detección de humo o fuego en tiempo real con Telegram, brindó una retroalimentación visual, así como un mecanismo de redundancia para comprender lo que se estaba presentando en el área donde se detectó el incendio.

Si bien es cierto que los resultados obtenidos fueron satisfactorios, en futuras iteraciones se optará por incorporar sistemas de cómputo en la nube para realizar el proceso de detección visual de fuego y humo para simplificar la cantidad de hardware requerido y la reducción de consumo energético del SAT propuesto.

7 Referencias

- Ahn, Y., Choi, H., & Kim, B. S. (2023). Development of early fire detection model for buildings using computer vision-based CCTV. *Journal of Building Engineering*, 65, 105647. <https://doi.org/10.1016/j.job.2022.105647>
- Ahrens, M. (2021). Smoke Alarms in U.S. Home Fires. National Fire Protection Association (NFPA).
- Alam, G. M. I., Tasnia, N., Biswas, T., Hossein, M. J., Tanim, S. A., & Miah, M. S. U. (2025). Real-Time Detection of Forest Fires Using FireNet-CNN and Explainable AI Techniques. *IEEE Access*. 10.1109/ACCESS.2025.3552352.
- Ali, M. M., & Ghodrati, M. (2025). Toward reliable fire detection in indoor CCTV footage: Reducing false alarms from benign flames using 3D attention CNNs. *IEEE Access*. 10.3390/fire8070285.
- An, L., Chen, L., & Hao, X. (2023). Indoor fire detection algorithm based on second-order exponential smoothing and information fusion. *Information*, 14(5), 258. <https://doi.org/10.3390/info14050258>
- Arifia, R., & Mulyana, I. (2025). Development of an IoT-Based Fire Detection System Using ESP32 with Fire Alerts via Telegram Bot. *Prosiding Seminar Nasional Universitas Ma Chung*, 5(1), 45-58.
- Aksüt, G., & Eren, T. (2025). Evaluation of wearable device technology in terms of health and safety in firefighters. *Technology and Health Care*, 33(2), 726-736. <https://doi.org/10.1177/09287329241291385>
- Cahyadi, H. D., & Teary, M. G. (2026). IoT-Based Fire Detection System Using ESP32 and Telegram. *Media Journal of General Computer Science*, 3(1), 1-9. <https://doi.org/10.62205/mjgcs.v3i1.146>
- Centre for Research on the Epidemiology of Disasters (CRED). (2025). State of wildfires 2024–2025. *PreventionWeb*.
- Chen, Y., et al. (2025). Evaluation of wearable device technology in terms of health and safety in firefighters. *International Journal of Industrial Ergonomics*, 90, 103325.
- Consejo Nacional para el Desarrollo y la Inclusión de las Personas con Discapacidad. (2017). *Diccionario de Lengua de Señas Mexicana*. Secretaría de Salud. https://educacionespecial.sep.gob.mx/storage/recursos/2023/05/xzrfl019nV-4Diccionario_lengua_%20Senas.pdf
- Copernicus Atmosphere Monitoring Service. (2024). State of Wildfires 2023-24: CAMS data supports assessment. European Union.
- Deng, X., Shi, X., Wang, H., Wang, Q., Bao, J., & Chen, Z. (2023). An indoor fire detection method based on multi-sensor fusion and a lightweight convolutional neural network. *Sensors*, 23(24), 9689. <https://doi.org/10.3390/s23249689>
- El-Madafri, I., Peña, M., & Olmedo-Torre, N. (2024). Real-Time Forest Fire Detection with Lightweight CNN Using Hierarchical Multi-Task Knowledge Distillation. *Fire*, 7(11), 392. <https://doi.org/10.3390/fire7110392>
- FEMA, Agencia Federal para el Manejo de Emergencias. (2023). *Sistemas de detección de incendios y nuevas tecnologías de respuesta*. Departamento de Seguridad Nacional. URL: <https://www.usfa.fema.gov>.
- Hou, F., Rui, X., Chen, Y., & Fan, X. (2023). Flame and smoke semantic dataset: Indoor fire detection with a deep semantic segmentation model. *Electronics*, 12(18), 3778. <https://doi.org/10.3390/electronics12183778>
- Institute of Electrical and Electronics Engineers. (2020). IEEE Standard for an Architectural Framework for the Internet of Things (IoT) (IEEE Std 2413-2019). 10.1109/IEEESTD.2020.9032420
- Istre, G. R., et al. (2020). Smoke alarms and prevention of house-fire-related deaths and injuries. *Western Journal of Emergency Medicine*, 15(2), 145.

- James, G., Witten, D., Hastie, T., & Tibshirani, R. (2013). *An Introduction to Statistical Learning: with Applications in R*. Springer.
- Jocher, G., Chaurasia, A., & Qiu, J. (2023). Ultralytics YOLOv8 (Versión 8.0.0) [Software]. <https://github.com/ultralytics/ultralytics>
- Kroese, D. P., Taimre, T., & Botev, Z. I. (2011). *Handbook of Monte Carlo Methods*. John Wiley & Sons.
- Li, Y., Shang, J., Yan, M., Ding, B., & Zhong, J. (2023). Real-time indoor early fire detection and localization on embedded platforms using fully convolutional one-stage object detection. *Sustainability*, 15(3), 1794. <https://doi.org/10.3390/su15031794>
- Mahbub, M., Hossain, M. M., & Gazi, M. S. A. (2021). Cloud-Enabled IoT-based and cloud-enabled integrated system for smart indoor lighting and ventilation as well as early fire detection and prevention. *Computer Networks*, 184, 107673. <https://doi.org/10.1016/j.comnet.2020.107673>
- Mukhiddinov, M., Abdusalomov, A. B., & Cho, J. (2022). Automatic fire detection and notification system based on improved YOLOv4 for blind and visually impaired people. *Sensors*, 22(9), 3307. <https://doi.org/10.3390/s22093307>
- National Fire Protection Association. (2024). NFPA 72: National Fire Alarm and Signaling Code (Ed. 2025). NFPA.
- Nazir, A., Mosleh, H., Takruri, M., Jallad, A. H., & Alhebsi, H. (2022). Early fire detection: A novel indoor laboratory dataset and data distribution analysis. *Fire*, 5(1), 11. <https://doi.org/10.3390/fire5010011>
- Peng, B., & Kim, T.-K. (2025). YOLO-HF: Early Detection of Home Fires Using YOLO. *IEEE Access*, 13, 79451–79466. [10.1109/ACCESS.2025.3566907](https://doi.org/10.1109/ACCESS.2025.3566907)
- Pincott, J., Tien, P. W., Wei, S., & Calautit, J. K. (2022). Indoor fire detection utilizing computer vision-based strategies. *Journal of Building Engineering*, 61, 105154. <https://doi.org/10.1016/j.jobbe.2022.105154>
- Rachman, F. Z., & Hendrantoro, G. (2020, June). A fire detection system using multi-sensor networks based on fuzzy logic in indoor scenarios. In *2020 8th International Conference on Information and Communication Technology (ICoICT)* (pp. 1-6). IEEE. [10.1109/ICoICT49345.2020.9166416](https://doi.org/10.1109/ICoICT49345.2020.9166416)
- Rachman, F. Z., & Hendrantoro, G. (2020). A fire detection system using multi-sensor networks based on fuzzy logic in indoor scenarios. *Proc. 8th Int. Conf. on Information and Communication Technology (ICoICT)*, 1–6. <https://doi.org/10.1109/ICoICT49345.2020.9166432>
- Russell, S. J., & Norvig, P. (2021). *Artificial Intelligence: A Modern Approach* (4a ed.). Pearson.
- Vaegae, N., Annepu, V., & Al-Mhiqani, M. (2024). Multisensor fuzzy logic approach for enhanced fire detection in smart cities. *Journal of King Saud University-Computer and Information Sciences*, 36(2), 101-115. [10.1155/2024/8511649](https://doi.org/10.1155/2024/8511649)



Esta obra está bajo una licencia de Creative Commons
Reconocimiento-NoComercial-CompartirIgual 2.5 México.