

**PROTOTIPO DE UN SISTEMA DE MONITOREO PARA DETECCIÓN DE  
INCENDIOS EN ÁREAS PROTEGIDAS DEL DEPARTAMENTO DE  
SANTANDER CON LA GENERACIÓN DE ALERTAS EN TIEMPO REAL POR  
MEDIO DE DRONES**

**KEVIN JOEL OLARTE CAMARGO  
LUISA FERNANDA CHACÓN CASTRO**

**UNIVERSIDAD AUTÓNOMA DE BUCARAMANGA – UNAB  
FACULTAD DE INGENIERIA  
PROGRAMA DE INGENIERÍA DE SISTEMAS  
PROYECTO DE GRADO II  
LÍNEA DE INVESTIGACIÓN EN SISTEMAS DE INFORMACIÓN E INGENIERIA  
DE SOFTWARE  
LINEA DE INVESTIGACIÓN EN TELEMÁTICA  
BUCARAMANGA, MAYO 31 DE 2019**

**PROTOTIPO DE UN SISTEMA DE MONITOREO PARA DETECCIÓN DE INCENDIOS  
EN ÁREAS PROTEGIDAS DEL DEPARTAMENTO DE SANTANDER CON LA  
GENERACIÓN DE ALERTAS EN TIEMPO REAL POR MEDIO DE DRONES**

**KEVIN JOEL OLARTE CAMARGO  
LUISA FERNANDA CHACÓN CASTRO**

**Proyecto de Trabajo de Grado para optar por el título de Ingeniero de Sistemas**

**DIRECTOR:  
Paulo Cesar Ramírez Prada**

**CO-DIRECTOR:  
Diana Teresa Parra Sánchez**

**UNIVERSIDAD AUTÓNOMA DE BUCARAMANGA – UNAB  
FACULTAD DE INGENIERIA  
PROGRAMA DE INGENIERÍA DE SISTEMAS  
PROYECTO DE GRADO II  
GRUPO DE INVESTIGACIÓN EN TECNOLOGÍAS DE INFORMACIÓN  
LÍNEA DE INVESTIGACIÓN EN SISTEMAS DE INFORMACIÓN E INGENIERIA DE  
SOFTWARE  
BUCARAMANGA, MAYO 31 DE 2019**

## TABLA DE CONTENIDO

1. INTRODUCCIÓN .....	6
2. PLANTEAMIENTO DEL PROBLEMA .....	7
3. OBJETIVOS .....	9
3.1 OBJETIVO GENERAL .....	9
3.2 OBJETIVOS ESPECÍFICOS .....	9
4. MARCO REFERENCIAL .....	10
4.1 MARCO CONCEPTUAL.....	10
4.2 MARCO TEÓRICO.....	11
4.3 ESTADO DEL ARTE .....	15
4.4 MARCO LEGAL .....	21
5. METODOLOGÍA.....	24
6. RESULTADOS .....	25
7. DISCUSIÓN.....	58
8. CONCLUSIONES.....	59
9. TRABAJO FUTURO .....	61
REFERENCIAS.....	62

## LISTADO DE TABLAS

Tabla 1. Ventajas y desventajas de los UAV de ala fija y multirrotor.....	11
Tabla 2: Criterios de búsqueda. ....	15
Tabla 3. Análisis de documentos recuperados.....	19
Tabla 4. Análisis de documentos relacionados con CNN.....	26
Tabla 5. Matriz de confusión de incendios .....	28
Tabla 6. Comparativo de drones .....	29
Tabla 7. Sensores de distancia .....	29
Tabla 8. Comparativa de la placa microcontroladora .....	30
Tabla 9. Especificaciones técnicas Bebop Drone.....	33
Tabla 10. Especificaciones técnicas de la Raspberry Pi .....	34
Tabla 11. Especificaciones técnicas sensor ultrasonidoHC-SR04 .....	35
Tabla 12. Especificaciones conversor de nivel lógico .....	36
Tabla 13. Comparativa de optimizadores.....	37
Tabla 14. Arquitectura de la CNN.....	39
Tabla 15. Conjunto de datos .....	40
Tabla 16. Principales estándares .....	42
Tabla 17. Características de los componentes de la arquitectura .....	43
Tabla 18. Escenario 1 .....	44
Tabla 19. Escenario 2 .....	44
Tabla 20. Propósito .....	51
Tabla 21. Casos de prueba .....	52
Tabla 22. Resultados de la matriz .....	56
Tabla 23. Comparativa del sistema obtenido con el planteado. ....	57

## LISTADO DE FIGURAS

Figura 1. Pérdida de <i>ha</i> desde 2011 hasta 2016 .....	8
Figura 2. Hectáreas afectadas por departamento .....	13
Figura 3. Comparación de plataformas de detección remota .....	14
Figura 4. Evolución de la visión por computadora .....	15
Figura 5. Principales áreas protegidas de Santander por cobertura geográfica ....	31
Figura 6. Serranía de los Yariguíes.....	32
Figura 7. <i>Parrot bebop drone</i> .....	33
Figura 8. Raspberry Pi 3 Modelo B+ .....	34
Figura 9. Sensor ultrasónico HC-SR04 .....	35
Figura 10. Conversor lógico de nivel .....	36
Figura 11. Diseño del circuito en Fritzing .....	37
Figura 12. Diagrama <i>Convolutional Neuronal Network</i> .....	39
Figura 13. Clasificación de las redes inalámbricas.....	41
Figura 14. Arquitectura del sistema integrado de detección de incendios.....	43
Figura 15. Entrenamiento de la CNN .....	44
Figura 16. Equipos del GameDevLab .....	45
Figura 17. Equipo de entrenamiento de la red neuronal .....	46
Figura 18. Entrenamiento de la CNN .....	46
Figura 19. Capas de la red neuronal .....	47
Figura 20. Precisión por lotes.....	48
Figura 21. Pérdida por lotes .....	48
Figura 22. Pérdida por épocas .....	49
Figura 23. Precisión por épocas.....	50
Figura 24. Escenario de pruebas .....	52
Figura 25. Parrot Bebop Drone .....	54
Figura 26. Plataforma de evasión de objetos .....	54
Figura 27. Matriz de confusión .....	55
Figura 29. Visualización de la plataforma web .....	57
Figura 30. Componentes para la detección de incendio .....	69
Figura 31. Componentes para el vuelo autónomo.....	69
Figura 32. Componentes para la generación de alertas.....	69

## LISTADO DE ANEXOS

Anexo 1. Email: Petición y respuesta de acceso a la Base de Datos.....	67
Anexo 2. Soluciones tecnológicas Software.....	69

## 1. INTRODUCCIÓN

Los drones son definidos por el ejército como un “*vehículo terrestre, naval o aeronáutico, controlado a distancia o de forma automática*”, creados en un principio para fines militares, por ejemplo, vigilancia en zonas de conflicto (Ángel & Jiménez, 2016). En la actualidad, estos dispositivos son empleados en otros escenarios (no necesariamente de tipo militar), para la detección temprana de anomalías. Ejemplo de ello, es la detección de incendios forestales (Iberdrola, 2019), causados principalmente por negligencia de la comunidad, o a causa de las altas temperaturas producto del calentamiento global; afectando el ecosistema, impactando negativamente la flora y la fauna existente en el lugar, así como las viviendas aledañas.

Una de las formas de evitar y tratar a tiempo los incendios forestales es con la ayuda de los drones ya que tienen la capacidad de resistir temperaturas extremas desde -5°C hasta 50°C lo cual es de ayuda para los bomberos (Mora Tebas, 2018); equipándolos con dispositivos que pueden capturar imágenes y videos (para ser procesados posteriormente) con ayuda de sensores y cámaras IR (Infrarrojas) o de espectro visible para detectar a tiempo situaciones de incendio, los cuales deben estar conectados a Internet (Márquez Díaz, 2018).

Como antecedente en el tema de estudio, el documento “*Test bed for applications of heterogeneous unmanned vehicle*”, es un banco de pruebas experimentales para UAVs conectados a WiFi con rutas pre planeadas mediante una estación de control para seguimiento de vehículos y aplicaciones multiagente. Los UAVs comparten su información de navegación a través de UDP (*User Datagram Protocol*). Para el control y visualización de la información presentan LabView desarrollando una interfaz gráfica de usuario o haciendo uso de ROS plataforma de reemplazo de *firmware* original (Palacios et al., 2017).

El presente documento corresponde a un proyecto de trabajo de grado del Programa de Ingeniería de Sistemas, en la línea de investigación en Sistemas de Información e Ingeniería de Software. Esta propuesta está basada en la tendencia tecnológica de Internet de las Cosas, a través del uso de drones para el monitoreo de incendios en áreas protegidas en el Departamento de Santander (Colombia).

## 2. PLANTEAMIENTO DEL PROBLEMA

Las emisiones de gases efecto invernadero se reducen gracias al aporte de los bosques, pues ellos ayudan a mitigar el cambio climático. Actualmente a nivel mundial, la Organización de la Naciones Unidas para la Alimentación y la Agricultura (FAO, 2018) *“brinda apoyo a más de 40 países en la creación y evaluación de un Sistema Nacional de Seguimiento Forestal (SNSF), con el fin de generar recursos informativos forestales fiables a la hora de crear políticas”*. De 1950 al 2015 se han perdido más de un 50 por ciento de los bosques por el crecimiento de la población y la demanda de alimentos (FAO, 2018). En 1990, el mundo tenía 4128 millones de hectáreas (*ha*) de bosque; en 2015 había disminuido a 3999 millones de *ha* (FAO, 2015a).

En el contexto colombiano desde el 2015, el Gobierno Nacional en cabeza del Ministerio de Ambiente y Desarrollo Sostenible (MADS) y el Instituto de Hidrología, Meteorología y Estudios Ambientales (IDEAM) han desarrollado un plan con el acompañamiento de indígenas, guardabosques, y red de vigías rurales (FAO; MADS; IDEAM, 2018) para el monitoreo de la fauna, recursos hídricos, estrategias de conservación, turismo, monitoreo de la deforestación, entre otros. Sin embargo, a pesar de las acciones ejecutadas, los bosques siguen sufriendo grandes transformaciones, debido al conflicto armado, el desarrollo de obras de infraestructura planteadas sin una consideración adecuada de variables ambientales, drenaje, conversión, sedimentación de los humedales de agua dulce, demanda de tierras para la agroindustria, la tala de árboles ilegales, la minería, y los incendios forestales (WWF-Colombia, 2017).

Los incendios forestales han causado la extinción de grandes cantidades de *ha* en Colombia, provocando pérdida de fauna y flora, destrucciones de viviendas, deforestación, entre otras (ver Figura 1). En la actualidad Colombia se encuentra reportada en el puesto 10 de emergencias en incendios forestales, teniendo un porcentaje de 2,01% en Santander, afectando 1.467,50 *ha* (DNBC, 2017). En el primer trimestre de 2019, se han presentado varios incendios forestales. Uno de ellos, fue reportado en el páramo Almorzadero en Santander, que dejó como saldo afectaciones en 220 hectáreas de bosque nativo (El Tiempo, 2019).






Figura 1. Pérdida de *ha* desde 2011 hasta 2016

Fuente: Tomado de (IDEAM, 2016)

Una forma de atender la problemática descrita anteriormente, está relacionada con la utilización de drones, equipados con cámaras y sensores para el monitoreo de incendios forestales en áreas protegidas del Departamento de Santander, detectando de manera oportuna posibles incendios para que las entidades competentes puedan actuar inmediatamente.

Lo anterior da origen a la siguiente pregunta de investigación: *¿De qué manera se puede mejorar el tiempo de respuesta a incendios en áreas protegidas en el Departamento de Santander?*

### **3. OBJETIVOS**

#### **3.1 OBJETIVO GENERAL**

Desarrollar un prototipo de sistema para la detección de incendios en áreas protegidas del Departamento de Santander mediante la implementación de drones que ejecuten operaciones de reconocimiento de área para la generación de alertas en tiempo real.

#### **3.2 OBJETIVOS ESPECÍFICOS**

- Elaborar un estado del arte sobre soluciones de sistemas de monitoreo aplicadas con drones para el control de incendios forestales.
- Desarrollar el sistema para el monitoreo de incendios en áreas protegidas con el control de drones y la generación de alertas en tiempo real.
- Realizar pruebas de funcionamiento del sistema de monitoreo de incendios en áreas protegidas de Santander en un entorno controlado.

## 4. MARCO REFERENCIAL

En esta sección es presentado el marco referencial del proyecto, conformado por el marco conceptual, marco teórico, estado del arte y marco legal.

### 4.1 MARCO CONCEPTUAL

El marco conceptual del proyecto está desarrollado en torno a los siguientes descriptores: *drones, forest fire, computer visión, reinforcement learning, y neural networks*.

*Dron: “Vehículo no tripulado que puede volar de forma autónoma o remota”* (Torres Simón, 2017).

*Área protegida: “Son lugares que son designados para la conservación de los ecosistemas”* (Achkar et al., 2011).

*Internet of Things: “Conectividad a Internet en dispositivos, sensores y artículos cotidianos (por ejemplo: productos de consumo, autos, monitores de salud portátiles y colecciones de dispositivos que funcionan juntos para crear conceptos tales como “ciudades inteligentes” y “casas inteligentes”)” recolectando datos para ser analizados y entregar servicios para ser usados en otros dispositivos* (Manyika et al., 2016).

*Red Ad hoc: “Es un tipo de red inalámbrica descentralizada que no depende de una infraestructura pre-existente, como routers (redes cableadas) o puntos de acceso (redes inalámbricas administradas)”. Son flexibles, autónomas y utilizan nodos para la comunicación hacía otros nodos* (Muñoz, Porta, & Contreras, 2014).

*Red neuronal artificial: Modelos computacionales inspirado en la inteligencia humana la cual va aprendiendo a través de la experiencia* (Flórez López & Fernández Fernández, 2008).

*Visión por computadora: “Rama de la inteligencia artificial que tiene como objetivo emular la visión humana”* (Bradski & Kaehler, 2008).

*Red Neuronal Convolutacional: “es una red multicapa jerárquica comúnmente utilizada para el aprendizaje profundo”* (Diaz Cuesta, 2018).

*Overfitting: “El ajuste excesivo es un error de modelado que se produce cuando una función se ajusta demasiado a un conjunto limitado de puntos de datos”* (Investopedia, 2019).

## 4.2 MARCO TEÓRICO

El marco teórico del proyecto se basa principalmente en la presentación de soluciones tecnológicas con drones para la detección de incendios en zonas forestales.

### *Concepto y características de Drones*

“Los drones son vehículos no tripulados que pueden volar de forma autónoma o remota” (Torres Simón, 2017). En un principio fueron diseñados para fines militares, para vigilancia en el combate. Luego fueron equipados con armamento y ahora están siendo utilizados para aplicaciones civiles como captura de imágenes y video aéreo, monitoreo y vigilancia, inspección de infraestructuras, búsqueda y rescate, gestión de emergencias, mapeo de terrenos, entre otros (Addati & Pérez Lance, 2014). Las principales características para elegir un UAV son: autonomía, carga útil transportable, dimensiones, capacidad de despliegue, y tipo de misión que debe cumplir. Los drones pueden ser clasificados según su alcance (corto alcance, mediano alcance, y largo alcance), o por el tipo de alas (fijas, y móviles o rotatorias) (Bermúdez Huertas & Villamil Hernández, 2015). En la Tabla 1, se muestran las diferencias que tiene cada UAV.

Tabla 1. Ventajas y desventajas de los UAV de ala fija y multirrotor.

Nombre	Ventaja	Desventaja	Uso
<b>Multirrotor</b>	Accesibilidad	Tiempos cortos de vuelo	Inspección aérea con fotografía y video
	Fácil de usar		
	VTOL (aterrizaje y despegue de forma vertical)		
	Buen control de la cámara	Poca capacidad de carga útil	
	Puede sobrevolar áreas congestionadas		
<b>Ala fija</b>	Larga duración	Requiere mucho espacio para el despegue y aterrizaje	-
	Gran cobertura de área	No VTOL	Mapeo aéreo, tubería, inspección de línea eléctrica
	Velocidad al volar	Requiere entrenamiento para volarlo	
		Costoso	
Fuente: Tomado de (Ahmed & Mehmood, 2017)			

De acuerdo a lo expuesto en la Tabla 1, los UAV multirrotor son ideales para la toma de imágenes y videos por tener la capacidad de volar en un punto fijo a una velocidad muy baja, con mayor precisión gracias a su maniobrabilidad, teniendo la capacidad de acercarse a su objetivo. Además, tienen estabilidad en cuanto al

despegue y aterrizaje, haciéndolo de forma vertical, reduciendo espacio en tierra. Los de ala fija son ideales para largos recorridos por tener un menor gasto energético, teniendo mayor duración de vuelo a mayor velocidad (García García, 2017).

### *Concepto y características de los sensores a bordo de los drones*

Los drones al ser una aeronave no tripulada, su piloto debe ser sustituido por sensores para que estos adquieran su maniobrabilidad, y se equipan según la función que vaya a tener el dron, algunos de estos sensores son (García García, 2017):

*De imagen:* para elegir la cámara adecuada se debe tener en cuenta la ligereza por el consumo energético, la robustez para soportar los posibles golpes, lentes intercambiables en función de la distancia, la resolución si es alta (4k), mayores a 300 px por pulgada (ppi) o baja menores de 100 ppi.

*En función de su longitud de onda:* longitud de onda óptica, infrarrojo o térmica, multiespectral e hiperespectral. La óptica captura imágenes entre 380 y 780 nm. Estos dispositivos están compuestos por lentes para controlar la luz entrante y enfocar la imagen. La Infrarroja mediante emisiones de infrarrojo del espectro electromagnético detecta imágenes en función de la temperatura con una longitud de onda de 3  $\mu m$  y 14  $\mu m$ . Las multiespectrales son las que generan imágenes con poca longitud de onda simultáneamente, y las hiperespectrales son las que tienen múltiples longitudes de onda.

### *Concepto y características de los Incendios forestales*

Los Organismos internacionales como la FAO, Organización de las Naciones Unidas (ONU), y la Organización Internacional de las Maderas Tropicales (OIMT), están preocupados por la presencia recurrente de los incendios forestales a nivel de todos los países, afectando de manera negativa, ocasionando pérdidas de los recursos boscosos, incremento de la deforestación, efectos sobre el aire, contaminación, entre otros (Minambiente, 2019).

Para el contexto colombiano, en períodos de sequía se ven afectados cada año 42000 ha por ser más susceptibles a la combustión, afectando páramos, bosques húmedos, área de plantación forestales, entre otros. Las principales causas son la expansión de frontera agropecuaria, y deficiencia en la educación ambiental de la población (IDEAM, 2019). En la Figura 2, se pueden observar los departamentos de Colombia más afectados en el año 2016. En el caso del Departamento de Casanare, la afectación fue significativa en comparación con el número de incendios que se generaron en ese año. Por el contrario, el Departamento de Cundinamarca fue el de mayor número de incendios, pero con menos ha afectadas.

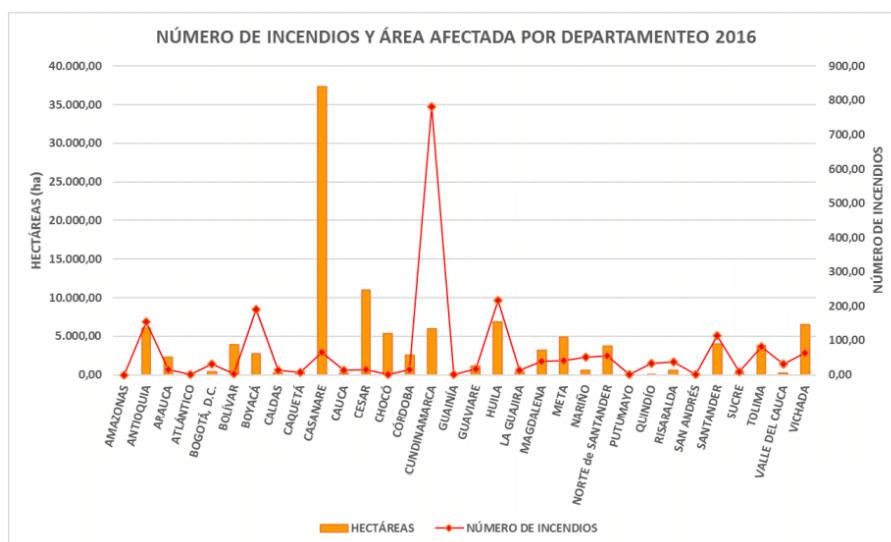


Figura 2. Hectáreas afectadas por departamento  
Fuente: Tomado de la IDEAM

Los incendios tienen distintas naturalezas como son: accidentales, negligencias, intencionales y naturales, los cuales se pueden clasificar en los siguientes tipos (Comisión Nacional Forestal, 2005):

- Incendio superficial: La propagación se hace de forma horizontal alcanzando hasta metro y medio de altura afectando pastizales, hojas, ramas, pequeños árboles, entre otros.
- Incendio subterráneo: La propagación del fuego se hace bajo el suelo, quemando materia orgánica acumulada y las raíces, generalmente no producen llamas y emiten poco humo.
- Incendio de copa o aéreo: son los más difíciles de controlar, ya que consume toda la vegetación propagándose de manera vertical.

Los diferentes tipos de incendios empiezan con incendios superficiales, pero van aumentando debido a los factores ambientales, al no tener un aviso eficiente y rápido a las autoridades competentes. Para el control de los incendios se emplean diferentes plataformas de control dependiendo de la aplicación y extensiones del terreno como son las plataformas satelitales, los vehículos aéreos tripulados, las técnicas terrestres y los UAV.

### *Concepto y características Remote-sensing platforms*

Las plataformas de detección remota son útiles para proporcionar información en aplicaciones agroforestales (Vanko et al., 2017). Las tecnologías tradicionales de teledetección abarcan plataformas satelitales y tripuladas, pero ahora los drones también están siendo utilizados para estos fines ya que tienen un costo bajo en comparación a las otras plataformas (Vanko et al., 2017). En la Figura 3, Vanko et

al., (2017) presentan un comparativo de las ventajas y desventajas de cada sistema remoto (de mayor altitud a menor altitud): (i) Satélites: gran cobertura y capacidad espectral amplia, pero baja resolución y baja cobertura en algunas regiones. (ii) Aviones tripulados: costosos para aplicar en proyectos pequeños como la detección de incendios en áreas específicas. (iii) UAV de ala fija y multirrotores: alternativa nueva y de bajo costo, donde se aplica para áreas específicas, y (iiii) Técnicas terrestres: son labores intensivas para las personas encargadas y tienen una única línea de visión.






Altitude		Pros	Cons
Satellite		<ul style="list-style-type: none"> <li>• Extensive coverage</li> <li>• Wide spectral capability</li> </ul>	<ul style="list-style-type: none"> <li>• Low-resolution</li> <li>• Image acquisition timing</li> <li>• Weak coverage in some regions</li> <li>• Sensitive to clouds</li> </ul>
Manned aircraft		<ul style="list-style-type: none"> <li>• Large coverage with single flight</li> <li>• High-resolution</li> <li>• Wide spectral capability</li> </ul>	<ul style="list-style-type: none"> <li>• Expensive (for small projects)</li> <li>• Image acquisition timing</li> <li>• Weather-dependent</li> <li>• Sensitive to clouds</li> <li>• Not available in remote regions</li> </ul>
Fixed-wing UAV		<ul style="list-style-type: none"> <li>• Cost-effective for small projects</li> <li>• Very high-resolution (fixed wing: up to 2cm/pixel; Rotary: sub-millimetre)</li> <li>• Not affected by clouds due to the lower flight altitude</li> <li>• Positional accuracy</li> </ul>	<ul style="list-style-type: none"> <li>• Small coverage</li> <li>• Regulation may restrict operations</li> <li>• Sensitive to bad weather</li> <li>• Difficult to reconstruct homogenous areas (few tie points)</li> </ul>
Multi-rotor UAV			
Terrestrial techniques		<ul style="list-style-type: none"> <li>• Excellent Positional accuracy</li> <li>• Few data (only required)</li> <li>• Very high-resolution</li> <li>• In-situ data classification</li> </ul>	<ul style="list-style-type: none"> <li>• Labour intensive</li> <li>• Only line-of-sight</li> <li>• Accessibility (some sites)</li> </ul>

Figura 3. Comparación de plataformas de detección remota  
Fuente: Tomado de (Vanko et al., 2017)

### *Aplicación del Inteligencia Artificial (IA) para la detección de incendios forestales.*

Según Sebe et al. (2005), “la visión por computadora es la ciencia y tecnología que permite a las máquinas ver por medio de teorías, diseños e implementaciones de algoritmos que procesan datos visuales para reconocer objetos, rastrear, y recuperar su forma y posición” (Sebe, Cohen, Huang, & Gard, 2005). Los dos pilares de la visión por computadora son: el sistema de formación de las imágenes y el sistema de procesamiento, en los cuales se capta y adquiere la imagen donde se procesa mediante los algoritmos para convertirse en información de alto nivel para ser utilizadas en robot o fuentes de datos (Cognex, 2018). En la Figura 4 se aprecian las aplicaciones de la visión por computadora la cual ha tenido diferentes desarrollos

desde su aparición. En la década del 2000 la visión por computadora se fundamentó a la aplicación de técnicas de aprendizaje automático (Szeliski, 2011).




Figura 4. Evolución de la visión por computadora  
Fuente: Tomado de (Szeliski, 2011).

### Robot Operating System (ROS)

Según la página oficial de Ros: “ROS es un framework flexible para escribir software de robots. Es una colección de herramientas y librerías que simplifican las tareas para crear un comportamiento robótico” (Ros, 2019).

Por lo tanto, ROS son bibliotecas requeridas para programar los distintos propósitos de los robots. ROS utiliza nodos los cuales son los encargados de comunicarse unos con otros (Morgan, Brian, & Smart, 2015). Un nodo es cualquier proceso que puede leer datos de un sensor, controlar un actuador o ejecutar algoritmos complejos. En este proyecto vamos a utilizar la versión ROS Kinetic el décimo lanzamiento de ROS el cual está dirigido a la versión de Ubuntu 16.04.

### 4.3 ESTADO DEL ARTE

Las bases de datos utilizadas para la búsqueda de publicaciones relacionadas con soluciones tecnológicas empleando drones para la detección de incendios en zonas forestales con alertas en tiempo real, fueron *IEEE Xplore*, *Scopus*, *Google Scholar*, y *Taylor & Francis*. Se emplearon los siguientes descriptores: *drones*, *forest fire*, *computer vision*, *reinforcement learning*, y *neural networks*. Esta búsqueda fue realizada el 8 de febrero del 2019. Fueron seleccionados un total de 12 documentos.

Tabla 2: Criterios de búsqueda.



Palabras Clave: <i>drones, forest fire, computer vision, reinforcement learning, neural networks.</i>	
Bases de datos Consultadas	<i>IEEE Xplore, Scopus, Google Scholar, y Taylor &amp; Francis.</i>
Cantidad de Referencias Recuperadas	12 documentos recuperados
Fecha de Búsqueda	Febrero 8 y 11 de 2019.
Criterios de Búsqueda	Rango de Fecha de la Búsqueda: entre 2013 y 2018.
	Pertinencia con el tema de investigación: <ul style="list-style-type: none"> <li>• <i>Drones.</i></li> <li>• <i>Forest fire.</i></li> <li>• <i>Computer vision.</i></li> <li>• <i>Reinforcement learning.</i></li> <li>• <i>Neural networks.</i></li> </ul>
	Documentos en inglés, publicados en Revistas Científicas, libros o Actas de Conferencia.

A continuación, se presenta una síntesis de los documentos estudiados:

*A survey of forest fire detection techniques:* El documento presenta un sistema de vigilancia con drones autónomos, para la detección de incendios forestales transmitiendo en tiempo real a la estación base mediante comunicación inalámbrica. Los autores, presentan una revisión de diferentes sistemas de monitoreo satelital, así como los sensores y cámaras utilizadas para cada caso de detección de incendios (Thamizhmathi & Usharani, 2014).

*A survey on technologies for automatic forest fire monitoring, detection, and fighting using unmanned aerial vehicles and remote sensing techniques:* Presenta un comparativo de tecnologías existentes de monitoreo, detección y combate de incendios forestales basadas en UAV (*Unmanned Aerial vehicle*), utilizando ROS con énfasis en las técnicas de monitoreo y detección. Los autores se enfocaron en la detección del color de la llama, o el humo utilizando la propagación hacia atrás (*backpropagation*) con redes neuronales. Demostraron que la combinación de imágenes infrarrojas y visuales puede contribuir a la detección robusta de incendios forestales, incluida una alta probabilidad de detección, bajas tasas de falsas alarmas y capacidades de adaptación mejoradas en diversas condiciones ambientales (Yuan, Zhang, & Liu, 2015).

*Efficient Forest Fire Detection Index for Application in Unmanned Aerial Systems (UASs):* En este documento se presenta un método para detectar incendios por medio de las tonalidades de las llamas y el humo, detectando etapas tempranas de incendios en boques y zonas urbanizadas con drones autónomos, equipados de un sensor óptico para contar con una visión de 180° y un sistema de transmisión inalámbrica, donde se envían las imágenes a la plataforma móvil que ejecuta el software de detección (Cruz, Eckert, Meneses, & Martínez, 2016).

*Airborne Optical and Thermal Remote Sensing for Wildfire Detection and Monitoring:* Presenta una revisión de técnicas de detección de incendios con plataformas aéreas tripuladas y no tripuladas de forma directa, semiautomática y automatizada. Para utilizar la visión artificial tuvieron en cuenta propiedades y características del fuego que incluyen el calor, la luz, el humo, el parpadeo, el movimiento y los subproductos químicos. El calor proporciona una señal fuerte para la detección de incendios. El color se detecta mediante algoritmos de visión artificial utilizando cámaras para detectar propiedades de color (Allison, Johnston, Craig, & Jennings, 2016).

*Sistema de monitoreo vigilancia usando cámaras de seguridad y drones en la finca “La María” de la UTEQ:* Los autores propusieron un esquema de red con el uso de cámaras de seguridad y drones, para tener monitoreo remoto de video y vigilancia IP mediante una LAN (*Local Area Network*) o Internet, para que el usuario pueda monitorear desde diferentes lugares mediante un navegador web estándar o un software de gestión de video (Suasnavas Males, 2016).

*Test bed for applications of heterogeneous unmanned vehicle:* Presenta pruebas de un banco para aplicaciones de drones heterogéneos (Parrot Ar y Bebop), controlando los vehículos en tiempo real en un entorno basado en el sistema VICON y LabVIEW (instrumento Nacional) o las plataformas de sistema operativo robótico, moviéndose juntos para rastrear un objetivo (el incendio). En la comunicación utilizaron comandos AT y el protocolo UDP (*User Datagram Protocol*), basándose en la sustitución del *firmware* original que lea los datos sin procesar los sensores (Palacios et al., 2017).

*The progress of operational forest fire monitoring with infrared remote sensing:* Es presentada una descripción de métodos para la detección de incendios, en los que se destacan los sensores remotos de infrarrojos, satelitales y drones (IRRS) para la detección de incendios forestales. Los autores demostraron que los drones equipados con sensores ópticos (incluidos los visibles y los infrarrojos) hasta sensores de microondas pudiesen recibir comandos de la estación terrestre y enviar información a la misma siendo efectivo para obtener datos en tiempo real de los incendios forestales (Hua & Shao, 2017).

*Flying ad-hoc network application scenarios and mobility models:* Se presentaron los modelos de movilidad con UAV mediante una red de comunicación *Ad hoc*. Los UAV dirigidos al monitoreo de incendios forestales son equipados con sensores específicos para monitorear éstas áreas y cuando un UAV detecta un incendio, se activa una alarma para que los otros UAV se acerquen al objetivo para monitorear el proceso desde cerca (Bujari et al., 2017).

*UAS, sensors, and data processing in agroforestry: a review towards practical applications:* Se presenta una comparación de las plataformas de teledetección, sus ventajas, desventajas, y los tipos de UAV, sensores, métodos de procesamiento, y aplicaciones en la agroforestería. Los autores presentan operaciones a realizar con

los datos adquiridos y puestos en un mosaico para hacer el preprocesamiento de imágenes, registro de imágenes, y fusión de imágenes para cubrir toda el área de interés. También muestran la calibración geométrica para evitar deformaciones de la imagen (Vanko et al., 2017).

*Emerging methods for early detection of forest fires using unmanned aerial vehicles and LoRaWAN sensor networks:* Los autores presentan dos soluciones para la detección temprana de incendios forestales. La primera es con el uso de drones con cámaras de doble lente, proporcionando imágenes estándar e IR en tierra utilizando UAV de viento fijo y uno de ala rotatoria los cuales se encargan de investigar el informe que envíen las cámaras. En la segunda utilizaron la tecnología de comunicación inalámbrica digital de largo alcance (LoRa), establecieron una red LoRaWAN con dos tipos de puertas de enlace: los concentradores, que montaron en los microcomputadores y los módulos Pycom LoPy con paneles de extensión, recibiendo datos de más de 6000 dispositivos de estaciones con sensores de temperatura, humedad y presión atmosférica (Hristov, Raychev, Kinaneva, & Plamen, 2018).

*An Application Framework for Forest Fire and Haze Detection with Data Acquisition Using Unmanned Aerial Vehicle:* El documento presenta una investigación en curso de un *framework* para mejorar el monitoreo en bosques basado en sensores, aprendizaje supervisado automático, Big Data, y drones junto con la API de *Cloud Vision* de Google. El sistema pretende recopilar los datos obtenidos por los sensores ubicados en diferentes sitios para detectar el humo y los incendios en una etapa temprana y mostrarlos en una aplicación móvil Android (Saadat & Husen, 2018).

*An Unmanned Aircraft System for Automatic Forest Fire Monitoring and Measurement:* El documento presenta un sistema de monitoreo de incendios forestales, utilizando drones para cubrir la alarma detectada desde varias direcciones. Los datos los obtienen en tiempo real con cámaras de infrarrojos o visuales. Al momento de detectar un incendio, se envían a la estación central las coordenadas, para que todos los drones lleguen al lugar para monitorear desde diferentes perspectivas. Luego, los drones se devuelven y aterrizan (Merino, Caballero, Martínez-De-Dios, Maza, & Ollero, 2012).

*A deep learning approach towards autonomous flight in forest environments:* Los autores presentan un sistema para detectar y evitar obstáculos de manera autónoma con el dron Parrot Bebop 2, utilizando una red neuronal AlexNet. El sistema fue probado en dos entornos, uno simulado con la plataforma *gazebo* con la versión *Ros kinetic kame* y un entorno forestal mediante un enlace de comunicación WiFi entre el *drone* y la estación de control. En los dos entornos el resultado fue exitoso al momento de esquivar los obstáculos (Dionisio Ortega, Rojas Perez, Martinez Carranza, & Cruz Vega, 2018).

En la Tabla 3, es presentada información relevante de cada uno de los documentos estudiados.

Tabla 3. Análisis de documentos recuperados.

Título	Tipo	Objetivo	Tecnologías	Dispositivos
<i>A survey of forest fire detection techniques</i> (Thamizhmathi & Usharani, 2014).	Artículo científico.	Evaluar la viabilidad de un sistema de detección de incendios utilizando drones, comunicación inalámbrica e inteligencia artificial.	Comunicación inalámbrica, red neuronal <i>feedforward</i> .	Drones y sensores.
<i>A survey on technologies for automatic forest fire monitoring, detection, and fighting using unmanned aerial vehicles and remote sensing techniques</i> (Yuan, Zhang, & Liu, 2015).	Artículo científico.	Realizar un comparativo de tecnologías utilizadas en la detección de incendios basadas en UAV.	Propagación hacia atrás ( <i>Backpropation</i> ), ROS, red neuronal, visión por computadora.	Drones y sensores.
<i>Efficient Forest Fire Detection Index for Application in Unmanned Aerial Systems (UASs)</i> (Cruz et al., 2016).	Acta de conferencia.	Evaluar técnicas de detección de incendios desde plataformas aéreas no tripulados.	Índice de detección de incendios forestales (FFDI), transmisión inalámbrica.	UAV ( <i>Bepop Parrot</i> ), plataforma móvil (tableta de cuatro núcleos, memoria 2GB, android), sensor óptico.
<i>Airborne Optical and Thermal Remote Sensing for Wildfire Detection and Monitoring</i> (Allison et al., 2016).	Acta de conferencia.	Evaluar las plataformas de detección de incendios con aviones tripulados y no tripulados de forma directa, automáticas y semiautomáticas.	Red neuronal.	Drones y sensores.
<i>Sistema de monitoreo vigilancia usando cámaras de seguridad y drones en la finca "La María" de la UTEQ</i> (Suasnavas Males, 2016).	Trabajo de grado.	Evaluar la factibilidad de un sistema de monitoreo vigilancia mediante drones para grabar en tiempo real.	GPS <sup>1</sup> , LAN.	Cámaras, dron Phantom 3 profesional, router, switch poe, tablet, gabinete para comunicaciones y servidores.

<sup>1</sup> GPS: Global Positioning System.

Título	Tipo	Objetivo	Tecnologías	Dispositivos
<i>Test bed for applications of heterogeneous unmanned vehicle</i> (Palacios et al., 2017).	Artículo científico.	Presentar un banco de prueba de aplicaciones con drones donde se pueda elegir entre cuatro entornos variados entre los drones y el software.	Ros, labview, Sistema de movimiento optiTrack, red neuronal.	Drones <i>Parrot</i> y <i>bebop</i> .
<i>The progress of operational forest fire monitoring with infrared remote sensing</i> (Hua & Shao, 2017).	Artículo científico.	Presentar un estudio de diferentes métodos para la detección de incendios.	Algoritmos FFM.	Drones y sensores.
<i>Flying ad-hoc network application scenarios and mobility models Home</i> (Vanus et al., 2016).	Acta de conferencia.	Presentar modelos de movilidad con drones mediante una red de comunicación <i>Ad-hoc</i> .	Redes <i>Ad hoc</i> .	Drones y sensores.
<i>UAS, sensors, and data processing in agroforestry: a review towards practical applications</i> (Vanko et al., 2017).	Artículo científico.	Comparar plataformas para teledetección con sus ventajas y desventajas.	Índices espectrales.	Drones, satélite, sensores RGB, infrarrojo, hiperespectral, multiespectral.
<i>Emerging methods for early detection of forest fires using unmanned aerial vehicles and LoRaWAN sensor networks</i> (Hristov et al., 2018).	Artículo científico.	Presentar dos soluciones para la detección temprana de incendios forestales.	Comunicación inalámbrica digital de largo alcance (LoRa), red LoRaWAN.	Drones, cámaras doble lente, sensores de temperatura, humedad y presión atmosférica.
<i>An Application Framework for Forest Fire and Haze Detection with Data Acquisition Using Unmanned Aerial Vehicle</i> (Saadat & Husen, 2018).	Artículo científico.	Presentar investigación de un <i>framework</i> para mejorar el monitoreo en bosques basado en sensores y aprendizaje automático, <i>Big Data</i> y drones.	Aprendizaje automático, <i>Big Data</i> , <i>Api Cloud Vision</i> .	Drones, móvil y sensores.

Título	Tipo	Objetivo	Tecnologías	Dispositivos
<i>An Unmanned Aircraft System for Automatic Forest Fire Monitoring and Measurement</i> (Merino et al., 2012).	Artículo científico.	Presentar un sistema de monitoreo de detección de incendios forestales en tiempo real, utilizando drones.	ANFIS ( <i>Adaptive Neuro-Fuzzy Inference Systems</i> ).	Drones Marvin, heliv y karma, sensor infrarrojo.
<i>A deep learning approach towards autonomous flight in forest environments</i> (Dionisio Ortega et al., 2018)	Artículo científico.	Presentar un sistema para detectar y evadir obstáculos por medio de drones y la red neuronal AlexNet.	Wifi, Red neuronal AlexNet, ROS, gazebo.	Dron parrot, bebop, sensores.

Fuente: Elaboración propia

#### 4.4 MARCO LEGAL

En el marco legal del proyecto se tendrán en consideración las siguientes normas y recomendaciones relacionadas con el tema del Trabajo de Grado, como son el cuidado de los bosques, el manejo de los drones y redes de comunicación descritas en el mismo orden.

*Para el cuidado de los bosques:*

Decreto 2811 del 18 de diciembre de 1974

Artículo 1. *“El ambiente es patrimonio común. El Estado y los particulares deben participar en su preservación y manejo, que son de utilidad pública e interés social”* (Minambiente, 1974).

Artículos de la constitución política del 91:

Artículo 79. *“Todas las personas tienen derecho a gozar de un ambiente sano. La ley garantizará la participación de la comunidad en las decisiones que puedan afectarlo”* (Constitucion politica de Colombia, 1991).

*Según (Aeronautica Civil de Colombia, 2015) no se permitirá operación RPAS en Colombia para:*

- a) Volar sobre área congestionada o aglomeraciones de personas.
- b) Volar de modo que se pueda crear un riesgo para las personas o propiedades en la superficie, ocasionados por vientos fuertes o imperfectos en aparato.
- c) Peso máximo de despegue superior a 25 Kg (Grandes).
- d) Elementos diferentes a los aprobados por la DSNA.
- e) Volar desde un aeródromo o en sus proximidades dentro de un radio de 2.7 NM - Millas Náuticas (5 Km) a la redonda.

- f) Volar a una altura superior a 500 pies (152 metros aproximadamente) sobre el terreno (AGL) o sobre el agua.
- g) Volar de modo que se aleje más de 750 metros de distancia del despegue.
- h) Volar en operación nocturna o diurna bajo reglas de vuelo por instrumentos.
- i) Volar al interior de una zona prohibida o restringida del espacio aéreo, publicada por la UAEAC.
- j) Volar en las proximidades dentro de un radio de 1 Milla Náutica (1.8 Km aproximadamente) a la redonda de donde se encuentra el presidente de la República, Vice Presidente y otras autoridades nacionales y extranjeras.
- k) Volar cerca de, o sobre instalaciones militares, policiales o centros carcelarios.
- l) Volar transportando animales.
- m) Arrojar objeto alguno estando en vuelo.
- n) Operar cerca de cualquier aeronave tripulada.
- o) Efectuar operaciones autónomas, en el ámbito civil, haciendo uso de Vehículos Aéreos Autónomos, independiente de cuál sea su finalidad, excepto para su pronta recuperación en caso de fallas o emergencia.

#### *Tecnologías de información y uso del espectro*

Recomendación Y.2060: Infraestructura mundial de la información, aspectos del protocolo internet y redes de la próxima generación “UIT-T Y.2060 se presenta en términos generales Internet de los objetos (IoT). Se aclara el concepto y el alcance de IoT, se identifican las características fundamentales y los requisitos de alto nivel de IoT y se describe el modelo de referencia IoT.” (Unión Internacional de Telecomunicaciones, 2012).

Ministerio de Tecnologías de la información y las comunicaciones, Decreto 1078 de 2015-2018: “Por el cual se expide el decreto único reglamentario de las tecnologías de la información y las comunicaciones” En el cual se determinan las entidades responsables asociadas al sector de la informática y las telecomunicaciones, sus funciones y responsabilidades en la administración del campo (Ministerio de Tecnologías de la Información y las Comunicaciones, 2015).

ANE, Política de espectro radioeléctrico 2015 – 2018: La Agencia Nacional del Espectro Radioeléctrico en base a la implementación de el Plan Vive Digital 2010 – 2014 (PVD) el cual tuvo con objetivo “impulsar la masificación y el uso de Internet a través del despliegue y uso eficiente de infraestructura y la promoción y apropiación de los servicios TIC” resuelve que es preciso “ajustar la política de espectro radioeléctrico para adecuarla al contexto actual, las tendencias que se avizoran y los lineamientos trazados tanto por la Ley 1753 de 2015 (Plan Nacional de Desarrollo 2014– 2018) como por el PVD 2014– 2018 (PVD-II)” (Agencia Nacional del Espectro, 2018) .

Documento CONPES 3920 Política Nacional de explotación de Datos (Big Data): El 17 de abril de 2018 se expidió este documento con el siguiente objetivo, *“La presente política tiene por objetivo aumentar el aprovechamiento de datos, mediante el desarrollo de las condiciones para que sean gestionados como activos para generar valor social y económico”* (Consejo Nacional de Política Económica y Social, 2018).



## 5. METODOLOGÍA

Para el desarrollo del proyecto de Trabajo de Grado, se han definido tres etapas principales, relacionadas estrechamente con los objetivos específicos del proyecto. A continuación, son presentadas las actividades asociadas con cada una de las etapas.

**Etapla 1:** Elaboración de un estado del arte sobre soluciones de sistemas de monitoreo aplicadas con drones para el control de incendios forestales.

Las actividades que se realizarán es esta etapa son:

1. Búsqueda en la base de datos académicos.
2. Identificación de soluciones tecnológicas con drones para la detección de incendios en zonas forestales con la generación de alertas en tiempo real.
3. Síntesis del estado del arte.
4. Documentación de resultados.

**Etapla 2:** Desarrollo del sistema para el monitoreo de incendios en áreas protegidas con el control de drones y la generación de alertas en tiempo real.

Las actividades que se realizarán es esta etapa son:

5. Selección de tecnologías (HW y SW).
6. Diseño del prototipo de monitoreo de la solución tecnológica con drones.
7. Construcción del prototipo de monitoreo de la solución tecnológica con drones.

**Etapla 3:** Pruebas de funcionamiento del sistema de monitoreo de incendios en áreas protegidas de Santander.

8. Comparativa del sistema obtenido con el planteado.
9. Medición de efectividad de envío de datos para la manipulación del dron.
10. Documentación de resultados.

## 6. RESULTADOS

Con el desarrollo del Proyecto de Investigación, se obtuvieron los siguientes resultados:

### 6.1 ESTADO DEL ARTE SOBRE SOLUCIONES DE SISTEMAS DE MONITOREO APLICADAS CON DRONES PARA EL CONTROL DE INCENDIOS FORESTALES

Se realizó una revisión de la literatura de los últimos cinco años utilizando base de datos académicas, obteniendo una serie de documentos relacionados con drones aplicados a la detección de incendios en zonas forestales en tiempo real, para identificar de manera relevante tecnologías, protocolos y, técnicas de *Deep Learning*. A continuación, es presentada información de dos investigaciones que influyeron en la elección de los dispositivos y herramientas software.

Vanko et al., (2017) en el documento titulado “*UAS, sensors, and data processing in agroforestry*”, presentaron un comparativo de plataformas de teledetección, tipos de sensores de imagen, etapas de procesamiento, y las aplicaciones que pueden tener los UAV, tomando en consideración las siguientes especificaciones: durabilidad de vuelo y capacidad de carga útil de cada plataforma de teledetección. Los autores demostraron que los UAV son óptimos en flexibilidad, procesamiento y resolución y deficientes en la cobertura, resistencia de vuelo y geo codificación. Adicionalmente presentaron la clasificación de los UAV, en dos clases: (i) De ala fija: tienen mayor capacidad de vuelo, y (ii) Rotatorios: tienen mayor maniobrabilidad y son especiales para monitorear zonas pequeñas (Vanko et al., 2017).

Merino et al., (2012), en el documento titulado “*An Unmanned Aircraft System for Automatic Forest Fire Monitoring and Measurement*”, presentaron un sistema de UAVs conectados a WiFi con misiones definidas mediante una estación central para detectar y monitorear incendios en tiempo real. Los UAVs son equipados con receptores GPS para compartir su ubicación y cámaras visuales e infrarrojas para detectar los incendios. Cuando un UAV detecta un incendio, otro va a verificar si el incendio es real. Al ser cierto, se crean misiones para que los UAVs monitoreen el incendio y procesen localmente las imágenes para mostrar la evolución de este y enviarla a la estación central, luego de la toma de fotografías dos UAVs aterrizan y el otro continúa su ruta (Merino et al., 2012).

Con base en los documentos anteriores, se efectuó la selección de dispositivos y herramientas software a utilizar teniendo en cuenta la funcionalidad. Se escogió el dron rotatorio por tener la capacidad de movilidad para capturar imágenes desde cualquier ángulo. Para el procesamiento de las imágenes la Raspberry Pi 3 modelo B+ con capacidad de 1,4 GHz para sus cuatro núcleos, que permite el control del dron en tiempo real manejando los estándares WLAN inalámbrica IEEE 802.11

a/b/g/n. Respecto al software, sistema operativo Ubuntu. Para la extracción y clasificación de características se utilizan imágenes RGB y la Red Neuronal Convolutiva (CNN) para el entrenamiento de estas.

## 6.2 SISTEMA DE MONITOREO DE DRONES PARA LA DETECCIÓN DE INCENDIOS Y GENERACIÓN DE ALERTAS EN TIEMPO REAL

Para el desarrollo del sistema de monitoreo, además de los documentos obtenidos en la revisión de la literatura, se estudiaron documentos adicionales que fueron hallados empleando el siguiente descriptor: *Convolutional Neural Network*. A continuación, es presentada información de ocho (8) documentos, que se relacionan con la temática del proyecto, los cuales hacen énfasis en la estructura teórica que se debe tener en cuenta para la descripción del algoritmo a implementar.

Tabla 4. Análisis de documentos relacionados con CNN

Título	Descripción	Tecnologías	Aspectos teóricos
<i>Energy-Efficient Deep CNN for Smoke Detection in Foggy IoT Environment</i> (Khan, Muhammad, Mumtaz, Baik, & de Albuquerque, 2019).	Framework de detección temprana de humo para un entorno de IoT basado en redes neuronales convolucionales (CNN).	Arquitectura VGG-16, CNN.	Los autores modificaron el modelo VGG-16 para la clasificación de humo y no humo en un entorno seguro e incierto.
<i>Efficient Fire Detection for Uncertain Surveillance Environment</i> (Muhammad, Khan, Elhoseny, Ahmed, & Baik, 2019).	Sistema de detección de incendios en videos capturados en escenarios de vigilancia para entornos inciertos de IoT.	Red 5G, CNN, MobileNet (V2), NVidia TITAN X (Pascal) con 12 GB, CPU Intel Core i5, sistema operativo Ubuntu y 64 GB de RAM, Raspberry Pi 3 con 1024 MiB SDRAM y 1.2 GHz y 64 bit.	Los datos de fuego de entrada se proporcionan a la CNN prevista para el entrenamiento durante el cual se ajustan los pesos de una gran cantidad de neuronas y se aprenden para clasificarlos en fuego y no fuego.
<i>Convolutional Neural Networks Based Fire Detection in Surveillance Videos (Framework)</i> (Muhammad, Ahmad, Mehmood, Rho, & Baik, 2018).	Framework para la detección de incendios para videos de vigilancia. Con la arquitectura de GoogleNet y CNN.	GoogleNet, CNN.	Detección de incendios en los sistemas de vigilancia CCTV (Circuito cerrado de televisión).
<i>Efficient Deep CNN-Based Fire Detection and Localization in Video Surveillance</i>	Arquitectura CNN inspirada en la arquitectura SqueezeNet para la	SqueezeNet	Utiliza núcleos convolucionales más pequeños y no contiene capas densas y

Título	Descripción	Tecnologías	Aspectos teóricos
<i>Applications</i> (Muhammad, Ahmad, Lv, et al., 2018).	detección de incendios, la localización y la comprensión semántica de la escena del incendio.		totalmente conectadas, lo que ayuda a mantener los requisitos computacionales al mínimo.
<i>Experimentally defined convolutional neural network architecture variants for non-temporal real-time fire detection</i> (Dunnings & Breckon, 2018).	Detección automática de regiones de píxeles de fuego en imágenes de vídeo en tiempo real con redes neuronales convolucionales definidas de complejidad reducida, aumentando de 3 a 4 veces el rendimiento computacional.	Alexnet, Insetion, VGG-16, CNN.	Comparativa y pruebas con arquitecturas reducidas de detección de incendio como lo son: Alexnet, Insetion, VGG-16 entre otros.
<i>Fire Detection in Infrared Video Surveillance Based on Convolutional Neural Network and SVM</i> (Wang, Wang, Zhang, & Zhang, 2018).	Algoritmo basado en la CNN y <i>Support Vector Machine</i> (SVM) para la detección de incendios en videovigilancia infrarroja (IR).	SVM, CNN, IR.	CNN de 9 capas denominada IRCNN para mejorar el rendimiento de detección de incendios por infrarrojos. Compuesta de las capas <i>Max pooling</i> en 1, 2, 4 y 6 y capas totalmente conectadas 7, 8 y 9
<i>Real-time Fire Detection Method Combining AdaBoost, LBP and Convolutional Neural Network in Video Sequence</i> (Maksymiv, Rak, & Peleshko, 2017).	Algoritmo para la detección de incendios, humo y explosiones.	Adaboost y el patrón binario local (LBP), CNN.	Procesa los datos registrados desde el monitoreo de la cámara, en base al enfoque en cascada y combinan <i>Adaboost</i> y el patrón binario local (LBP) para obtener la Región de interés (ROI) y reducir la complejidad del tiempo.
<i>Convolutional Neural Network for Video Fire and Smoke Detection</i> (Frizzi et al., 2016).	CNN para identificar el fuego o humo en videos y localización de la ubicación de la alarma.	CNN, RGB, microprocesador Intel Xeon (frecuencia de CPU 3,1 Ghz, RAM 16Go) y una tarjeta gráfica GTX 980 Ti (2816 núcleos, 6 GB de memoria).	El conjunto de entrenamiento está compuesto por 27919 imágenes RGB etiquetadas de tamaño 64x64 píxeles. 8915 para humo, 7257 para fuego y 11752 negativo (sin fuego ni humo). Tomando para entrenamiento 60% de

Título	Descripción	Tecnologías	Aspectos teóricos
			las imágenes, Validación 20% y prueba 20%.

Fuente: Elaboración propia

De los documentos estudiados, con base a la relación del proyecto de investigación y la metodología, el documento “*Convolutional Neural Network for Video Fire and Smoke Detection*”, fue tomado como base para el desarrollo del proyecto de grado. Los autores, crearon tres subconjuntos de imágenes: entrenamiento 60%, validación 20% y prueba 20%. La arquitectura propuesta estaba conformada por nueve capas combinando convolution y max pooling, donde: (i) Las capas del uno a la cuatro tienen 16 mapas de características, (ii) Las capas cinco y seis tienen un solo mapa de características, y (iii) Las capas siete y ocho están totalmente conectadas para así clasificar si una imagen tiene fuego o no. La red fue entrenada aproximadamente durante 100 épocas con 27919 imágenes RGB etiquetadas de tamaño 64x64 píxeles con 8915 para humo, 7257 para fuego y 11752 negativo (sin fuego ni humo). En los resultados obtuvieron 97,9% de la precisión de clasificación en 5584 imágenes de prueba, 1427 imágenes de incendio, 1758 de humo, 2399 negativas, demostrando el desempeño del algoritmo de clasificación de incendios en la Tabla 5.

Tabla 5. Matriz de confusión de incendios

<i>Fire</i>	<i>True class</i>		
		True	False
<i>Hypothesis class</i>	True	1400	3°
	False	27°	4154

Fuente: Tomado de (Frizzi et al., 2016)

## Selección de dispositivos Hardware

Para el desarrollo del sistema, además de la revisión de la literatura se efectuó un comparativo de los componentes hardware que más se utilizan en los documentos ya mencionados para el sistema de detección de incendios. A continuación, es presentada el comparativo de drones, placa microcontroladora y sensores de distancia. Para el desarrollo de la solución tecnológicas, específicamente en la captura de imágenes se valoró la utilización del dron y tras investigar en la literatura se valoraron 5 alternativas que cumplían lo requerido (ver Tabla 6).

Tabla 6. Comparativo de drones

Marca	Parrot Bebop	Parrot AR Drone	DJI Mavic Pro	DJI Spark	Intel Aero ready to fly
<b>Precio</b>	\$ 950.000	\$ 648.000	\$2,790.000	\$1,509.000	\$ 3,405.471
<b>Dimensiones</b>	33x38x3.6cm	58.4x58.4x13cm	8.3x8.3x19.8cm	143x143x55mm	36x36x22,2mm
<b>Alcance wifi (m)</b>	250	50	7000	100	300
<b>Peso (gr)</b>	410	436	734	300	300
<b>Velocidad</b>	16 km/h	18 km/h	65KM/H	50 km/h	15 m/s
<b>Altura máxima</b>	40 m	100 m	120 m	100 m	500 m
<b>GPS</b>	Sí	No	sí	no	Sí
<b>Cámara (px)</b>	4096x3072	1280x720	4000x3000	1080	1080
<b>Fuente</b>	(Aero Expo, 2019b)	(Parrot, 2019)	(Mavic pro, 2019)	(Dji Spark, 2019)	(Intel Aero ready to Fly, 2019)

Fuente: Elaboración propia

Con base en los proyectos estudiados en la literatura los drones vuelan de manera autónoma por medio de sensores de distancia para alertar la presencia de un objeto y así evitar choques. En la Tabla 7, se realiza un comparativo de los sensores más utilizados para la evasión de objetos.

Tabla 7. Sensores de distancia

Características	HC-SR04	Sensor laser infrarrojo VL53L0X
<b>Rango de medición</b>	2cm a 400cm	50mm a 1200mm
<b>Alimentación</b>	5v	3V – 5V
<b>Consumo</b>	15mA	10mA
<b>Precisión</b>	+ – 3mm	+ – 30mm
<b>Dimensiones</b>	45x20x15 mm	4.4x2.4x1mm
<b>Precio</b>	\$9.000	\$69.583,05
<b>Fuente</b>	(Dynamo Electronics S.A.S, 2019)	(Electronic Components, 2019)

Fuente: Elaboración propia

Para el procesamiento de imágenes y la evasión de objetos se utiliza un microcontrolador que permite la programación de estos módulos. Los microcontroladores más comunes son la Raspberry Pi 3 B+ y el Arduino Uno R3 como se presenta a continuación.

Tabla 8. Comparativa de la placa microcontroladora

Características	Placa microcontroladora	
	Raspberry Pi 3 B+	Arduino Uno R3
<b>Peso</b>	59g	25G
<b>Microcontrolador</b>	ATmega328	ATmega328
<b>Voltaje Operativo</b>	5V	5V
<b>Voltaje de Entrada (recomendada)</b>	7 - 12 v	7 - 12 v
<b>Pines de Entradas/Salidas Digital</b>	14 (De las cuales 6 son salidas PWM)	14 (De las cuales 6 son salidas PWM)
<b>Pines de Entradas Análogas</b>	6	6
<b>Memoria Flash</b>	32 KB (ATmega328) de los cuales 0,5 KB es usado por Bootloader.	32 KB (ATmega328) de los cuales 0,5 KB es usado por Bootloader.
<b>SRAM</b>	2 KB (ATmega328)	2 KB (ATmega328)
<b>EEPROM</b>	1 KB (ATmega328)	1 KB (ATmega328)
<b>Velocidad del Reloj</b>	16 MHz	16 MHz
<b>Precio</b>	\$165.000	\$20.000
<b>Fuente</b>	(Raspberry Pi, 2019)	(Arduino, 2019)

Fuente: Elaboración propia

Con base en los documentos estudiados en la literatura y la comparativa de los dispositivos, se efectuó la selección de los dispositivos y herramientas software a utilizar teniendo en cuenta la relación costo-funcionalidad. Se escogió el dron rotatorio *Parrot Bebop* por tener la capacidad de movilidad para capturar imágenes desde cualquier ángulo. Tiene conectividad WiFi de 2,4Ghz y 5 Ghz con conexión ad-hoc, y una cámara de alta calidad(Aero Expo, 2019a). Respecto al software, tiene el sistema operativo Ubuntu. Para el procesamiento de las imágenes se utiliza la Raspberry Pi 3 model B+ con capacidad de 1,4 GHz para sus cuatro núcleos, que permite el control del dron en tiempo real manejando el estándar WLAN inalámbrica IEEE 802.11n. Para la extracción y clasificación de características se utilizaron imágenes RGB y la Red Neuronal Convolutiva (CNN) para el entrenamiento de estas, la cual cuenta con 8 capas: *convolution 2D, maxpooling, convolution, maxpooling, flatten, dense, dropout, dense*. Y por último se emplearon los sensores de distancia los cuales por medio de ondas ultrasónicas rebotan sobre los objetos que se presenten y estos son captados por los transductores del sensor para la evasión de objetos del dron.

## Diseño de solución tecnológica

El diseño de la solución tecnológica se basó principalmente en la revisión de la literatura de documentos publicados en bases de datos académicas, los cuales permitieron identificar dispositivos, escenarios de aplicación, tecnologías y protocolos. La solución tecnológica propuesta, ha sido diseñada tomando en consideración como escenario de aplicación las áreas protegidas del departamento de Santander. En la Figura 5, son presentadas las principales áreas protegidas del Departamento de Santander, de acuerdo a su cobertura geográfica.




Figura 5. Principales áreas protegidas de Santander por cobertura geográfica  
Fuente: Tomado de (RUNAP, 2019a)

La protección del ecosistema por parte del gobierno local y nacional, es una necesidad que puede ser atendida a partir del despliegue de soluciones tecnológicas. Estos ecosistemas son considerados prioritarios, de tal modo que se puedan asegurar los bienes y servicios ambientales para el uso de los ciudadanos, reflejado principalmente en el aseguramiento del servicio de agua apta para el consumo humano (Corporación Autónoma Regional para la Defensa de la Meseta de Bucaramanga, 2011). Se resalta que las zonas boscosas proporcionan condiciones ambientales aptas para que especies animales y vegetales sobrevivan. (FAO, 2015b). Este proyecto, ha planteado como propósito principal, el diseño de una solución tecnológica que permita proteger la cobertura boscosa de las áreas protegidas del Departamento de Santander, a partir de la detección temprana de incendios empleando drones.



En la Figura 6, es presentada información de la Serranía de los Yariguíes, que tiene una extensión geográfica de 418.951,69 hectáreas.

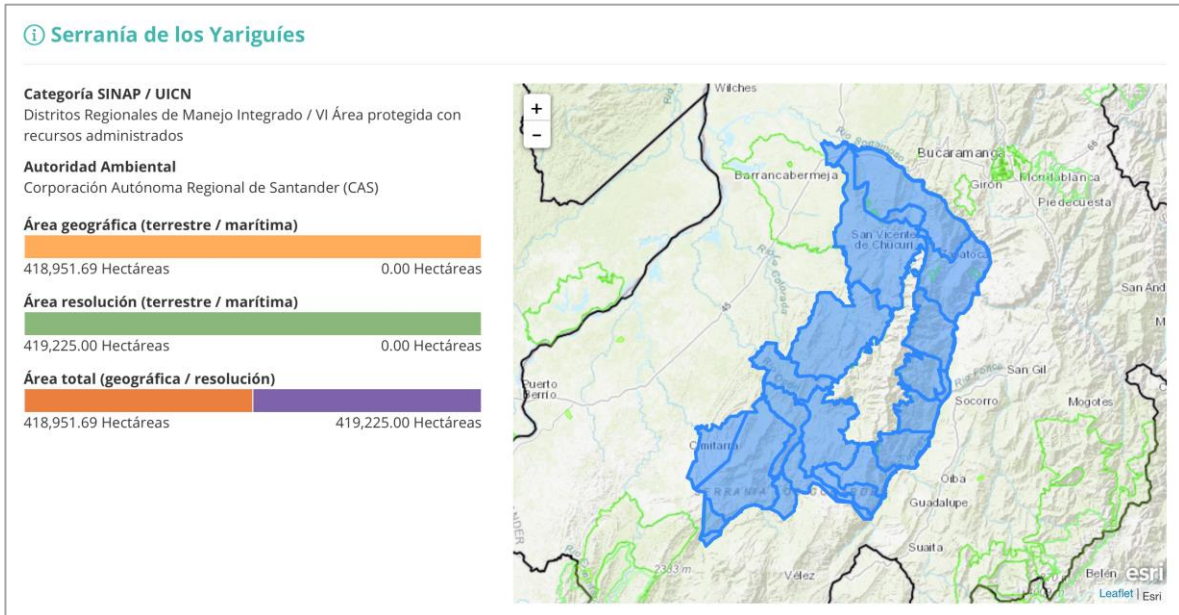


Figura 6. Serranía de los Yariguíes  
Fuente: Tomado de (RUNAP, 2019b)

Luego de una breve presentación del contexto para el cual ha sido planteada la solución tecnológica, a continuación, serán presentados en detalle los componentes hardware y software que comprenden la solución tecnológica propuesta.

### *Dron parrot bebop*

Vehículo aéreo no tripulado, multirrotor de cuatro (4) motores o cuadricóptero, utilizado para la captura de imágenes y videos con una cámara de 14 megapíxeles y ángulo de visión de 180° para la detección de incendios mediante una CNN, para la generación de alertas, transmitidas por una red inalámbrica mediante el estándar IEEE 802.11n a una plataforma Web donde se visualiza la ubicación del dron proporcionada por el GPS que incluye el dron (ver Figura 7). En cuanto a la programación se realizó con Python para la captura de imágenes y detección de incendios (“Parrot bebop drone user guide,” 2014).



Figura 7. Parrot bebop drone

Fuente: Tomado de ("Parrot bebop drone user guide," 2014)

En la Tabla 9, se presentan las especificaciones técnicas del *Bebop dron*, el cual fue adquirido por parte del equipo del proyecto.

Tabla 9. Especificaciones técnicas Bebop Drone.

<b>Bebop Drone</b>	
Alcance	250m.
Conectividad	WiFi MIMO en frecuencias 2,4Ghz y 5 Ghz conexión ad-hoc.
Estándar	802.11 a/b/g/n/ac
Batería	Polímero de litio 1200mAh.
Cámara	Video de alta calidad 1080px captura de imágenes 14px y estabilizador de imagen de 3 ejes.
Peso que soporta	-
Tiempo de vuelo	12 min.
Velocidad del dron	16 km/h
Fuente: Tomando de (Aero Expo, 2019b)	

### *Raspberry Pi 3 Modelo B+*

Ordenador de placa reducida de bajo coste, con un circuito integrado, compuesto por la unidad de procesamiento central (CPU), la unidad de procesamiento de gráficos (GPU), memoria de acceso aleatoria (RAM) y la tarjeta microSD, con capacidad de conexión inalámbrica para la comunicación de dispositivos (ver Figura 8). Se emplea el encabezado GPIO de la Raspberry Pi 3 B+, una *protoboard*, cables de puente y un conversor lógico de niveles para conectar los sensores de distancia empleados para la evasión de obstáculos controlado por el sistema operativo RASPBIAN, versión para arquitecturas ARM de DEBIAN, distribución Linux de uso popular con OpenCv y Python (Raspberry Pi, 2019).



Figura 8. Raspberry Pi 3 Modelo B+  
Fuente: Tomado de (Raspberry Pi Foundation, 2019)

En la Tabla 10, se presentan las especificaciones técnicas de la Raspberry Pi 3.

Tabla 10. Especificaciones técnicas de la Raspberry Pi

<b>Raspberry Pi 3</b>	
Chip	Broadcom BCM2837B0.
Procesador	Cortex-A53 (ARMv8) SoC de 64 bits a 1,4 GHz.
Conectividad	LAN inalámbrica IEEE 802.11 b / g / n / ac de 2.4GHz y 5GHz, Bluetooth 4.2, BLE.
Memoria de acceso aleatorio	SDRAM LPDDR2 de 1 GB.
Adaptador	Gigabit Ethernet sobre USB 2.0.
Rendimiento máximo	300 Mbps.
Cabecera	GPIO de 40 pines extendida.
Puerto	HDMI, 4 puertos USB 2.0.
Estándar	CSI para conectar una cámara Raspberry Pi.
Puerto de visualización	DSI para conectar una pantalla táctil.
Salida estéreo	4 polos y puerto de video compuesto
Entrada de corriente	Continua de 5v/2.5A
Soporte	Power-over-Ethernet (PoE) (requiere PoE HAT por separado)
Puerto	Micro SD
Fuente: Tomado de (Raspberry Pi Foundation, 2019).	

### *Sensor ultrasónico HC-SR04*

Sensor de distancia compuesto por dos transductores (ver Figura 9) para la medición de distancia mediante el uso de ondas ultrasónicas, las cuales no son afectadas por condiciones ambientales o propiedades de las que este hecho el objeto. El sensor actúa por medio de un transductor emitiendo una onda ultrasónica (*trigger*) la cual rebota sobre el objeto y es devuelta al otro transductor, midiendo en microsegundos está operación permitiendo la evasión de objetos del dron con la conexión de la Raspberry Pi 3 B+ y un conversor lógico (Freaks, 2012).



Figura 9. Sensor ultrasónico HC-SR04  
 Fuente: Tomado de (Freaks, 2012)

En la Tabla 11, se presentan las especificaciones técnicas del sensor ultrasonido HC-SR04.

Tabla 11. Especificaciones técnicas sensor ultrasonido HC-SR04

<b>Sensor ultrasonidos HC-SR04</b>	
Alcance	DC 5v
Corriente	15mA
Frecuencia	40Hz
Rango máximo	4m
Rango mínimo	2cm
Ángulo de medición	15 grados
Señal de entrada Tigger	10uS TTL pulse
Señal de salida Echo	Señal de palanca TTL de entrada y el rango en proporción
Dimensión	45 * 20 * 15mm
Tomado de: (Freaks, 2012)	

### *Conversor lógico de nivel*

Componente electrónico que permite conectar elementos de 3.3V a 5V o viceversa para la interacción de señales digitales (ver Figura 10). Los pines tienen un espaciado compatible para conectarlos sobre una *protoboard*, permitiendo la conexión del GPIO de la Raspberry Pi 3 B+ que trabaja con 3,3V, al sensor ultrasónico HC-SR04 que trabaja con 5,0V sobre la *protoboard* para transportar la información que emite el sensor a la Raspberry Pi 3 B+ para ser mostrado en pantalla por medio del programa realizado en Python (naylampmechatronics, 2013).




Figura 10. Conversor lógico de nivel  
Fuente: Tomado de (Rambal, 2019)

En la Tabla 12, se presentan las especificaciones técnicas del conversor de nivel lógico.

Tabla 12. Especificaciones conversor de nivel lógico

<b>Conversor de nivel lógico</b>	
Dimensiones sin pines	15,2mm de longitud x 2,5mm de alto
Longitud pines	5,6 mm
Peso	1,2g
Conversor	5v a 3v bidireccional
Compatible	Señales digitales, <i>protoboard</i>
Tomado de: (naylampmechatronics, 2013)	

### *Diseño del circuito*

En la Figura 11, se presenta el diseño del circuito, conformado por los siguientes elementos: Raspberry Pi 3 B+, tres sensores HC-SR04, conversor lógico de nivel, *protoboard* de 170 puntos, alimentación (3V a 5V) con una conexión de 5V. El sensor trabaja con 5V y mide el tiempo que tarda la señal en rebotar, enviando esta información por medio de un conversor de nivel a la GPIO de la Raspberry Pi 3 B+ que funciona a 3,3V conectados a una *protoboard* para permitir la evasión de objetos. Se implementó un programa en Python para la toma de datos del sistema, mostrando en pantalla la distancia del sensor HC-SR04 al objeto que detecte.




Figura 11. Diseño del circuito en Fritzing

El diseño del circuito integrado, se realizó empleando la herramienta Fritzing (fritzing, 2019). Fritzing es una herramienta *open source* que permite la creación de diagramas de conexión en Arduino y Raspberry.

### Convolutional Neuronal Network (CNN).

Para el aprendizaje de la CNN se implementaron componentes como los optimizadores, métricas y la función *loss*. El optimizador permite a la red neuronal calcular los pesos de los parámetros a partir de los datos de entrada y de la función definida, en este caso *categorical\_crossentropy*, la cual mide el grado de error entre salidas calculadas y las salidas deseadas de los datos de entrenamiento (Keras, 2019a). A continuación, es presentado un cuadro comparativo de optimizadores (ver Tabla 13).

Tabla 13. Comparativa de optimizadores

Optimizador	Descripción
<i>Stochastic gradient descent</i>	Cada vez que realiza el cálculo del gradiente toma una muestra o subconjunto aleatoria con un tiempo mínimo. El algoritmo irá moviéndose hacia el mínimo de forma menos coherente en cada iteración, pero gracias a esto, resulta más sencillo escapar de un mínimo local (Burrueco, 2019).
<i>Gradient Descent</i>	Calcula el gradiente a partir de un pequeño subconjunto aleatorio de muestras llamadas mini-lotes. Este algoritmo tarda menos en alcanzar el mínimo que <i>Stochastic Gradient Descent</i> pero corre el riesgo de caer en un mínimo local más fácilmente (Burrueco, 2019).

Optimizador	Descripción
<i>Momentum</i>	Calcula el gradiente en la posición actual y va acumulando el incremento a las variables en cada iteración y determina la siguiente actualización como una combinación lineal entre el gradiente y el incremento anterior (Burrueco, 2019).
<i>AdaGrad</i>	Utiliza diferentes tasas de aprendizaje para las variables, teniendo en cuenta gradiente acumulado en cada dimensión. En la tasa de aprendizaje para una variable puede decrecer rápidamente por los altos valores del gradiente al comienzo del entrenamiento (Burrueco, 2019).
<i>RMSProp</i>	Variable de AdaGrad en la que utiliza el concepto de mini-lotes para considerar solo los gradientes más recientes (Burrueco, 2019).
<i>Adam</i>	Combina la metodología de Momentum y RMSProp, calculando una combinación lineal entre el gradiente y el incremento anterior, y considera los gradientes recientes para mantener diferentes tasas de aprendizaje por variable. En redes neuronales convolucionales y multicapa es el optimizador más rápido (Bock, Goppold, & Weiß, 2018).

Fuente: Elaboración propia

De los algoritmos estudiados para la optimización basada en gradientes, fue tomado como base el optimizador *Adam* por ser sencillo de implementar, computacionalmente eficiente, tiene pocos requisitos de memoria, es invariante al re escalado diagonal de los gradientes, es adecuado para problemas con gran número de datos y gradientes muy ruidosos o dispersos. Adam converge más rápido en las CNN en comparación con los otros optimizadores (P.Kingm & Ba, 2015).

Una vez definido el optimizador se continúa con las métricas para monitorizar el proceso de entrenamiento, utilizando la métrica *accuracy* para representar la porción de imágenes que son clasificadas correctamente sobre el total de casos (Keras, 2019b).

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN}$$

Los valores obtenidos por el clasificador pueden ser:

- TP (*True positive*): El valor real y el valor predicho por el clasificador son positivos.
- TN (*True negative*): El valor real y el predicho por el clasificador son negativos.
- FP (*False positive*): El valor real es negativo, pero el clasificador lo ha predicho como positivo.
- FN (*False negative*): El valor real es positivo, pero el clasificador ha predicho como negativo.

*Diagrama Convolutional Neuronal Network (CNN).*

A partir de lo presentado anteriormente, se propone la siguiente arquitectura para la CNN (ver Figura 12), la cual ofreció un correcto funcionamiento en el entrenamiento

de la red teniendo en cuenta los pesos, las imágenes suministradas por (Rossie, 2019) y por último el cálculo del error total de las probabilidades resultantes. La arquitectura propuesta de la CNN está compuesta por ocho (8) capas, a saber: Convolution, Max pooling, Convolution, Max pooling, Flatten, Dense, DropOut, y Dense.

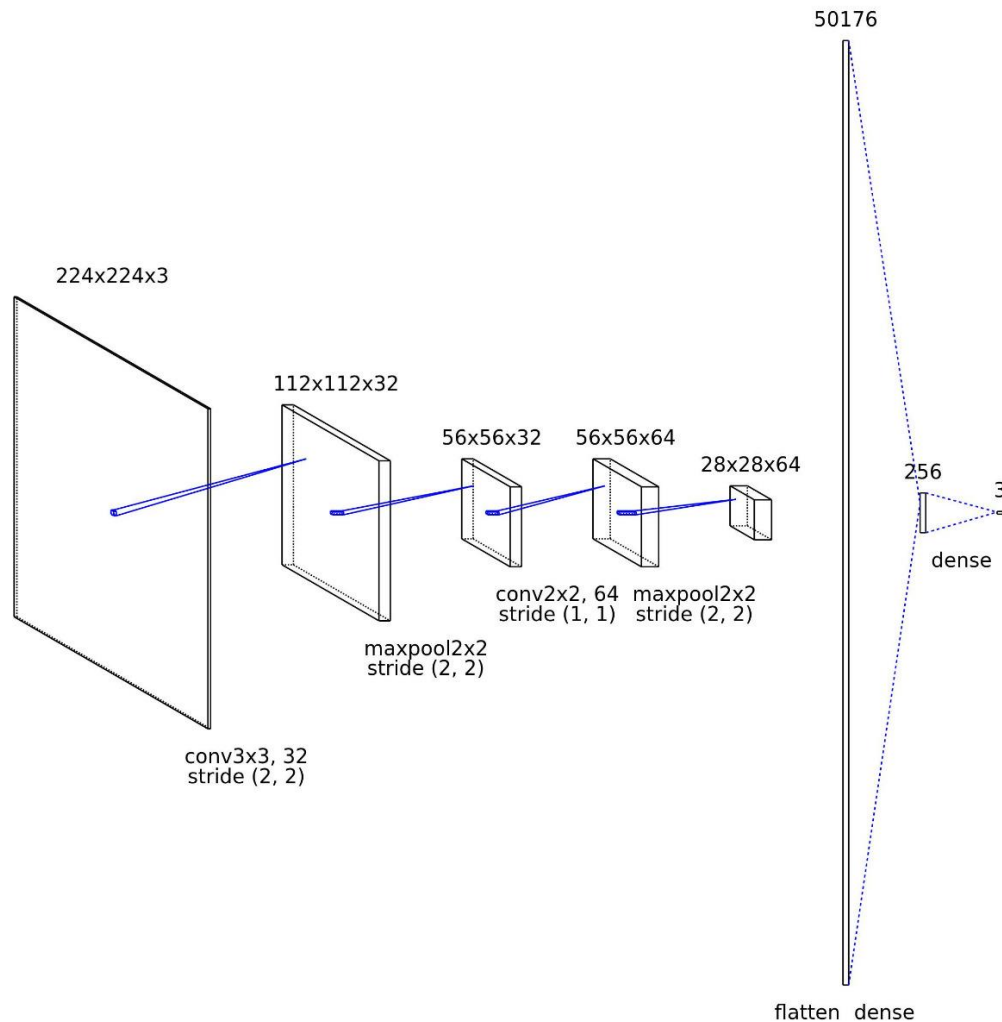


Figura 12. Diagrama *Convolutional Neuronal Network*  
Fuente: Elaboración propia

En la Tabla 14 se presentan las características de la arquitectura de la CNN, empleada para la detección de incendios forestales.

Tabla 14. Arquitectura de la CNN



Características	Cantidad	Descripción
Capas	8	<i>Convolution, Max pooling, Convolution, Max pooling, Flatten, Dense, DropOut, Dense.</i>
Épocas	10	Iteraciones de aprendizaje
Lote	32	Tamaño elementos
Pasos	900	Entrenamiento
Pasos	300	Validación
Filtros de convolución	2	1. 32 tamaño (3,3) 2. 64 tamaño (2,2)
Clases	3	<i>Incendio_dia, Incendio_noche, No_Incendio.</i>
Tasa de aprendizaje	0.0001	
Implementaciones		<ul style="list-style-type: none"> <li>- Re escalamiento, zoom y giro de las imágenes para cubrir más casos en el algoritmo.</li> <li>- Tasa de perdida en '<i>categorical_crossentropy</i>'.</li> <li>- Optimizador <i>Adam</i></li> <li>- Métrica de mejora '<i>accuracy</i>', "<i>recall</i>", "<i>precisión</i>"</li> </ul>

Fuente: Elaboración propia

La CNN fue desarrollada en la herramienta *Tensorflow* con la implementación del entorno de desarrollo *Keras* y *Tensorboard* en la creación de gráficas basadas en la métrica *accuracy*. Para la configuración y evaluación del modelo se dividieron los datos disponibles en dos conjuntos: datos de entrenamiento y datos de validación (Ver Tabla 15).

Tabla 15. Conjunto de datos

Proceso	Cantidad de imágenes	Distribución	Tipo
Entrenamiento	2562	1017	Incendio día
		530	Incendio noche
		1015	No incendio
Validación	356	118	Incendio día
		110	Incendio noche
		128	No incendio
Test	230	100	Incendio día
		60	Incendio noche
		70	No incendio

Fuente: Elaboración propia

### *Tecnologías de acceso a Internet*

Para el desarrollo de la solución tecnológica que permita la detección de incendios en áreas protegidas del Departamento de Santander, se ha tomado como tecnología de acceso a Internet WiFi, tomando en consideración las especificaciones técnicas del *Dron parrot bebop*. La red WiFi permite la conectividad de equipos y dispositivos mediante ondas de radio, a ciertas distancias. Se pueden clasificar en cuatro grupos según el área de aplicación y el alcance de la señal (ver Figura 13): *Wireless*

*Personal Area Networks (WPAN), Wireless Local Area Networks (WLAN), Wireless Metropolitan Area Networks (WMAN) y Wireless Wide Area Networks(WWAN)* (Kurose & Ross, 2005).




Figura 13. Clasificación de las redes inalámbricas  
Fuente: Tomado de (Salazar, 2016)

Teniendo en cuenta lo presentado en la Figura 13, las redes inalámbricas también se pueden clasificar en dos subgrupos: de corto y largo alcance, siendo las de corto alcance WPAN y WLAN, la primera es de área personal donde los dispositivos están muy cerca y la segunda es para área local con un alcance hasta de 100m, basándose en el estándar IEEE 802.11. Las de largo alcance WMAN y WWAN, son las que abarcan grandes áreas, por ejemplo, el territorio de un país (Kurose & Ross, 2005).

### *Arquitectura de red*

Existen dos modos de configurar la arquitectura de una red inalámbrica: infraestructura y *Ad-Hoc*.

1. Modo Infraestructura: Los dispositivos están conectados a la red inalámbrica en un punto de acceso (AP) como *routers* o *switches*, transportando datos de la red inalámbrica a una Ethernet cableada, actuando como puente. Este modo ofrece seguridad, facilidad de gestión, escalabilidad y estabilidad, pero tiene un coste adicional por el punto de acceso (Kurose & Ross, 2005).
2. Modo Ad-Hoc: Los dispositivos se comunican directamente entre sí y no dependen de un control central establecido. El modo ad hoc es adecuado para un grupo pequeño de dispositivos en estrecha proximidad entre sí (Kurose & Ross, 2005).

### *Estándar IEEE 802.11*

En la Tabla 16, se presenta un comparativo de los principales estándares IEEE 802.11 b/a/g/n. Luego de estudiadas y revisadas las especificaciones del Dron, para

la solución tecnológica hará uso del estándar IEEE 802.11n empleando la capa física *MIMO*, a una velocidad de 600Mbps y un alcance de 300m en entornos *outdoor*, operando en la banda de frecuencia de 2,4Ghz, desplegado en modo *Ad-Hoc* para el envío de alertas a la plataforma web donde se visualizarán los procesos del dron.

Tabla 16. Principales estándares

Especificaciones	802.11b	802.11a	802.11g	802.11n
Banda	2,4Ghz	5Ghz	2,4Ghz	2,4Ghz/5Ghz
Capa física	DSSS <sup>2</sup>	OFDM <sup>3</sup>	DSSS/OFDM	MIMO <sup>4</sup> /OFDM
	DPSK <sup>5</sup> sin/con CCK <sup>6</sup> o PBCC <sup>7</sup>	PSK <sup>8</sup> /QAM <sup>9</sup>	DPSK/PSK/QAM	
Tasa máxima	11Mbps	54 Mbps	54 Mbps	600 Mbps
Alcance exterior	150m	120m	150m	300m
Año	1999	1999	2003	2008
Rendimiento	Medio	Mejor rendimiento	Medio	Máximo rendimiento
Compatibilidad	No compatible con 802.11 a	No compatible con 802.11 b	802.11b	Con todos
Fuente: Tomado de (Kurose & Ross, 2005; WiFi Alliance, 2019)				

En la Figura 14, es presentada la arquitectura del sistema integrado de detección de incendios propuesto. La arquitectura propuesta, está conformada por los siguientes elementos: base de datos, servidor, plataforma web, implementación de inteligencia artificial y drones. El dron equipado con una cámara, captura las imágenes en áreas protegidas de Bucaramanga. Las imágenes grabadas se transmiten al servidor donde se analizan mediante el procesamiento de imágenes con la CNN. Si se identifica un incendio, se inicia con una alarma que va directamente a la plataforma web por vía WiFi utilizando el estándar IEEE 802.11n y el modo *Ad Hoc*.

<sup>2</sup> DSSS: Direct Sequence Spread Spectrum

<sup>3</sup> OFDM: Orthogonal Frequency Division Multiplexing

<sup>4</sup> MIMO: Multiple Input Multiple Output

<sup>5</sup> DPSK: Differential Phase Shift Keying

<sup>6</sup> CCK: Complementary Code Keying

<sup>7</sup> PBCC: Packet Binary Convolutional Coding

<sup>8</sup> PSK: Pre-Shared Key

<sup>9</sup> QAM: Quadrature Amplitude Modulation

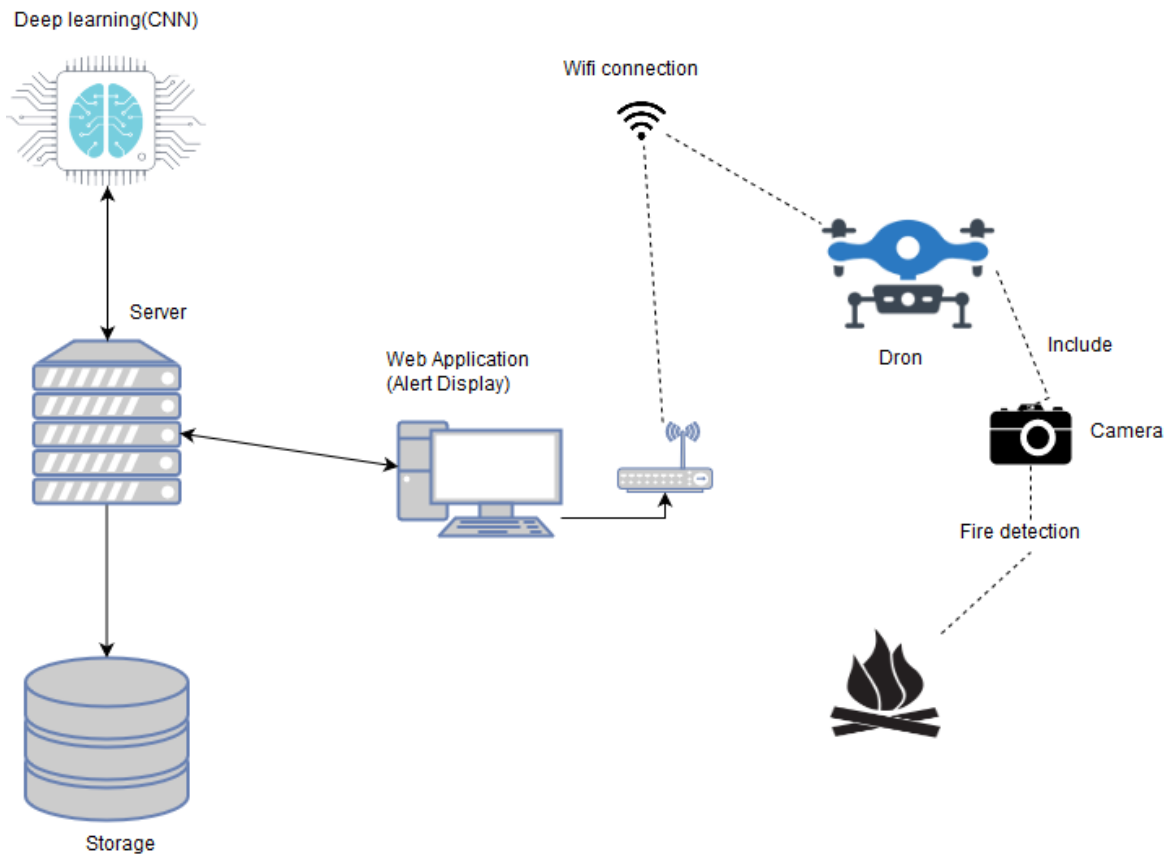


Figura 14. Arquitectura del sistema integrado de detección de incendios  
Fuente: Elaboración propia

En la Tabla 17, son presentadas las características de los componentes de la arquitectura.

Tabla 17. Características de los componentes de la arquitectura

Características de los componentes	
Base de datos	MySql
Servidor	Flask Python
Librerías	CNN Tensorflow-implementación Keras
plataforma web	Webpack-JavaScript implementación Socket.o
Red WiFi	UDP-http, WLAN estándar 802.11n, modo Ad-hoc
Dron	Parrot Bebop drone

Fuente: Elaboración propia

Teniendo en cuenta lo anterior, definiendo los componentes hardware y software, también para el desarrollo del proyecto se requieren de diversos equipos y herramientas tanto de electrónica como de informática. A continuación, se describen los escenarios de trabajo del entrenamiento de las redes neuronales (ver Tabla 18).

Tabla 18. Escenario 1

<b>Lenovo G40-80</b>		
Descripción	Computadora portátil.	
Datos de contacto persona responsable	<b>Nombre</b>	Kevin Olarte Camargo Estudiante
	<b>Correo</b>	<a href="mailto:kolarte@unab.edu.co">kolarte@unab.edu.co</a>
Especificaciones del equipo	Lenovo G40-80: ✓ Computadora personal con las siguientes características: procesador intel core i5 quinta generación, memoria Ram DDR3 8 GB, memoria AMD radeon R300(No apta para entrenamiento). ✓ Televisor.	

En la Figura 15, es presentado el entrenamiento de la CNN. En este escenario no fue posible efectuar el entrenamiento completo, debido a las limitaciones del equipo. Por lo tanto, fue empleado el Laboratorio de Videojuegos de la Universidad Autónoma de Bucaramanga, el cual es presentado con mayor detalle a continuación (ver Tabla 19).

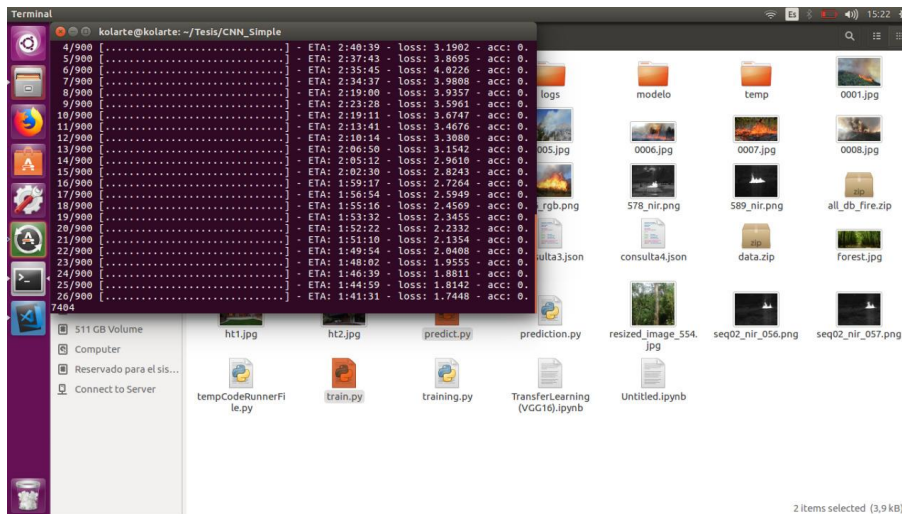


Figura 15. Entrenamiento de la CNN  
Fuente: Elaboración propia

El laboratorio de video juegos de la universidad cuenta con equipos de gran potencia para el desarrollo de actividades dentro de la misma. En el desarrollo del entrenamiento de la CNN se utilizó un equipo con las siguientes especificaciones.

Tabla 19. Escenario 2

<b>Laboratorio de Videojuegos</b>		
Institución	Universidad Autónoma de Bucaramanga UNAB	
Nombre Laboratorio	Laboratorio GameDevLab	
Descripción del Laboratorio	Cuenta con software especializado para el desarrollo de videojuegos y adecuaciones mobiliarias para realizar encuentros de semilleros de investigación,  Ubicación: Campus Jardín, Edificio de Ingenierías, Quinto piso Gamedevlab – UNAB.	
Datos de contacto persona responsable	<b>Nombre</b>	Daniel Arenas Seleey. Director €
	<b>Correo</b>	<a href="mailto:darenas@unab.edu.co">darenas@unab.edu.co</a>
	<b>Teléfono</b>	6436111 ext. 203
Relación de equipos con los que cuenta el laboratorio	El laboratorio cuenta con los siguientes equipos: <ul style="list-style-type: none"> <li>✓ 3 computadores especializados con las siguientes características: Motherboard Asus X99-PRO/USB 3.1 Intel Socket 2011-v3 Core i7 Processors, 8 x DIMM, Quad Channel Memory Architecture Desktop Processor Intel Core i7-5820K Haswell-E 6-Core 3.3GHz LGA 2011-v3 140W BX80648175820K Patriot Memory VIPER 4 Series 2800MHz (PC4 22400) 16GB Dual Channel DDR4 Kit PV416G280C6K Graphic Card GeForce GTX 6 GB 1060 DUAL-GTX1060-O6G ASUS Desktop Hard Disk Drive Toshiba 3.5-Inch 1TB 7200 RPM SATA3/SATA 6.0.</li> <li>✓ Tablero convencional</li> <li>✓ Televisor para conferencias</li> </ul>	

La imágenes presentadas a continuación hacen parte del laboratorio de video juegos. En la Figura 16, se muestran los equipos con los que cuenta el laboratorio de videojuegos, los equipos son potentes, por esto se tomó uno para el entrenamiento de la red neutonal con aprobación del decano (ver Figura 17).



Figura 16. Equipos del GameDevLab

En la Figura 18, se presenta el entrenamiento de la CNN, en donde tardó aproximadamente 3 horas. El algoritmo se entrenó con 2562 imágenes, y se validó con 356 imágenes. Las imágenes fueron proporcionadas de *Corsican Fire Database* (Rossie, 2019), búsquedas en bases de datos y tomadas por el mismo equipo.



Figura 17. Equipo de entrenamiento de la red neuronal




Figura 18. Entrenamiento de la CNN



En la Figura 19, se presentan las capas de la red neuronal, los filtros, las métricas y el optimizador para el entrenamiento. Las capas que componen la red son: convolución, *pooling* y la capa totalmente conectada (*dense layer*). La capa convolucional es la encargada de recibir la imagen y extraer las características. *Pooling* reduce dimensiones para evitar el sobreajuste. Dense layer encargada de clasificar la clase a la que pertenece la imagen, en el caso de estudio las clases: incendio, incendio noche o no incendio (Diaz Cuesta, 2018). Los filtros se aplican a las imágenes de entrenamiento con distintas resoluciones, y la salida se emplea para la siguiente capa. La métrica monitorea el entrenamiento y el optimizador a partir de los datos de entrada permite a la red neuronal calcular los pesos de los parámetros.

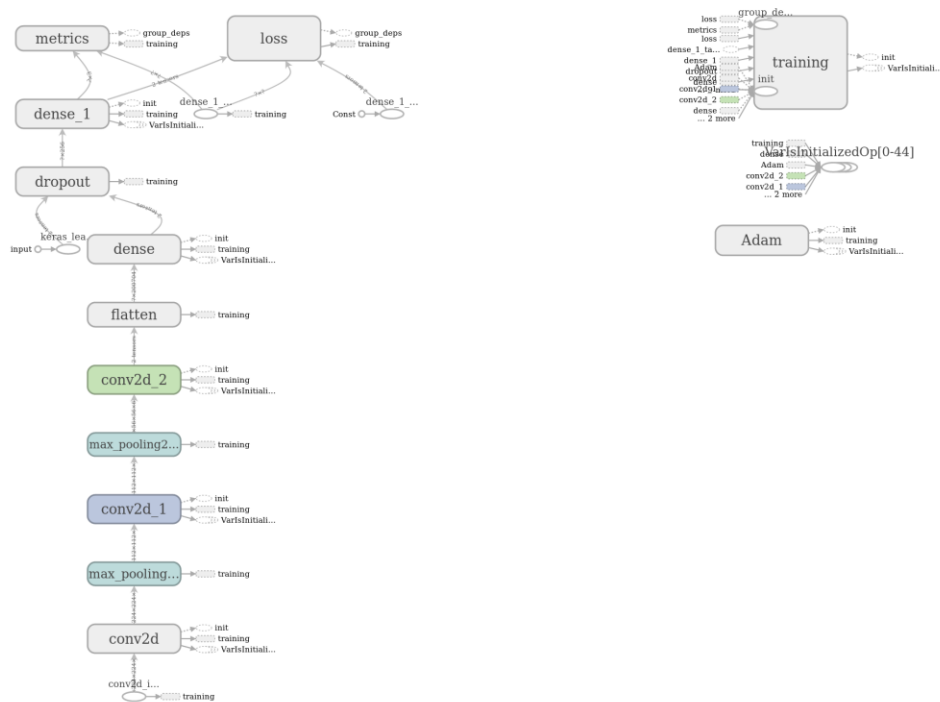


Figura 19. Capas de la red neuronal  
Fuente: Elaboración propia

Los resultados del entrenamiento de la CNN, se presentan a continuación.

En la Figura 20, se presenta la gráfica de precisión de procesamiento por lotes de la red con los valores obtenidos para las imágenes de entrenamiento en cada época. Observando una precisión inestable al principio, pero al pasar aproximadamente del 18% de las imágenes del entrenamiento se mantuvo estable con una precisión del 100%.






Figura 20. Precisión por lotes

En la Figura 21, se presenta la gráfica de pérdida por lotes, mostrando los valores obtenidos para las imágenes de entrenamiento en cada época. Al principio los valores de error de clasificación son altos, pero a medida que avanza el entrenamiento tiende a disminuir, la cual finaliza con cantidades muy pequeñas que tienden a cero, indicando que el procesamiento es efectivo.




Figura 21. Pérdida por lotes

En la Figura 22, se presenta la pérdida por épocas, mostrando los valores obtenidos para las imágenes de validación en cada iteración. El algoritmo obtiene valores que tienden a cero, asegurando que las predicciones están más cerca de las etiquetas reales.




Figura 22. Pérdida por épocas

En la Figura 23, se presenta la precisión por época, mostrando el aumento de los valores para las imágenes de validación por épocas asegurando que las predicciones están más cerca de las etiquetas reales.




Figura 23. Precisión por épocas

Como se ha apreciado, de forma general, los resultados de los diferentes casos han sido positivos progresivamente desde en un punto del entrenamiento y luego se mantienen en el valor deseado hasta el final, obteniendo buena precisión para las predicciones. Por lo anterior se espera que la solución tecnológica presente un sistema de detección de incendios con tasas bajas de falsas alarmas, clasificando las imágenes que se proporcionan del video capturado por el dron y enviadas mediante comunicación inalámbrica para la generación de las alarmas y ubicación en la plataforma web.

### 6.3 PRUEBAS DE FUNCIONAMIENTO DEL SISTEMA DE MONITOREO DE INCENDIOS EN ÁREAS PROTEGIDAS DE SANTANDER

Esta sección busca conocer los resultados obtenidos de la solución tecnológica. Para ello se diseñó el plan de pruebas que se presenta a continuación con el fin de determinar si el sistema funciona de manera eficiente.

#### *Plan de pruebas*

Este documento tiene como finalidad entregar los pasos a seguir para la aplicación correcta de las estrategias y pruebas necesarias del sistema de detección de incendios por medio de drones, con el fin de verificar las funciones y procesos que lo componen, así como encontrar los posibles fallos o errores que se presenten durante el periodo de pruebas y contemplar si cumple con el funcionamiento total del mismo. A continuación, se describen los pasos a seguir:

- Planificación de las pruebas: Identificar requisitos, recursos y estrategias de las pruebas.
- Diseño de las pruebas: Identificar y describir los casos de prueba.
- Implementación de las pruebas: Establecer el entorno.
- Ejecución de las pruebas: Ejecutar los casos de prueba, evaluando la ejecución y resultados.

## 1. Planificación de las pruebas

### *Introducción*

En la solución tecnológica se realizaron pruebas de campo en un entorno controlado en el oriente de Bucaramanga, en cabecera parte alta, con el vehículo aéreo no tripulado *parrot bebop drone* equipado de una cámara y un GPS, junto con una red neuronal pre entrenada donde se enviarán alertas a una plataforma web para evaluar su funcionamiento óptimo. En la Tabla 20, se especifica el propósito de las pruebas de la solución tecnológica. Tabla 20. Propósito

Tabla 20. Propósito

<b>Características de pruebas</b>	<b>Módulos</b>
Componentes a probar	Reconocimiento de la CNN en imágenes de incendios y no incendios.
	Transporte de datos por medio de la red WiFi a la plataforma web.
	Almacenamiento en la base de datos.
	Visualización de las alertas
Validar	Conectividad, detección de incendios, almacenamiento de datos y visualización de alertas.
Responsables	Las pruebas son responsabilidad del equipo de proyecto.

Fuente: Elaboración propia

### *Entorno y configuración de las pruebas*

Para el proceso de pruebas del proyecto se emplearon los siguientes recursos:

- Equipo prueba: Lenovo G40-80, procesador intel core i5 quinta generación, memoria Ram DDR3 8 GB, memoria AMD radeon R300.
- Base de datos: MySQL

### *Escenario*

Las pruebas de campo se realizaron en un entorno controlado en el oriente de Bucaramanga, en el barrio Morrorrico (Ver Figura 24).



Figura 24. Escenario de pruebas  
Fuente: Elaboración propia

## 2. Diseño de las pruebas

### *Estrategias de pruebas*

Tabla 21. Casos de prueba

Nivel de prueba	Objetivo	Técnica	Criterio	Cumplimiento	Observaciones
Pruebas de integración	Asegurar que el dron tenga comunicación con la plataforma web.	Red WiFi con el estándar 802.11n	-Las imágenes se envíen para su procesamiento.	Sí	
Pruebas de sistema	Asegurar que el dron detecte los incendios y envíe alertas a la aplicación.	CNN	-El algoritmo clasifica las imágenes correctamente.	Parcial	Se presenta conflicto en las predicciones incendio noche.
Pruebas de almacenamiento	Asegurar que se guarden las imágenes posteriores al procesamiento de la CNN.	Base de datos	-Las imágenes se guardan correctamente.	Sí	
Pruebas de plataforma web	Asegurar que las alarmas se visualicen en la aplicación.	Front end	-Las alarmas se visualizan en pantalla.	Sí	

Fuente: Elaboración propia

## 3. Implementación de las pruebas

En esta sección se presenta las pruebas para evaluar la solución tecnológica en un entorno real controlado. La solución tecnológica demostró ser efectiva en la clasificación de imágenes. Se realizó una simulación de día y una de noche definiendo dos criterios de evaluación. A continuación, se presenta los enlaces de los videos obtenido por el dron donde se extrajeron las imágenes para su posterior clasificación.



Figura 25. Imagen del video de incendio día  
Enlace: <https://www.youtube.com/watch?v=fnzK1rYQauQ>



Figura 26. Imagen del video de incendio noche  
Enlace: [https://www.youtube.com/watch?v=Za1c9\\_w44y0](https://www.youtube.com/watch?v=Za1c9_w44y0)

En las pruebas, se utilizó el *Parrot Bebop Drone* (ver Figura 27), para la captura de los videos estableciendo una comunicación a través de WiFi estándar 802.11n. Con el dron se presentaron inconvenientes en el GPS porque la información de la ubicación se da incorrecta.



Figura 27. Parrot Bebop Drone  
Fuente: Elaboración propia

Para el vuelo autónomo del dron, se utilizaron los sensores ultrasónicos HC-SR04, los cuales entregan la medida de tiempo de vuelo de la señal ultrasónica. La velocidad del sonido está directamente relacionada con la temperatura ambiente y el material por el que se propague. En esta medición el tiempo de retorno de la señal es de  $780 \mu s$  que corresponde a  $14 \text{ cm}$ . Como la distancia máxima de detección es de  $400 \text{ cm}$ , tardaría  $24 \text{ ms}$  en hacer la lectura, y si tarda más de eso despreciamos la medida como fuera de rango para la evasión de objetos con el dron, para solucionar este inconveniente se recomienda los sensores laser por ser más rápido y precisos (Lago Canadas, 2017).




Figura 28. Plataforma de evasión de objetos  
Fuente: Elaboración propia

#### 4. Ejecución de las pruebas

Al igual que se han realizado las pruebas iniciales con el entrenamiento, se realizan pruebas en un entorno controlado, en donde el dron captura un video y luego este es procesado para extraer las imágenes de este para clasificarlas y detectar si hay incendio o no. Al detectar incendio se genera una alarma donde se muestra en una plataforma web. A continuación, se presenta el proceso de las pruebas.



El algoritmo 1 presenta los pasos para implementar el experimento descrito anteriormente.

### Algoritmo 1. Proceso para la implementación del dron en un entorno controlado

**Require:** *Install all the necessary libraries, toolkits, SDKs, etc...accordingly to the platform to be used.*

1. *Initialize the Parrot Bebop drone communications by modifying the network configuration and selecting a valid range of TCP/UDP ports of drone.*
2. *Connecting to the server computer through the communication protocol*
3. *While No error do*
4. *Get image from drone*
5. *Save image in .jpg format*
6. *Start CNN algorithm prediction*
7. *If prediction is true then create alert and save image in database*
8. *End while*
9. *Close all communications*

Después de la captura del video, se realizó la validación con el conjunto de prueba compuesto por 230 imágenes extraídas de los videos capturados por el dron, de las cuales 70 eran no incendio, 100 incendio día y 60 incendio noche. La precisión de la clasificación de las pruebas obtuvo una tasa de éxito del 94% en el incendio como se presenta en la matriz de confusión (ver la Figura 29).




Figura 29. Matriz de confusión  
Fuente: Elaboración propia



Al principio se presentó *overfitting* en la CNN debido a las pocas imágenes que se contaba en el *data set* para el entrenamiento, para evitar esto se usaron técnicas de *data augmentation* y se balanceo el *dataset* de la siguiente manera: el *dataset* fue dividido en 3 partes de las cuales se tomaron 2/3 para entrenamiento y el otro 1/3 se tomó 0.80 para validación y el 0.20 para test.

Se utilizaron de la clase incendio día 1189 imágenes en total, 789 imágenes para entrenamiento 300 imágenes para validación y 100 imágenes para test. En incendio noche 904 imágenes en total, 603 imágenes para entrenamiento, 241 imágenes para validación y 60 imágenes para test. En la clase no incendio 1062 imágenes en total, 603 imágenes para entrenamiento, 284 imágenes para validación y 70 imágenes para test. En la matriz de confusión se cambió en hiper parámetros el *batch\_size* a 64 y se incluyó las métricas de *recall* y *precisión* para mejorar el algoritmo.

Tabla 22. Resultados de la matriz

	Precisión	<i>Recall</i>	<i>f1-score</i>	<i>Support</i>
Incendio noche	0.98	0.82	0.88	100
Incendio día	1.00	0.97	0.98	60
No incendio	0.78	0.99	0.87	70
Micro avg	0.91	0.91	0.91	230
Macro avg	0.92	0.92	0.92	230
Weighted avg	0.92	0.91	0.91	230

Fuente: Elaboración propia

Las imágenes al ser clasificadas como incendio se envían mediante la conexión WiFi, el servidor guarda en un directorio temporal una imagen cada treinta (30) *seg*, para luego ser procesada por la CNN y finalmente la imagen es retransmitida a la aplicación cada treinta (30) *seg* por medio de *web sockets* para la visualización en la plataforma, junto con su ubicación (ver Figura 30).

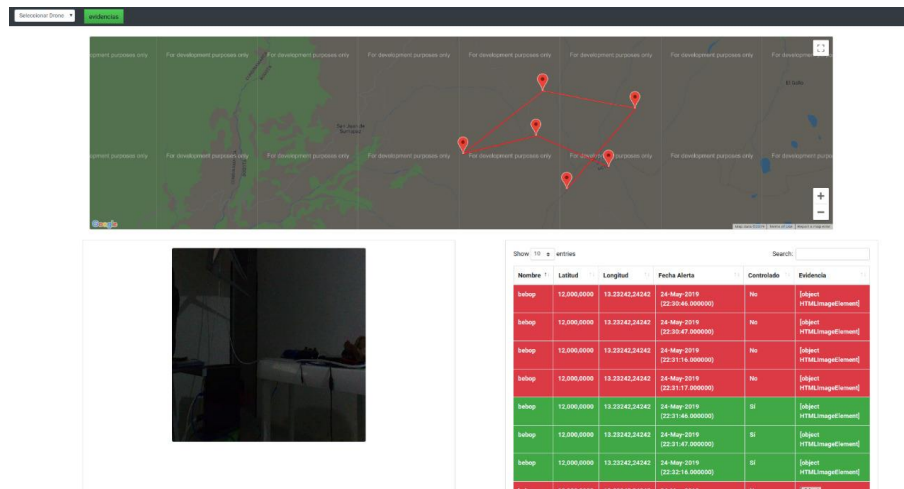


Figura 30. Visualización de la plataforma web  
Fuente: Elaboración propia

En la Tabla 23, se especifica el proceso del sistema planteado con el obtenido.

Tabla 23. Comparativa del sistema obtenido con el planteado.

Sistema planteado	Sistema obtenido
Clasificación de imágenes por medio de CNN.	Las imágenes clasificadas obtuvieron los siguientes porcentajes: 100% incendio día, 98% incendio noche, 78% no incendio.
Captura de imágenes por medio del dron.	Captura de imágenes por medio de la cámara incorporada del dron.
Generación de alertas en tiempo real.	Generación de alertas por medio de módulos independientes debido a la falta de capacidad de procesamiento del computador.
Visualización de alertas en la plataforma web.	Visualización de alertas en plataforma web después de ser clasificada como incendio mediante la CNN.
Creación de rutas de monitoreo.	Creación de rutas dummies de monitoreo.
Rastreo y ubicación del dron	El GPS genera información errónea.

Fuente: Elaboración propia

## 7. DISCUSIÓN

El sistema convencional para la detección de incendios se hace por medio de puestos de observación, cámaras térmicas, y la comunidad, lo cual no es confiable ya que se presentan gran cantidad de falsas llamadas que generan demora en la intervención de los bomberos en los verdaderos incendios. Por tanto, este prototipo de detección de incendios mediante inteligencia artificial (CNN) para la clasificación de las imágenes y un dron para monitorear y detectar las imágenes de incendio las cuales se envían cada treinta (30) segundos, generando alertas automáticamente en una plataforma web mejorando el tiempo de respuesta.

Es importante la detección temprana e identificación del incendio para evitar consecuencias en la flora, fauna y la población en general. A lo largo de los años se están buscando mejores métodos y tecnologías para combatir los incendios, mediante la utilización de drones. Como se observó en el desarrollo del proyecto los drones de ala rotatorio son eficientes en la captura de imágenes por tener mayor maniobrabilidad, pero presentan capacidad limitada de vuelo siendo útiles en cortos períodos de tiempo. También durante el proceso del proyecto de grado se halló el entorno *Google Colab* que permite crear, ejecutar, guardar y acceder a recursos informáticos potentes en la nube. Este entorno permite lanzar algoritmos con el uso de tarjeta gráfica para reducir el tiempo de entrenamiento de la CNN, puesto que el entrenamiento necesita de computadoras potentes y se pudo asistir a un taller para conocer los fundamentos matemáticos y las bases del funcionamiento de cada neurona lo cual facilitó el diseño de la arquitectura de la red neuronal con las principales características. Por lo anterior, se puede confirmar que los drones junto con la inteligencia artificial pueden contribuir a la detección temprana de incendios, ya que estos siguen desarrollando mejoras en sus componentes para lograr la eficiencia.

De acuerdo con los resultados encontrados en esta investigación se puede decir que con mayor cantidad de imágenes en el entrenamiento, su efectividad será mejor como se ilustró con las imágenes de día, su efectividad fue de 100%, pero las de incendio de noche por no tener suficiente cantidad de imágenes de entrenamiento tendían a clasificarse como incendio día, después se mejoró la cantidad de imágenes del *dataset* teniendo resultados en incendio noche de 98%.

## 8. CONCLUSIONES

En este trabajo, se presenta un sistema de detección de incendios, apoyado en una Red Neuronal Convolucional. El objetivo ha sido detectar mediante la cámara del dron incendios a través de la clasificación de imágenes con CNN y ejecutar una alarma justo después de detectado. La salida de la clasificación es leída y ordenada de acuerdo a los tres valores posibles: incendio día, incendio noche, no incendio. Las dos primeras clases generan una alarma hacia la plataforma web, donde las imágenes se guardan en una base de datos y se consultan cada treinta (30) *seg*.

La solución tecnológica se probó en un entorno real controlado demostrando la precisión de la CNN en la detección de incendios y de no incendios obteniendo 92% de precisión en la matriz, debido al entrenamiento de la red con cantidad de datos similares de las clases incendio día, incendio noche y no incendio.

Globalmente la mayoría de los objetivos del proyecto se han cumplido, pues se ha desarrollado parcialmente el sistema de detección de incendios con generación de alarmas. Se ha verificado su correcto funcionamiento realizando pruebas en diferentes entornos. De esta manera se da cumplimiento al propósito de este proyecto, ya que, en base a lo desarrollado a lo largo del proceso, se puede detectar el incendio con altas tasas de precisión para el mejoramiento de tiempo de respuesta en incendios en áreas protegidas de Santander.

Durante el desarrollo de la investigación se seleccionan tecnologías como la Raspberry Pi 3 B+ por la capacidad de computo, la cual es mayor en comparación con Arduino. Los sensores ultrasónicos se escogieron por ser económicos y medianamente eficientes, aunque no adecuado para el alcance del proyecto. El dron Parrot Bebop fue elegido por el tipo de transmisión de datos, por contar con un ecosistema de desarrollo en evolución y por la relación calidad precio.

Se observó que el desarrollo de la inteligencia Artificial (IA) está tomando cada vez más fuerza y está permitiendo realizar tareas más diversas, pero para trabajar de manera eficiente es importante contar con una tarjeta gráfica y buenos procesadores, permitiendo mejor tiempo en operaciones de entrenamiento y ejecución de la misma en tiempo real. En cuanto al desarrollo de la IA se realizó con el lenguaje Python el cual va en crecimiento, dado que cada vez se encuentra más documentación de diversos campos y como experiencia personal tuvimos el privilegio de participar en algunos talleres de desarrollo impartidos por el grupo Python Bucaramanga con el patrocinio del MINTIC, que nos favoreció en la profundización en Redes Neuronales.

En cuanto a las zonas boscosas específicamente en el caso de estudio las áreas protegidas del Departamento de Santander los incendios causan grandes pérdidas de flora y fauna, las cuales son irreparables o bien toman mucho tiempo para recuperarse con una mejor gestión se puede lograr minimizar el impacto de estos en el ambiente, como inculcar conciencia ecológica a todas las personas especialmente a aquellas que tienen contacto directo con los bosques y a los turistas para evitar la contaminación por ser uno de los principales detonantes de los incendios.

La acción del hombre representa aproximadamente un daño del 90% de las causas de los incendios forestales, para tener un cambio real se debe concientizar a las personas, principalmente a quienes tienen contacto directo con los bosques para así prevenir pérdidas de flora y fauna, las cuales son irreparables o bien toman mucho tiempo recuperarse. Con una mejor gestión se puede lograr minimizar el impacto de los incendios en el ambiente, detectando focos de posibles incendios antes que se propaguen.

Finalmente, las limitaciones que tuvo el desarrollo de este proyecto de grado fueron los recursos disponibles que se contaban para el desarrollo del mismo. En la siguiente sección se especifican los dispositivos a detalle.

## 9. TRABAJO FUTURO

En este proyecto se encontraron limitantes o puntos a mejorar los cuales son mencionados a continuación. La capacidad computacional siempre fue una limitante en nuestro caso al no tener al alcance una máquina para pruebas continuas, se recomienda el uso de mejores equipos de cómputo con tarjeta gráfica incluida o bien usar plataformas en la nube como *Google colab* la cual permite buen rendimiento.

La solución tecnológica propuesta al emplear WiFi, tiene limitaciones respecto al área de cobertura, lo que impide que el dron efectúe largos recorridos. Por ende, se plantea a futuro el uso de tecnologías móviles celulares para alcanzar una mayor cobertura o el despliegue de radioenlaces, teniendo en consideración que las áreas protegidas son terrenos extensos. Sin embargo, este tipo de tecnologías de acceso requieren alta inversión para su implementación.

La transmisión de imágenes por la red WiFi y posterior procesamiento en el servidor acarrea altos tiempos de respuesta, los cuales pueden ser optimizados si el dron cuenta con computación a bordo para realizar operaciones de reconocimiento en tiempo real separando las tareas de visualización y procesamiento de imágenes del servidor.

La autonomía de vuelo para nuestro dron es muy baja dado que contamos con 15 minutos de batería, se recomienda usar drones con mayor autonomía de vuelo o bien crear zonas de recarga inalámbrica (inductiva) lo cual permitiría cubrir mayores extensiones con el mismo dron.

Finalmente, un *data set* más amplio, el cual cuente con datos balanceados para aumentar la precisión y eliminar sesgos en la CNN. La inserción de la clase no incendio noche puede permitir un continuo monitoreo dado que se cubrirían los posibles escenarios.

## REFERENCIAS

- Achkar, M., Cantón, V., Díaz, I., Domínguez, A., Faccio, C., Fernández, G., ... Sosa, B. (2011). *Áreas protegidas Un desafío en el ordenamiento ambiental del territorio*. <https://doi.org/10.1360/zd-2013-43-6-1064>
- Addati, G., & Pérez Lance, G. (2014). Introducción a los UAV's, drones o VANTs de uso civil. *Econstor*.
- Aero Expo. (2019a). BD BeBop Datasheet 210x297 UK 19nov14.
- Aero Expo. (2019b). Parrot bebop drone. Retrieved from <http://pdf.aeroexpo.online/pdf/parrot/bd-bebop-datasheet-210x297-uk-19nov14/170278-68.html>
- Aeronautica Civil de Colombia. (2015). *Requisitos Generales de Aeronavegabilidad y Operaciones para RPAS*. Retrieved from [http://www.aerocivil.gov.co/Lists/NoticiasInternet/Attachments/197/CIRCULAR REGLAMENTARIA 002 - RPAS.pdf](http://www.aerocivil.gov.co/Lists/NoticiasInternet/Attachments/197/CIRCULAR%20REGLAMENTARIA%20002%20-%20RPAS.pdf)
- Agencia Nacional del Espectro. (2018). Política de espectro radioeléctrico.
- Ahmed, S., & Mehmood, S. (2017). *Incorporation of Drones into Fire and Rescue Service of Esbjerg Municipality for a Robust Emergency Response*. Aalborg University Esbjerg.
- Allison, R. S., Johnston, J. M., Craig, G., & Jennings, S. (2016). Airborne optical and thermal remote sensing for wildfire detection and monitoring. *MPDI*, 16(8). <https://doi.org/10.3390/s16081310>
- Ángel, M., & Jiménez, I. (2016). *Diseño e implementación de un Dron Para la detección de incendios forestales*. Universidad abierta de Cataluña.
- Arduino. (2019). Arduino uno rev3. Retrieved from <https://store.arduino.cc/usa/arduino-uno-rev3>
- Bermúdez Huertas, A., & Villamil Hernández, L. (2015). *Vehículos Aéreos no tripulados, Drones y sus sistemas de comunicación*.
- Bock, S., Goppold, J., & Weiß, M. (2018). An improvement of the convergence proof of the (p. 6).
- Bradski, G., & Kaehler, A. (2008). *Learning OpenCV. Learning OpenCV*. <https://doi.org/10.1109/MRA.2009.933612>
- Bujari, A., Calafate, C. T., Cano, J.-C., Manzoni, P., Palazzi, C. E., & Ronzani, D. (2017). Flying ad-hoc network application scenarios and mobility models. *International Journal of Distributed Sensor Networks*, 13(10), 17. <https://doi.org/10.1177/1550147717738192>
- Burrueco, D. (2019). Otros optimizadores. Retrieved from <https://www.interactivechaos.com/manual/tutorial-de-machine-learning/otros-optimizadores>
- Cognex. (2018). *Introducción a la visión Artificial Una guía para la automatización de procesos y mejorar la calidad*. Retrieved from <https://www.cognex.com/es-ar/library/media/files/17151.pdf>
- Comisión Nacional Forestal. (2005). Incendios forestales: Guía práctica para comunicadores.

- Consejo Nacional de Política Económica y Social. (2018). *CONPES 3920: Política Nacional de Explotación de Datos (Big Data)*. Bogotá.
- Constitucion politica de Colombia. (1991). *Constitucion politica de Colombia 1991*. Retrieved from [http://www.corteconstitucional.gov.co/inicio/Constitucion politica de Colombia.pdf](http://www.corteconstitucional.gov.co/inicio/Constitucion%20politica%20de%20Colombia.pdf)
- Corporación Autónoma Regional para la Defensa de la Meseta de Bucaramanga. (2011). *Áreas Protegidas En La Jurisdicción De La Cdmb, Santander, Colombia*.
- Cruz, H., Eckert, M., Meneses, J., & Martínez, J. F. (2016). Efficient forest fire detection index for application in Unmanned Aerial Systems (UASs), *16*(6). <https://doi.org/10.3390/s16060893>
- Diaz Cuesta, C. (2018). *Redes Neuronales Convolucionales*.
- Dionisio Ortega, S., Rojas Perez, L. O., Martinez Carranza, J., & Cruz Vega, I. (2018). A deep learning approach towards autonomous flight in forest environments. In *Conference internacional 2018* (Vol. 2018-Janua, pp. 139–144). IEEE. <https://doi.org/10.1109/CONIELECOMP.2018.8327189>
- Dji Spark. (2019). Spark. Retrieved from <https://www.dji.com/spark>
- Dunnings, A. J., & Breckon, T. P. (2018). Experimentally defined convolutional neural network architecture variants for non-temporal real-time fire detection. *Proceedings - International Conference on Image Processing, ICIP*, 1358–1362. <https://doi.org/10.1109/ICIP.2018.8451657>
- Dynamo Electronics S.A.S. (2019). Sensor de ultrasonido HC-SR04. Retrieved from <https://www.dynamoelectronics.com/medir-distancias/863-sensor-de-ultrasonido-hc-sr04.html>
- El Tiempo. (2019, February 5). Incendio forestal consumió al menos 220 hectáreas del páramo El Almorzadero en Santander, p. 1. Retrieved from <https://www.eltiempo.com/colombia/otras-ciudades/incendio-en-paramo-de-santurban-afecta-a-80-hectareas-de-bosque-323168>
- Electronic Components. (2019). VL53L0X Datasheet. Retrieved from [https://www.alldatasheet.com/view.jsp?Searchword=VL53L0X&gclid=EAlaIQobChMlZK6T3v3A4gIVQwOGCh3IRwzvEAAAYASAAEgIrbPD\\_BwE](https://www.alldatasheet.com/view.jsp?Searchword=VL53L0X&gclid=EAlaIQobChMlZK6T3v3A4gIVQwOGCh3IRwzvEAAAYASAAEgIrbPD_BwE)
- FAO; MADS; IDEAM. (2018). *Lineamientos para el monitoreo comunitario participativo en Colombia*. Bogotá.
- FAO. (2015a). *Evaluación de los recursos forestales mundiales 2015* (2nd ed.). Rom.
- FAO. (2015b). Los bosques y suelos forestales contribuyen de manera esencial a la producción agrícola y la seguridad alimentaria mundial. Retrieved from <http://www.fao.org/soils-2015/news/news-detail/es/c/285875/>
- FAO. (2018). *Fortalecimiento de los sistemas nacionales de monitoreo de los bosques para REDD +*. Roma.
- Flórez López, R., & Fernández Fernández, J. M. (2008). *Las Redes Neuronales Artificiales*. (Netbiblo, Ed.).
- Freaks, E. (2012). Ultrasonic Ranging Module HC - SR04, 3–5. Retrieved from <http://www.micropik.com/PDF/HCSR04.pdf>
- fritzing. (2019). fritzing. Retrieved from <http://fritzing.org/home/>



- Frizzi, S., Kaabi, R., Bouchouicha, M., Ginoux, J. M., Moreau, E., & Fnaiech, F. (2016). Convolutional Neural Network for Video Fire and Smoke Detection. *IECON Proceedings (Industrial Electronics Conference)*, 877–882. <https://doi.org/10.1109/IECON.2016.7793196>
- García García, I. (2017). *Estudio sobre vehículos aéreos no tripulados y sus aplicaciones*. Valladolid. Retrieved from <https://uvadoc.uva.es/bitstream/10324/23021/1/TFG-P-528.pdf>
- Hristov, G., Raychev, J., Kinaneva, D., & Plamen, Z. (2018). Emerging methods for early detection of forest fires using unmanned aerial vehicles and LoRaWAN sensor networks. *2018 28th EAEEIE Annual Conference (EAEEIE)*, 1–4.
- Hua, L., & Shao, G. (2017). The progress of operational forest fire monitoring with infrared remote sensing. *Forestry Research*, 28(2), 215–229. <https://doi.org/10.1007/s11676-016-0361-8>
- Iberdrola. (2019). Diferentes tipos y usos de drones. Retrieved from <https://www.iberdrola.com/te-interesa/tecnologia/drones-usos-tipos>
- IDEAM. (2016). *Estrategia integral de control a la deforestación*.
- IDEAM. (2019). Incendios de la cobertura vegetal. Retrieved from <http://www.ideam.gov.co/web/ecosistemas/incendios-cobertura-vegetal>
- Intel Aero ready to Fly. (2019). Intel.
- Investopedia. (2019). Overfitting. Retrieved from <https://www.investopedia.com/terms/o/overfitting.asp>
- Keras. (2019a). Keras documentation. Retrieved from <https://keras.io/optimizers/>
- Keras. (2019b). Keras documentation. Retrieved from <https://keras.io/metrics/>
- Khan, S., Muhammad, K., Mumtaz, S., Baik, S. W., & de Albuquerque, V. H. C. (2019). Energy-Efficient Deep CNN for Smoke Detection in Foggy IoT Environment. *IEEE Internet of Things Journal*, 1–1. <https://doi.org/10.1109/JIOT.2019.2896120>
- Kurose, J., & Ross, K. (2005). *Computer Networking - A top-down approach*. Pearson.
- Lago Canadas, J. (2017). *Diseño y control de un dron con evasión de obstáculos*.
- Maksymiv, O., Rak, T., & Peleshko, D. (2017). Real-time fire detection method combining AdaBoost, LBP and convolutional neural network in video sequence. *2017 14th International Conference The Experience of Designing and Application of CAD Systems in Microelectronics, CADSM 2017 - Proceedings*, 351–353. <https://doi.org/10.1109/CADSM.2017.7916148>
- Manyika, J., Chui, M., Bisson, P., Woetzel, J., Dobbs, R., Bughin, J., & Aharon, D. (2016). El Internet de las cosas: Un informe de la política pública de Internet Society ( ISOC ). *Internet Society*, 1–8.
- Márquez Díaz, J. E. (2018). Seguridad metropolitana mediante el uso coordinado de Drones. *Ingenierías USBMed*, 9(1), 39. <https://doi.org/10.21500/20275846.3299>
- Mavic pro. (2019). Mavic pro wherever you go. Retrieved from <https://www.dji.com/mavic>
- Merino, L., Caballero, F., Martínez-De-Dios, J. R., Maza, I., & Ollero, A. (2012). An unmanned aircraft system for automatic forest fire monitoring and

- measurement. *Journal of Intelligent and Robotic Systems: Theory and Applications*, 65(1–4), 533–548. <https://doi.org/10.1007/s10846-011-9560-x>
- Minambiente. (1974). *Decreto 2811 del 18 de Diciembre de 1974*. Retrieved from [http://www.minambiente.gov.co/images/GestionIntegraldelRecursoHidrico/pdf/normativa/Decreto\\_2811\\_de\\_1974.pdf](http://www.minambiente.gov.co/images/GestionIntegraldelRecursoHidrico/pdf/normativa/Decreto_2811_de_1974.pdf)
- Minambiente. (2019). Los incendios forestales. Retrieved from <http://www.minambiente.gov.co/index.php/component/content/article?id=428:pantilla-bosques-biodiversidad-y-servicios-ecosistematicos-23>
- Ministerio de Tecnologías de la Información y las Comunicaciones. (2015). *Decreto 1078. Decreto único reglamentario del Sector de Tecnologías de la Información y las Comunicaciones*. Retrieved from [https://www.mintic.gov.co/portal/604/articles-9528\\_documento.pdf](https://www.mintic.gov.co/portal/604/articles-9528_documento.pdf)
- Mora Tebas, J. (2018). Drones: ¿La Clave para el desarrollo y la seguridad en África? *IEEE*, 33. Retrieved from Dron, UAV, RA, África, seguridad, desarrollo, dronización
- Morgan, Q., Brian, G., & Smart, W. D. (2015). *Programming Robots with ROS*. (S. D. Blanchette Meghan, Ed.) (1st ed.). Boston.
- Muhammad, K., Ahmad, J., Lv, Z., Bellavista, P., Yang, P., & Baik, S. W. (2018). Efficient Deep CNN-Based Fire Detection and Localization in Video Surveillance Applications. *IEEE Transactions on Systems, Man, and Cybernetics: Systems, PP*, 1–16. <https://doi.org/10.1109/TSMC.2018.2830099>
- Muhammad, K., Ahmad, J., Mehmood, I., Rho, S., & Baik, S. W. (2018). Convolutional Neural Networks Based Fire Detection in Surveillance Videos. *IEEE Access*, 6, 18174–18183. <https://doi.org/10.1109/ACCESS.2018.2812835>
- Muhammad, K., Khan, S., Elhoseny, M., Ahmed, S. H., & Baik, S. W. (2019). Efficient Fire Detection for Uncertain Surveillance Environment. *IEEE Transactions on Industrial Informatics, PP(c)*, 1–1. <https://doi.org/10.1109/tii.2019.2897594>
- Muñoz, F., Porta, J., & Contreras, M. (2014). *Redes Ad Hoc*. Retrieved from <http://www.eng.auburn.edu/~jtc0004/jtc/manet/applet.htm?>
- naylampmechatronics. (2013). Conversor de nivel lógico I2C 5V a 3.3V. Retrieved from <https://naylampmechatronics.com/conversores-ttl/67-conversor-de-nivel-logico-i2c.html>
- P.Kingm, D., & Ba, J. L. (2015). Adam: A method for stochastic optimization (p. 15).
- Palacios, F. M., Quesada, E. S. E., Sanahuja, G., Salazar, S., Salazar, O. G., & Carrillo, L. R. G. (2017). Test bed for applications of heterogeneous unmanned vehicles. *International Journal of Advanced Robotic Systems*, 14(1), 1–14. <https://doi.org/10.1177/1729881416687111>
- Parrot. (2019). Parrot Ar. Drone.
- Parrot bebop drone user guide. (2014), 33.
- Rambal. (2019). *Conversor de nivel lógico Bidireccional. (4 canales)*.
- Raspberry Pi. (2019). Raspberry Pi 3. Retrieved from <https://www.raspberrypi.org/products/raspberry-pi-3-model-b-plus/>
- Ros. (2019). ROS. Retrieved from <http://www.ros.org/about-ros/>

- Rossie, L. (2019). Corsican fire database. Retrieved from <http://cfdb.univ-corse.fr/>
- RUNAP. (2019a). Áreas protegidas. Retrieved from <http://runap.parquesnacionales.gov.co/departamento/935>
- RUNAP. (2019b). Serranía de los Yariguíes. Retrieved from <http://runap.parquesnacionales.gov.co/area-protegida/473>
- Saadat, M. N., & Husen, M. N. (2018). An Application Framework for Forest Fire and Haze Detection with Data Acquisition Using Unmanned Aerial Vehicle. In *Proceedings of the 12th International Conference on Ubiquitous Information Management and Communication - IMCOM '18* (pp. 1–7). New York, New York, USA: ACM Press. <https://doi.org/10.1145/3164541.3164624>
- Salazar, J. (2016). *Redes inalámbricas*.
- Sebe, N., Cohen, I., Huang, T., & Gard, A. (2005). *Machine Learning in Computer Vision* (Vol. 29). Berlin/Heidelberg: Springer-Verlag. <https://doi.org/10.1007/1-4020-3275-7>
- Suasnavas Males, P. A. (2016). *Sistema de vigilancia usando cámaras de seguridad y drones en la finca "La María" de la UTEQ*. Universidad de Guayaquil.
- Szeliski, R. (2011). *Computer Vision: Algorithms & Applications*, 5, 832. <https://doi.org/10.1007/978-1-84882-935-0>
- Thamizhmathi, M., & Usharani, S. (2014). A survey of Forest Fire Detection Techniques. *International Journal of Distributed Sensor Networks*, 2(12), 7. Retrieved from <http://journals.sagepub.com/doi/10.1155/2014/597368>
- Torres Simón, F. J. (2017). *El dron aplicado al sector audiovisual*. Editorial Tébar Flores.
- Unión Internacional de Telecomunicaciones. (2012). *Descripción general de Internet de los objetos. Sector de Normalización de las Telecomunicaciones de la UIT*.
- Vanko, J., Sousa, J. J., Adão, T., Pádua, L., Morais, R., Hruška, J., & Peres, E. (2017). UAS, sensors, and data processing in agroforestry: a review towards practical applications. *International Journal of Remote Sensing*, 38(8–10), 1–43. <https://doi.org/10.1080/01431161.2017.1297548>
- Vanus, J., Martinek, R., Bilik, P., Zidek, J., Dohnalek, P., & Gajdos, P. (2016). New method for accurate prediction of CO<sub>2</sub> in the Smart Home. In *Conference Record - IEEE Instrumentation and Measurement Technology Conference* (Vol. 2016-July). <https://doi.org/10.1109/I2MTC.2016.7520562>
- Wang, K., Wang, Y., Zhang, J., & Zhang, Q. (2018). Fire Detection in Infrared Video Surveillance Based on Convolutional Neural Network and SVM (p. 1). Hefei.
- WWF-Colombia. (2017). *Colombia Viva: Un país megadiverso de cara al futuro*. Cali.
- Yuan, C., Zhang, Y., & Liu, Z. (2015). A survey on technologies for automatic forest fire monitoring, detection, and fighting using unmanned aerial vehicles and remote sensing techniques. *Canadian Journal of Forest Research*, 45(7), 783–792. <https://doi.org/10.1139/cjfr-2014-0347>

## Anexo 1. Email: Petición y respuesta de acceso a la Base de Datos

28/4/2019

Universidad Autónoma de Bucaramanga Mail - Request access to the Corsican Fire Database



LUISA FERNANDA CHACON CASTRO <lchacon565@unab.edu.co>

---

### Request access to the Corsican Fire Database

1 message

---

KEVIN JOEL OLARTE CAMARGO <kolarte@unab.edu.co>

Tue, Feb 26, 2019 at 9:10 PM

To: lrossi@univ-corse.fr

Bcc: lchacon565@unab.edu.co

Dear Dr. Lucile Rossi,

My name is Kevin J. Olarte. I'm a Systems Engineer student at the Universidad Autonoma de Bucaramanga (Colombia). Actually, I'm working on my Thesis degree. The purpose is to develop a technological solution based on Internet of Things in order to detect fires in protected areas.

As part of our work, we want to create an algorithm in order to detect fires using images captured by drones. In Colombia, there are many forest fires, but there are still no technological solutions to solve this problem and allow an immediate reaction.

I would like to have access to the image database to continue with our project, working in controlled environments.

Website: <http://www.unab.edu.co>

Best regards,

KEVIN JOEL OLARTE  
Coordinador Semillero De Desarrollo Web



Fuente: Tomado de (Rossie, 2019)



---

**Request access to the Corsican Fire Database**

---

Lucile ROSSI <rossi\_l@univ-corse.fr>

28 de febrero de 2019, 6:16

Para: KEVIN JOEL OLARTE CAMARGO <kolarte@unab.edu.co>

Dear Kevin

Here your login and password to access to the Corsican Fire Database

- login: OlarKe
- password: Ke27v02

Yours

Lucile Rossi

De : KEVIN JOEL OLARTE CAMARGO [mailto:kolarte@unab.edu.co]

Envoyé : mercredi 27 février 2019 23:34

À : Lucile ROSSI <rossi\_l@univ-corse.fr>

Objet : Re: Request access to the Corsican Fire Database

[El texto citado está oculto]

Fuente: Tomado de (Rossie, 2019)

## Anexo 2. Soluciones tecnológicas Software

### Detección de incendios y creación de redes neuronales convolucionales

Nombre	Descripción	Enlace
Tensorflow-gpu	<i>Framework</i> base para la creación de CNN.	<a href="https://www.tensorflow.org/install/gpu">https://www.tensorflow.org/install/gpu</a>
Python	Programación de los componentes.	<a href="https://www.python.org/">https://www.python.org/</a>
Ubuntu	Sistema operativo del entrenamiento para la red neuronal.	<a href="https://www.ubuntu.com/">https://www.ubuntu.com/</a>
Sphinx	Generador de documentación de Python.	<a href="http://www.sphinx-doc.org/en/master/">http://www.sphinx-doc.org/en/master/</a>
Numpy	Compilador de Python a C para acelerar de procesos.	<a href="https://www.numpy.org/">https://www.numpy.org/</a>
Opencv	Librería para tratamiento de imágenes y lectura de video.	<a href="https://opencv.org/">https://opencv.org/</a>
MySql	Base de datos	<a href="https://www.mysql.com/">https://www.mysql.com/</a>
Anaconda	Plataforma de ciencias de datos	<a href="https://www.anaconda.com/">https://www.anaconda.com/</a>

Figura 31. Componentes para la detección de incendio

Fuente: Elaboración propia

Nombre	Descripción	Enlace
Tensorflow	Librería para	<a href="https://www.tensorflow.org/">https://www.tensorflow.org/</a>
Python	Programación de los sensores	<a href="https://www.python.org/">https://www.python.org/</a>
Raspbian	Sistema operativo para la Raspberry pi 3 B+	

Figura 32. Componentes para el vuelo autónomo

Fuente: Elaboración propia

Nombre	Descripción	Enlace
Plataforma web	Plataforma para visualizar alarmas y ubicación del dron.	
Red WiFi	Para la transmisión de datos.	<a href="https://www.wi-fi.org/">https://www.wi-fi.org/</a>
Flask	Servidor de la plataforma web.	<a href="http://flask.pocoo.org/">http://flask.pocoo.org/</a>

Figura 33. Componentes para la generación de alertas

Fuente: Elaboración propia

Bucaramanga, 31 de mayo de 2019

Señor

**Jorge Andrick Parra Valencia**

Programa de Ingeniería de Sistemas

Facultad de Ingeniería

Universidad Autónoma de Bucaramanga

Bucaramanga

Asunto: Carta aval para la presentación de Proyecto de Trabajo de Grado I

Mediante la presente me permito avalar el envío del Anteproyecto de Trabajo de Grado de los estudiantes Kevin Joel Olarte Camargo y Luisa Fernanda Chacón Castro titulado ***“Prototipo de un sistema de monitoreo para incendios en áreas protegidas del Departamento de Santander con la generación de alertas en tiempo real por medio de drones”***

Cordialmente,

---

**Paulo César Ramírez Prada**

Director Trabajo de Grado