

StopFire: Alertas de Incendios Forestales en Argentina Usando IoT y Machine Learning

Alejandra Curbelo¹ [0000-0003-1708-6624], Juan Cruz Alric¹ [0000-0002-8854-9844] y Pablo Ezequiel Inchausti¹ [0000-0002-8342-1796]

¹Universidad Argentina de la Empresa (UADE), Instituto de Tecnología (INTEC). Buenos Aires, Argentina
{alcurbelo, jalric, pinchausti}@uade.edu.ar

Resumen. Los incendios forestales son devastadores para un ambiente y sus efectos se miden en cientos de miles de hectáreas. Para contribuir en la prevención de incendios forestales, se desarrolla una solución de monitoreo por imágenes de las zonas en riesgo basada en IoT, y la utilización de modelos de Machine Learning con Redes Neuronales Convolucionales para identificar en las imágenes la presencia del fuego. La solución se completa con un tablero de monitoreo de los dispositivos de IoT y una aplicación móvil para reportar el riesgo de incendio enviando imágenes geolocalizadas.

Keywords: Incendios Forestales. Machine Learning, IoT, Redes Neuronales

1 Introducción

Un incendio forestal se define como un fuego que se propaga rápidamente y de forma descontrolada a través de la vegetación de una zona, y, si bien se pueden originar por causas naturales, como las tormentas eléctricas, más del 95% de los incendios forestales en Argentina son provocados por el hombre, ya sea de forma intencional, o no [1].

Los incendios forestales suelen producir efectos devastadores, y de acuerdo al Servicio Nacional de Manejo del Fuego (SNMF), en el 2021 más de 302 mil hectáreas en Argentina fueron afectadas por el fuego, con la provincia de San Luis encabezando la lista [2]. En febrero del 2022, los incendios forestales de Corrientes afectaron más de 900 mil hectáreas, un equivalente al 11% de la superficie provincial [3].

El objetivo del presente trabajo es contribuir a la prevención de incendios forestales en Argentina, y desarrollar un sistema de alertas y monitoreo por imágenes. Se utiliza IoT para el monitoreo y se determina la presencia del fuego con modelos de Machine Learning (ML). Se complementa la solución con una aplicación móvil para reportar el riesgo de incendio en una zona, enviando imágenes con información geolocalizada.

El trabajo inicia en el 2022 como Proyecto Final de Ingeniería Informática (PFI) de Alejandra Curbelo y Juan Cruz Alric, siendo Pablo Inchausti, docente en PFI, el tutor.

También se integra en el INTEC, el Instituto de Tecnología de UADE, a la línea A21T03: *Aplicaciones de Machine Learning para el uso de Recursos Naturales*. [4] y continúa el trabajo de *AQUA* [5] sobre prevención de incendios forestales en Pinamar.

2 Materiales y Métodos

El sistema StopFire está compuesto por una aplicación web, con un módulo de detección de incendios forestales que integra un modelo de Machine Learning para analizar imágenes de zonas forestales capturadas por dispositivos de IoT.

Los dispositivos de IoT se conectan a servicios desplegados en el Cloud Provider AWS, y reciben imágenes cada 30 minutos, para procesarlas y generar una alerta en caso de que el modelo entrenado detecte que existe un posible incendio en la zona.

El sistema de monitoreo se presenta como un tablero que permite ver las cámaras conectadas a la red, con su ubicación geográfica. En el módulo de alertas se muestra la foto que el modelo utilizó para determinar el potencial foco de incendio, con información geolocalizada de la cámara y el día y la hora de la captura de la imagen. En la **Fig. 1.** se describe el modelo de solución de StopFire a alto nivel:

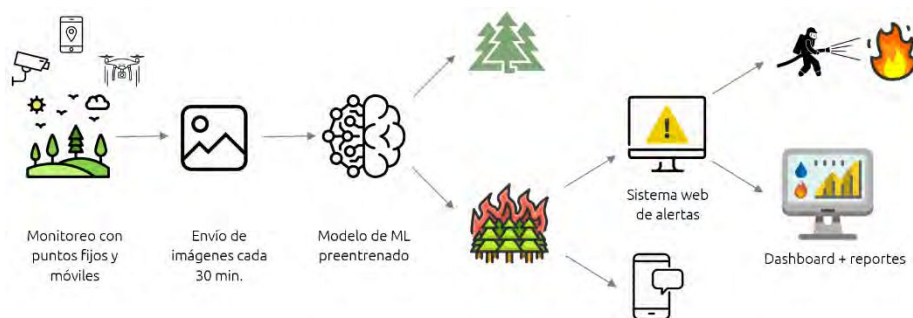


Fig. 1. StopFire: modelo de solución

Respecto a la aplicación móvil, permitiría que, de forma voluntaria, las personas presentes en zonas forestales puedan reportar incidentes con riesgo de incendios. Desde la aplicación se permite el envío de imágenes al sistema de monitoreo y analizarlas con los modelos de detección de incendios, y también obtener la información geolocalizada del lugar y el tiempo de la captura de la imagen para identificar la zona de riesgo.

Teniendo en cuenta que el factor humano es responsable de más del 95% de los incendios forestales [1], la aplicación móvil permite involucrar de forma directa a nuestra sociedad, y le permite contribuir en la prevención reportando incidentes desde las zonas de riesgo, y así reducir el nivel de responsabilidad en estos desastres naturales.

De esta forma, también el envío de imágenes mediante las aplicaciones móviles permite escalar la red de monitoreo más allá de los dispositivos de IoT desplegados en la zona. Y el análisis de las imágenes enviadas, también sirven tanto para mejorar el entrenamiento de los modelos, como para identificar lugares propensos a incendios con el objetivo de ampliar la red de dispositivos.

La tecnología para el desarrollo de los modelos de Machine Learning (ML) está basada en Redes Neuronales Artificiales (RNA), técnicas de visión por computadora y Redes Neuronales Convolucionales (CNN) que son especialmente efectivas en campos como la visión artificial.

2.1 Redes Neuronales Convolucionales (CNN)

La Red Neuronal Convolutacional (CNN) es un tipo de red neuronal multicapa o arquitectura de aprendizaje profundo inspirada en el sistema visual de los seres vivos. Tienen una arquitectura *feed forward*, que significa que las neuronas de cada capa se conectan con todas las neuronas de la capa siguiente, pero no con neuronas de la misma capa. Las primeras capas de la red aprenden y extraen las características de alto nivel, mientras que las capas más profundas, extraen las características de bajo nivel. [6]

En las CNN, hay tres tipos de capas intermedias: la capa convolutacional, que es el componente más importante de las arquitecturas CNN porque es la que genera un mapa con las características de las imágenes a partir de las imágenes de entrada. La capa de agrupación, que toma las características de mayor tamaño y las reduce en mapas de características de menor tamaño. Y finalmente, la capa completamente conectada, que se utiliza como clasificador, y que, a partir de la última capa de agrupación, se pasa por la red *feed forward* para generar la salida. [6]

Para el desarrollo de la CNN se utilizó la librería *fast.ai* [7], que se especializa en Deep Learning, para creación de las redes neuronales.

2.2 Preparación de los datos

Para el entrenamiento de la red neuronal, se usaron conjuntos de datos públicos de incendios forestales provenientes de plataformas libres como Kaggle. Por ejemplo, *Wildfire Detection Image Data* [8] es un conjunto de datos con imágenes de uso libre de incendios forestales para entrenar modelos de Machine Learning y Deep Learning.

El procedimiento inicia con la carga de las 1.832 imágenes etiquetadas de Kaggle, y adicionalmente, para aumentar la muestra disponible para el entrenamiento, se utilizó la librería *fast.ai* y su función *aug_transforms* para crear una lista de transformaciones a partir de rotaciones, acercamientos, deformaciones e iluminación sobre los datos de entrenamiento. Adicionalmente se utilizaron imágenes de incendios reales en Argentina para probar el rendimiento del modelo con datos locales de Argentina.

En la **Fig. 2** se pueden ver algunas de las imágenes que se utilizan en la etapa de entrenamiento, posterior al proceso de preparación de los datos.



Fig. 2. Imágenes procesadas y listas para ser utilizadas en el entrenamiento de la Red Neuronal.

2.3 Entrenamiento de la Red Neuronal Convolutacional (CNN)

Una vez que se prepararon los datos, se debe entrenar la red neuronal. Se probaron 2 modelos que reciben los nombres de *ResNet* y *ConvNeXt*.

Se crearon y probaron 3 versiones de *ResNet*: *ResNet34*, *ResNet50* y *ResNet101*. En los 3 casos, el modelo arrojó falsos positivos y negativos en imágenes de bosques donde había neblina, mucho humo, o imágenes donde se veía el atardecer de fondo, como se observa en la **Fig. 3**



Fig. 3. Ejemplo de falsos positivos y negativos obtenidos usando *ResNet*

Para mejorar los resultados obtenidos con *ResNet*, se creó una red CNN denominada *ConvNeXt* que obtuvo una precisión del 100%, que significa que no hubo falsos positivos o negativos, y el modelo pudo clasificar correctamente las imágenes con y sin fuego. En la **Fig. 4** se observa la matriz de confusión asociada al modelo *ConvNeXt*

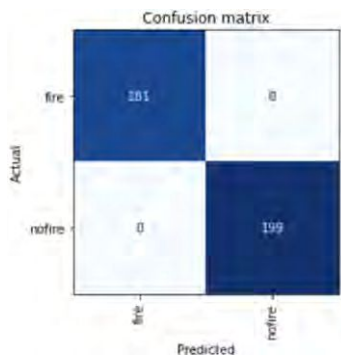


Fig. 4. matriz de confusión del modelo *ConvNeXt*

Después de generar los 4 modelos y comparar los resultados de la matriz de confusión de cada uno, se decidió integrar el modelo *ConvNeXt* en el tablero de la aplicación de monitoreo. Es decir, se priorizó un modelo que no genera falsos negativos, porque se desea que el modelo no falle cuando se necesite identificar si en una imagen se está produciendo un incendio, que se traduce en el envío de alertas de incendios en fases tempranas del incidente.

Con la información provista por el modelo, en el tablero de monitoreo se genera una alerta que le permite a los equipos de bomberos reaccionar a tiempo, y así reducir las probabilidades de que el fuego se convierta en un desastre difícil de contener.

3 Posibles Líneas de Investigación Futura

Como línea de investigación futura, proyectada a desarrollar dentro del INTEC, se propone extender al presente monitoreo por imágenes, con una red de dispositivos IoT con sensores de variables meteorológicas y atmosféricas. Este tipo de monitoreo por sensores, que incluiría variables climáticas, como la humedad relativa y la temperatura, y del estado el aire, como la presencia de partículas de humo y de gases combustibles, [9] permitiría obtener indicios de la presencia de incendios en la zona.

Para validar el aporte del presente trabajo y sus líneas de investigación, se entrevista a una autoridad de la Federación Mendocina de Bomberos Voluntarios. Respecto a StopFire, el entrevistado indica que mejoraría el esquema actual de prevención de incendios, ya que dependen principalmente de notificaciones vía telefónica y del análisis de imágenes satelitales de sitios gratuitos y en tiempo real como *FireMap* [10].

En cuanto al aporte de la solución de monitoreo integral, el entrevistado la considera *muy buena*, y agrega que es ideal detectar la columna de humo ‘cuanto antes’ porque las dos primeras horas son cruciales para controlar un incendio y evitar el caos.

Agradecimientos. Al Instituto de Tecnología (INTEC) de la Universidad Argentina de la Empresa (UADE) por integrar el PFI en la línea de investigación de *Aplicaciones de Machine Learning para Mejorar el uso de Recursos Naturales (A21T03)*.

Referencias

1. Argentina.gob.ar, «¿Qué es y cómo funciona el Servicio Nacional de Manejo del Fuego?», (2020). <https://www.argentina.gob.ar/ambiente/fuego/servicio-nacional> (accedido 31/7/22).
2. Argentina.gob.ar, «Reportes diarios del Servicio Nacional de Manejo del Fuego», (2021). <https://www.argentina.gob.ar/ambiente/fuego/diciembre-2021> (accedido 31/7/22).
3. Kurtz, D.B., Perucca, A.R., Saucedo, G., «Al 21 de febrero de 2022, la superficie quemada fue de 934.238 hectáreas | INTA». <https://inta.gob.ar/noticias/al-21-de-febrero-de-2022-la-superficie-quemada-fue-de-934238-hectareas> (accedido 31/7/22).
4. Inchausti, P.E., Martínez Saucedo, A.C., Amet, L., Blanco, P., Nievas, G., Giusto, L., «Aplicaciones de Machine Learning para el uso Sustentable de Recursos Naturales». <https://wicc2022.tk/workshop/6256d0d67c76870009464c77/post/6260a4135fedd100097c5c73> (accedido 31/7/22).
5. Martínez Saucedo, A.C., «AQUA: Desarrollo de un Modelo de Machine Learning para Prevenir Incendios Forestales en Pinamar», Tesis, Universidad Argentina de la Empresa, (2021). <https://repositorio.uade.edu.ar/xmlui/handle/123456789/14106> (accedido 5/9/22)
6. Ghosh, A., Sufian, A., Sultana, F., Chakrabarti, A., De, D., «Fundamental Concepts of Convolutional Neural Network», (2020), pp. 519-567. doi: 10.1007/978-3-030-32644-9_36.
7. fast.ai, «fast.ai - Welcome to fastai». <https://docs.fast.ai/> (accedido 31/7/22).
8. Dincer, B., «Kaggle» (2021) <https://www.kaggle.com/datasets/brsdincer/wildfire-detection-image-data> Wildfire Detection Image Data (accedido 31/7/22).
9. Argentina.gob.ar, «¿Cuáles son las variables y qué factores las afectan?», (2018). <https://www.argentina.gob.ar/ambiente/fuego/conocemas/variables> (accedido 3/9/22).
10. Robert E. Wolfe, «NASA-FIRMS», (2022). <https://firms.modaps.eosdis.nasa.gov/map/> (accedido 22/8/22).