



Machine Learning Application for Automatic Emergency Signal Activation

Idiño Quispe Raymunde¹ , Christian Ovalle² 



¹Universidad Tecnológica del Perú, Perú, u18201100@utp.edu.pe

²Universidad Tecnológica del Perú, Perú, dovalle@utp.edu.pe

Abstract– The development of an innovative system that uses Machine Learning and IoT sensors to automatically activate emergency signals in critical situations, improving the speed and efficiency of the response. Using a Random Forest machine learning model, trained with data from temperature, gas, humidity, and flame sensors, the system achieved a 96.8% accuracy, with key metrics such as an AUC of 0.997 and an F1-score of 0.968. Integrated with an Arduino microcontroller, this system can autonomously activate alarms and lights, eliminating the need for human intervention in emergency situations. By detecting risks such as gas leaks, fires, or temperature spikes, the system responds almost instantly, which can be crucial for saving lives. This approach not only optimizes safety in vulnerable environments but also establishes a smarter and more efficient model for emergency management.

Keywords– Machine Learning, Emergency Signals, IoT (Internet of Things), Random Forest.

Aplicación de Machine Learning para la Activación Automática de Señales de Emergencia

Idiño Quispe Raymendez¹ , Christian Ovalle² 

¹Universidad Tecnológica del Perú, Perú, u18201100@utp.edu.pe

²Universidad Tecnológica del Perú, Perú, dovalle@utp.edu.pe

Resumen– Este trabajo presenta el desarrollo de un sistema innovador que emplea Machine Learning y sensores IoT para activar automáticamente señales de emergencia en situaciones críticas, mejorando así la rapidez y eficiencia en la respuesta ante emergencias. Utilizando un modelo de aprendizaje automático Random Forest, entrenado con datos de sensores de temperatura, gas, humedad y llama, el sistema alcanzó una precisión del 96.8%, con métricas destacadas como un AUC de 0.997 y un F1-score de 0.968. Integrado con un microcontrolador Arduino, el sistema tiene la capacidad de activar alarmas y luces de forma autónoma, eliminando la necesidad de intervención humana en momentos de emergencia. Al detectar riesgos como fugas de gas, incendios o aumentos de temperatura, el sistema reacciona casi de inmediato, lo cual es crucial para salvar vidas. Este enfoque no solo mejora la seguridad en entornos vulnerables, sino que también ofrece un modelo más inteligente y eficiente para la gestión de emergencias.

Palabras clave– Machine Learning, Señales de emergencia, IoT (Internet de las Cosas), Random Forest.

I. INTRODUCCIÓN

La seguridad es una prioridad fundamental en nuestra vida cotidiana, especialmente frente a situaciones de emergencia como accidentes o desastres naturales. En estos escenarios, la rapidez y eficiencia de los sistemas de respuesta son cruciales para salvar vidas y mitigar riesgos [1]. Las señales de emergencia, como bocinas, luces intermitentes y alarmas visuales, juegan un papel esencial en la gestión de crisis. Sin embargo, los sistemas tradicionales suelen depender de activaciones manuales o de operadores humanos, lo que puede generar demoras en momentos críticos.

El avance de las tecnologías, especialmente la inteligencia artificial (IA) y el aprendizaje automático (Machine Learning, ML), ha abierto nuevas oportunidades para optimizar estos sistemas. Estos enfoques permiten procesar grandes volúmenes de datos en tiempo real, facilitando una respuesta automatizada y más precisa ante emergencias [2]. A diferencia de los sistemas convencionales, que funcionan con umbrales fijos y condiciones predefinidas, los modelos de Machine Learning pueden identificar patrones complejos en los datos, lo que les permite anticipar riesgos y mejorar la precisión de la respuesta. Esta capacidad de aprender de los datos y adaptarse a nuevas situaciones hace que los modelos de ML sean una solución más robusta y flexible, especialmente en escenarios donde los riesgos son variados y cambiantes.

En este contexto, el uso de Machine Learning para la activación automática de señales de emergencia se presenta como una solución prometedora. Mediante la integración de sensores como el DHT11 (temperatura y humedad), MQ-2

(detección de gases) y KY-026 (detección de flamas), junto con dispositivos de alerta como bocinas y luces LED RGB 8x8, es posible monitorear de manera constante variables ambientales clave [3]. Estos sensores, combinados con algoritmos de aprendizaje automático, permiten no solo detectar situaciones críticas, sino también anticiparlas, logrando una activación inmediata y autónoma de las señales de emergencia [4].

Frente a los sistemas tradicionales, los sistemas basados en Machine Learning ofrecen ventajas significativas. Mientras que los métodos manuales pueden ser lentos e imprecisos, los sistemas automatizados actúan de forma inmediata, un factor decisivo en emergencias. Además, su capacidad de aprendizaje continuo les permite adaptarse a nuevos patrones y condiciones, mejorando su precisión y eficiencia con el tiempo [5]. Esto no solo optimiza la respuesta en tiempo real, sino que también incrementa la inteligencia y efectividad del Sistema [6].

En situaciones de emergencia, cada segundo es vital. Tecnologías como esta no solo ayudan a salvar vidas, sino que también ofrecen tranquilidad al saber que siempre hay un sistema atento, listo para actuar de inmediato ante cualquier amenaza. Este enfoque representa un cambio significativo, pasando de reaccionar tarde a estar siempre preparados, de improvisar en una crisis a proteger de forma proactiva.

El objetivo de este proyecto es desarrollar un sistema que utilice Machine Learning para la activación automática de señales de emergencia, empleando los componentes mencionados, con el fin de reducir los tiempos de respuesta en situaciones de crisis y mejorar la seguridad de las personas en entornos vulnerables.

II. ESTADO DEL ARTE

La automatización de señales de emergencia mediante Machine Learning es un campo emergente que está comenzando a recibir atención en la investigación. Si bien el uso de tecnologías avanzadas en la automatización de sistemas de seguridad ha experimentado un crecimiento considerable, la aplicación específica de Machine Learning para la activación automática de señales de emergencia es todavía un área poco explorada. Sin embargo, diversos estudios y desarrollos previos han comenzado a investigar la implementación de tecnologías similares, como la detección de anomalías en entornos industriales, la predicción de incendios y la gestión de evacuaciones. Estos avances proporcionan un punto de partida valioso para este proyecto, ya que demuestran el potencial de las tecnologías emergentes para mejorar la rapidez y eficiencia de las respuestas ante situaciones de emergencia.

A. Prototipo de sistema de detección de peligros en interiores mediante sensores e IoT

En esta investigación, se exploró la implementación de sistemas automáticos de monitoreo para emergencias, con un enfoque en la detección de situaciones críticas como fugas de gas, incendios y cambios repentinos en las condiciones ambientales. Para ello, se utilizaron sensores como el DHT11, MQ-2 y KY-026, junto con un sistema basado en Arduino. Este sistema permitía la activación automática de señales de emergencia, tales como alarmas sonoras y luces intermitentes, sin necesidad de intervención manual. Al detectar condiciones peligrosas, el sistema activaba las alarmas de manera inmediata, reduciendo significativamente los tiempos de respuesta ante situaciones de riesgo. Este enfoque automatizado mejoró la eficiencia y rapidez en la gestión de emergencias, lo cual es crucial para garantizar la seguridad en entornos vulnerables [7].

B. Uso de redes neuronales en la predicción de procesos ambientales

La predicción de fenómenos ambientales, especialmente en lo que respecta a las emisiones de gases de efecto invernadero, ha ganado gran interés debido a la capacidad de las redes neuronales para procesar grandes volúmenes de datos y proporcionar predicciones precisas. Las redes neuronales recurrentes (RNN), especialmente variantes como Simple RNN y LSTM-RNN, se destacan en la modelización de procesos complejos debido a su capacidad para manejar datos secuenciales y realizar proyecciones a diferentes escalas temporales y espaciales. Este estudio demuestra la efectividad de estos modelos en la predicción de emisiones, identificando valores atípicos y realizando proyecciones con alta precisión. Además, se observó que el uso de redes neuronales recurrentes es prometedor para el monitoreo y anticipación de cambios ambientales, ofreciendo un enfoque valioso para agencias gubernamentales e iniciativas ambientales [8].

C. Un sistema de evacuación y control de incendios en edificios inteligentes basado en el Internet de las cosas y un algoritmo inteligente híbrido

En respuesta a los recientes incidentes de propagación rápida de incendios en edificios de gran altura, ha surgido la necesidad urgente de mejorar los sistemas de evacuación y la seguridad contra incendios. En este contexto, el Internet de las Cosas (IoT) se presenta como una herramienta clave para optimizar la eficiencia de los servicios de seguridad. Los edificios inteligentes, equipados con sensores IoT, permiten monitorear parámetros ambientales como temperatura, humedad, luminosidad y calidad del aire. Esta investigación propuso un sistema innovador de evacuación y control de incendios en edificios inteligentes, basado en IoT, que optimiza las rutas de evacuación en tiempo real durante incidentes de incendio. El sistema utiliza un enfoque híbrido de optimización que mejora las rutas dinámicamente, ajustándolas según las condiciones cambiantes del incendio. Los resultados experimentales mostraron que el método propuesto redujo el tiempo de ejecución en un 10,41%, el costo de ejecución en un 25% y el consumo de energía en un 11,90% en comparación

con otros enfoques, lo que contribuye a un sistema de evacuación más rápido, eficiente y sostenible [9].

D. Diseño e implementación de sistema de seguridad y monitoreo en el hogar mediante el uso de redes de sensores inalámbricos WSN/internet de las cosas IoT

Este artículo presentó un sistema de seguridad para el hogar basado en el Internet de las Cosas (IoT), diseñado para detectar actividades sospechosas y activar alarmas dentro de la vivienda. El sistema utilizó sensores para monitorear parámetros como gas, humedad, temperatura corporal y movimiento, apoyándose en microcontroladores como Arduino y Raspberry Pi. Además, se desarrolló una aplicación móvil en Android que permitía al propietario recibir alertas en tiempo real sobre cualquier actividad anómala. Los resultados obtenidos de las simulaciones demostraron que el sistema propuesto fue eficaz, ofreciendo una solución innovadora para mejorar la seguridad en el hogar [10].

III. METODOLOGÍA

Este proyecto presenta un diseño experimental para un sistema automatizado que utiliza Machine Learning (ML) para la activación automática de señales de emergencia. El sistema emplea sensores de temperatura, gas, humedad y flama conectados a un microcontrolador Arduino para recolectar datos en tiempo real. Estos datos se utilizan para entrenar un modelo de Random Forest, con el objetivo de predecir eventos críticos y activar señales de emergencia, como alarmas sonoras y luces intermitentes, de manera autónoma. [11].

El uso de Machine Learning ofrece ventajas claras sobre los sistemas tradicionales basados en umbrales fijos, ya que permite detectar patrones complejos en los datos, lo que facilita la anticipación de riesgos. Mientras que los sistemas convencionales reaccionan solo cuando se superan ciertos umbrales predefinidos, el Random Forest aprende de los datos y adapta sus predicciones a nuevas situaciones, mejorando la precisión y la rapidez del sistema. Este enfoque permite no solo responder más rápidamente, sino también anticiparse a emergencias antes de que se presenten.

En la Figura 1 se muestra el sistema propuesto para la activación automática de señales de emergencia, compuesto por varios sensores conectados a un microcontrolador Arduino Uno. Estos sensores incluyen el DHT11, que mide la temperatura y humedad ambiental, el MQ-2, encargado de detectar gases peligrosos como el monóxido de carbono [12], y el KY-026, utilizado para identificar la presencia de llamas. Los datos recopilados por estos sensores son procesados en tiempo real por el microcontrolador, que utiliza algoritmos de Machine Learning para analizar la información y detectar patrones que podrían indicar una situación de emergencia. En caso de que el sistema identifique un evento crítico, se activan señales de emergencia, tales como una matriz de LEDs RGB 8x8 y un buzzer, para alertar de inmediato a las personas en el entorno.

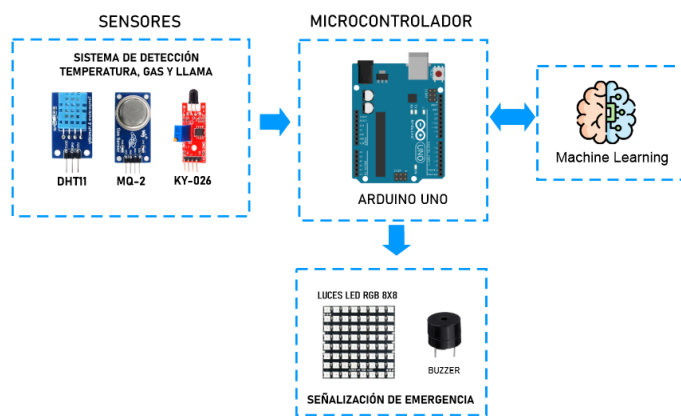


Fig. 1 Diagrama del Sistema de Señales de Emergencia

A. Componentes del sistema de activación de alarmas

Para construir el prototipo se siguió un proceso en etapas para garantizar su funcionalidad y confiabilidad. Primero, se preparó y configuró el microcontrolador Arduino Uno, asignando los pines necesarios para conectar los sensores seleccionados. Luego, se ensamblaron los sensores, asegurando conexiones estables con cables y soldaduras. Posteriormente, se programó el Arduino utilizando la plataforma Arduino IDE, integrando algoritmos que permiten procesar los datos de los sensores en tiempo real. Durante el ensamblaje, se cuidó la disposición física de los componentes para optimizar su funcionamiento. Finalmente, se realizaron pruebas simuladas, como presencia de gases, para ajustar la programación y confirmar que el sistema respondiera de manera precisa y rápida. En la tabla I se muestra los componentes y materiales utilizados.

TABLA I
COMPONENTES UTILIZADOS

Componente	Cantidad
MQ-2 Sensor de gas	1
KY-026 Sensor de flama	1
DHT11 Sensor de Temperatura	1
TMB12A12 Zumbador	1
LED RGB 8 x 8	6
Arduino Uno	1
Fuente de Alimentación 5V 2Ah	1

B. Parámetros de umbral para activación de señales de emergencia

Los umbrales para activar las señales de emergencia se definen según los valores que registraron los sensores de gas, temperatura, llama y humedad. Estos límites son fundamentales para saber cuándo el sistema debe dar una alerta. Si el sensor MQ-2 detecta una concentración de gas superior a 300 ppm, la alarma se activa, indicando un riesgo elevado. En el caso del sensor KY-026, la alerta se dispara si el nivel de llama baja de 700, lo que señala la presencia de fuego. Para el sensor DHT11, la alarma se enciende cuando la temperatura supera los 30°C,

lo que podría significar un peligro de incendio o sobrecalentamiento. Finalmente, si el sensor de humedad detecta que la humedad relativa excede el 60%, esto sugiere que las condiciones ambientales pueden ser peligrosas. Como se muestra en la Tabla II.

TABLA II
NIVELES DE SEGURIDAD Y RIESGO DE SENSORES

Sensor	Nivel Seguro	Nivel Moderado	Nivel Alto	Nivel Critico
MQ-2	0 ppm – 200 ppm	200 – 300 ppm	300 ppm – 500 ppm	> 500 ppm
KY-026	900 – 1024	900 – 700	700 ppm – 200 ppm	200 – 0
DHT11	0°C -20°C	20°C -30°C	30°C - 50°C	50°C -100°C
DHT11	20 – 40 %HR	40 – 60%HR	60 – 80%HR	80 – 100 %HR

C. Recolección de datos

Una vez activado el sistema, se procedió a la recolección de datos en tiempo real a través de los sensores conectados al microcontrolador Arduino Uno. El sensor DHT11 registró constantemente la temperatura ambiental, permitiendo detectar cualquier aumento inusual que pudiera indicar una situación crítica. Al mismo tiempo, el MQ-2 comenzó a medir la presencia de gases peligrosos, como el monóxido de carbono, emitiendo alertas ante posibles fugas de gas o situaciones de riesgo. Además, el KY-026, encargado de detectar llamas, contribuyó a identificar posibles incendios. Para evaluar la efectividad del sistema, se expusieron los sensores a diferentes pruebas, como la liberación controlada de humo y la simulación de condiciones extremas, garantizando que los datos recolectados fueran representativos de situaciones reales. Como se muestra en la Fig. 2

Temperatura (°C)	Gas (MQ-2)	Llama (KY-026)	Humedad HR (%)	Evento
25	150	950	45	Normal
28	220	780	50	Normal
32	350	650	60	Temperatura alta
34	400	620	70	Temperatura alta
40	500	500	65	Temperatura alta
18	100	980	30	Normal
20	180	920	55	Normal
35	480	400	80	Fuego detectado
50	520	300	85	Temperatura alta
10	70	1000	40	Normal

Fig. 2 Datos recolectados

D. Aplicación de Modelos de Machine Learning

Se eligió el modelo Random Forest debido a su capacidad para abordar eficazmente la predicción de la activación de señales de emergencia, especialmente en escenarios donde los datos provienen de múltiples sensores con relaciones complejas. Este modelo es particularmente adecuado, ya que puede manejar la interacción no lineal entre diferentes sensores, tales como gas, temperatura, llama y humedad, que pueden estar correlacionados de manera compleja y dinámica. A diferencia de los modelos lineales simples, Random Forest es capaz de capturar patrones más complejos y de adaptarse a situaciones variables en tiempo real. [13].

Una de las principales ventajas de Random Forest es su resistencia al sobreajuste, gracias a su capacidad para utilizar múltiples árboles de decisión y promediar los resultados, lo que lo hace robusto incluso con datos ruidosos o atípicos. Esto es esencial para el sistema de activación automática de señales de emergencia, ya que los datos de los sensores pueden variar debido a condiciones ambientales cambiantes. Además, Random Forest es flexible y eficiente, mejorando su rendimiento a medida que se le proporcionan más datos, lo que lo convierte en una herramienta ideal para aplicaciones en tiempo real.

E. Entrenamiento de algoritmos de Machine Learning

Para esta investigación, se utilizó la plataforma Orange Data Mining para entrenar el modelo de Random Forest, una herramienta elegida debido a su facilidad de uso y su capacidad para simplificar el desarrollo de modelos de Machine Learning. Su interfaz visual permite a los usuarios ajustar configuraciones, probar diferentes parámetros y analizar los resultados de manera clara y accesible, lo que la convierte en una opción ideal incluso para aquellos con poca experiencia en programación. [14]

Random Forest destacó por su robustez y precisión al manejar múltiples variables y detectar patrones complejos en los datos. Orange facilitó tanto el entrenamiento del modelo como la visualización de los procesos de clasificación y predicción, lo que permitió comprender de manera efectiva cómo el modelo toma decisiones y mejora con el tiempo. Esto se ilustra en la Fig. 3.

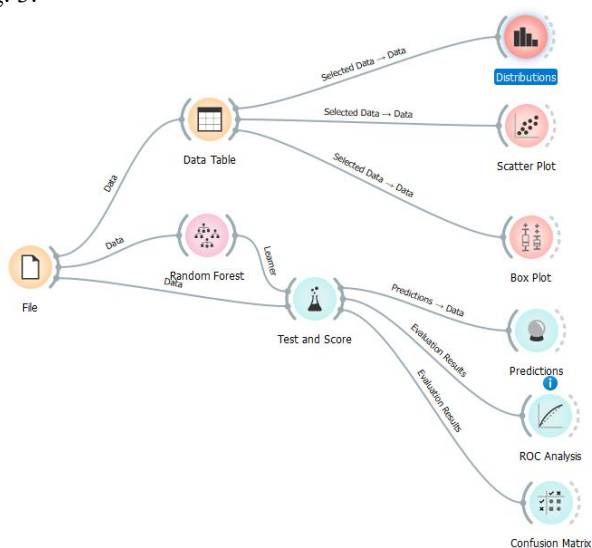


Fig. 3 Se muestra el modelo utilizando en Orange

En la Figura 4, se muestra un gráfico de dispersión (scatter plot) que ilustra cómo se relacionan las diferentes variables de los sensores con el evento que intentamos predecir. Cada punto en el gráfico representa una medición tomada, donde los ejes X e Y corresponden a los valores de dos o más sensores, como el gas (MQ-2), la temperatura (DHT11), la llama (KY-026) y la humedad relativa. Este tipo de gráfico es útil para identificar patrones o tendencias en los datos, así como para observar la distribución de los eventos que activan las alarmas en función

de las lecturas de los sensores. Además, proporciona una representación visual de las relaciones entre las variables, permitiendo detectar correlaciones no lineales o puntos atípicos que podrían influir en las predicciones de las alarmas.




Fig. 4 Distribución de Relación entre sensores y activación de alarmas

En la Fig 5. se muestra el gráfico de barras muestra la distribución de los diferentes eventos que se registraron en el sistema, como fuga de gas, temperatura alta y llama detectada. En el eje X se indican estos eventos, mientras que en el eje Y se muestra cuántas veces cada uno ocurrió en el conjunto de datos. Se puede ver que eventos como fuga de gas y temperatura alta ocurren con mayor frecuencia, lo que sugiere que estos son los más comunes en el entorno monitoreado. Por otro lado, el evento de llama detectada es menos frecuente, lo que es esperable dado que los incendios no se producen tan a menudo. Este gráfico nos ayuda a comprender qué tipos de eventos son más comunes y cómo se distribuyen, lo que es clave para ajustar la activación de las alarmas y mejorar la respuesta ante situaciones de riesgo.




Fig. 5 Gráfico de barras de la distribución de los diferentes eventos

IV. RESULTADOS Y DISCUSIONES

El modelo Random Forest ha demostrado un rendimiento excelente en la predicción de eventos de emergencia, con un AUC de 0.997, lo que significa que es muy efectivo para distinguir entre diferentes situaciones. La precisión del modelo

es de 96.9%, lo que indica que la mayoría de sus predicciones son correctas. Además, el F1-score y el recall, ambos con un valor de 0.968, muestran que el modelo tiene un buen balance entre identificar correctamente los eventos y evitar falsos positivos. La exactitud global de 96.8% confirma que el modelo clasifica bien la mayoría de los eventos. Finalmente, el MCC de 0.951 demuestra que el modelo es robusto, manejando tanto los casos correctos como los incorrectos de manera eficiente, lo que lo convierte en una herramienta confiable para la activación de señales de emergencia. Como se muestra en la Tabla III

TABLA III

MÉTRICAS DE EVALUACIÓN DEL MODELO RANDOM FOREST

Métrica	Valor
AUC	0.997
CA (presión)	0.968
F1-score	0.968
Precisión (Prec)	0.969
Recall	0.968
MCC	0.951

A. Resultados de la evaluación con matriz de confusión

La Fig. 6 muestra los resultados de la matriz de confusión del modelo Random Forest, donde se reflejan las predicciones de cinco eventos: Fuego detectado, Fuga de gas, Humedad alta, Normal y Temperatura alta. Los valores en la diagonal principal indican cuántas veces el modelo clasificó correctamente cada evento, mientras que los números fuera de la diagonal representan las clasificaciones erróneas. Por ejemplo, el modelo identificó correctamente 180 casos de Fuego detectado, pero cometió algunos errores al confundirlo con otros eventos, como Fuga de gas o Temperatura alta. De manera similar, la Fuga de gas fue clasificada correctamente en su mayoría, pero 1 caso se confundió con Fuego detectado. Para Humedad alta, se registraron 56 clasificaciones correctas, pero también hubo errores al clasificar algunos eventos como Fuego detectado o Temperatura alta.

		Predicted					Σ
		Fuego detectado	Fuga de gas	Humedad alta	Normal	Temperatura alta	
Actual	Fuego detectado	180	1	2	4	3	190
	Fuga de gas	1	399	0	0	0	400
	Humedad alta	1	0	56	2	1	60
	Normal	1	0	3	36	0	40
	Temperatura alta	0	0	5	2	103	110
Σ		183	400	66	44	107	800

Fig. 6 Resultados de matriz de confusión

A. Resultados de evaluación con curva ROC

La Fig. 7 muestra el análisis de la curva ROC del modelo Random Forest utilizado para la detección de fugas de gas, evidenciando un rendimiento altamente eficiente. La curva se aproxima al vértice superior izquierdo, lo que indica una alta sensibilidad (tasa de verdaderos positivos cercana a 1.0) y una baja tasa de falsos positivos. Con un umbral predeterminado y costos iguales asignados para errores de falsos positivos y falsos negativos, el modelo demuestra un equilibrio adecuado en la clasificación, lo

que sugiere su capacidad para distinguir de manera precisa entre eventos de fuga y condiciones normales.




Fig. 7 Curva ROC para el evento fuga de gas

IV. CONCLUSIONES

El desarrollo y evaluación del sistema automatizado de activación de señales de emergencia utilizando Machine Learning ha mostrado resultados altamente positivos en cuanto a precisión y efectividad. Al emplear el modelo Random Forest, entrenado con datos de sensores de temperatura, gas, humedad y llama, se ha logrado una capacidad de predicción de eventos críticos con una precisión global del 96.8%. Métricas como el AUC de 0.997, el F1-score de 0.968 y el MCC de 0.951 resaltan la solidez del modelo, demostrando su habilidad para identificar rápidamente situaciones de riesgo, tales como fugas de gas, incendios o aumentos de temperatura, con pocos errores. Este sistema automatizado no solo optimiza la rapidez de activación de señales de emergencia, sino que también reduce la necesidad de intervención humana, lo cual es crucial en momentos de crisis, cuando cada segunda cuenta.

La matriz de confusión y el análisis de la curva ROC han proporcionado información valiosa sobre el rendimiento del modelo, permitiendo una evaluación más precisa de su capacidad para clasificar correctamente los eventos. Aunque se presentaron algunos errores de clasificación entre eventos similares, la eficiencia global del modelo se mantiene alta, lo que demuestra que el sistema es adecuado para su implementación en entornos reales.

La integración de sensores IoT con Machine Learning para la activación automática de señales de emergencia es una propuesta innovadora que puede incrementar la seguridad en entornos vulnerables, proporcionando una respuesta más rápida y eficaz ante situaciones de crisis.

Aunque el modelo de Random Forest ha demostrado una excelente capacidad para predecir situaciones de emergencia con una alta precisión, existen ciertas limitaciones. En entornos con sensores defectuosos o condiciones extremas (como temperaturas extremadamente altas o bajas), la calidad de los datos podría verse afectada, lo que podría impactar negativamente en las predicciones. Además, el modelo podría beneficiarse de la integración de más variables o sensores que mejoren la detección de emergencias complejas, como la detección de humo en lugar de solo la temperatura. Futuras

investigaciones podrían centrarse en la optimización de los umbrales y la integración de nuevas tecnologías para superar estas limitaciones y mejorar aún más la eficiencia del sistema.

REFERENCES

- [1] S. Li Sun, Q. Zhao, and W. Zhi Xie, "Study on Safe Evacuation Routes Based on Crowd Density Map of Shopping Mall," *IEEE Access*, vol. 8, pp. 153981–153992, 2020, doi: 10.1109/ACCESS.2020.3015956.
- [2] H. Bi and E. Gelenbe, "A Survey of Algorithms and Systems for Evacuating People in Confined Spaces," *Electronics (Basel)*, vol. 8, no. 6, p. 711, Jun. 2019, doi: 10.3390/electronics8060711.
- [3] S. Debnath, S. Ahmed, S. Das, A.-A. Nahid, and A. K. Bairagi, "IoT based Low-Cost Gas Leakage, Fire, and Temperature Detection System with Call Facilities," in *2020 2nd International Conference on Advanced Information and Communication Technology (ICAICT)*, IEEE, Nov. 2020, pp. 11–16. doi: 10.1109/ICAICT51780.2020.9333530.
- [4] G. Verma, P. Mittal, and S. Farheen, "Real Time Weather Prediction System Using IOT and Machine Learning," in *2020 6th International Conference on Signal Processing and Communication (ICSC)*, IEEE, Mar. 2020, pp. 322–324. doi: 10.1109/ICSC48311.2020.9182766.
- [5] K. Dokic, "Microcontrollers on the Edge – Is ESP32 with Camera Ready for Machine Learning?," 2020, pp. 213–220. doi: 10.1007/978-3-030-51935-3_23.
- [6] S. Thouti, N. Venu, D. R. Rinku, A. Arora, and N. Rajeswaran, "Investigation on identify the multiple issues in IoT devices using Convolutional Neural Network," *Measurement: Sensors*, vol. 24, p. 100509, Dec. 2022, doi: 10.1016/j.measen.2022.100509.
- [7] J. M. S. Waworundeng, M. A. T. Kalalo, and D. P. Y. Lokollo, "A Prototype of Indoor Hazard Detection System using Sensors and IoT," in *2020 2nd International Conference on Cybernetics and Intelligent System (ICORIS)*, IEEE, Oct. 2020, pp. 1–6. doi: 10.1109/ICORIS50180.2020.9320809.
- [8] K. Kolesnikova, L. Naizabayeva, A. Myrzabayeva, and R. Lisnevskiy, "Use the neural networks in prediction of environmental processes," in *2024 IEEE 4th International Conference on Smart Information Systems and Technologies (SIST)*, IEEE, May 2024, pp. 625–630. doi: 10.1109/SIST61555.2024.10629330.
- [9] A. Mohammadiounotikandi, H. F. Fakhrudden, M. N. Meqdad, B. F. Ibrahim, N. Jafari Navimipour, and M. Unal, "A Fire Evacuation and Control System in Smart Buildings Based on the Internet of Things and a Hybrid Intelligent Algorithm," *Fire*, vol. 6, no. 4, p. 171, Apr. 2023, doi: 10.3390/fire6040171.
- [10] H. H. Qasim, A. E. Hamza, H. H. Ibrahim, H. A. Saeed, and M. I. Hamzah, "Design and implementation home security system and monitoring by using wireless sensor networks WSN/internet of things IOT," *International Journal of Electrical and Computer Engineering (IJECE)*, vol. 10, no. 3, p. 2617, Jun. 2020, doi: 10.11591/ijece.v10i3.pp2617-2624.
- [11] A. G. Gavarkovs, R. A. Kusurkar, K. Kulasegaram, and R. Brydges, "Going beyond the comparison: toward experimental instructional design research with impact," *Advances in Health Sciences Education*, Aug. 2024, doi: 10.1007/s10459-024-10365-9.
- [12] K. Gupta, G. Gokul Krishna, and T. Anjali, "An IoT based System for Domestic Air Quality Monitoring and Cooking Gas Leak Detection for a Safer Home," in *2020 International Conference on Communication and Signal Processing (ICCS)*, IEEE, Jul. 2020, pp. 0705–0709. doi: 10.1109/ICCS48568.2020.9182051.
- [13] J. J. Espinosa Zúñiga, "Aplicación de algoritmos Random Forest y XGBoost en una base de solicitudes de tarjetas de crédito," *Ingeniería Investigación y Tecnología*, vol. 21, no. 3, pp. 1–16, Jul. 2020, doi: 10.22201/ii.25940732e.2020.21.3.022.
- [14] Z. Dobesova, "Evaluation of Orange data mining software and examples for lecturing machine learning tasks in geoinformatics," *Computer Applications in Engineering Education*, vol. 32, no. 4, Jul. 2024, doi: 10.1002/cae.22735.