



**unl**

Universidad  
Nacional  
de Loja

**Universidad Nacional de Loja**

**Facultad Agropecuaria y de Recursos Naturales Renovables**

**Carrera de Ingeniería Ambiental**

**Zonas susceptibles a incendios forestales basado en algoritmos de aprendizaje automático (Machine Learning) en el cantón Macará, Loja – Ecuador**

**Trabajo de Integración Curricular previa  
a la obtención del título de Ingeniero  
Ambiental**

**AUTOR:**

Daniel Eduardo Samaniego Herrera

**DIRECTOR:**

Ing. Carlos Guillermo Chuncho Morocho Mg. Sc.

Loja – Ecuador  
2024

## Certificación

Loja, 25 de noviembre de 2024

Ing. Carlos Guillermo Chuncho Morocho *Mg.Sc*

**DIRECTOR DE TRABAJO DE INTEGRACIÓN CURRICULAR**

### **C E R T I F I C O:**

Que he revisado y orientado todo el proceso de la elaboración del Trabajo de Integración Curricular denominado: **Zonas susceptibles a incendios forestales basado en algoritmos de aprendizaje automático (Machine Learning) en el cantón Macará, Loja – Ecuador**, de autoría del estudiante **Daniel Eduardo Samaniego Herrera**, con cédula de identidad No. **1150146767**, previa a la obtención del título de Ingeniero Ambiental. Una vez que el trabajo cumple con todos los requisitos estipulados por la Universidad Nacional de Loja, apruebo y autorizo su presentación para los trámites de titulación.



Firmado electrónicamente por:  
**CARLOS GUILLERMO  
CHUNCHO MOROCHO**

Ing. Carlos Guillermo Chuncho Morocho *Mg.Sc*

**DIRECTOR DEL TRABAJO DE TITULACIÓN**

## Autoría

Yo, **Daniel Eduardo Samaniego Herrera**, declaro ser autor del presente Trabajo de Integración Curricular y eximo expresamente a la Universidad Nacional de Loja y a sus representantes jurídicos de posibles reclamos y acciones legales por el contenido del mismo. Adicionalmente acepto y autorizo a la Universidad Nacional de Loja, la publicación de mi Trabajo de Titulación en el Repositorio Institucional – Biblioteca Virtual.



**Cédula:** 1150146767

**Fecha:** 20 de diciembre de 2024

**Correo electrónico:** [daniel.samaniego@unl.edu.ec](mailto:daniel.samaniego@unl.edu.ec)

**Celular:** 0992180160

Carta de autorización

Yo **Daniel Eduardo Samaniego Herrera**, declaro ser autor del Trabajo de Integración Curricular denominado: **Zonas susceptibles a incendios forestales basado en algoritmos de aprendizaje automático (Machine Learning) en el cantón Macará, Loja – Ecuador** como requisito para optar el título de **Ingeniero Ambiental**, autorizo al Sistema Bibliotecario de la Universidad Nacional de Loja para que con fines académicos muestre la producción intelectual de la Universidad, a través de la visibilidad de su contenido de la siguiente manera en el Repositorio Institucional. Los usuarios pueden consultar el contenido de este trabajo en el Repositorio Institucional, en las redes de información del país y del exterior con las cuales tenga convenio la Universidad. La Universidad Nacional de Loja no se responsabiliza por el plagio o copia del Trabajo de Integración Curricular que realice un tercero.

Para constancia de esta autorización, en la ciudad de Loja a los veinte y cinco días del mes noviembre del dos mil veinte y cuatro.



**Autor:** Daniel Eduardo Samaniego Herrera

**Cédula:** 1150146767

**Dirección:** Bruselas y Paris

**Correo electrónico:** daniel.samaniego@unl.edu.ec

**Celular:** 0992180160

**DATOS COMPLEMENTARIOS:**

**Director del Trabajo de Titulación:**

Ing. Carlos Guillermo Chunchu Morocho *Mg.Sc*

## **Dedicatoria**

Quiero dedicar este trabajo a mis padres, cuyo amor, apoyo incondicional y sacrificio constante han sido los pilares que me han permitido llegar hasta este momento tan importante de mi vida. A mi familia en general, especialmente a mis hermanos, quienes han estado presentes a lo largo de este camino, compartiendo alegrías y desafíos.

Con especial cariño, a mi abuelita, quien siempre nos inspiró a salir adelante y cuya mayor felicidad es ver a quienes ama cumplir sus metas. A mi bisabuelita, quien no pudo estar para presenciar este logro, pero sé que desde donde esté, me acompaña con su amor eterno.

Y finalmente, a mi querido perrito Ruffo, que hoy ya no está conmigo. Su compañía incondicional, incluso en las madrugadas, y esa mirada que transmitía tranquilidad y apoyo, fueron un refugio en los momentos más difíciles.

A todos ellos, gracias por ser mi motor y mi inspiración.

*Daniel Eduardo Samaniego Herrera*

## **Agradecimiento**

Quiero expresar mi más profundo agradecimiento a la carrera de Ingeniería Ambiental y a la planta docente, por su guía y sabiduría que han iluminado mi camino académico, las experiencias y conocimientos que me han brindado las llevaré siempre conmigo.

A mis padres, mi mayor fuente de amor, apoyo y consejo, les agradezco de corazón por moldear la persona que soy hoy. Su ejemplo e inspiración me han impulsado a superar cada desafío, con el deseo de que se sientan orgullosos al ver que han criado a alguien con valores sólidos y determinación para conquistar sus sueños.

Quiero agradecer a mi enamorada por haber estado conmigo en esta etapa y acompañarme en el camino, siendo ella alguien especial y valiosa en mi vida, dándome amor, apoyo y ayuda cuando lo necesitaba, además de no dejar que me rinda en momentos en que las dudas nublaban mi camino.

De manera especial, quiero expresar mi más sincera gratitud al Ing. Fernando Alexis González Soto, Mg. Sc., por su invaluable guía y mentoría, fundamentales para completar este Trabajo de Titulación. También agradezco al Centro de Investigaciones Territoriales por los valiosos conocimientos que me brindaron y que enriquecieron significativamente mi formación.

A mis amigos, gracias por su comprensión, compañía y apoyo incondicional en cada etapa de este viaje. Su presencia ha sido una fuente constante de motivación y alegría.

*Daniel Eduardo Samaniego Herrera*

## Índice de contenidos

<b>Portada</b> .....	<b>i</b>
<b>Certificación de director</b> .....	<b>ii</b>
<b>Autoría</b> .....	<b>iii</b>
<b>Carta de autorización del estudiante</b> .....	<b>iv</b>
<b>Dedicatoria</b> .....	<b>v</b>
<b>Agradecimiento</b> .....	<b>vi</b>
<b>Índice de contenidos</b> .....	<b>vii</b>
Índice de tablas .....	xi
Índice de figuras .....	xi
Índice de ecuaciones .....	xii
Índice de anexos .....	xii
<b>1. Título</b> .....	<b>1</b>
<b>2. Resumen</b> .....	<b>2</b>
Abstract .....	3
<b>3. Introducción</b> .....	<b>4</b>
<b>4. Marco Teórico</b> .....	<b>7</b>
4.1. Incendios forestales .....	7
4.2. Incendios forestales en el marco nacional y local .....	8
4.3. Efectos que causan los incendios.....	9
4.4. Probabilidad de ocurrencia de los incendios forestales .....	10
4.5. Zonas forestales .....	10
4.5.1. Bosques Secos .....	11
4.6. Teledetección en el Análisis de Incendios Forestales .....	12
4.7. Machine Learning como herramienta para la detección y prevención de incendios forestales .....	13

4.7.1.	Puntos de calor .....	16
4.7.2.	Índices de vegetación .....	16
4.7.3.	Topografía .....	19
4.7.4.	Accesibilidad y asentamientos urbanos.....	19
4.8.	Técnicas de aprendizaje automático .....	19
4.8.1.	Algoritmos de aprendizaje automático.....	20
<b>5.</b>	<b>Metodología .....</b>	<b>22</b>
5.1.	Área de estudio .....	22
5.2.	Herramientas de Software .....	23
5.2.1.	De escritorio .....	23
5.2.2.	Online .....	24
5.3.	Establecer una línea base de las variables predictivas para la determinación de la ocurrencia de incendios forestales en el cantón Macará.....	24
5.3.1.	Identificación de variables.....	24
5.3.2.	Recolección de datos .....	30
5.3.3.	Preparación de los datos .....	31
5.3.4.	Obtención de la capa de accesibilidad.....	32
5.3.5.	Extracción de información de las variables.....	34
5.3.6.	Identificar las variables de importancia.....	35
5.4.	Evaluar algoritmos de Machine Learning para la generación de un modelo de susceptibilidad a incendios forestales en el cantón Macará.....	36
5.4.1.	Generación y aplicación del modelo utilizando tres técnicas de aprendizaje automático supervisado.....	37
5.4.2.	Evaluación y validación del rendimiento del modelo mediante dos indicadores .....	39
5.5.	Automatización del modelo de susceptibilidad a incendios forestales para mapeo de zonas de riesgo a incendios forestales en el cantón Macará.....	42



5.5.1.	Mapeo de zonas de riesgo a incendios forestales .....	43
<b>6.</b>	<b>Resultados .....</b>	<b>47</b>
6.1.	Línea base de las variables predictivas para la determinación de la ocurrencia de incendios forestales en el cantón Macará. ....	47
6.1.1.	Elaboración y recolección de variables .....	47
6.1.2.	Recolección y preparación de datos .....	53
6.1.3.	Extracción de los datos.....	54
6.1.4.	Identificación de las variables de importancia .....	54
6.2.	Evaluación de algoritmos de Machine Learning para la generación de un modelo de susceptibilidad a incendios forestales en el cantón Macará.....	55
6.3.	Automatización del modelo de susceptibilidad a incendios forestales para mapeo de zonas de riesgo a incendios forestales en el cantón Macará.....	58
6.3.1.	Mapeo de zonas de riesgo a incendios forestales .....	59
<b>7.</b>	<b>Discusión .....</b>	<b>66</b>
<b>8.</b>	<b>Conclusiones .....</b>	<b>73</b>
<b>9.</b>	<b>Recomendaciones .....</b>	<b>74</b>
<b>11.</b>	<b>Bibliografía .....</b>	<b>79</b>
<b>10.</b>	<b>Anexos .....</b>	<b>75</b>

## Índice de tablas

<b>Tabla 1.</b> Índices espectrales de condiciones del suelo y vegetación.....	17
<b>Tabla 2.</b> Variables topográficas.....	25
<b>Tabla 3.</b> Variables de interacción antrópica .....	26
<b>Tabla 4.</b> Variables del estado de vegetación .....	28
<b>Tabla 5.</b> Criterios para determinar incendios forestales .....	32
<b>Tabla 6.</b> Coste de movilidad según la clase de superficie. Fuente: Manual de Prácticas de ordenación Territorial. ....	34
<b>Tabla 7.</b> Clases para la reclasificación de la probabilidad de ocurrencia de incendios .....	39
<b>Tabla 8.</b> Valores de precisión del modelo de acuerdo con el AUC.....	40
<b>Tabla 9.</b> Matriz de confusión.....	42
<b>Tabla 10.</b> Factor de Inflación de la Varianza de cada variable de importancia .....	55
<b>Tabla 11.</b> Rendimiento de los modelos RL, MARS y LTM .....	56
<b>Tabla 12.</b> Importancia de las variables en los modelos empleados .....	57
<b>Tabla 13.</b> Porcentajes de susceptibilidad de acuerdo al periodo del año .....	61

## Índice de figuras

<b>Figura 1.</b> Mapa de ubicación de Zona de estudio (Macará).....	22
<b>Figura 2.</b> Diagrama de flujo del proceso el cálculo de accesibilidad. Fuente: Reyes (2017). 33	
<b>Figura 3.</b> Proceso para la generación de la base de datos. Adaptado de Reyes y Córdova, (2021) .....	35
<b>Figura 4.</b> Identificación de las variables de importancia requeridas para la aplicación del modelo.....	36
<b>Figura 5.</b> Fases para la generación del mapa de probabilidad de ocurrencia de incendios forestales en el cantón Macará. Adaptado de Reyes y Loján (2022). .....	37
<b>Figura 6.</b> Análisis espaciotemporal para la automatización del riesgo de incendios .....	43
<b>Figura 7.</b> Rangos de susceptibilidad a incendios forestales. ....	45
<b>Figura 8.</b> Proceso para la generación de los modelos de susceptibilidad. Adaptado del Manual de aplicación susceptibilidad a incendios forestales. Caso: Cantón Loja por Reyes (2021)....	46
<b>Figura 9.</b> Variables topográficas.....	48
<b>Figura 10.</b> Variables de interacción antrópica (Accesibilidad) .....	50
<b>Figura 11.</b> Variables de interacción antrópica (Distancias).....	51
<b>Figura 12.</b> Variables de estado de la vegetación (Índices espectrales).....	53
<b>Figura 13.</b> Puntos de calor depurados con su respectivo punto de control .....	54
<b>Figura 14.</b> Variables de importancia para predicción de incendios forestales .....	55
<b>Figura 15.</b> Número de datos clasificados correctamente (aciertos) o incorrectamente (errores) .....	57
<b>Figura 16.</b> Espacialización de los modelos empleados .....	58
<b>Figura 17.</b> Automatización del modelo en Google Earth Engine.....	59
<b>Figura 18.</b> Zonificación del riesgo de incendios forestales basada en un análisis espacio-temporal para el cantón Macará durante el periodo de enero a diciembre de 2020. ....	60
<b>Figura 19.</b> Mapeo de la calidad global, inhomogeneidad y distinción del análisis clúster para la zonificación del riesgo de incendios forestales .....	63
<b>Figura 20.</b> Zonificación y mapeo de áreas propensas a incendiarse, mediante técnicas de clustering .....	65

## Índice de ecuaciones

(Ec. 1) Factor de inflacion de la varianza .....	36
(Ec. 2) Regresión Logística.....	38
(Ec. 3) Splines de regresión adaptativa multivariante (MARS).....	38
(Ec. 5) Sencibilidad.....	40
(Ec. 6) Especificidad .....	40
(Ec. 7) Kappa .....	41
(Ec. 8) Calidad Global .....	44

## Índice de Anexos

<b>Anexo 1.</b> Base de datos .....	86
<b>Anexo 2.</b> Certificado de traducción del abstract .....	90
<b>Anexo 3.</b> Script de estado de vegetación para el cantón Macará.....	91

## **1. Título**

Zonas susceptibles a incendios forestales basado en algoritmos de aprendizaje automático (Machine Learning) en el cantón Macará, Loja – Ecuador

## 2. Resumen

Los incendios forestales representan una amenaza significativa, especialmente en áreas con vegetación densa y condiciones climáticas adversas como los bosques secos, así mismo pueden destruir bosques, reducir la biodiversidad, degradar el suelo y aumentar el dióxido de carbono en la atmósfera, agravando el cambio climático. Este estudio se centra en identificar las zonas susceptibles a incendios forestales en el cantón Macará, Loja, Ecuador, utilizando algoritmos de aprendizaje automático para desarrollar un modelo predictivo para la gestión y prevención de estos eventos. Se analizaron variables topográficas, índices de vegetación y factores antropogénicos, utilizando datos de Sentinel-2A y puntos de calor del sensor VIIRS (2018-2021). Posteriormente, se extrajo la información para crear una base de datos. Se emplearon algoritmos de aprendizaje automático como regresión logística, árboles de decisión y splines de regresión adaptativa multivariante (MARS). El modelo MARS mostró el mejor desempeño con un AUC de 0.97 y un índice Kappa de 0.91, indicando alta precisión en la predicción de áreas susceptibles a incendios forestales. Las áreas con mayor susceptibilidad se encontraron en zonas con alta densidad de vegetación, alta accesibilidad y significativa interacción humana. Este modelo permite crear un mapa de susceptibilidad a incendios forestales, crucial para la planificación y ejecución de estrategias de prevención y mitigación por parte de las autoridades locales. En conclusión, este estudio proporciona un análisis detallado de los factores que influyen en los incendios forestales en Macará mediante el modelo MARS destacando la importancia de la distancia a zonas antrópicas, ríos y la humedad (Moisture), además de que proporciona un mapa de susceptibilidad a incendios forestales, lo cual es una herramienta práctica para su gestión, contribuyendo a la conservación de los ecosistemas y al bienestar de las comunidades locales. Las limitaciones incluyen la necesidad de datos meteorológicos y la nubosidad, la cual limita la obtención de datos.

**Palabras clave:** *Aprendizaje automático, bosque seco, incendios forestales, Multivariate Adaptive Regression Splines (MARS), susceptibilidad.*

## **Abstract**

Forest fires represent a significant threat, especially in areas with dense vegetation and adverse climatic conditions such as dry forests, and can destroy forests, reduce biodiversity, degrade soil and increase carbon dioxide in the atmosphere, aggravating climate change. This study focuses on identifying areas susceptible to forest fires in the Macará canton, Loja, Ecuador, using machine learning algorithms to develop a predictive model for the management and prevention of these events. Topographic variables, vegetation indices and anthropogenic factors were analyzed using Sentinel-2A data and hot spots from the VIIRS sensor (2018-2021). Subsequently, the information was extracted to create a database. Machine learning algorithms such as logistic regression, decision trees and multivariate adaptive regression splines (MARS) were used. The MARS model showed the best performance with an AUC of 0.97 and a Kappa index of 0.91, indicating high accuracy in predicting areas susceptible to forest fires. The areas with the highest susceptibility were found in zones with high vegetation density, high accessibility and significant human interaction. This model allows the creation of a forest fire susceptibility map, crucial for the planning and implementation of prevention and mitigation strategies by local authorities. In conclusion, this study provides a detailed analysis of the factors that influence forest fires in Macará using the MARS model highlighting the importance of distance to anthropogenic areas, rivers and Moisture, in addition to providing a map of susceptibility to forest fires, which is a practical tool for their management, contributing to the conservation of ecosystems and the welfare of local communities. Limitations include the need for meteorological data and cloud cover, which limits data collection.

## **Keywords:**

Machine learning, dry forest, forest fires, Multivariate Adaptive Regression Splines (MARS), susceptibility.



### 3. Introducción

El fuego desde tiempos inmemoriales, ha sido una fuerza elemental que moldea y regula los ecosistemas naturales, desempeñando un papel crucial en la estructura, función y dinámica de los medios terrestres. Esta afirmación destaca la importancia intrínseca del fuego en la ecología del planeta, siendo parte integral de su historia evolutiva, influenciando tanto por factores climáticos como por susceptibilidad natural, especialmente durante temporadas de sequía (Villers, 2006). Sin embargo, la preparación de tierras agrícolas son una causa común de incendios, ya que, cuando el fuego escapa del control se convierte en un incendio forestal, siendo un suceso catastrófico con orígenes tanto natural como antrópico (Pausas, 2020), por lo cual, este evento impacta de manera severa a la vida humana, la fauna, la flora y el ambiente (Stephens et al., 2013). Esta realidad pone de manifiesto la importancia de comprender los factores que influyen en la ocurrencia y propagación de los incendios forestales, así como sus impactos a largo plazo en los ecosistemas.

Los incendios forestales pueden alterar extensas áreas de bosques, provocando cambios drásticos en la composición y estructura de los ecosistemas, con consecuencias que dependen de diversos factores, como la intensidad del fuego, la vegetación presente y las características del suelo (Bodí et al., 2012). Además, la repetición de estos eventos puede alterar las propiedades del suelo, aumentando la erosión y disminuyendo su fertilidad (Cuesta y Giraldo, 2013).

Para estudiar la probabilidad de incendios forestales, es esencial utilizar la teledetección, ya que permite monitorear las condiciones de la vegetación antes y después de un incendio mediante imágenes satelitales. Esto facilita la evaluación de la severidad del incendio, la tasa de pérdida de cobertura vegetal y el proceso de recuperación (Di Bella et al., 2008). El uso de estas imágenes ha sido crucial para implementar modelos basados en índices espectrales para el monitoreo y reporte de incendios forestales (Gholinejad y Khesali, 2021). Por lo que, Reyes y Loján (2022) proponen emplear técnicas de aprendizaje supervisado, como árboles de decisión (LMT), regresión logística (RL) y splines de regresión adaptativa multivariante (MARS).

A nivel global, representan una amenaza significativa, con pérdidas anuales estimadas entre 20 y 40 millones de hectáreas en áreas tropicales, y de 10 a 15 millones de hectáreas en zonas boreales y templadas, mayormente atribuidas a actividades humanas como la agricultura y la conversión de suelos (Villers, 2006).

En Ecuador, según el Servicio Nacional de Gestión de Riesgos y Emergencias (SNGRE, 2021), los incendios forestales en 2021 afectaron un total de 3.520,45 hectáreas de cobertura vegetal a través de 600 eventos registrados a nivel nacional. En ese mismo año, la provincia de Loja se destacó como una de las más afectadas, con 782,50 hectáreas impactadas, junto con las provincias de Guayas, Azuay e Imbabura (SNGRE, 2021). El Ministerio del Ambiente del Ecuador (MAE, 2013) y el Sistema de Alerta del Distrito Metropolitano de Quito (SADMQ, 2013) estiman que solo el 4% de los incendios forestales en el país son de origen natural, mientras que el 96% se deben a actividades antropogénicas. Además, Ecuador, como muchos otros países, enfrenta el desafío constante de los incendios forestales, con impactos significativos en sus diversos ecosistemas. Datos recientes revelan la magnitud de este problema, con pérdidas anuales considerables de hectáreas de vegetación y afectaciones tanto en áreas rurales como urbanas (Servicio Nacional de Gestión de Riesgos y Emergencias, 2021). Asimismo, los datos del Servicio Nacional de Gestión de Riesgos y Emergencias del 2018 al 2021 revelan que ha habido un total de 23 incendios forestales en el cantón Macará, específicamente en las zonas de bosque seco, siendo todos estos eventos causados por acciones humanas.

En este contexto, según el Proyecto Bosque Seco (1998), Aguirre et al. (2006) y Mendoza et al. (2021), la provincia de Loja se caracteriza por una considerable extensión de bosque seco, que representa el 20% de su territorio. Parte de este ecosistema se encuentra en Macará, lo que lo expone a una constante vulnerabilidad frente a los incendios forestales. Este riesgo se debe a características geográficas, como las altas temperaturas y la baja precipitación media anual, así como a factores ecológicos, incluyendo la predominancia de vegetación caducifolia adaptada a condiciones climáticas extremas. Estos ecosistemas, además de ser frágiles, están bajo presión constante por actividades humanas como la agricultura y el cambio de uso del suelo, lo que altera su estructura, diversidad y dinámica natural. Según Mendoza et al. (2021), estos factores incrementan su susceptibilidad a incendios forestales. Por ello, identificar las áreas más propensas a estos eventos resulta crucial para desarrollar estrategias

efectivas de prevención y mitigación, que permitan proteger tanto los ecosistemas como los recursos asociados.

Esta investigación tiene por objetivo abordar la problemática de los incendios forestales en el cantón Macará, Loja, Ecuador. Por ello, busca no solo comprender la dinámica de estos eventos, sino también desarrollar modelos predictivos que identifiquen las áreas con mayor susceptibilidad a incendios forestales, utilizando técnicas estadísticas, sistemas de información geográfica y aprendizaje automático (Reyes-Bueno y Balcázar-Gallegos, 2021). La importancia de este estudio radica en su contribución a salvaguardar los ecosistemas en riesgo, la reducción de amenazas ambientales y el fomento de un crecimiento sostenible en Macará debido a la presencia del ecosistema denominado “bosque seco” y regiones análogas a este, ya que este ecosistema alberga exuberante biodiversidad y está en constante peligro de sufrir un evento de fuego forestal, debido a la vegetación seca, la cual es característica de la zona de estudio (Aguirre y Delgado, 2005). Al descubrir y entender las áreas más vulnerables, se podrán establecer tácticas preventivas y planes de manejo eficaces, fortaleciendo la capacidad de adaptación de los ecosistemas y las comunidades que de ellos dependen (Chuvienco et al., 2007; Sandoval, 2018).

Esta investigación propone no solo generar conocimiento científico sobre la susceptibilidad a incendios forestales en el cantón Macará, sino también proporcionar herramientas prácticas para la gestión y prevención de estos eventos, contribuyendo así a la conservación de los recursos naturales y al bienestar de las comunidades locales. Los resultados de esta investigación podrían ser útiles para crear políticas públicas y prácticas de manejo en otros ecosistemas similares.

Por lo tanto, el estudio propone responder a la pregunta: ¿Cuáles son las zonas susceptibles a incendios forestales en el cantón Macará, Loja, Ecuador? Para responder esta pregunta, el objetivo es desarrollar un sistema de mapeo de susceptibilidad a incendios forestales, basado en algoritmos de Machine Learning, aplicado específicamente en el cantón Macará. En este proceso, i) se estableció una línea base de las variables predictivas para la determinación de la ocurrencia de incendios forestales en el cantón Macará. ii) Además se evaluaron algoritmos de Machine Learning para la generación de un modelo de susceptibilidad a incendios forestales en el cantón antes mencionado. iii) Y, por último, se automatizó dicho modelo para el mapeo de zonas de riesgo a incendios forestales en el mismo cantón.

## 4. Marco Teórico

### 4.1. Incendios forestales

Los incendios forestales son un fenómeno global que se da en los cinco continentes sin excepción y muchas veces están asociados a la destrucción de la naturaleza, recursos forestales, agrícolas y pecuarios (Úbeda y Francos, 2018). Agama (2016) define el incendio forestal como un fuego que arde y se propaga con gran intensidad por el combustible vegetal, lo que dificulta su control. Los incendios forestales tienen una amplia propagación, una velocidad de extensión inigualable, una facilidad para cambiar la dirección de propagación y superan obstáculos como carreteras, ríos y cortafuegos. Estos factores diferencian a los incendios forestales de otros tipos de incendios.

En el 2019, la plataforma Global Forest Watch Fires (GFW Fires) registró más de 4,5 millones de alertas de calor detectadas alrededor del mundo, con un aumento de 400.000 en comparación con el año anterior. El número y la magnitud de los incendios están aumentando a escala global. Los expertos creen que hay una conexión entre el aumento de los incendios y las altas temperaturas del mar causadas por el cambio climático (Schauenberg, 2020).

Según Madariaga (2011), los incendios forestales de origen natural ocurren cuando no hay intervención humana. Estos pueden generarse por fenómenos naturales como rayos o erupciones volcánicas que liberan lava y fuego, afectando la vegetación circundante. Por otro lado, las causas antropogénicas incluyen tanto actos intencionados como accidentes. Actualmente, la mayoría de los incendios forestales son provocados por el ser humano, ya sea por negligencia o desconocimiento, independientemente del lugar o la época. Hernández (2019) y Salom (2018) concluyen que tanto la intencionalidad como la falta de conocimiento son factores que contribuyen a la ocurrencia de incendios forestales.

El fuego no siempre es negativo, pues a veces puede beneficiar a la naturaleza al promover la biodiversidad, de tal manera de que si existiesen algunas especies de plantas que pueden ser dominantes en un ecosistema y que impiden que otras especies crezcan, un incendio puede disminuir la presencia de estas especies dominantes, permitiendo a otras especies crecer y prosperar. Sin embargo, cuando se usa de manera inapropiada o se produce por negligencia,

puede desencadenar en un incendio forestal que puede tener consecuencias catastróficas para el medio ambiente, así como para la salud y seguridad de las personas (CNF, 2010).

#### **4.2. Incendios forestales en el marco nacional y local**

Según los informes del Servicio Nacional de Gestión del Riesgo y Emergencia, entre 2010 y 2018, los incendios forestales representaron el 38 % de los fenómenos naturales que generan riesgo. La región Sierra experimentó la mayor afectación, con un 80 %, mientras que la región Costa sufrió un 18 % y la región amazónica e insular solo sufrió un 2 % (CAF, 2020), esto se traduce en aproximadamente 164.000 hectáreas de bosques nativos e intervenidos destruidas por incendios forestales, lo que implica que el 99 % de este fenómeno está relacionado directa e indirectamente con las actividades humanas, como las explotaciones forestales, el turismo sin responsabilidad y principalmente la expansión de la actividad agrícola y ganadera (CAF, 2020).

Aunque en la provincia de Loja se han reportado incendios forestales, la información es limitada. Sin embargo, se puede decir que los bosques de la provincia se encuentran entre 190 y 1000 m.s.n.m. en tierras bajas y en las estribaciones occidentales de la cordillera de Los Andes, y representan el 20% de la provincia, de los cuales, algunas zonas presentan más susceptibilidad a incendios forestales debido a varios factores como son el tipo de clima y tipo de bosque (Herbario Loja et al., 2001; Aguirre-Mendoza et al., 2006; Aguirre-Mendoza y Kvist, 2009).

Una gran parte de los bosques secos de Loja se sitúan en el centro de la Zona de Endemismo Tumbesino, que se extiende por un área de 50000 km<sup>2</sup> entre Ecuador y Perú y son de gran relevancia debido a su amplia variedad de flora y fauna (Best y Kresler, 1995). Estos bosques han soportado presiones antrópicas, producto de la extracción maderera, conversión de uso de la tierra, incendios forestales y sobrepastoreo caprino (Aguirre-Mendoza et al., 2001; Chiriboga y Andrade, 2005; Espinosa et al., 2012). Y producto de ello están en grave peligro de sufrir un evento de fuego forestal, lo cual podría agravar los problemas socioambientales del territorio.

### 4.3. Efectos que causan los incendios

Los incendios tienen un impacto en la estructura, composición y servicios de la vegetación. Es importante destacar que la respuesta de la vegetación a un incendio varía según las características propias de cada especie. Por ejemplo, *Cercidium praecox* (palo verde) y el *Acacia macracantha* (faique) son especies que no toleran el fuego, por lo que si se produce un incendio en esta vegetación, es muy probable que su dinámica y composición sufran cambios significativos (Jaksic y Fariña, 2015). El mantenimiento de una población de especies vegetales depende en gran medida de la resistencia de las semillas en el suelo o en la planta, así como de la capacidad de rebrote de la vegetación afectada (Parra y Bernal, 2010). Así mismo, Rodríguez (2012) señala que los efectos de reemplazar especies nativas por exóticas tras un incendio forestal se evidencian en la reducción de la precipitación, los movimientos de masa de aire, los cambios en la temperatura y la humedad del suelo.

Otro componente afectado es el suelo que cumple varias funciones, incluida la retención de carbono, la purificación del agua, el ciclo de nutrientes, el hábitat de los seres vivos, la base de la infraestructura humana y el suministro de alimentos, fibras y combustible (Gonzales, 2017). La degradación del suelo se intensifica, entre otros factores, por los incendios forestales, ya que después de un incendio, el suelo queda expuesto al viento y al agua, lo que lo hace susceptible a la erosión (Ashes to Life, 2019). Los impactos varían según la topografía del lugar, la intensidad del proceso de erosión, la regeneración de la cubierta vegetal, la recurrencia, la intensidad y la duración del incendio (Rodríguez, 2012). Además, los incendios forestales tienen un impacto significativo en las propiedades físicas, químicas y biológicas del suelo, lo que resulta en una pérdida de nutrientes y una disminución de materia orgánica.

Menos visibles, pero aún preocupantes son los efectos de los incendios en la sociedad, debido a que la inhalación de humo y partículas finas, presentes en los incendios forestales pueden causar problemas respiratorios. Además, pueden causar trauma emocional y estrés (Reid et al., 2016). También existen problemas sociales como la destrucción de viviendas y otras propiedades, lo que puede resultar en la desmovilización de personas y la pérdida de bienes (Hsiang et al., 2014). Y, por último, impactos a nivel económico, debido a los costos de supresión de incendios, la pérdida de ingresos agrícolas y turísticos, así como los costos de reconstrucción y recuperación (Doerr y Santín, 2016) que son poco visibilizados después de que ocurran estos fenómenos.

#### **4.4. Probabilidad de ocurrencia de los incendios forestales**

Según Pérez et al. (2013), la magnitud de los incendios forestales es influenciada por una serie de factores que se pueden clasificar en dos categorías principales: ambientales y antropogénicos. Los factores ambientales, que incluyen la precipitación, la temperatura y la altitud, pueden afectar la disponibilidad de combustible y la propagación del fuego. En contraste, los factores antropogénicos, que están relacionados con la actividad humana, pueden influir en la probabilidad de inicio de incendios y en la capacidad de respuesta y control de los mismos. Estos pueden incluir la distancia a caminos, localidades, zonas deforestadas y el índice de gravedad de población.

Verdú y Salas (2011) también mencionan que la frecuencia de los incendios forestales está determinada por una variedad de factores ambientales y humanos. Estos factores, que pueden agruparse en cuatro categorías principales: condiciones meteorológicas, tipo y estado de la vegetación, variables topográficas y actividades humanas, determinan la probabilidad de inicio y propagación del fuego. Por otro lado, el inicio de un incendio forestal requiere la presencia de tres elementos básicos que componen el triángulo del fuego: oxígeno, combustible y calor. El combustible, que es el material vegetal presente en una zona, tiene la capacidad de encenderse al ser expuesto a una fuente de calor (Díaz García, 2015).

Finalmente, Oliveira y colaboradores (2012) mencionan que los factores físicos, que reflejan las condiciones naturales intrínsecas del territorio, y los factores humanos, que se establecen con variables importantes por su relación con la ocurrencia de incendios forestales, son ambos significativos en la aparición de incendios forestales.

#### **4.5. Zonas forestales**

Una zona forestal abarca terrenos que albergan rodales naturales o plantados de árboles, con una altura mínima de 5 metros *in situ*, ya sea con fines productivos o no. Estas áreas son esenciales para la biodiversidad, la regulación del clima, la conservación del suelo y el agua, además de brindar hábitats para numerosas especies de plantas y animales. (Toledo et al., 2022)

Los bosques son ecosistemas terrestres de alta densidad de árboles y vida vegetal, desempeñando funciones fundamentales en la Tierra. Actúan como sumideros de carbono, absorbiendo dióxido de carbono atmosférico y mitigando el cambio climático (FAO, 2016). Además, desempeñan un papel crucial en el ciclo del agua al regular la cantidad de agua en la atmósfera a través de la evapotranspiración (Bonan, 2008). También proveen alimentos, madera, medicinas y otros productos esenciales para las comunidades locales y la economía (FAO, 2020). Asimismo, los bosques tienen un valor cultural y espiritual para diversas comunidades alrededor del mundo (Mooney et al., 2005).

#### **4.5.1. Bosques Secos**

Los bosques secos son formaciones vegetales caducifolias y delicadas que se desarrollan en duras condiciones climáticas, con precipitaciones anuales de 400-600 mm y una temperatura media de 24,9 °C (Aguirre et al., 2006). Estos bosques se encuentran en dos partes diferentes del país: la primera está en la costa del Pacífico central, que incluye las provincias de Esmeraldas, Manabí, Santa Elena y Guayas; el segundo está en la costa sur y las vertientes occidentales de Los Andes, en las provincias de El Oro y Loja (Aguirre y Geada, 2017).

La mayor parte del bosque seco se encuentra en la provincia de Loja, que se extiende entre 190 y 1100 metros sobre el nivel del mar, e incluyen tierras bajas, estribaciones occidentales bajas de la cordillera de Los Andes y valles secos interandinos en el sur. Alrededor del 20% (2 000 km<sup>2</sup>) de la provincia se compone de bosques secos, donde la precipitación media anual es de 500 mm y la temperatura varía entre 20 a 26 °C. Existe un período seco de mayo a noviembre y otro lluvioso de diciembre a abril. La mayoría de las veces, los suelos sobre los que se desarrollan son arcillosos, los mismos que en épocas de lluvia, forman lodazales y en épocas de sequía aparecen grandes grietas (Herbario Loja et al., 2001, 2003).

Ramírez y colaboradores (2018) señalan que la preservación y cuidado del bosque seco son cruciales tanto para los seres vivos que lo habitan como para la supervivencia humana. Es esencial reconocer los beneficios que este tipo de ecosistema proporciona, es decir, los servicios que la sociedad puede obtener de él. Estos servicios abarcan desde el suministro de alimentos, plantas ornamentales y materiales de construcción, hasta la regulación del clima, la calidad del agua y la prevención de la erosión del suelo. Además, incluyen aspectos culturales como ceremonias tradicionales, actividades ecoturísticas y preservación de la identidad local.



#### 4.6. Teledetección en el Análisis de Incendios Forestales

Según Emilio Chuvieco Salinero (1991), la teledetección es una técnica que consiste en la adquisición de información sobre objetos, áreas o fenómenos a través de la observación remota, utilizando sensores ubicados en plataformas aéreas o satelitales. Esta técnica permite recopilar datos sobre la superficie terrestre sin necesidad de contacto directo, lo que facilita el monitoreo de cambios ambientales, la evaluación de recursos naturales y la detección de diversos procesos, como la deforestación, la erosión del suelo o la urbanización.

La teledetección se fundamenta en la observación de objetos desde una distancia que no requiere contacto directo con ellos. Los sensores remotos pasivos se ubican en diversas plataformas y tienen la función de capturar la energía electromagnética reflejada por el sol y emitida por la superficie terrestre en distintas longitudes de onda. Estas longitudes de onda abarcan el espectro visible (0,4-0,7  $\mu\text{m}$ ), el infrarrojo cercano (0,7-1,3  $\mu\text{m}$ ), el infrarrojo medio (1,3-8  $\mu\text{m}$ ) y el infrarrojo térmico (8-14  $\mu\text{m}$ ) (Di Bella et al., 2008).

El análisis y evaluación de la susceptibilidad a incendios forestales han avanzado considerablemente gracias a la implementación de Sistemas de Información Geográfica (SIG) y métodos de teledetección. Estas herramientas tecnológicas posibilitan el estudio exhaustivo de extensas regiones, permitiendo identificar con alta precisión las áreas más propensas a sufrir incendios. La incorporación de técnicas de minería de datos y aprendizaje automático ha revolucionado este campo, permitiendo a los científicos abordar de manera más efectiva esta problemática mediante el uso de múltiples variables. Estas técnicas facilitan la creación de modelos predictivos robustos y fiables que se fundamentan en el análisis de amplias bases de datos que reflejan diversas condiciones ambientales y características del terreno, mejorando así la efectividad de los sistemas preventivos contra incendios (Reyes y Balcázar, 2021).

La calidad de las imágenes capturadas por teledetección es crucial para el éxito de estas metodologías. Investigadores como Gómez y Martín (2008) han resaltado la importancia de los índices espectrales en la interpretación adecuada de los datos satelitales. Estos índices son esenciales para convertir los datos crudos en información aplicable, mejorando significativamente la capacidad para identificar y monitorizar las áreas con alto riesgo de incendio. Este proceso incluye ajustes y calibraciones específicos que aumentan la precisión de

los sistemas de detección, permitiendo así respuestas más rápidas y eficaces frente a posibles amenazas.

Dentro de este marco, la misión Sentinel-2 de la Comisión Europea (2018) desempeña un rol fundamental. Compuesta por los satélites Sentinel-2A y Sentinel-2B, que orbitan en posiciones estratégicas, permite cubrir el planeta entero cada cinco días cuando ambos satélites están operativos, o cada diez días utilizando solo uno. Esta capacidad de resolución espacial, sin precedentes, es vital para el monitoreo continuo de los cambios en la superficie terrestre, incluyendo la detección precoz de incendios forestales (ESA, 2011). La funcionalidad multispectral de sus scanners facilita la captura de imágenes en diversas longitudes de onda, como el visible y el infrarrojo, herramientas clave para evaluar la salud vegetal y las condiciones previas a los incendios.

Asimismo, el Satélite Suomi, gestionado conjuntamente por la NASA, la NOAA y el Departamento de Defensa de los EE. UU., juega un papel vital en la vigilancia ambiental global. Desde su lanzamiento en 2011, el instrumento VIIRS incorporado ha sido esencial para la observación de la Tierra en una amplia gama de longitudes de onda, incluyendo el visible y el infrarrojo (Keck et al., 2011). Esta capacidad es invaluable para analizar fenómenos meteorológicos y cambios en la superficie terrestre, proporcionando datos cruciales no solo para la investigación de incendios forestales y la gestión de desastres, sino también para el seguimiento del cambio climático a nivel mundial.

#### **4.7. Machine Learning como herramienta para la detección y prevención de incendios forestales**

Los incendios forestales son una gran preocupación ambiental porque si no tienen una detección temprana, pueden causar daños irreversibles a los ecosistemas, la economía y la vida humana. Por lo tanto, la detección temprana de estos incendios se convierte en una herramienta crucial para combatir este problema de manera más efectiva (Cárdenas et al., 2015).

Para prevención de todos los efectos negativos causados por incendios forestales, se requiere realizar modelos de susceptibilidad a incendios forestales mediante herramientas de aprendizaje automático, para de esta manera tener un medio que ayude a la prevención de eventos de fuego en zonas con mayor probabilidad de sufrir un incendio forestal.

El uso de algoritmos de aprendizaje automático (Machine Learning) es una herramienta efectiva para la identificación de zonas de susceptibilidad a incendios forestales. Estos algoritmos como regresión logística, árboles de decisión y splines de regresión adaptativa multivariante, los cuales utilizan modelos matemáticos y estadísticos para analizar datos geoespaciales y variables ambientales con el fin de predecir áreas propensas a la ocurrencia de incendios forestales (Breiman, 2001; MacQueen, 1967; Vapnik, 1995). Los algoritmos de aprendizaje automático también pueden adaptarse a medida que se dispone de nuevos datos, lo que permite que los modelos de predicción de incendios forestales se actualicen y mejoren con el tiempo. Esto es especialmente importante dado que los patrones de incendios forestales pueden cambiar debido a factores como el cambio climático y las alteraciones en el uso del suelo (Prasad et al., 2006).

El aprendizaje automático puede ser particularmente útil en la identificación de zonas de susceptibilidad a incendios forestales debido a su capacidad para manejar grandes volúmenes de datos y descubrir patrones complejos. Los modelos de aprendizaje automático pueden incorporar una amplia gama de datos, incluyendo información climática, topográfica, de uso del suelo y de vegetación, para predecir la probabilidad de incendios forestales en diferentes áreas (Prasad et al., 2006). Además, los algoritmos de aprendizaje profundo, una subcategoría de aprendizaje automático, también se han utilizado para predecir la susceptibilidad a incendios forestales. Estos algoritmos, como las redes neuronales convolucionales, pueden analizar imágenes de satélite para identificar patrones que pueden indicar un mayor riesgo de incendios forestales (LeCun et al., 2015).

En un estudio realizado por Viegas et al. (1992), se utilizaron técnicas de aprendizaje automático para identificar áreas en Portugal que eran especialmente vulnerables a incendios forestales. El estudio logró obtener un modelo preciso para la predicción de zonas de riesgo utilizando datos de variables topográficas, climáticas y de uso del suelo. En otro estudio realizado por Chuvieco et al. (2010), se utilizaron algoritmos de aprendizaje automático para identificar áreas vulnerables a incendios forestales en la región mediterránea. El estudio creó un modelo de predicción de incendios forestales utilizando datos de teledetección, variables climáticas y de relieve. Por último, en un estudio llevado a cabo por Reyes y Loján (2022) se emplearon técnicas de aprendizaje automático para identificar las áreas vulnerables a incendios forestales en el cantón Loja-Ecuador, lo que resultó en resultados favorables.

Estos ejemplos demuestran que los algoritmos de aprendizaje automático pueden ser una herramienta útil para predecir áreas propensas a incendios forestales. Estos modelos pueden ayudar a los gestores de recursos naturales y a los equipos de prevención de incendios a tomar decisiones más informadas y a implementar medidas de mitigación de riesgos de manera más efectiva. Para hacer estos modelos más efectivos, se deben usar correctamente las variables de entrada, entre las que están los puntos de calor, índices de vegetación, topografía, accesibilidad y asentamientos humanos.

Schroeder et al. (2008) destacaron la utilidad de los puntos de calor detectados por el satélite MODIS para mapear áreas en Brasil con actividad de incendios, estableciendo una relación directa entre estos, lo que confirma la relevancia de estos datos para predecir y gestionar incendios forestales. Asimismo, Pettinari y Chuvieco (2016) exploraron cómo el NDVI puede indicar el riesgo de incendios en California, concluyendo que las regiones con vegetación en mal estado son más propensas a incendiarse, lo que resalta la importancia de monitorizar la salud vegetal para la prevención de incendios.

Otros estudios como el de Kalabokidis et al. (2015) investigaron el impacto de la topografía en la propagación de incendios en Grecia, encontrando que las áreas con pendientes abruptas y ciertas orientaciones del terreno son especialmente vulnerables, lo que subraya la necesidad de considerar estos factores en las estrategias de gestión de riesgos. También Naderpour et al. (2021) aplicaron redes neuronales profundas para evaluar el riesgo de incendios en Sydney, Australia, enfatizando cómo la accesibilidad influye significativamente en la gestión de incendios. El estudio muestra que la distancia a carreteras y zonas residenciales son indicadores clave para la prevención y respuesta ante estos fenómenos al igual que la investigación realizada por Novo et al. (2020) en Galicia, España. Estas investigaciones promueven una gestión adecuada de la vegetación a lo largo de las carreteras para mitigar el riesgo a incendios forestales.

Los estudios mencionados destacan la importancia de integrar la planificación del uso del suelo y las prácticas de gestión forestal para reducir la probabilidad de incendios, refuerzan la idea de que una combinación de tecnología avanzada y un entendimiento profundo de las variables ambientales y humanas es esencial para mejorar la prevención y gestión de incendios forestales.

#### **4.7.1. Puntos de calor**

En este contexto, un punto de calor se refiere a un lugar donde se ha observado una anomalía térmica que puede indicar la presencia de un incendio forestal. Los sensores remotos en satélites, que pueden medir la radiación infrarroja emitida por un incendio, se utilizan con frecuencia para detectar estos puntos de calor (Giglio et al., 2003). Los puntos de calor pueden usarse de varias maneras en un modelo de susceptibilidad a incendios forestales. Por ejemplo, los datos de puntos de calor históricos pueden usarse para identificar áreas que pueden ser propensas a incendios. Esto permite modelar el riesgo futuro de incendios (Schroeder et al., 2014). Es importante tener en cuenta que los puntos de calor no son perfectos, aunque son útiles, ya que pueden pasar por alto incendios demasiado pequeños o que están ocultos por el dosel del bosque. Por lo tanto, uno de los muchos factores que se utilizan en los modelos de susceptibilidad a incendios forestales es con frecuencia el punto de calor.

#### **4.7.2. Índices de vegetación**

Campbell (2011) explica que los índices de vegetación son una de las formas más comunes de evaluar y monitorear la vegetación, utilizando información satelital y multispectral. Se definen como medidas cuantitativas del valor de la biomasa o el vigor de la vegetación, que se obtienen sumando, restando o multiplicando ciertos datos espectrales que brindan información sobre el vigor de la vegetación en un pixel. Debido a que funcionan como estimadores de varios cambios en la cobertura vegetal, los indicadores permiten el monitoreo de la vegetación (Reynosa, 2016). Los índices de vegetación son variables cruciales para identificar áreas susceptibles a incendios forestales. Estos índices se calculan utilizando datos de teledetección, como imágenes satelitales y proporcionan información sobre la salud y la densidad de la vegetación en un área específica (Chuvienco et al., 2010).

El Índice de Vegetación de Diferencia Normalizada (NDVI) y el Índice de Vegetación de Quema (VBI) son algunos de los índices de vegetación más utilizados para detectar incendios forestales. Estos índices se basan en las diferencias entre la reflectancia de la vegetación en los rangos infrarrojo cercano y rojo, lo que permite evaluar su cantidad y salud (Ghorbanzadeh et al., 2019). Los índices de vegetación pueden utilizarse en los modelos de susceptibilidad a

incendios forestales para identificar áreas con una mayor densidad de vegetación, lo que indica un mayor riesgo de incendios. Además, los cambios en los índices de vegetación a lo largo del tiempo pueden indicar áreas que han experimentado sequías o estrés hídrico, lo que también puede aumentar la susceptibilidad a los incendios forestales (Riaño et al., 2003).

La Tabla 1 muestra una descripción más detallada sobre cada uno de los índices espectrales, para un mejor entendimiento de cómo es que estas variables ayudan a la identificación y predicción.

**Tabla 1.** Índices espectrales de condiciones del suelo y vegetación

Índice	Descripción	Rango	Interpretación
<b>Índice de Vegetación de la Diferencia Normalizada (NDVI)</b>	El NDVI ofrece una evaluación de la cantidad, calidad y crecimiento de la vegetación al medir la biomasa verde, la cual se calcula considerando el área foliar y el contenido de clorofila.	-1 a -0,1	Superficies con escasa cubierta vegetal
		-0,1 a 0,1	Superficies con vegetación media
		0,2 a 1	Superficies con alta cubierta vegetal
		-1 a -0,8	Suelo desnudo
<b>Índice de Diferencia Normalizada de Humedad (NDMI)</b>	El NDMI facilita la medición del contenido de agua en la vegetación, lo que permite identificar zonas que puedan estar experimentando estrés hídrico.	-0,8 a -0,6	Cubierta de dosel casi ausente
		-0,6 a -0,4	Cubierta de dosel muy baja
		-0,4 a 0	Cubierta de dosel seca
		0 a 0,2	Cubierta de dosel medio baja, bajo estrés hídrico
		0,2 a 0,4	Cubierta de dosel media alta, estrés hídrico medio
		0,4 a 0,6	Cubierta de dosel alta, sin estrés hídrico
		0,6 a 0,8	Cubierta de dosel muy alta, sin estrés hídrico
		0,8 a 1	Cubierta total de dosel, sin estrés hídrico
<b>Índice de Vegetación Atmosféricamente Resistente</b>	El ARVI es una adaptación del NDVI que corrige los efectos de dispersión atmosférica	-1 a -0,1	Cuerpos de agua
		-0,1 a 0,1	Áreas rocosas, arenosas o nieve

<b>(ARVI)</b>	observados en el espectro de reflectancia roja, utilizando datos de la longitud de onda azul.	0,2 a 0,4	Hierbas y arbustos
		0,4 a 1	Árboles
<b>Índice de Vegetación de Diferencia Normalizada verde (GNDVI)</b>	El GNDVI se emplea para medir la cantidad y el estado de salud de la vegetación en una zona específica, y es más receptivo a los cambios en la clorofila que el NDVI.	-1 a -0,2	Suelo desnudo
		-0,2 a 0,2	Vegetación moderada
		0,2 a 1	Vegetación sana
<b>Índice de Suelo Desnudo (BSI)</b>	El BSI identifica zonas con escasa vegetación, usando un indicador numérico que combina bandas espectrales azules, rojas, infrarrojas cercanas e infrarrojas de onda corta para capturar las variaciones del suelo.	-1 a 0	Vegetación arbustiva
		0 a 0,6	Vegetación herbácea
		> 0,6	Suelo desnudo
		< -0,25	Alto crecimiento de vegetación posterior al fuego
		-0,25 a -0,1	Bajo crecimiento de vegetación posterior al fuego
<b>Índice de Calcificación Normalizada (NBR)</b>	El NBR identifica áreas afectadas por incendios y supervisa la recuperación ecológica utilizando las bandas de infrarrojo cercano e infrarrojo de onda corta, las cuales son sensibles a las variaciones en la vegetación.	-0,1 a 0,1	Zonas estables o sin quemar
		0,1 a 0,27	Cubierta de dósel seca
		0,27 a 0,44	Cubierta de dósel seca
		0,44 a 0,66	Zonas quemadas con gravedad moderada-baja
		> 0,66	Zonas quemadas con gravedad alta
		< 0,2	Suelo desnudo
		0,2 a 0,8	Vegetación Sana
> 0,8	Suelo cubierto por vegetación		
<b>Índice de Humedad (Moisture)</b>	El índice de Moisture es una métrica que refleja el grado de humedad existente en el suelo y en la vegetación.	-1 a -0,3	Superficies sin agua, sequías
		-0,3 a 0	Sequía moderada
<b>Índice de Agua de Diferencia Normalizada (NDWI)</b>	El NDWI identifica y monitorea variaciones sutiles en los niveles de agua de cuerpos acuáticos, destacando estas diferencias en las imágenes satelitales,	0 a 0,2	Inundación, humedad alta
		0,2 a 1	Superficie del agua

<b>Índice de Vegetación Ajustada al Suelo (SAVI)</b>	El SAVI es un indicador de la vegetación que ajusta el NDVI para incorporar los efectos del suelo en la medición.	-1 a -0,1	Superficies con escasa cubierta vegetal
		-0,1 a 0,1	Superficies con vegetación media
		0,2 a 1	Superficies con alta cubierta vegetal

Fuentes: (De La Casa y Ovando, 2006; Gilabert, 1997; González, 2020; Reyes y Loján, 2022; Solis et al., 2021).

### 4.7.3. Topografía

La orientación de la pendiente tiene un impacto en la cantidad de radiación solar que absorbe el suelo y la vegetación. La orientación de la pendiente también influye en la velocidad del viento, lo que hace que los incendios se propaguen más rápidamente debido a la mayor velocidad del viento (Vadrevu et al., 2010). Según Burgess (2011), la pendiente es la tasa de cambio en los valores de elevación entre dos puntos específicos, expresados en grados o porcentajes. La pendiente ayuda a precalentar la cobertura vegetal. En un incendio, el fuego puede moverse rápidamente en pendientes ascendentes.

### 4.7.4. Accesibilidad y asentamientos urbanos

Según un estudio realizado en Polonia, el acceso humano a las zonas forestales aumenta significativamente el riesgo de incendios forestales. Este estudio destacó que la densidad de carreteras y la proximidad de las zonas urbanizadas a los bosques están fuertemente correlacionadas con una mayor frecuencia de incendios. Además, se encontró que casi todos los factores antropogénicos analizados, como la longitud de los límites entre los bosques y las áreas urbanizadas, tenían un impacto significativo en la densidad de los incendios forestales (Kolaneck et al., 2021).

## 4.8. Técnicas de aprendizaje automático

En el ámbito del aprendizaje automático supervisado, se comienza con un conjunto de datos que incluyen variables independientes y dependientes específicas para ciertos eventos. Estas variables independientes determinan la ocurrencia de eventos como incendios forestales y las dependientes son los resultados observados de estos eventos. Utilizando estos datos, se desarrolla un modelo predictivo que, basado en patrones aprendidos durante el entrenamiento,



puede anticipar resultados para situaciones futuras. Este enfoque es una de las varias categorías principales de técnicas de aprendizaje automático, que también incluyen el aprendizaje no supervisado y el aprendizaje basado en agentes (Cárdenas et al., 2015).

Dentro del aprendizaje basado en agentes, que se distingue de otros métodos, se simulan las acciones e interacciones de uno o más agentes autónomos. Una aplicación típica es el aprendizaje reforzado, que se emplea cuando la información sobre las variables objetivo es incompleta (Jain et al., 2020).

En cuanto al aprendizaje no supervisado, este método involucra la introducción de datos sin etiquetas al algoritmo, permitiendo que éste agrupe los datos basándose en sus propias características intrínsecas. El objetivo es que el algoritmo identifique patrones que sugieran agrupaciones lógicas, lo cual es útil para la identificación de patrones y la predicción de futuros conjuntos de datos similares (Jain et al., 2020; Sandoval, 2018; Sancho, 2020).

Finalmente, el aprendizaje supervisado implica la alimentación del modelo con datos estructurados en forma de preguntas (características) y respuestas (etiquetas). Este proceso permite construir una función predictiva que, tras el entrenamiento, pueda estimar los resultados para nuevos datos basándose en las entradas proporcionadas (Jain et al., 2020; Moncayo, 2013; Sandoval, 2018).

#### **4.8.1. Algoritmos de aprendizaje automático**

En esta investigación, se aplicaron tres algoritmos distintos: regresión logística (RL), árboles de decisión logística (LMT) y splines de regresión adaptativa multivariante (MARS). Estos métodos son ampliamente reconocidos en la literatura de aprendizaje automático aplicado a la gestión y ciencia de incendios forestales, como se detalla en el estudio "A review of machine learning applications in wildfire science and management" por Jain, P., Coogan, S. C. P., Subramanian, S. G., Crowley, M., Taylor, S., y Flannigan, M. D. (2020).

La regresión logística (RL) establece y cuantifica las relaciones entre una variable dependiente y múltiples variables independientes, ya sean continuas o categóricas. Considerada uno de los algoritmos más simples y prevalentes en el aprendizaje automático, la RL se caracteriza por su modelo lineal, optimizando su desempeño cuando los datos pueden separarse linealmente (Ibáñez, 2019). Este método ha sido utilizado para prever la ocurrencia de incendios


forestales y analizar sus factores determinantes en distintas regiones y a diversas escalas (Guo et al., 2016).

Los árboles de decisión logística (LMT) integran técnicas de árboles de decisión con regresión logística empleando el algoritmo LogitBoost. En cada nodo del árbol, se desarrolla un modelo de regresión logística a través de LogitBoost, y el ajuste del árbol se realiza utilizando el algoritmo CART (Árboles de Clasificación y Regresión). Estos modelos de árboles logísticos son conocidos por proporcionar una representación efectiva de los datos. Además, para evitar el sobreajuste, se emplea validación cruzada, lo cual es esencial para calibrar el número de iteraciones necesarias y así lograr un equilibrio óptimo entre el rendimiento del modelo y su capacidad de generalización (Landwehr, Hall, y Frank, 2005; Hastie, Tibshirani, y Friedman, 2009).

El algoritmo Splines de Regresión Adaptativa Multivariante (MARS) es una herramienta poderosa para la creación automatizada de modelos predictivos, que facilita la selección y transformación de variables, además de establecer interacciones entre ellas. Este método gestiona eficazmente los valores faltantes y emplea técnicas para prevenir el sobreajuste. MARS es especialmente eficaz para descubrir patrones y relaciones complejas que pueden ser difíciles de detectar con métodos más tradicionales. Su capacidad para modelar interacciones no lineales y complejidades dentro de los datos lo hace invaluable en el campo de la minería de datos y el análisis estadístico (Friedman, 1991). El MARS procede en dos fases: la creación de funciones base, seguida por una fase de poda que elimina funciones base menos significativas, simplificando y mejorando la interpretación del modelo final (Dobilas, 2020).

## 5. Metodología

### 5.1. Área de estudio



*Figura 1. Mapa de ubicación de Zona de estudio (Macará).*

Según Aguirre y colaboradores (2018), la provincia de Loja se distingue por su vasta extensión de bosque seco, que representa aproximadamente el 20% de su territorio, de los cuales el 14% corresponde al cantón Macará. Además, aproximadamente el 59% de la superficie de Macará está cubierta por bosque seco (Aguirre, 2013). El cantón Macará limita al norte con Zapotillo y Paltas, al sur y este con Perú, y al oeste con Zapotillo. Su área es de 599 km<sup>2</sup>, con altitudes entre 295 y 2,460 m.s.n.m., y alrededor del 80% de su superficie está bajo los 1,000 m.s.n.m., lo que promueve la existencia de ecosistemas templado, subtropical y cálido. La precipitación promedio anual varía entre 400 y 900 mm, y las temperaturas fluctúan entre 18 y 22°C (GAD Macará, 2023).

Según el GAD de Macará (2023), el ecosistema de bosque seco tropical en Macará es ecológicamente importante por su adaptabilidad a la aridez y por albergar especies endémicas, muchas en riesgo por la deforestación y la expansión agrícola. La hidrografía está representada por el río Macará y el Catamayo o Santa Rosa, que funcionan como límites internacionales y corredores ecológicos clave. Estos ríos, que se originan en las montañas ecuatorianas y fluyen hacia el Perú (donde se llaman Chira), aportan conectividad entre ecosistemas y sostienen la biodiversidad en un ambiente de limitación hídrica.

Ubicado en los Andes bajos, Macará recibe influencias climáticas del Pacífico y la Amazonía, creando un régimen climático de tipo costa. Esta combinación de ecosistemas y su ubicación estratégica en una zona de transición hacen de Macará una zona de estudio relevante. Su perfil ecológico contribuye a la comprensión de los procesos naturales y los desafíos de conservación de los bosques secos tropicales, un ecosistema vulnerable y de gran biodiversidad. La originalidad climática y el alto valor ecológico justifican la selección de esta área para investigar las dinámicas de adaptación y conservación del bosque seco en Loja (GAD Macará, 2023).

## **5.2. Herramientas de software**

En el desarrollo de este estudio se seleccionaron diversas herramientas de software tanto de escritorio como en línea, enfocadas en el análisis de datos geospaciales y estadísticos, para el estudio de áreas susceptibles a incendios forestales. La elección de estos programas responde a la necesidad de trabajar con datos complejos, asegurando un análisis preciso y una visualización detallada de información geográfica.

### **5.2.1. De escritorio**

- **QGIS 3.30.3.** - Sistema de Información Geográfica (SIG) de código abierto que funciona en diversas plataformas. Es ampliamente reconocido por su capacidad para visualizar, analizar y gestionar datos geospaciales, abarcando tanto formatos vectoriales como raster. Este software es una herramienta esencial para profesionales que trabajan con información geográfica, ofreciendo funcionalidades avanzadas y personalización a través de plugins.

- **SAGA GIS 9.2.0.** - es un SIG de código abierto que se distingue por su especialización en el análisis avanzado de terreno y el procesamiento de imágenes raster. Este software es particularmente útil para realizar estudios de geomorfología y análisis hidrológicos, proporcionando un conjunto de herramientas específicas para estos fines.
- **R 4.4.0.** – es un lenguaje de programación dedicado principalmente a la estadística y el análisis de datos, que también incluye capacidades extendidas para la manipulación y visualización de datos geoespaciales. R es altamente valorado en la comunidad científica y académica por su flexibilidad y la extensa biblioteca de paquetes disponibles para diversas aplicaciones analíticas.

### 5.2.2. Online

- **Google Earth Engine.** - es una plataforma en la nube para el análisis de imágenes satelitales a gran escala. Ofrece herramientas avanzadas para el monitoreo y análisis de cambios ambientales, haciendo posible el manejo de grandes volúmenes de datos geoespaciales de manera eficiente.
- **Geoportales y Visores Geográficos.** - cómo ArcGIS Online o OpenStreetMap, proporcionan acceso fácil a datos geoespaciales y mapas interactivos. Estas plataformas permiten a los usuarios visualizar y analizar información geográfica sin la necesidad de software especializado, facilitando así el acceso a una amplia gama de recursos y datos públicos.

## 5.3. Establecer una línea base de las variables predictivas para la determinación de la ocurrencia de incendios forestales en el cantón Macará.

### 5.3.1. Identificación de variables

Se generó una base de datos para recopilar información sobre las variables asociadas con la ocurrencia de incendios forestales, las cuales fueron seleccionadas mediante una revisión bibliográfica que respalda su relevancia en este tipo de eventos.

El primer paso en la investigación consistió en identificar las variables asociadas con el inicio de los incendios forestales en el cantón Macará. Córdova (2020) destaca que para prevenir incendios forestales es crucial considerar diversas variables vinculadas a estos eventos.

En este contexto, se han seleccionado variables topográficas e índices espectrales provenientes del satélite Sentinel 2A, junto con variables que reflejan la interacción humana con el entorno. En total, se han identificado 23 variables independientes, cuyos detalles se presentan en las Tablas 2, 3 y 4. Estas tablas se han adaptado del informe de Loján (2020), el cual describe las variables utilizadas para generar modelos de susceptibilidad a incendios e incluye fuentes para su descarga.

La Tabla 2 detalla las variables topográficas propias del terreno que fueron identificadas y recopiladas, las cuales ayudan a establecer una línea base para determinar la ocurrencia de incendios forestales. Para la obtención de estas variables, se utilizaron Modelos de Elevación Digital (DEM) de alta resolución, específicamente los datos provenientes de ALOS PALSAR. Estos modelos ofrecen información detallada y precisa para áreas específicas, lo que resulta esencial en análisis espaciales como los realizados en esta investigación.

**Tabla 2.** Variables topográficas

	<b>Variable</b>	<b>Descripción</b>	<b>Metadatos de la capa</b>
1	Elevación	Altura sobre el nivel del mar.	SRC: EPSG:32717 Resolución espacial: 10 x 10 metros Unidades: m.s.n.m.
2	Pendiente	Grado de inclinación del terreno, puede medirse en grados o porcentaje.	SRC: EPSG:32717 Resolución espacial: 10 x 10 metros Unidades: porcentaje (%)
3	Orientación	Dirección de pendiente descendente que presenta cada celda, tomando como referencia los puntos cardinales (Norte, Sur, Este, Oeste)	SRC: EPSG:32717 Resolución espacial: 10 x 10 metros Rango de valores: 0– 360 Unidades: grados (°)

*Nota:* **Elevación** se extrajo directamente del DEM; **pendiente** se calculó con la herramienta "slope", y **orientación** con la función "aspect".

La Tabla 3 detalla las variables de interacción antrópica que fueron identificadas, elaboradas y recopiladas, las cuales ayudan a establecer una línea base para determinar la ocurrencia de incendios forestales.

**Tabla 3. Variables de interacción antrópica**

Variable	Descripción	Proceso de obtención	Metadatos de la capa
4 Accesibilidad al centro económico	Facilidad para desplazarse desde cualquier lugar del cantón hasta el centro económico.	Se utiliza la herramienta GRASS `r.cost.full` para configurar los puntos objetivos. Estos puntos corresponden a una capa de centro económico que ha sido digitalizada manualmente.	SRC: EPSG:32717 Resolución espacial: 10 x 10 metros Unidades: minutos
5 Accesibilidad a áreas protegidas	Facilidad para desplazarse desde cualquier lugar del cantón hasta áreas protegidas.	Se emplea la herramienta GRASS `r.cost.full` para establecer como puntos objetivos la capa correspondiente a las áreas protegidas, la cual fue obtenida del <b>Mapa interactivo Ambiental</b> . Dentro de esta capa, se consideran diversas categorías de áreas protegidas, incluyendo:  - Sistema Nacional de Áreas Protegidas Bosque y Vegetación Protectora - Área Bajo Conservación - Patrimonio Forestal del Estado - Áreas de Protección Hídrica	SRC: EPSG:32717 Resolución espacial: 10 x 10 metros Unidades: minutos
6 Accesibilidad a zonas pobladas	Facilidad para desplazarse desde cualquier lugar del cantón hasta poblados.	Se emplea la herramienta GRASS `r.cost.full` para configurar como puntos objetivos la capa de poblados, la cual se ha descargado del portal del <b>SNI</b> .	SRC: EPSG:32717 Resolución espacial: 10 x 10 metros Unidades: minutos
7 Accesibilidad a vías	Facilidad para desplazarse desde cualquier lugar del cantón hasta vías.	Utilizando la herramienta GRASS `r.cost.full`, se establece como puntos objetivos la capa de vías que ha sido digitalizada manualmente a partir de Google Maps Satélite.	SRC: EPSG:32717 Resolución espacial: 10 x 10 metros Unidades: minutos
8 Accesibilidad a zonas antrópicas	Facilidad para desplazarse desde cualquier lugar del cantón hasta zonas pobladas o zonas agropecuarias.	Se configura la herramienta GRASS `r.cost.full` para establecer como puntos objetivos la capa de cobertura vegetal, la cual se ha obtenido del <b>Mapa interactivo Ambiental</b> .	SRC: EPSG:32717 Resolución espacial: 10 x 10 metros Unidades: minutos

9	Distancia a centros económicos	Distancia desde el centro económico.	Se emplea la herramienta GRASS `r.grow.distance` para establecer como puntos objetivos la capa de centro económico, la cual se ha descargado del portal del <b>SNI</b> .	SRC: EPSG:32717 Resolución espacial: 10 x 10 metros Unidades: metros
10	Distancia a ríos	Distancia desde ríos.	Se utiliza la herramienta GRASS `r.grow.distance` para configurar como puntos objetivos la capa de ríos, la cual fue generada a partir del Modelo de Elevación Digital (DEM).	SRC: EPSG:32717 Resolución espacial: 10 x 10 metros Unidades: metros
11	Distancia a vías	Distancia desde vías	Se configura la herramienta GRASS `r.grow.distance` para utilizar como puntos objetivos la capa de vías, que ha sido digitalizada manualmente a partir de Google Maps Satélite.	SRC: EPSG:32717 Resolución espacial: 10 x 10 metros Unidades: metros
12	Distancia a las áreas protegidas	Distancia desde áreas protegidas	Se emplea la herramienta GRASS `r.grow.distance` para configurar como puntos objetivos la capa de áreas protegidas, descargada desde el <b>Mapa interactivo Ambiental</b> . Las categorías de áreas protegidas consideradas en este análisis incluyen: <ul style="list-style-type: none"><li>- Sistema Nacional de Áreas Protegidas Bosque y Vegetación Protectora</li><li>- Área Bajo Conservación</li><li>- Patrimonio Forestal del Estado</li><li>- Áreas de Protección Hídrica</li></ul>	SRC: EPSG:32717 Resolución espacial: 10 x 10 metros Unidades: metros
13	Distancia a zonas antrópicas	Distancia desde zonas pobladas o zonas agropecuarias.	Se utiliza la herramienta GRASS `r.grow.distance` para configurar como puntos objetivos la capa que incluye zonas pobladas o zonas agropecuarias.	SRC: EPSG:32717 Resolución espacial: 10 x 10 metros Unidades: metros

*Nota:* Adaptado de “Informe de variables que se utilizan para la generación de modelos de susceptibilidad de incendios con la identificación de sus fuentes para descarga por Loján (2020).”

La Tabla 4 detalla las variables del estado de la vegetación que fueron identificadas, obtenidas de con la ayuda de Google Earth Engine (GEE) y recopiladas, las cuales ayudan a establecer una línea base para determinar la ocurrencia de incendios forestales. El proceso de



obtención para estas variables es utilizando el script de Google Earth Engine mostrado en el Anexo 2, el cual emplea imágenes Sentinel 2A.

**Tabla 4.** Variables del estado de vegetación

Variable	Descripción	Metadatos de la capa
<b><i>Atmospherically Resistant Vegetation Index</i></b>		
14	<p>ARVI</p> <p>Índice de Vegetación Resistente a la Atmósfera (ARVI), una versión modificada del NDVI para contrarrestar los efectos de dispersión atmosférica</p> $ARVI = \frac{NIR - (2 * Red) + Blue}{NIR + (2 * Red) + Blue}$ <p><b>Donde:</b>  <b>NIR</b> (Región del Infrarrojo Cercano) se asigna a la banda 8 (B8).  <b>Red</b> (Rojo del espectro visible) se asigna a la banda 11 (B11).  <b>Blue</b> (Azul del espectro visible) se asigna a la banda 2 (B2).</p>	<p>SRC: EPSG:32717</p> <p>Resolución espacial: 10 x 10 metros</p> <p>Rango de valores: -1 a 1</p>
<b><i>Bare Soil Index</i></b>		
15	<p>BSI</p> <p>Índice de Suelo Descubierta (BSI), utilizado para identificar áreas sin cobertura vegetal:</p> $BSI = \frac{(Red + SWIR) - (NIR + Blue)}{(Red + SWIR) + (NIR + Blue)}$ <p><b>Donde:</b>  <b>Red</b> (Rojo del espectro visible) corresponde a la banda 11 (B11).  <b>SWIR</b> (Infrarrojo de Onda Corta) corresponde a la banda 4 (B4).  <b>NIR</b> (Región del Infrarrojo Cercano) corresponde a la banda 8 (B8).  <b>Blue</b> (Azul del espectro visible) corresponde a la banda 2 (B2).</p>	<p>SRC: EPSG:32717</p> <p>Resolución espacial: 10 x 10 metros</p> <p>Rango de valores: -1 a 1</p>
<b><i>Green Normalized Difference Vegetation Index</i></b>		
16	<p>GNDVI</p> <p>Índice de Vegetación de Diferencia Normalizada Verde (GNDVI), una variante del NDVI que es más sensible a las variaciones en el contenido de clorofila y nitrógeno en los cultivos:</p> $GNDVI = \frac{NIR - SWIR}{NIR + SWIR}$ <p><b>Donde:</b>  <b>SWIR</b> (Infrarrojo de Onda Corta) corresponde a la banda 3 (B3).  <b>NIR</b> (Región del Infrarrojo Cercano) corresponde a la banda 8 (B8).</p>	<p>SRC: EPSG:32717</p> <p>Resolución espacial: 10 x 10 metros</p> <p>Rango de valores: -1 a 1</p>
<b><i>Moisture Stress Index</i></b>		
17	<p>MSI</p> <p>Índice de Estrés Hídrico (MSI), diseñado para evaluar el estrés hídrico en la vegetación:</p> $MSI = \frac{MidIR}{NIR}$ <p><b>Donde:</b>  <b>MidIR</b> (Infrarrojo de Onda Media) corresponde a la banda 11 (B11).  <b>NIR</b> (Región del Infrarrojo Cercano) corresponde a la banda 8 (B8).</p>	<p>SRC: EPSG:32717</p> <p>Resolución espacial: 10 x 10 metros</p> <p>Rango de valores: 0 a 3+</p>

<b>Normalized Burn Ratio</b>		
		Índice de Proporción de Quemado Normalizado (NBR), utilizado para estimar la extensión y el desarrollo de áreas afectadas por incendios:
18	NBR	$NBR = \frac{NIR - SWIR}{NIR + SWIR}$ <p style="text-align: center;"><b>Donde:</b>  <b>SWIR</b> (Infrarrojo de Onda Corta) corresponde a la banda 12 (B12).  <b>NIR</b> (Región del Infrarrojo Cercano) corresponde a la banda 8 (B8).</p>
		SRC: EPSG:32717 Resolución espacial: 10 x 10 metros Rango de valores: -1 a 1
<b>Normalized Difference Moisture Index</b>		
		Índice de Diferencia de Humedad Normalizado (NDMI), utilizado para determinar el contenido de agua en la vegetación:
19	NDMI	$NDMI = \frac{NIR - SWIR}{NIR + SWIR}$ <p style="text-align: center;"><b>Donde:</b>  <b>SWIR</b> (Infrarrojo de Onda Corta) corresponde a la banda 11 (B11).  <b>NIR</b> (Región del Infrarrojo Cercano) corresponde a la banda 8 (B8).</p>
		SRC: EPSG:32717 Resolución espacial: 10 x 10 metros Rango de valores: -1 a 1
<b>Normalized Difference Water Index</b>		
		Índice de Diferencia Normalizada del Agua (NDWI), utilizado para identificar masas de agua y zonas de elevada humedad:
20	NDWI	$NDWI = \frac{NIR - Green}{NIR + Green}$ <p style="text-align: center;"><b>Donde:</b>  <b>NIR</b> (Región del Infrarrojo Cercano) corresponde a la banda 8 (B8).  <b>Green</b> (Verde del espectro visible) corresponde a la banda 3 (B3).</p>
		SRC: EPSG:32717 Resolución espacial: 10 x 10 metros Rango de valores: -1 a 1
<b>Normalized Difference Vegetation Index</b>		
		Índice de Diferencia Normalizada de Vegetación (NDVI), que ayuda a evaluar la facilidad con la que el fuego puede propagarse en la vegetación:
21	NDVI	$NDVI = \frac{NIR - Red}{NIR + Red}$ <p style="text-align: center;"><b>Donde:</b>  <b>NIR</b> (Región del Infrarrojo Cercano) corresponde a la banda 8 (B8).  <b>Red</b> (Rojo del espectro visible) corresponde a la banda 4 (B4).</p>
		SRC: EPSG:32717 Resolución espacial: 10 x 10 metros Rango de valores: -1 a 1
<b>Soil Adjusted Vegetation Index</b>		
		Índice de Vegetación Ajustado al Suelo (SAVI), diseñado para analizar la vegetación en etapas de crecimiento inicial o cuando está dispersa:
22	SAVI	$SAVI = \frac{(NIR - Red) * (1 + L)}{(NIR + Red + L)}$ <p style="text-align: center;"><b>Donde:</b>  <b>NIR</b> (Región del Infrarrojo Cercano) corresponde a la banda 8 (B8).  <b>Red</b> (Rojo del espectro visible) corresponde a la banda 4 (B4).  <b>L</b> es el factor de corrección de la luminosidad del suelo, utilizado para minimizar la influencia del fondo del suelo en el índice.</p>
		SRC: EPSG:32717 Resolución espacial: 10 x 10 metros Rango de valores: -1 a 1

---

### Normalized Difference Moisture Index

Índice de Diferencia de Humedad Normalizado (NDMI), que se utiliza para estimar el contenido de humedad en la vegetación:

23 Moisture  $Moisture = \frac{NIR - SWIR}{NIR + SWIR}$  SRC: EPSG:32717  
Resolución espacial: 10 x 10 metros

**Donde:**

**SWIR** (Infrarrojo de Onda Corta) corresponde a la banda 11 (B11). Rango de valores: -1 a

**NIR** (Región del Infrarrojo Cercano) corresponde a la banda 8A (B8A). 1

---

*Nota:* Adaptado de “Informe de variables que se utilizan para la generación de modelos de susceptibilidad de incendios con la identificación de sus fuentes para descarga por Loja (2020).”

### 5.3.2. Recolección de datos

La recopilación de datos es un componente esencial de esta investigación. Para ello, se utilizaron y recolectaron datos de la plataforma Fire Information for Resource Management System (FIRMS) de la NASA, que emplea el satélite SUOMI y su herramienta VIIRS (Visible Infrared Imaging Radiometer Suite), especializada en la detección de puntos calientes y eventos relacionados con incendios forestales.

Se recopilaron datos de focos de calor que podrían haber sido incendios forestales, desde diciembre de 2018 hasta diciembre de 2021, abarcando el área del cantón Macará. Este rango temporal fue seleccionado debido a varias consideraciones clave. En primer lugar, la metodología base es de Reyes y Loján (2022). Por lo que se consideró adaptar esta metodología al cantón Macará, pero los datos de VIIRS se depuran utilizando imágenes de Sentinel-2A, las cuales no están disponibles antes de 2018, lo que imposibilita incluir años anteriores. En segundo lugar, no se seleccionaron años posteriores a 2021 porque en 2022 y 2023 casi no se registraron incendios, lo que habría afectado la representatividad del modelo al incluir años con baja incidencia.

El período 2018-2021 incluye los años con mayor incidencia de incendios en el área de estudio, proporcionando un conjunto de datos fijo, consistente y representativo para desarrollar y validar el modelo. Esto permite identificar patrones interanuales y estacionales relevantes, además de garantizar que los resultados puedan ser replicados y comparados con datos futuros. Así, este rango temporal constituye una base sólida para posteriores análisis y actualizaciones del modelo, evitando la influencia de datos atípicos o no representativos.

### 5.3.3. Preparación de los datos

Para la preparación de los datos, se realizó un proceso de depuración que consistió en comparar los focos de calor detectados por la herramienta VIIRS con imágenes del satélite Sentinel-2A las cuales se actualizan cada 5 días. Estas imágenes, mediante el análisis y la combinación de bandas específicas, permiten calcular el índice de vegetación NBR, utilizado para identificar zonas quemadas, así como visualizar el color natural del terreno.

Durante este análisis, se verificó si los focos de calor coincidían con áreas de alta severidad (zonas rojas) en las imágenes. La presencia de coincidencias indicaba la ocurrencia de un incendio forestal en la fecha registrada. En caso de no confirmarse un incendio, la información era descartada. Si el incendio era validado, se asignaba un punto de control cercano (a menos de 2 km de distancia) como "no incendio", asegurando así una distribución balanceada de datos (50% de ocurrencia y 50% de no ocurrencia). Este procedimiento fue fundamental para garantizar la precisión y relevancia de los datos empleados en el modelo, siguiendo la metodología propuesta por Reyes y Loján (2022).

El muestreo utilizado fue por juicio con múltiples criterios, un método no probabilístico en el que el investigador selecciona intencionadamente los elementos de la muestra con base en su conocimiento, lo que puede observar y su experiencia sobre el fenómeno (Reyes y Loján, 2022). En este caso, se priorizaron datos de focos de calor representativos de incendios forestales con un proceso de ignición claro y asociados a información sobre la Potencia Radiactiva del Fuego (FRP). Este indicador permite caracterizar la intensidad y el tamaño de los incendios a partir de la emisión de energía radiante.

La selección de los datos se centró en los focos de calor más representativos para el análisis de la susceptibilidad a incendios en el cantón Macará. Los criterios específicos empleados están descritos en la Tabla 5, ordenados según su relevancia.

**Tabla 5. Criterios para determinar incendios forestales**


<b>Criterios para determinar incendios forestales</b>	
<b>“ACQ_TIME”</b>	¿Cuál sucedió primero?
<b>“CONFIDENCE”</b>	n, l, h
<b>“FRP”</b>	FRP > 9
<b>Tonalidad</b>	Tonalidades oscuras e intensas (marrones, rojiza, naranjas, negras)

Nota: "ACQ\_TIME" (Fecha de registro del foco de calor), "CONFIDENCE" (**n**: nivel de confianza intermedio, **l**: nivel de confianza bajo y **h**: nivel de confianza alto) y "FRP" (Poder Radiativo del Fuego)

#### **5.3.4. Obtención de la capa de accesibilidad**

De acuerdo con la metodología propuesta por Reyes (2017) en el "Manual de Prácticas de Ordenación Territorial", la estimación de la superficie de fricción y la accesibilidad se detalla en la Figura 3.

Para calcular la accesibilidad al centro económico, se utilizaron varias capas obtenidas de diferentes fuentes: la cobertura vegetal y la ubicación del centro económico se extrajeron del mapa interactivo del MAATE, mientras que el centro económico también se obtuvo del Geoportal del Instituto Geográfico Militar (IGM). En cuanto a las vías, fue necesario digitalizarlas manualmente a partir de las imágenes satelitales de Google Maps. Además, se clasificaron los elementos de la capa de vías en tres categorías: vías primarias (asfaltadas), vías secundarias (de tierra) y vías terciarias (senderos), asignando a cada una el ancho correspondiente en metros.



**Figura 2.** Diagrama de flujo del proceso el cálculo de accesibilidad.

*Nota:* Obtenido del Manual de Prácticas de ordenación Territorial por Reyes (2017).

Para obtener datos sobre la accesibilidad, es fundamental calcular una superficie de fricción que asigne un coste, expresado en minutos. Según Reyes (2017) indica que es necesario establecer inicialmente la velocidad requerida para transitar cada punto del territorio, tomando

en cuenta que factores como la cobertura vegetal, la pendiente, las vías y los ríos restringen el desplazamiento. La Tabla 6 proporciona detalles sobre la asignación de tiempo para cada capa, basada en la velocidad necesaria para el movimiento. Además, se le asignó un valor de tiempo a cada una según criterio personal y según la metodología de Reyes (2017).

**Tabla 6.** Coste de movilidad según la clase de superficie. Fuente: Manual de Prácticas de ordenación Territorial.

Capa	Clase	Coste (min)
Cobertura	Área Poblada, Área sin cobertura vegetal, Infraestructura	1 200
	Cultivo anual, Cultivo semipermanente, Mosaico agropecuario, Pastizal, Plantación forestal, Vegetación herbácea	1 500
	Bosque nativo, Natural, Vegetación arbustiva	2 400
Ríos	Orden 0	1 200
	Orden 1	1 500
	Orden 2	2 000
	Orden 3	3 000
Vías	Vía primaria	80
	Vía secundaria	120
	Vía terciaria	200

*Nota:* adaptado del Manual de Prácticas de ordenación Territorial por Reyes (2017).

### 5.3.5. Extracción de información de las variables

De las 23 variables en la base de datos, 13 son permanentes (variables de interacción antrópica y variables topográficas) y 10 son actualizables porque reflejan cambios en la cobertura vegetal a lo largo del tiempo (variables de estado vegetal), por lo que su tratamiento de datos es diferente. Para generar la base de datos, utilizamos el software libre QGIS v.3.30.3 con su complemento “Point Sampling Tool”, que nos permite seleccionar puntos de interés en un mapa y extraer información asociada a esos puntos de muestreo, como valores de atributos o características, que en este caso específico son los focos de calor que identificamos como incendios forestales en formato shape. Se extrajo información de las variables alrededor de los

focos de calor y se creará una base de datos en formato shape para exportarla en formato csv. La figura 4 muestra este proceso a través de un diagrama de flujo.




Figura 3. Proceso para la generación de la base de datos. Adaptado de Reyes y Córdova, (2021)

### 5.3.6. Identificar las variables de importancia

Para identificar las variables de importancia que servirán para la predicción de incendios forestales en el cantón Macará, se llevó a cabo un análisis estadístico en el software 'R Studio' lo cual consta de 2 segmentos, lo cual mostrará como resultado las variables de mayor importancia (Figura 4). Lo primero fue un análisis de correlación para asegurarse de que las variables sean independientes, ya que es fundamental que las variables identificadores y predictores de incendios no estén correlacionados (Reyes y Loján, 2022). Este proceso nos permite identificar las variables que tienen la menor relación mutua. Y el segundo segmento según Reyes y Loján (2022) consistió en un test de multicolinealidad llamado Factor de Inflación de Varianza (VIF), donde valores mayores a 10 se eliminan porque están muy correlacionados y los valores cercanos a 1 están poco correlacionados, lo cual permitió saber el nivel de correlación existente entre las variables antes identificadas, debido que, según Rojas et al. (2023), la colinealidad entre factores disminuye la eficacia estadística del modelo, lo que puede llevar a un sobreajuste y a un incremento en la incertidumbre de los resultados.



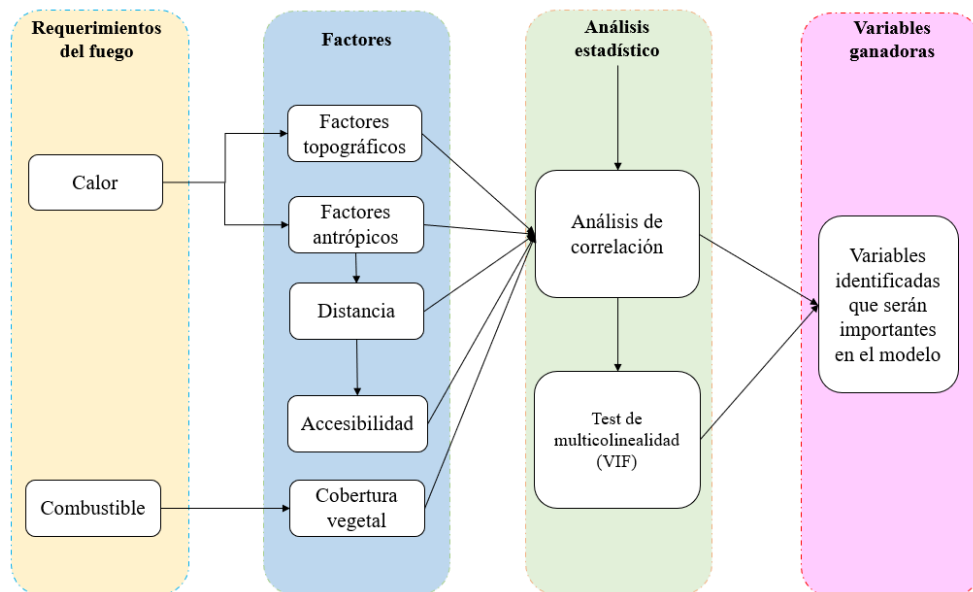
$$VIF = \frac{1}{1-R_d^2} \quad (Ec. 1)$$

Donde:

$R^2$ : es el factor determinante para la regresión de variables explicativas

d: Se refiere a todas las demás variables explicativas

Reyes y Loján (2022) explican que un valor elevado del Factor de Inflación de la Varianza (VIF) indica una mayor probabilidad de multicolinealidad. En la evaluación mediante la prueba VIF, se consideran valores superiores a 10 como indicativos de un nivel crítico de colinealidad.




*Figura 4. Identificación de las variables de importancia requeridas para la aplicación del modelo*

#### 5.4. Evaluar algoritmos de Machine Learning para la generación de un modelo de susceptibilidad a incendios forestales en el cantón Macará

Para evaluar el modelo de predicción, diseñado para identificar áreas susceptibles a incendios forestales en el cantón Macará, se desarrollaron tres etapas clave, como se muestra en la Figura 5. La primera etapa correspondió a la preparación de la base de datos, que incluyó la limpieza y análisis de datos ambientales y antrópicos, definiendo las variables críticas necesarias para el modelo, cuyo proceso de obtención ya se describió previamente. En la segunda etapa, se llevó a cabo la creación y aplicación del modelo mediante tres técnicas de

aprendizaje automático supervisado: árboles de decisión logístico (LMT), regresión logística (LR) y splines de regresión adaptativa multivariante (MARS). Finalmente, en la tercera etapa, se evaluó y validó el modelo utilizando dos indicadores principales: el área bajo la curva (AUC) de la ROC, que mide su capacidad predictiva, y la índice kappa de Cohen, que determina la sensibilidad y consistencia del modelo.



**Figura 5.** Fases para la generación del mapa de probabilidad de ocurrencia de incendios forestales en el cantón Macará. Adaptado de Reyes y Loján (2022).

#### 5.4.1. Generación y aplicación del modelo utilizando tres técnicas de aprendizaje automático supervisado

Según la metodología de Reyes (2017), los modelos se desarrollaron utilizando tres algoritmos de aprendizaje automático supervisado ampliamente empleados en minería de datos y predicción:

- **Regresión logística (RL)** es una técnica estadística que se usa para predecir si algo va a pasar o no, como un “sí” o “no”. En este contexto es un “sí” podría

haber un incendio o “no” podría haber un incendio, representado con 1 y 0 respectivamente (Ecuación 2).

$$\mathit{logit}(P_i) = \ln\left(\frac{P_i}{1-P_i}\right) = \alpha_0 + \alpha_1 x_1 + \alpha_2 x_2 + \dots + \alpha_n x_n \quad (\text{Ec. 2})$$

en donde  $p$  es la probabilidad de ocurrencia de incendios forestales,  $n$  es el número de covariables,  $(\alpha_1, \alpha_2, \dots, \alpha_n)$  son los coeficientes para cada variable y  $(x_1, x_2, \dots, x_n)$

- **Splines de regresión adaptativa multivariante (MARS)** es una técnica que construye relaciones de manera flexible entre variables usando “splines”, que son como segmentos de líneas curvas que se ajustan a los datos y es útil cuando los datos no siguen una sola forma fija y hay muchos factores que influyen en el resultado (Ecuación 3).

$$y_t = f(x_t) = \beta_0 + \sum_{i=1}^k \beta_i B(x_{it}) \quad (\text{Ec. 3})$$

donde  $y_t$  es la variable respuesta en el instante  $t$  y  $\beta_i$  son los parámetros del modelo para las respectivas variables  $x_{it}$ , que van de  $i = 1, \dots, k$ . El valor  $\beta_0$  representa al intercepto, las funciones bases  $B(x_{it})$  son funciones que dependen de las respectivas variables  $x_{it}$ , en donde cada  $B(x_{it})$  puede escribirse como  $B(x_{it}) = \max(0, x_{it} - c)$  o  $B(x_{it}) = \max(0, c - x_{it})$ ,  $c$  es un valor umbral y  $k$  representa el número de explicativas, que incluye interacciones de las variables predictoras

- **Árboles de decisión logística (LMT)** son un conjunto de preguntas y respuestas para tomar una decisión, donde cada rama representa una pregunta sobre los datos, y cada respuesta nos lleva a una nueva pregunta o directamente a una predicción. Al final, obtenemos una decisión o predicción. En cada rama del árbol la ecuación básica se expresa generalmente mediante la regresión logística. La regresión logística tiene la siguiente ecuación

El proceso se ejecutó en RStudio utilizando el paquete "caret", posteriormente se divide la base de datos en un 75% para entrenamiento y un 25% para validación del modelo (Reyes y Loján, 2022). Esta proporción fue seleccionada de esta manera, porque permite un equilibrio adecuado entre el tamaño del conjunto de entrenamiento, necesario para que el

modelo aprenda de manera efectiva, y el conjunto de validación, que evalúa su desempeño. En el análisis del 75% de los datos se observa el funcionamiento del modelo en función de la información proporcionada.

Los paquetes "weka" y "earth" se utilizaron para implementar LMT y MARS respectivamente, con LMT ajustado mediante validación cruzada y MARS empleando poda "backward" y un grado de interacción específicos. Además, se utilizó la función "varImp" del paquete "caret" para evaluar la importancia de las variables y la función "predict" para generar un ráster con las predicciones de los modelos. Los resultados se reclasificaron en cinco clases de probabilidad de incendios, según la Tabla 7, y se visualizaron en formato (.tif).

**Tabla 7.** Clases para la reclasificación de la probabilidad de ocurrencia de incendios

Probabilidad	Clase	Interpretación de probabilidad
$X \leq 0,2$	1	Muy baja
$0,2 > X \leq 0,4$	2	Baja
$0,4 > X \leq 0,6$	3	Media
$0,6 > X \leq 0,8$	4	Alta
$X > 0,8$	5	Muy alta

*Nota:* Adaptado de "Assessment of Three Machine Learning Techniques with Open-Access Geographic Data for Forest Fire Susceptibility Monitoring-Evidence from Southern Ecuador" por Reyes y Loján (2022).

#### 5.4.2. Evaluación y validación del rendimiento del modelo mediante dos indicadores

Una vez identificada la técnica de aprendizaje automático supervisado más adecuada para los datos, se proporciona al modelo el segundo conjunto de datos, correspondiente al 25% restante, que se destina a la validación. Esto permite evaluar el rendimiento del modelo y generar el mapa de susceptibilidad basado en las métricas de evaluación. Independientemente del algoritmo o técnica utilizada, todos los modelos serán evaluados utilizando dos herramientas clave: el Área Bajo la Curva (AUC) y el Coeficiente Kappa de Cohen.

Por medio de estas dos métricas de evaluación, vamos a determinar que técnica de aprendizaje es el que mejor se adaptó a nuestros datos en base a si los resultados de las métricas son las óptimas, el cual se lo va a escoger para nuestro modelo de predicción.

- **Área Bajo la Curva**

La curva ROC permite evaluar la capacidad del modelo entrenado para clasificar información (Cerdea y Cifuentes, 2012). Este mide la relación entre la sensibilidad, también conocida como "tasa de verdaderos positivos", y la especificidad, también conocida como "tasa de falsos positivos", lo que permite visualizar el desempeño del modelo en diferentes umbrales de clasificación y es especialmente útil para comparar la precisión de diferentes modelos (Hern et al., 2019).

$$\text{Sensibilidad} = \frac{VP}{VP+FN} \quad (\text{Ec. 4})$$

Donde:

VP = verdaderos positivos

FN = falsos negativos

$$\text{Especificidad} = \frac{VN}{FP+VN} \quad (\text{Ec. 5})$$

Donde:

VN = verdaderos negativos

FP = falsos positivos

El área bajo la curva (AUC) de la curva ROC es un indicador que determina la confiabilidad de un modelo, señalando la probabilidad de que dicho modelo realice predicciones correctas (Hern et al., 2019). Generalmente, se considera que valores superiores a 0.70 representan buenos predictores, reflejando la habilidad del modelo para distinguir entre clases positivas y negativas. En la Tabla 8, se presentan los valores para interpretar el AUC

**Tabla 8.** Valores de precisión del modelo de acuerdo con el AUC

Valor de AUC	Nivel de precisión
0,50 – 0,60	Insuficiente
0,60 - 0,70	Pobre
0,70 – 0,80	Regular
0,80 – 0,90	Bueno
0,90 – 1,00	Excelente

Fuente: Hern, E. R., Lemus, D. F., y Pineda, W. D. (2019).

- **Coefficiente de Kappa de Cohen**

El coeficiente Kappa, también conocido como índice de Kappa, es un método estadístico que estima la concordancia entre dos observadores o herramientas de medición para el mismo fenómeno (Galparsoro y Pita, 2010). Su objetivo es ajustar el efecto del azar en la proporción de la concordancia esperada, tal como establece la ecuación 4.

$$Kappa = \frac{P_0 - P_e}{1 - P_e} \quad (Ec. 6)$$

Donde:

$P_0$  = proporción de concordancia observada

$P_e$  = proporción de concordancia esperada por el azar

Se utilizó la interpretación cualitativa más conocida para evaluar la concordancia de variables categóricas, especialmente aquellas con salida dicotómica o binaria (como en el presente estudio). Los valores menores a 0,40 indican una concordancia pobre o débil; los valores entre 0,41 y 0,6 indican una concordancia moderada; los valores entre 0,61 y 0,8 indican una concordancia buena o significativa; y los valores superiores a 0,80 tienen un nivel de conformidad casi perfecto (Landa et al., 2014).

El índice de Kappa se calculó utilizando la matriz de confusión (Tabla 9), la cual facilita la evaluación del desempeño de un algoritmo y la correspondencia con las clases reales de los datos, típicamente en contextos de aprendizaje. Las filas de la matriz representan las instancias de una clase según la predicción, mientras que las columnas muestran las instancias según su clasificación real (o, al contrario). Este índice es útil porque permite identificar fácilmente si el modelo está confundiendo dos clases, es decir, si frecuentemente etiqueta una clase incorrectamente como otra. En contextos de clasificación binaria, donde solo existen dos posibles resultados, esta matriz se emplea para medir la eficacia del modelo (Paredes, 2020).

**Tabla 9.** Matriz de confusión.

	Realmente es positivo (0)	Realmente es negativo (1)
Predicho como positivo (0)	Verdaderos Positivos (VP)	Falsos Positivos (FP)
Predicho como negativo (1)	Falsos Negativos (FN)	Verdaderos Negativos (VN)

*Nota:* Obtenido de *Data Science con R. Análisis de datos y algoritmos de predicción* por Paredes (2020).

### **5.5. Automatización del modelo de susceptibilidad a incendios forestales para mapeo de zonas de riesgo a incendios forestales en el cantón Macará**

Se utiliza la plataforma Google Earth Engine (GEE) para automatizar el modelo y generar visores web, que en este caso evalúa la susceptibilidad a incendios forestales en el cantón Macará, para lo cual se debe describir el código del modelo generado anteriormente. El código debe incluir la importación de los datos usados, el procesamiento y análisis de los mismos. Una vez escrito el código, se procede a ejecutar el script. Esto iniciará el procesamiento de los datos y se generarán los resultados.

Para visualizar los resultados del modelo, se pueden utilizar diversas herramientas de visualización disponibles, las cuales permiten analizar los resultados del modelo y observar las áreas con mayor riesgo de incendios forestales en base a un rango de susceptibilidad. Estas herramientas permiten analizar los resultados obtenidos y observar las áreas con mayor riesgo de incendios forestales. Es importante destacar que el modelo utiliza imágenes satelitales proporcionadas por el satélite "Sentinel 2" para generar los resultados.

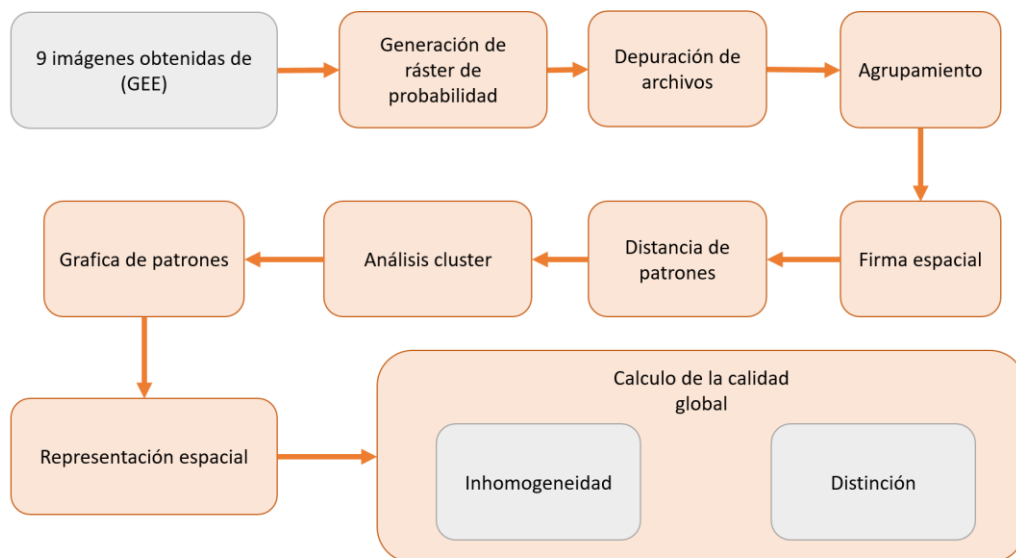
Una vez generados los resultados, se pueden representar en forma de mapas temáticos utilizando Google Earth Engine. Estos mapas se actualizan automáticamente cada 5 días, lo que garantiza que la información esté siempre actualizada. Esta frecuencia de actualización permite una interpretación visual clara y precisa de las zonas identificadas como más propensas a la ocurrencia y propagación de incendios forestales.

Además, se automatiza la ejecución del modelo para que el usuario pueda seleccionar los intervalos de tiempo en los que desea observar las predicciones de incendios forestales. Esto brinda flexibilidad al usuario y le permite acceder a la información relevante según sus necesidades.

Es importante destacar que el modelo no solo se limita a realizar predicciones, sino que también puede proporcionar información valiosa sobre la importancia relativa de cada variable en la predicción. Esto permite comprender qué factores son más influyentes en la ocurrencia de incendios forestales y puede ayudar en la toma de decisiones para la prevención y gestión de incendios. Además, el modelo puede ser actualizado y mejorado continuamente a medida que se disponga de nuevos datos, lo que permite una mayor precisión y capacidad predictiva a lo largo del tiempo.

### 5.5.1. Mapeo de zonas de riesgo a incendios forestales

En este estudio, luego de la automatización, se evaluó el riesgo de incendios forestales utilizando técnicas de clustering para identificar patrones espaciales y temporales en los datos, proceso que se ilustra en la Figura 6.



**Figura 6.** Análisis espaciotemporal para la automatización del riesgo de incendios



Utilizando un modelo de probabilidad adaptado (en el punto 3.4. se identifica que modelo se adapta mejor) a los datos obtenidos, se generaron imágenes mensuales de incendios reclasificadas desde enero hasta diciembre de 2020 en la plataforma Google Earth Engine (GEE). Durante este proceso, se sustituyeron los valores afectados por la presencia de nubes con valores nulos, utilizando el software QGIS.

A partir del código de automatización, se realizaron modificaciones para calcular las firmas espectrales a partir de un mosaico compuesto por nueve imágenes ráster de probabilidad de ocurrencia. Estas imágenes fueron generadas en Google Earth Engine (GEE) para el periodo de enero a diciembre de 2020, utilizando el modelo MARS. Para luego en el análisis de clúster, ordenar cronológicamente las imágenes y agruparlas utilizando el paquete "motif" (Nowosad, 2021) en R.

La calidad global de la agrupación se evaluó mediante la fórmula de la Ecuación 5, basada en la inhomogeneidad y la distinción. La inhomogeneidad mide la variabilidad entre los objetos dentro de un clúster, con valores cercanos a 0 indicando mayor homogeneidad. La distinción, por su parte, mide la distancia promedio entre un clúster y los restantes, con valores próximos a 1 señalando una mayor diferenciación. Así, la calidad global del clúster mejora a medida que el valor se aproxima a 1 (Nowosad, 2021).

$$\mathbf{Calidad\ global} = 1 - \left( \frac{\mathit{inhomogeneidad}}{\mathit{distinción}} \right) \quad (\mathit{Ec. 7})$$

Para visualizar los resultados del modelo, se pueden utilizar diversas herramientas de visualización disponibles, las cuales permiten analizar los resultados del modelo y observar las áreas con mayor riesgo de incendios forestales en base a un rango de susceptibilidad. Estas herramientas permiten analizar los resultados obtenidos y observar las áreas con mayor riesgo de incendios forestales. Es importante destacar que el modelo utiliza imágenes satelitales proporcionadas por el satélite "Sentinel 2" para generar los resultados.

Una vez generados los resultados, se pueden representar en forma de mapas temáticos utilizando Google Earth Engine. Estos mapas se actualizan automáticamente cada 5 días, lo que garantiza que la información esté siempre actualizada. Esta frecuencia de actualización permite una interpretación visual clara y precisa de las zonas identificadas como más propensas a la ocurrencia y propagación de incendios forestales.

Además, se automatiza la ejecución del modelo para que el usuario pueda seleccionar los intervalos de tiempo en los que desea observar las predicciones de incendios forestales. Esto brinda flexibilidad al usuario y le permite acceder a la información relevante según sus necesidades.

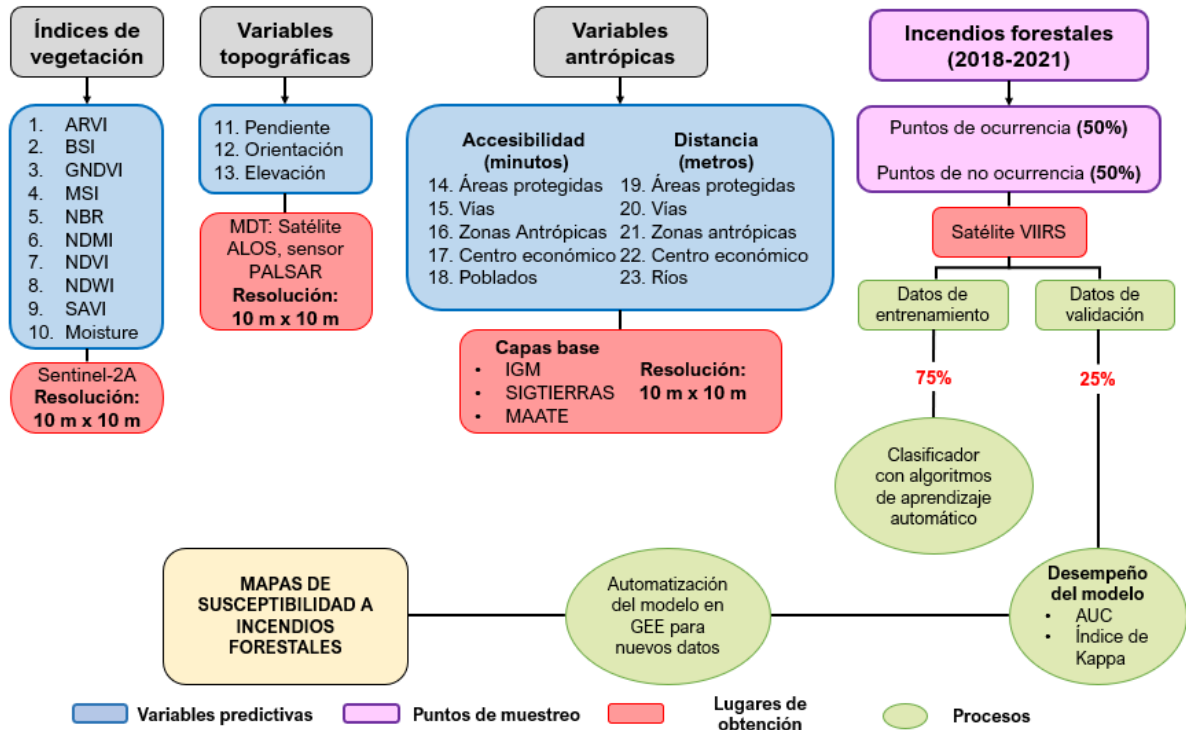
Es importante destacar que el modelo no solo se limita a realizar predicciones, sino que también puede proporcionar información valiosa sobre la importancia relativa de cada variable en la predicción. Esto permite comprender qué factores son más influyentes en la ocurrencia de incendios forestales y puede ayudar en la toma de decisiones para la prevención y gestión de incendios. Además, el modelo puede ser actualizado y mejorado continuamente a medida que se disponga de nuevos datos, lo que permite una mayor precisión y capacidad predictiva a lo largo del tiempo.

Para la presentación de los resultados, se pueden emplear herramientas de visualización que facilitan el análisis de los datos generados por el modelo y permiten identificar las zonas con mayor susceptibilidad a incendios forestales, como se muestra en la Figura 7. Adicionalmente, el modelo ofrece la flexibilidad de ser actualizado y perfeccionado de manera continua con la incorporación de nuevos datos, lo que mejora su precisión y eficacia predictiva a lo largo del tiempo. Estas predicciones son fundamentales para la toma de decisiones conscientes y la planificación de estrategias preventivas futuras.

<b>GRADO DE SUSCEPTIBILIDAD</b>			
	<b>RANGO</b>	<b>CATEGORIA</b>	<b>DESCRIPCIÓN</b>
	0 a 0.20	<b>Muy baja</b>	Escasa o nula probabilidad de ocurrencia de incendios forestales.
	0.20 a 0.40	<b>Baja</b>	Incendios forestales pueden ocurrir bajo comportamiento natural anómalo muy puntual.
	0.40 a 0.60	<b>Media</b>	Ocurrencia de incendios forestales responde la ciclicidad normal de convergencia de variables naturales asociadas.
	0.60 a 0.80	<b>Alta</b>	Todas las condiciones estáticas necesarias para la ocurrencia de incendios forestales.
	0.80 a 1	<b>Muy alta</b>	Todas las condiciones estáticas necesarias para la ocurrencia de incendios forestales. Procesos de ignición latentes.
		<b>Sin datos</b>	Zonas con alta nubosidad. Información satelital no disponible.

*Figura 7. Rangos de susceptibilidad a incendios forestales.*

En la Figura 8 se explica a detalle y un resumen del proceso para la generación de los modelos de susceptibilidad a incendios forestales. Estas predicciones se visualizan en Google Earth Engine, proporcionando una herramienta valiosa para la gestión de riesgos de incendios forestales.



**Figura 8.** Proceso para la generación de los modelos de susceptibilidad. Adaptado del Manual de aplicación susceptibilidad a incendios forestales. Caso: Cantón Loja por Reyes (2021).

## **6. Resultados**

### **6.1. Línea base de las variables predictivas para la determinación de la ocurrencia de incendios forestales en el cantón Macará.**

#### **6.1.1. Elaboración y recolección de variables**


Se definieron, recopilaron y analizaron las variables detalladas en la sección de identificación de variables, las cuales son cruciales para el análisis y predicción de incendios forestales. A continuación, se presentan exhaustivamente todas las variables identificadas, destacando su relevancia y utilidad en el contexto de la predicción y comprensión de la dinámica de los incendios forestales. En la Figura 9, se ilustran específicamente las variables topográficas del cantón Macará, incluyendo aspectos como la elevación, la pendiente y la orientación del terreno. Estas variables son fundamentales, ya que proporcionan una comprensión detallada del terreno que puede influir significativamente en la propagación y el riesgo de incendios forestales.

La mayor parte del territorio del cantón Macará se encuentra entre 240 y 1,150 metros sobre el nivel del mar (74% del área total), lo que indica que estas elevaciones predominan en la región y pueden influir directamente en la susceptibilidad a incendios. Las áreas de menor altitud (240-720 m.s.n.m.) y media altitud (720-1,150 m.s.n.m.) suelen ser más secas y cálidas, condiciones que favorecen la propagación del fuego y aumentan el riesgo de incendios. Además, estas zonas son más accesibles, lo que facilita la intervención y el control de incendios en caso de ocurrencia. En contraste, las elevaciones más altas, que representan solo el 7,61% del área, suelen tener mayor humedad y temperaturas más bajas, factores que reducen la probabilidad de incendios, pero presentan desafíos logísticos en caso de intervención, debido a la topografía escarpada.

La distribución de la orientación del terreno en Macará es bastante uniforme, con cada rango de orientación representando aproximadamente una cuarta parte del área total. En esta región ecuatorial, las orientaciones entre 190° y 360° (que representan el 56,74% del área total) están expuestas a la radiación solar directa durante las horas de la tarde, cuando las temperaturas alcanzan su punto máximo y la humedad disminuye significativamente. Esta exposición prolongada al sol incrementa la temperatura del suelo y reduce la humedad de la vegetación,

factores que pueden aumentar la susceptibilidad a incendios. En cambio, las orientaciones opuestas (entre 0° y 180°) suelen recibir menor incidencia solar en las horas de mayor calor, lo que disminuye el riesgo de inflamabilidad. Dado el clima cálido y seco predominante en Macará, las áreas orientadas al suroeste y oeste presentan un riesgo mayor de incendios debido a las condiciones de calor y aridez intensificadas por la exposición solar directa.


La pendiente del terreno varía significativamente en el cantón Macará, afectando directamente la susceptibilidad a incendios forestales. Las pendientes pronunciadas (30% - 75%), que cubren el 14,16% del área, incrementan el riesgo de propagación rápida del fuego, ya que este tiende a moverse más velozmente cuesta arriba debido al pre-calentamiento de la vegetación en las pendientes superiores. Además, estas áreas escarpadas presentan dificultades logísticas para el acceso y control del fuego, lo que complica las labores de contención. En contraste, las áreas con pendientes más suaves (0% - 15%) son más accesibles y facilitan la implementación de medidas preventivas y de control. Estas zonas planas o de baja pendiente, que representan un mayor porcentaje del territorio, pueden ser prioritarias en la gestión de riesgos y el establecimiento de cortafuegos debido a la facilidad de acceso y manejo.



**Figura 9.** Variables topográficas

En la Figura 10 se presentan las variables de interacción antrópica, enfocadas específicamente en las variables de accesibilidad. cruciales para una respuesta rápida y efectiva en situaciones de incendio forestal. Pero, por otro lado, la proximidad a áreas con marcada actividad antrópica, también puede aumentar la probabilidad de incendios debido a la mayor actividad humana y el uso de recursos naturales. En el caso de accesibilidad a centros económicos, se detectó que el 38,36% del territorio (áreas en azul) tiene una mejor capacidad de respuesta en caso de incendios, permitiendo un acceso rápido a recursos y personal, mientras que el 9,30% (áreas en rojo) presenta una mayor dificultad para acceder a los sitios, lo que complica las intervenciones. En términos de accesibilidad a poblados, el 43,15% del territorio (áreas en azul) facilita una rápida movilización de ayuda, mientras que el 8,09% (áreas en rojo) es menos accesible, dificultando la respuesta rápida. Respecto a las zonas antrópicas, el 62,92% del área dentro de los 10 minutos de acceso puede recibir respuestas extremadamente rápidas, mientras que el 5,21% (áreas en rojo) presenta desafíos logísticos significativos para la movilización de cuerpos de emergencia.

El acceso a áreas protegidas en menos de 40 minutos abarca el 75,79% del territorio, favoreciendo una intervención eficaz, mientras que el 7,40% (áreas en rojo) presenta desafíos en la coordinación de emergencias debido al mayor tiempo de acceso. Finalmente, el 46,94% del territorio tiene acceso a vías en un rango de 0 a 15 minutos, optimizando el despliegue rápido de recursos, mientras que el 8,66% (áreas en rojo) enfrenta mayores desafíos para la llegada de ayuda debido al tiempo requerido entre 60 y 125 minutos.




**Figura 10.** Variables de interacción antrópica (Accesibilidad)

En la Figura 11 se muestran las variables de interacción antrópica relacionadas con las distancias (metros), las cuales son cruciales para determinar áreas de alto riesgo. antropogénica. En el caso de distancia a centros económicos se determinó que el 33,44% del territorio, representado en verde, está muy cerca de centros económicos, optimizando el acceso a recursos como el personal de emergencias, mientras que el 8,22% del territorio, en rojo, puede enfrentar retrasos significativos en la respuesta debido a la distancia. Además, el 68,84% del territorio (representado en verde), está a menos distancia de zonas antrópicas, facilitando una rápida intervención, mientras que las áreas en rojo, que comprenden solo el 2,09%, presentan mayores desafíos logísticos para la movilización de recursos y personal.

Asimismo, el 52,02% del territorio, en verde, está cercano a vías principales, lo que facilita el acceso rápido para controlar incendios, mientras que el 4,22% en rojo enfrenta desafíos en la respuesta rápida. Casi la mitad del territorio (45,97%), en verde, está cerca de

áreas protegidas, mientras que el 4,89% en rojo podría tener más flexibilidad en las operaciones de control. Finalmente, un 38,69% del territorio, en verde, está extremadamente cerca de ríos, facilitando el acceso a recursos hídricos esenciales para combatir incendios, mientras que el 8,65% en rojo puede tener dificultades para obtener agua rápidamente.



**Figura 11.** Variables de interacción antrópica (Distancias)


En la Figura 12 se presentan las variables del estado de la vegetación, evaluadas a través de índices espectrales. Estos índices son herramientas esenciales para evaluar la salud y el estrés de la vegetación, proporcionando información crítica sobre la densidad de la vegetación, la humedad del suelo y la presencia de materia vegetal seca. Estos factores influyen significativamente en la inflamabilidad de un área. A continuación, se analiza cada uno de estos índices:

Se determinó que el Índice de Estrés Hídrico (MSI) muestra que las áreas en azul oscuro tienen mayor estrés hídrico, indicando vegetación más seca y susceptible a incendios, mientras



que las zonas en verde tienen menor estrés y vegetación más saludable. El Índice de Vegetación de Diferencia Normalizada (NDVI) identifica regiones con alta biomasa, con áreas en azul indicando mayor densidad de vegetación, y zonas en amarillo y verde mostrando menor densidad. El Índice de Relación de Normalización (NBR) revela que las regiones en marrón oscuro tienen mayor severidad de quemado, y las áreas en amarillo son menos afectadas por incendios recientes. El Índice de Agua de Diferencia Normalizada (NDWI) muestra áreas en verde claro con mayor disponibilidad de agua, reduciendo la inflamabilidad, mientras que las áreas en blanco tienen menor contenido de agua.


Además, el Índice de Vegetación de Diferencia Normalizada de Verde (GNDVI) indica que las áreas en rojo tienen mayor contenido de clorofila y vegetación más saludable, mientras que las zonas en azul tienen vegetación menos densa. El Índice de Suelo de Diferencia Normalizada (BSI) muestra áreas en naranja oscuro con mayor presencia de suelo expuesto, aumentando el riesgo de erosión y disminuyendo la humedad del suelo. El Índice de Humedad de Diferencia Normalizada (NDMI) evalúa la humedad del suelo, con áreas en marrón indicando suelos más secos y áreas en blanco suelos más húmedos. El Índice de Humedad (Moisture) indica que las áreas en azul oscuro tienen mayor humedad, mientras que las áreas en azul claro tienen menor humedad, aumentando la susceptibilidad al fuego. El Índice de Vegetación Ajustado al Suelo (SAVI) muestra que las áreas en rojo oscuro tienen alta densidad de vegetación, y las áreas en rosa claro menor densidad. Finalmente, el Índice de Vegetación de Relación Ajustada (ARVI) corrige efectos atmosféricos, con áreas en azul oscuro indicando vegetación más densa y saludable, y áreas en azul claro sugiriendo vegetación menos densa.



*Figura 12. Variables de estado de la vegetación (Índices espectrales)*

### 6.1.2. Recolección y preparación de datos

Se obtuvieron 46 focos de calor identificados como incendios forestales, a cada uno de ellos se les agrego un punto de control, el cual no es un incendio cercano junto con su respectiva fecha de ocurrencia. Esto se hizo con el fin de garantizar el correcto funcionamiento del modelo para identificar qué zonas son propensas a incendios y cuáles no.




*Figura 13. Puntos de calor depurados con su respectivo punto de control*

### 6.1.3. Extracción de los datos

Los resultados obtenidos fueron compilados y presentados en una base de datos en formato (.csv), facilitando la visualización y el posterior análisis de los datos. La base de datos se muestra en el Anexo 1.

### 6.1.4. Identificación de las variables de importancia

Las variables que mostraron menor correlación y, por lo tanto, son consideradas como independientes fueron la Distancia a zonas antrópicas, la Distancia a ríos y Moisture, que se presentan en la Figura 14



**Figura 14.** Variables de importancia para predicción de incendios forestales

Para respaldar el análisis de multicolinealidad, se aplicó el Factor de Inflación de Varianza (VIF) para verificar numéricamente que las variables no presentan colinealidad. Los valores de VIF de las variables de importancia se presentan en la Tabla 10. Estos valores muestran que todas las variables tienen un VIF cercano a 1, lo que indica que no hay problemas significativos de colinealidad entre ellas.

**Tabla 10.** Factor de Inflación de la Varianza de cada variable de importancia

Variabes	VIF
Distancia a zonas antrópicas	1,056
Distancia a ríos	1,000
Moisture	1,056

## 6.2. Evaluación de algoritmos de Machine Learning para la generación de un modelo de susceptibilidad a incendios forestales en el cantón Macará

Después de identificar las variables importantes, se desarrolló un modelo de susceptibilidad utilizando distintas técnicas de aprendizaje automático. Para el método MARS, se empleó la función "earth"; para la Regresión Logística, se utilizó "glm"; y para los Árboles de Decisión Logística, se aplicó "rpart". Los resultados obtenidos se presentan en la Tabla 11,

que indican que la técnica MARS es la más adecuada para este modelo debido a su mayor adaptabilidad y representatividad.


Para considerar que los modelos son adecuados, se evaluaron varios indicadores de rendimiento, como el Área bajo la curva (AUC), Precisión, Índice Kappa, Sensibilidad y Especificidad. En general, un AUC superior a 0,8, una Precisión superior a 0,85, y un Índice Kappa superior a 0,7 son indicativos de un buen rendimiento del modelo. Los resultados de la Tabla 11 muestran que MARS supera estos umbrales, especialmente en el set de validación, con un AUC de 0,975, Precisión de 0,954 y un Índice Kappa de 0,909. Por estas razones, se seleccionó el modelo MARS por su destacada capacidad para representar adecuadamente los datos analizados.

**Tabla 11.** Rendimiento de los modelos RL, MARS y LTM

Variables	Set de entrenamiento			Set de validación		
	RL	MARS	LMT	RL	MARS	LMT
Área bajo la curva (AUC)	0,822	0,905	0,645	0,787	0,975	0,535
Precisión	0,857	0,885	0,085	0,863	0,954	0,318
Índice Kappa	0,714	0,771	-0,828	0,727	0,909	-0,363
Sensibilidad	0,828	0,800	0,005	0,818	0,909	0,363
Especificidad	0,885	0,971	0,114	0,909	1,000	0,272

*Nota:* Los análisis se realizaron utilizando el comando AUC, que es parte del paquete pROC, y el comando confusionMatrix, incluido en el paquete caret.

En la Figura 15, se exhiben los datos clasificados correcta e incorrectamente en los sets de entrenamiento y validación de los modelos empleados. Donde el modelo MARS fue el más preciso y eficiente, con una alta precisión tanto en el set de entrenamiento como en el de validación, superando a los modelos de Regresión Logística y Árboles de Decisión Logística. En el set de entrenamiento, MARS mostró 62 clasificaciones correctas con solo 8 errores, y en el set de validación, 21 aciertos con solo 1 error. En comparación, la Regresión Logística tuvo un rendimiento ligeramente inferior, con 60 aciertos y 10 errores en el entrenamiento, y 19 aciertos y 3 errores en la validación. Los Árboles de Decisión mostraron un rendimiento significativamente menor, con solo 6 aciertos y 64 errores en el entrenamiento, mejorando ligeramente en la validación con 7 aciertos y 15 errores. El Gráfico 15 resume estos resultados, destacando la superioridad del modelo MARS en términos de precisión y capacidad de generalización.



**Figura 15.** Número de datos clasificados correctamente (aciertos) o incorrectamente (errores)


En cada modelo implementado, las variables de importancia desempeñan roles de diferente magnitud en cuanto a su contribución a los resultados del modelo. la Tabla 12 muestra que la influencia de cada variable varía significativamente entre los diferentes modelos de aprendizaje automático utilizados. En particular, en cada uno de los modelos empleados, la variable Moisture fue más importante, seguida de distancia a zonas antrópicas y por último distancia a ríos. Es importante destacar que, según el soporte de minitab (s.f.), el modelo MARS mide la importancia de variables en porcentajes, mientras que RL y LMT no tienen un rango específico, solo se cuantifica de mayor a menor importancia de acuerdo a una escala numérica infinita

**Tabla 12.** Importancia de las variables en los modelos empleados

Variable	RL	MARS	LMT
Moisture	1,71	100%	7,615
Distancia a zonas antrópicas	1,04	43,20%	5,133
Distancia a ríos	0,23	19,51%	0,942

Basándose en los resultados obtenidos, se procedió a la espacialización de los modelos, los que se muestran en la Figura 16. Esta representación gráfica que facilita la comprensión de la susceptibilidad a incendios forestales, tal como se predice mediante cada uno de los modelos empleados. Aunque los tres modelos identifican áreas propensas a incendios y parecen

adaptarse adecuadamente a los datos, proporcionando resultados prometedores, es crucial destacar las diferencias en términos de fiabilidad y adaptación estadística. Desde un enfoque estadístico, el modelo MARS sobresale por su capacidad superior de ajuste a los datos, como se evidencia por su Área Bajo la Curva (AUC) significativamente mayor en el set de validación (0,975), comparado con la Regresión Logística (0,787) y los Árboles de Decisión (0,535).



*Figura 16. Espacialización de los modelos empleados*

### **6.3. Automatización del modelo de susceptibilidad a incendios forestales para mapeo de zonas de riesgo a incendios forestales en el cantón Macará**

Una vez obtenidos los resultados de los modelos utilizados y determinado cuál se adapta mejor y es más fiable (en este caso es MARS), se procede a automatizar este modelo en la plataforma Google Earth Engine. A través de un [script](#), esta automatización permite al usuario visualizar la susceptibilidad a incendios forestales para cualquier fecha de interés en el cantón Macará, tal y como se muestra en la Figura 17 la que es un ejemplo de cómo se visualiza la susceptibilidad.





Figura 17. Automatización del modelo en Google Earth Engine

### 6.3.1. Mapeo de zonas de riesgo a incendios forestales

En la Figura 18 se presentan las 9 imágenes obtenidas del año 2020 con su respectiva susceptibilidad a incendios forestales, calculada mediante el modelo MARS para cada época del año. Además, el número de agrupamientos se definió en cinco clases sin tomar en cuenta las áreas sin datos, ya que estas áreas presentan nubosidad. Esto permite una buena separación entre los datos, facilitando un análisis más claro y preciso de la susceptibilidad a incendios forestales a lo largo del año.





**Figura 18.** Zonificación del riesgo de incendios forestales basada en un análisis espacio-temporal para el cantón Macará durante el periodo de enero a diciembre de 2020.

La Tabla 13 muestra la susceptibilidad a incendios forestales en diferentes periodos del año. Se observa que, de febrero a julio, las áreas con muy baja susceptibilidad a incendios abarcan un promedio significativo del territorio, con un 80,64% en febrero-marzo, 93,92% en marzo-mayo, 89,44% en mayo-junio, y 71,83% en junio-julio. Esto sugiere que, durante estos meses, caracterizados por condiciones de mayor humedad y menores temperaturas debido a la temporada lluviosa, la probabilidad de incendios es considerablemente baja.

Sin embargo, en la segunda mitad del año, de junio a diciembre, la susceptibilidad a incendios forestales aumenta significativamente. Este incremento coincide con la llegada de la temporada seca, cuando la vegetación se encuentra más seca y las temperaturas elevadas contribuyen a condiciones favorables para la ignición y propagación del fuego. En junio-julio, las áreas con alta susceptibilidad alcanzan el 6,61% y las de muy alta, el 12,14%, aumentando de manera continua hasta alcanzar su punto máximo en noviembre-diciembre, con un 14,03% en alta y un 38,95% en muy alta susceptibilidad.

Estas variaciones estacionales en la susceptibilidad destacan la importancia de adaptar las estrategias de manejo y prevención de incendios a las condiciones climáticas. Durante los meses de mayor susceptibilidad, es crucial implementar medidas preventivas más estrictas, como patrullajes de monitoreo, programas de reducción de material combustible, y campañas de sensibilización a la población para minimizar el riesgo de incendios. La planificación de recursos debe considerar estos picos de susceptibilidad, destinando más personal y equipamiento a las áreas y periodos de alto riesgo.


*Tabla 13. Porcentajes de susceptibilidad de acuerdo al periodo del año*

<b>ENE - FEB</b>		<b>FEB - MAR</b>		<b>MAR - MAY</b>	
<b>Susceptibilidad</b>	<b>% Área</b>	<b>Susceptibilidad</b>	<b>% Área</b>	<b>Susceptibilidad</b>	<b>% Área</b>
Sin Datos	3,37	Sin Datos	7,40	Sin Datos	2,36
Muy Baja	55,15	Muy Baja	80,64	Muy Baja	93,92
Baja	6,12	Baja	1,28	Baja	0,43
Media	5,44	Media	1,04	Media	0,34
Alta	8,91	Alta	2,43	Alta	0,66
Muy Alta	21,02	Muy Alta	7,21	Muy Alta	2,29
<b>MAY - JUN</b>		<b>JUN - JUL</b>		<b>JUL - SEP</b>	
<b>Susceptibilidad</b>	<b>% Área</b>	<b>Susceptibilidad</b>	<b>% Área</b>	<b>Susceptibilidad</b>	<b>% Área</b>
Sin Datos	0,12	Sin Datos	0,17	Sin Datos	0,12
Muy Baja	89,44	Muy Baja	71,83	Muy Baja	45,55
Baja	2,16	Baja	5,12	Baja	8,41
Media	1,63	Media	4,13	Media	7,54
Alta	2,57	Alta	6,61	Alta	11,98
Muy Alta	4,08	Muy Alta	12,14	Muy Alta	26,40
<b>SEP - OCT</b>		<b>OCT - NOV</b>		<b>NOV - DIC</b>	
<b>Susceptibilidad</b>	<b>% Área</b>	<b>Susceptibilidad</b>	<b>% Área</b>	<b>Susceptibilidad</b>	<b>% Área</b>
Sin Datos	0,28	Sin Datos	0,29	Sin Datos	1,21
Muy Baja	32,19	Muy Baja	31,37	Muy Baja	29,23
Baja	8,77	Baja	8,75	Baja	8,37
Media	8,50	Media	8,52	Media	8,20
Alta	14,04	Alta	13,83	Alta	14,03
Muy Alta	36,22	Muy Alta	37,23	Muy Alta	38,95

### **6.3.1.1. Zonas susceptibles a incendios forestales**

En la Figura 19 se puede apreciar el resultado de la evaluación de la calidad global, que integra las métricas de inhomogeneidad y distinción. Los resultados indican que la inhomogeneidad de los clústeres fue baja, con valores de 0,116 a 0,368; lo que sugiere que los objetos dentro de cada clúster son similares entre sí, reflejando un agrupamiento consistente y bien definido. A nivel de incendios, esto significa que las áreas dentro de cada clúster tienen características comunes en cuanto a su susceptibilidad a incendios, lo que permite identificar zonas homogéneas con un riesgo similar. Por otro lado, la distinción mostró valores de 0,405 a 0,567; lo que implica una clara diferenciación entre los clústeres. Esto es crucial a nivel de incendios, ya que permite distinguir con precisión las áreas con diferentes niveles de susceptibilidad. En términos prácticos, esto significa que se pueden identificar y priorizar las zonas más propensas a incendios para implementar medidas de prevención y respuesta más efectivas.

En conjunto, estos factores contribuyen a una calidad global del clúster con valores que oscilan entre 0,269 y 0,775. Estos resultados indican una estructura de clústeres eficaz. Valores cercanos a 0,269 indican una calidad de agrupamiento moderada. Aunque los clústeres muestran cierta similitud interna y diferenciación externa, hay margen para mejorar la cohesión dentro de los clústeres y la separación entre ellos. Y valores cercanos a 0,775 indican una calidad de agrupamiento muy buena. Esto significa que los clústeres son internamente muy homogéneos (los píxeles dentro de un mismo clúster son muy similares entre sí) y externamente bien diferenciados (los clústeres son claramente distintos unos de otros).



**Figura 19.** Mapeo de la calidad global, inhomogeneidad y distinción del análisis clúster para la zonificación del riesgo de incendios forestales

La Figura 20 muestra de manera detallada la zonificación y el mapeo de áreas propensas a sufrir un evento de fuego forestal en el cantón Macará. Este mapa podría ser una herramienta valiosa tanto para el cuerpo de bomberos como para la comunidad en general, permitiendo identificar y priorizar las zonas que requieren mayor vigilancia y precaución. La representación gráfica facilita la comprensión de las áreas más vulnerables y contribuye a la planificación de estrategias de respuesta y prevención eficaces. A continuación, se analizan los resultados de los clústeres identificados:

- **Clúster de Muy Baja Susceptibilidad (1):** Este clúster con 18,42% del total del territorio representa zonas con muy baja susceptibilidad a incendios forestales. Las zonas en azul en el mapa indican áreas donde las condiciones ambientales y la vegetación no favorecen la ocurrencia de incendios. Estas áreas requieren una vigilancia mínima en comparación con las zonas de mayor riesgo.
- **Clúster de Baja Susceptibilidad (2):** El 25,25% del total del territorio, son las áreas con baja susceptibilidad están representadas en verde. Estas regiones tienen un riesgo ligeramente mayor que las de muy baja susceptibilidad, pero aún presentan condiciones relativamente seguras. Es importante mantener una vigilancia moderada en estas áreas para prevenir la propagación de incendios.
- **Clúster de Susceptibilidad Media (3):** Las zonas de susceptibilidad media, mostradas en amarillo, las cuales abarcan un 26,27% del territorio, representan áreas con un riesgo intermedio de incendios forestales. Estas regiones tienen una combinación de condiciones ambientales y vegetación que pueden favorecer la ocurrencia de incendios bajo ciertas circunstancias. Se recomienda una vigilancia y preparación activa en estas áreas.
- **Clúster de Alta Susceptibilidad (4):** Un 11,27% son las áreas con alta susceptibilidad, indicadas en naranja, son regiones donde las condiciones son favorables para la ocurrencia de incendios forestales. Estas áreas requieren una vigilancia intensiva y estrategias de prevención robustas para minimizar el riesgo de incendios.
- **Clúster de Muy Alta Susceptibilidad (5):** Las zonas de muy alta susceptibilidad, mostradas en rojo abarcan un 18,79% del territorio, y son las más vulnerables a incendios forestales. Estas regiones presentan las condiciones más favorables para la propagación de incendios y requieren una vigilancia continua, recursos de respuesta rápida y medidas preventivas rigurosas para mitigar el riesgo.




Figura 20. Zonificación y mapeo de áreas propensas a incendiarse, mediante técnicas de clustering

## 7. Discusión

Según los estudios de Reyes y Loján (2022) y Pausas (2020), para la realización de una línea base de variables predictivas de incendios forestales, se debe tener en cuenta que los incendios forestales son causados por factores como la topografía, la actividad antrópica, el clima de la zona, y el estado de la vegetación. Estos elementos son esenciales para determinar qué variables incluir en el presente estudio. La revisión del estudio de Díaz García (2015) confirma que los incendios forestales son provocados por una variedad de factores como lo son la topografía del terreno, incluyendo aspectos naturales como las condiciones climáticas y la actividad antrópica relacionada a la quema para actividades agrícolas y pecuarias. No obstante, se destaca que las variables meteorológicas, como la temperatura, la humedad relativa, la velocidad y dirección del viento, y las precipitaciones, desempeñan un papel crucial en la predicción y comportamiento de los incendios forestales (Cortez y Morais, 2007). Estas variables son fundamentales para los modelos de probabilidad de incendios forestales, con estudios que demuestran que pueden representar hasta un 60 % de relevancia en estos eventos, sin desestimar las variables de interacción antrópica (Muñoz et al., 2005).

En el contexto de Ecuador, el acceso a información meteorológica de alta resolución y actualizada de manera constante es limitado y, en muchos casos, costoso. Además, los datos disponibles suelen estar a escalas amplias y se actualizan semanal o mensualmente, lo que debilita los modelos predictivos en lugar de fortalecerlos. En varios estudios, se ha demostrado que el acceso a variables meteorológicas es fundamental debido a la amplia disponibilidad y fácil acceso a datos espaciales en muchos países, lo que facilita su integración en modelos predictivos (Rojas et al., 2023).

Existen varias plataformas en línea que ofrecen información meteorológica, aunque predominantemente a escalas amplias y como promedios semanales o mensuales. Tal es el caso de la colección ERA5-Land, que proporciona datos mensuales de temperatura, precipitación, presión atmosférica y velocidad del viento a una resolución de 1,11 km por pixel (Muñoz et al., 2021). Por otro lado, el conjunto de datos TerraClimate proporciona una gama más amplia de variables, incluyendo evapotranspiración real y potencial, déficit hídrico, humedad del suelo, precipitación acumulada y temperaturas máximas y mínimas mensuales a nivel mundial; sin

embargo, su resolución está limitada a una escala de 2,5 km por pixel (Abatzoglou et al., 2018), siendo esta, de menos resolución que la colección ERA5-Land.

Dada esta limitación en el acceso a datos meteorológicos de alta resolución y su costo, en el presente estudio se consideraron los índices espectrales como indicadores de condiciones climáticas (De La Casa y Ovando, 2006; Gómez y Martín, 2008). Los índices espectrales, son aquellos que combinan dos o más bandas del espectro electromagnético y permiten evaluar la condición de la vegetación o del suelo de manera más detallada (Tran et al., 2022). Estos índices facilitan la obtención precisa y eficiente de la distribución espacial de la estructura de la vegetación (Ovando et al., 2021). Por esta razón, en el presente estudio se optó por no utilizar variables meteorológicas y, en su lugar, se emplearon diversos índices espectrales para sustituir variables como la humedad y la temperatura del suelo, entre otras.

Además de las limitaciones mencionadas, la nubosidad impone restricciones adicionales, como indican Reyes y Loján (2022). En presencia de nubes, es imposible extraer datos sobre el estado de la vegetación, dado que el satélite Sentinel-2A no puede penetrar la cobertura nubosa, lo que resulta en una pérdida significativa de información crucial para los estudios. Por esta razón, Gao et al. (2021) recomiendan el uso de imágenes de radar, como las proporcionadas por Sentinel-1, que sí pueden penetrar las nubes y, por lo tanto, complementar o reconstruir la información faltante en las imágenes ópticas de Sentinel-2. Sin embargo, debido a la falta de información sobre cómo utilizar Sentinel-1 para la predicción de incendios, esta sugerencia no se ha implementado.

Las limitaciones mencionadas subrayan la necesidad de investigaciones futuras que exploren métodos alternativos y más eficaces para la obtención y uso de datos en modelos predictivos de incendios forestales. Una de las direcciones futuras podría incluir el desarrollo de técnicas para integrar efectivamente datos de Sentinel-1 con Sentinel-2, compensando las limitaciones impuestas por la nubosidad. Además, se sugiere trabajar en colaboración con instituciones que puedan proporcionar acceso a datos de mayor resolución a costos reducidos, o desarrollar algoritmos que optimicen el uso de datos disponibles de menor resolución. Estas estrategias podrían mejorar significativamente la capacidad de los modelos predictivos en Ecuador y similares contextos geográficos de Macará.



En el presente estudio, se consideraron los focos de calor obtenidos del Visible Infrared Imaging Radiometer Suite (VIIRS) según el enfoque metodológico de Reyes y Loján (2022). Esta elección metodológica se debe a las ventajas que ofrece VIIRS en comparación con MODIS, ya que según Xiong y Butler (2020), VIIRS permite detectar y mapear incendios forestales con mayor precisión y detalle, proporciona datos con mayor frecuencia y ofrece una mejor calidad de datos gracias a su mayor sensibilidad y calibración, lo que permite detectar incendios más pequeños y menos intensos. En contraste, investigaciones previas, como las de Wang et al. (2007), Giglio et al. (2016), Parto et al. (2020) y Schiks et al. (2024), utilizaron datos de incendios del Moderate Resolution Imaging Spectrometer (MODIS), sugiriendo que aunque MODIS ha sido una herramienta valiosa en esos estudios, en el presente estudio VIIRS presenta mejoras significativas en la precisión y calidad de los datos obtenidos.

En cuanto a las variables de importancia identificadas en el presente estudio según el análisis de multicolinealidad, se destacaron el índice de humedad (Moisture), la distancia a zonas antrópicas y la distancia a ríos. Estas variables también fueron empleadas en el estudio de Kalantar y colaboradores (2020), así como en la investigación de Reyes y Loján (2022) sobre el monitoreo de la susceptibilidad a incendios forestales en el cantón Loja. Cabe mencionar que, en los estudios previamente mencionados, además de las variables de importancia identificadas en el presente trabajo, también se consideraron otras variables relevantes. Esto resalta que no todos los estudios sobre la susceptibilidad a incendios forestales utilizan las mismas variables, ya que cada investigación es única y los resultados dependen específicamente de los datos y características de la zona de estudio. En consecuencia, la elección de las variables y los resultados obtenidos variarán según el contexto y las particularidades del área investigada.

Es importante mencionar que, si bien las características del ecosistema de bosque seco no afectan directamente la predicción de incendios o la selección de variables, sí proporcionan un contexto específico que ayuda a interpretar los resultados del modelo y a identificar las variables que podrían ser relevantes en áreas con condiciones similares. En el caso del cantón Macará, la humedad de la vegetación es una variable crítica, medida por el índice de Moisture, debido a la sequedad característica de la vegetación en este entorno. Además, la proximidad a zonas antrópicas es otra variable significativa, ya que la actividad humana en áreas cercanas influye en la ocurrencia de incendios forestales. Por último, la distancia a ríos se considera

relevante debido a que, en caso de incendios, la cercanía a estos cuerpos de agua podría facilitar su mitigación.

Para el Factor de Inflación de la Varianza (VIF) se tuvo en cuenta la metodología de Reyes y Loján (2022), además de la revisión de los trabajos de Liao y Valliant (2012) y Shrestha (2020). Estos trabajos establecen que en una escala de 1 a 10, los valores cercanos a 1 representan menor multicolinealidad, mientras que los valores cercanos a 10 indican una mayor correlación entre las variables. En este estudio, los resultados obtenidos en la presente investigación mostraron que las variables de importancia presentan una baja o nula correlación, dado que los valores de VIF están muy próximos a 1.

La selección de variables con bajos valores de VIF es crucial para la construcción del modelo de susceptibilidad a incendios forestales, ya que garantiza que cada variable aporte información única y significativa, reduciendo la redundancia y mejorando la interpretabilidad del modelo (Kalantar et al., 2020). Esto es particularmente importante en el contexto del cantón Macará, donde la precisión del modelo depende de la clara distinción y la influencia independiente de cada variable sobre la probabilidad de incendios.

Además, la baja multicolinealidad indicada por los valores de VIF cercanos a 1 sugiere que el modelo desarrollado es más estable y confiable. En el contexto específico del cantón Macará, donde la vegetación y las condiciones climáticas pueden variar significativamente, un modelo con esta característica es esencial para predecir con precisión las zonas de mayor riesgo de incendios forestales. La interpretación de estos resultados apunta a un modelo robusto que puede ser crucial para las estrategias de manejo y prevención de incendios en la región (Reyes y Loján (2022).

El modelo Multivariate Adaptive Regression Splines (MARS) mostró los mejores resultados en comparación con la regresión logística y los árboles de decisión logística, alcanzando un AUC de 0,905 en la fase de entrenamiento y 0,975 en la fase de validación. Estos valores indican que el modelo MARS tiene una capacidad excepcional para discriminar entre ocurrencias y no ocurrencias de incendios forestales. Un AUC de 0,975 en la fase de validación sugiere que el modelo MARS tiene una alta precisión y fiabilidad en la predicción de incendios

forestales, tal y como lo menciona Bui y colaboradores (2019), los cuales obtuvieron resultados similares, siendo MARS el modelo que mejor se adaptó en su estudio.

Por otro lado, el modelo que mostró peor rendimiento fue el de árboles de decisión logística, con valores de AUC de 0,645 en el conjunto de entrenamiento y 0,535 en el de validación, lo que indica que no es capaz de discriminar eficazmente entre ocurrencias y no ocurrencias de incendios forestales en este contexto. Estos resultados pueden deberse a las condiciones y variables específicas del conjunto de datos utilizados en este estudio, así como a las particularidades de la zona de estudio en Macará. En comparación, el trabajo de Jalilian y Jouibary (2023) obtuvo un mejor desempeño con árboles de decisión logística frente a MARS, lo que sugiere que el rendimiento de estos modelos puede variar considerablemente en función del contexto y de las características de los datos, como el tipo de vegetación, las variables climáticas o la estructura geográfica.

Según Schnell (2020), los resultados obtenidos en este estudio revelan un desempeño excelente del modelo MARS, con el índice de Kappa mostrando valores de 0,771 y 0,909 para el set de entrenamiento y el de validación, respectivamente. Un valor de Kappa superior a 0,75 indica una excelente concordancia entre las predicciones del modelo y los resultados observados, lo que refuerza la fiabilidad y precisión del modelo MARS en la predicción de incendios forestales. El índice Kappa es una medida robusta de la concordancia que ajusta el acuerdo observado por el acuerdo esperado por azar, proporcionando así una evaluación más precisa que el simple porcentaje de acuerdo. Valores de Kappa entre 0,61 y 0,80 se consideran sustanciales, mientras que valores superiores a 0,81 se consideran casi perfectos (Landis y Koch, 1977).

MARS, con su capacidad para modelar interacciones complejas y no lineales entre variables, parece ser especialmente adecuado para capturar las dinámicas de incendios en una región con estas variaciones. La regresión logística y los árboles de decisión, aunque útiles en otros artículos como los de Joshi y Dhakal (2021); y Mugridge y Wang, en el presente estudio no alcanzaron la misma precisión en este entorno particular, posiblemente debido a su menor flexibilidad para adaptarse a las heterogeneidades locales, o no se adaptaron a las condiciones específicas del territorio, mostrando así que no todos los estudios van a ser iguales.

El Plan de Desarrollo y Ordenamiento Territorial (PDOT) de Macará detalla varios años en los que se registraron incendios forestales en el cantón. Estos eventos suelen ocurrir principalmente durante los meses de mayor calor y sequedad, típicamente en verano, cuando las condiciones climáticas favorecen la propagación del fuego debido a la vegetación seca. Este patrón coincide con la zonificación del riesgo de incendios forestales basada en un análisis espacio-temporal, que muestra un aumento de áreas con alta susceptibilidad a incendios forestales de junio a diciembre. Durante este período, se presenta la temporada seca y con ello mayores temperaturas, incrementando el riesgo de incendios.

El estudio de Lavrukhin et al. (2023) y Nowosad (2021) menciona que la inhomogeneidad mide el grado de diferencia entre todos los objetos en un clúster, con valores entre 0 y 1. Un valor bajo indica homogeneidad, sugiriendo que los objetos son similares entre sí. En este estudio, los valores de inhomogeneidad oscilaron entre 0,116 y 0,368, reflejando una buena calidad de agrupamiento. Esto significa que las áreas dentro de cada clúster tienen características comunes en cuanto a su susceptibilidad a incendios, permitiendo identificar zonas homogéneas con un riesgo similar.

Por otro lado, Zucarelli (2021) y Nowosad (2021) destacan que la distinción en el contexto de clustering se refiere a la medida en que los clústeres formados por un algoritmo son diferentes entre sí, por lo que una alta distinción indicaría que los clústeres son claramente separables y que los elementos dentro de cada uno son similares, diferenciándose significativamente de los elementos de otros clústeres. Además, mencionan que este valor varía entre 0 y 1, donde un valor alto implica una clara separación entre los clústeres. En el presente estudio, los valores de distinción obtenidos varían de 0,405 a 0,567, lo que sugiere una clara diferenciación entre los clústeres. En el contexto de incendios forestales, según Reyes y Loján (2022), esto significa que las áreas dentro de cada clúster tienen características comunes en cuanto a su susceptibilidad a incendios, permitiendo identificar zonas homogéneas con un riesgo similar.

Las métricas de distinción e inhomogeneidad, cuando se consideran conjuntamente, determinan la calidad global del clustering. Los valores obtenidos en este estudio varían entre 0,269 y 0,775, lo que según Nowosad (2021) indica una estructura de clústeres eficaz, ya que,

estas métricas proporcionan una medida de la coherencia interna dentro de los clústeres y la separación entre ellos, sugiriendo que los elementos dentro de un mismo clúster son muy similares entre sí, y externamente bien diferenciados, significando que los clústeres son claramente distintos unos de otros, es decir indica una calidad de agrupación buena.

El análisis de la susceptibilidad a incendios forestales en el cantón Macará revela una complejidad significativa en la gestión del riesgo debido a la variabilidad en las condiciones ambientales y la vegetación. El clúster de Muy Baja Susceptibilidad identifica áreas donde las condiciones no favorecen la ocurrencia de incendios, lo que implica una necesidad mínima de vigilancia. En contraste, el clúster de Muy Alta Susceptibilidad requiere una vigilancia continua y recursos de respuesta rápida debido a las condiciones extremadamente favorables para la propagación de incendios forestales.

Históricamente, el cantón Macará ha enfrentado numerosos incendios forestales. Según informes de la Secretaría Nacional de Gestión de Riesgos, la provincia de Loja, que incluye a Macará, ha registrado múltiples emergencias por incendios forestales. En el año 2020, se reportaron más de 100 incendios forestales en diferentes cantones de Loja, incluyendo Macará, afectando cientos de hectáreas. Estos incendios han sido en su mayoría causados por la actividad humana, como las quemas agrícolas que se salen de control debido a los fuertes vientos y condiciones secas. Por lo que es importante tener en cuenta el mapa de la zonificación de incendios forestales, ya que el mismo indica las zonas a tener en cuenta.

## 8. Conclusiones

Se identificaron las variables predictivas clave para desarrollar modelos de predicción de incendios forestales en el cantón Macará. La selección se basó en su relación directa con la ocurrencia de incendios y su baja colinealidad, confirmada mediante el Factor de Inflación de la Varianza (VIF). Entre estas variables destacan la distancia a zonas antrópicas y a ríos, debido a su influencia en la probabilidad de ignición, y la humedad, cuya disminución o ausencia favorece la propagación del fuego en ecosistemas de bosque seco. Estas variables proporcionan una base sólida y confiable para el modelo predictivo.

Se evaluaron tres algoritmos de aprendizaje automático: regresión logística, árboles de decisión logística (LMT) y splines de regresión adaptativa multivariante (MARS). Aunque la regresión logística destacó por su sencillez y capacidad de interpretar relaciones lineales, su desempeño fue limitado frente a la complejidad no lineal de los incendios forestales en Macará. Por su parte, el modelo LMT presentó menor precisión y capacidad de discriminación que MARS, con valores de AUC inferiores. En contraste, MARS demostró ser el algoritmo más efectivo, logrando un AUC y un índice Kappa excelentes (entre 0,9 y 1) en la validación. Su capacidad para manejar interacciones no lineales complejas lo posiciona como el modelo más adecuado para predecir la susceptibilidad a incendios en esta región.

La implementación de MARS en Google Earth Engine automatizó la generación de mapas de susceptibilidad a incendios, actualizándose cada cinco días gracias a los índices espectrales utilizados. La validez de los datos se corroboró mediante la comparación con registros históricos del Sistema Nacional Descentralizado de Gestión de Riesgos (SNDGR). Este modelo no solo facilita la visualización de zonas de riesgo, sino que también respalda la planificación de estrategias preventivas y de mitigación. Como resultado, se cumplió el objetivo de desarrollar un modelo automatizado que identifica zonas vulnerables, proporcionando a las autoridades una herramienta clave para mejorar la gestión y respuesta ante incendios en el cantón Macará.

## 9. Recomendaciones

Utilizar imágenes del satélite Sentinel 2A en la investigación y monitoreo de incendios forestales a menudo se complica por la obstrucción de nubes. En este estudio, se enfrentó el reto de eliminar información valiosa debido a la nubosidad, para de este modo mantener la precisión de los análisis. Dado este obstáculo, se recomienda adoptar por metodologías que permitan un análisis completo sin eliminar datos importantes. En este contexto, el uso de Sentinel-1 es altamente beneficioso. Su tecnología de radar de apertura sintética (SAR) captura imágenes sin interferencias de nubosidad, a diferencia de los métodos ópticos tradicionales, lo que mejora la fiabilidad y profundidad de los estudios sobre incendios forestales.

A medida que este estudio avanzó, se realizó una revisión de la literatura que incluyó diversos métodos de Machine Learning. Aunque en la presente investigación no se aplicaron todos estos modelos, principalmente debido a falta de tiempo y un conocimiento limitado sobre las variadas técnicas disponibles, se recomienda explorar otros modelos de Machine Learning en futuras investigaciones. Esta exploración es crucial, ya que no se puede determinar con certeza si otros modelos podrían ofrecer un rendimiento superior o inferior específicamente para el cantón Macará y sus variables únicas.

## 10. Bibliografía

- Abatzoglou, J. T., Dobrowski, S. Z., Parks, S. A., & Hegewisch, K. C. (2018). TerraClimate: Monthly Climate and Climatic Water Balance for Global Terrestrial Surfaces, University of Idaho.
- Agama, V. (2016). Los Incendios Forestales Vulneran los Derechos de la Naturaleza en el Distrito Metropolitano de Quito, en la Parroquia de Puembo en el año 2015 [Tesis tercer nivel, Universidad Central del Ecuador]. Repositorio institucional de la Universidad Central del Ecuador. <http://www.dspace.uce.edu.ec/bitstream/25000/7391/1/T-UCE-0013-Ab-347.pdf>
- Agama, V. (2016). Los Incendios Forestales Vulneran los Derechos de la Naturaleza en el Distrito Metropolitano de Quito, en la Parroquia de Puembo en el año 2015 [Tesis tercer nivel, Universidad Central del Ecuador]. Repositorio institucional de la Universidad Central del Ecuador. <http://www.dspace.uce.edu.ec/bitstream/25000/7391/1/T-UCE-0013-Ab-347.pdf>
- Aguirre Padilla, N., Alvarado Espejo, J., y Granda Pardo, J. (2018). Bienes y servicios ecosistémicos de los bosques secos de la provincia de Loja. *Bosques Latitud Cero*, 119.
- Aguirre Mendoza, Z. (2013). Estructura del bosque seco de la provincia de Loja y sus productos forestales no maderables: Caso de estudio Macará (Doctoral dissertation, Universidad de Pinar del Río " Hermanos Saíz Montes de Oca". Facultad Forestal y Agronomía. Departamento Forestal).
- Aguirre, Z., Kvist, L. P., y Sánchez, O. (2006). Bosques secos en Ecuador y su diversidad. *Botánica económica de los Andes Centrales*, 2006, 162-187.
- Aguirre, Z., y Delgado, T. (2005). Vegetación de los bosques secos de Cerro Negro-Cazaderos, Occidente de la Provincia de Loja. *Biodiversidad en los bosques secos de la zona de Cerro Negro-Cazaderos, occidente de la provincia de Loja: un reporte de las evaluaciones ecológicas y socioeconómicas rápidas*, 9-24.
- Aguirre-Mendoza, Z. y L. Kvist. 2009. Composición florística y estructura de bosques estacionalmente secos en el sur-occidental de Ecuador, provincia de Loja, municipios de Macara y Zapotillo. *Arnaldoa* 16(2): 87 – 99. ISSN: 1815-8242
- Aguirre-Mendoza, Z., y Geda-Lopez, G. (2017). Estado de conservación de los bosques secos de la provincia de Loja, Ecuador. *Arnaldoa*, 24(1), 207-228.
- Aguirre-Mendoza, Z.; E. Cueva; B. Merino; W. Quizhpe y A. Valverde. 2001. Evaluación ecológica rápida de la vegetación en los bosques secos de La Ceiba y Cordillera Arañitas, provincia de Loja, Ecuador. Pp. 15-35. En M. A.



- Aguirre-Mendoza, Z.; L. Kvist y R. Linares. 2006. Especies leñosas y formaciones vegetales en los bosques estacionalmente secos de Ecuador y Perú. *Arnaldoa*. 13(2): 324 – 350. ISSN: 1815-8242
- Albacete, A. (04 de octubre de 2019). Tratamiento de Imágenes Sentinel-2 con ArcGis. <https://storymaps.arcgis.com/stories/8cf7c8024f6e4eb1bbb1d977bda137cf>
- Ashes to Life. (28 de marzo de 2019). El suelo: El gran perjudicado tras los incendios. <https://www.ashestolife.es/el-suelo-el-gran-perjudicado-tras-los-incendios/>
- Aytekin, E. (03 de agosto de 2021). Incendios arrasan bosques en el mundo. <https://www.aa.com.tr/es/mundo/los-incendios-que-arrasan-los-bosques-en-diversas-partesdel-mundo/2322531>
- Banco de Desarrollo de América Latina-CAF. (14 de mayo de 2020). Ecuador Fortalecerá la Prevención de Incendios Forestales en las Zonas más Vulnerables. <https://www.caf.com/es/actualidad/noticias/2020/05/ecuador-fortalecera-la-prevencion-deincendios-forestales-en-las-zonas-mas-vulnerables/>
- Best, B. y M. Kessler. 1995. Biodiversity and Conservation in Tumbesian Ecuador and Perú. Birdlife Internacional. Cambridge. UK. 218 p.
- Bonan, G. B. (2008). Forests and climate change: Forcings, feedbacks, and the climate benefits of forests. In *Science* (Vol. 320, Issue 5882, pp. 1444–1449). <https://doi.org/10.1126/science.1155121>
- Castillo, M., Pedernera, P., y Pena, E. (2003). Incendios forestales y medio ambiente: una síntesis global. *Revista Ambiente y Desarrollo*, 9(3), 44-53.
- Bui, D. T., Hoang, N. D., y Samui, P. (2019). Spatial pattern analysis and prediction of forest fire using new machine learning approach of Multivariate Adaptive Regression Splines and Differential Flower Pollination optimization: A case study at Lao Cai province (Viet Nam). *Journal of environmental management*, 237, 476-487.
- Burgess, R. (2011). Desarrollo de un modelo espacial, dinámico y difuso de riesgo de incendio para el Distrito de Chitwan, Nepal. [Tesis de Maestría, Universidad de Twente]. Universidad de Twente. <http://essay.utwente.nl/84887/1/burgess.pdf>
- Campbell, B. (2011). Introducción a la teledetección
- Cárdenas, M., Medel, R., Castillo, J., Vázquez, J. C., y Casco, O. (2015). Modelos de Aprendizaje Supervisados : aplicaciones para la predicción de incendios forestales en la provincia de Córdoba. XVII Workshop de Investigadores En Ciencias de La Computación, 1–5.

<https://sedici.unlp.edu.ar/handle/10915/45467><http://sedici.unlp.edu.ar/handle/10915/45467%0Ahttp://hdl.handle.net/10915/45467>

- Cerda, J., y Cifuentes, L. (2012). Use of ROC curves in clinical research: Theoretical-practical aspects. *Revista Chilena de Infectología*, 29(2), 138–141. <https://doi.org/10.4067/S0716-10182012000200003>
- Chiriboga, C. y K. Andrade. 2005. Diagnóstico socioeconómico de las poblaciones usuarias de los remanentes de bosque seco de los cantones Alamor y Zapotillo en la provincia de Loja, Ecuador.
- Chuvieco, E. (1991). Fundamentos de teledetección espacial. *Estudios Geográficos*, 52(203), 371.
- Chuvieco, E., Aguado, I., Yebra, M., Nieto, H. (2007). Generación de un modelo de peligro sobre incendios forestales con Teledetección y SIG. Ed. Martin. [https://www.researchgate.net/publication/237810521\\_Generacion\\_de\\_un\\_Modelo\\_de\\_Peligro\\_de\\_Incendios\\_Forestales\\_mediante\\_Teledeteccion\\_y\\_SIG](https://www.researchgate.net/publication/237810521_Generacion_de_un_Modelo_de_Peligro_de_Incendios_Forestales_mediante_Teledeteccion_y_SIG)
- Chuvieco, E., Aguado, I., Yebra, M., Nieto, H., Salas, J., Martín, M. P., ... y Zamora, R. (2010). Development of a framework for fire risk assessment using remote sensing and geographic information system technologies. *Ecological modelling*, 221(1), 46-58.
- Córdova, J. I. L. (2020). Identificación de áreas susceptibles de incendios forestales en el cantón Loja y propuesta de acciones de prevención y mitigación.
- Cortez, P., & Morais, A. D. J. R. (2007). A data mining approach to predict forest fires using meteorological data.
- Cuesta, J. R., y Giraldo, I. O. (2013). Efectos de los incendios forestales en las propiedades del suelo. *Estado del arte. Cuaderno activa*, 5, 59-67.
- De La Casa, A., & Ovando, G. (2006). *Relación entre la precipitación e Índices de Vegetación durante el comienzo del ciclo anual de lluvias en la Provincia de Córdoba, Argentina*. 35, 67–86. <https://www.redalyc.org/pdf/864/86435105.pdf>
- Di Bella, C.M., Posse, G., Beget, M.E., Fischer, M.A., Mari, N., Veron, S. (2008). La teledetección como herramienta para la prevención, seguimiento y evaluación de incendios e inundaciones. *Ecosistemas* 17(3):39-52.
- Díaz García, E. R. (2015). Construcción de Mapas de Combustible Forestal para Detectar el Peligro de Incendio en un Bosque de Pino-Encino.
- Díaz-Uriarte, R., y Alvarez de Andrés, S. (2006). Gene selection and classification of microarray data using random forest. *BMC bioinformatics*, 7, 1-13.

- Dobillas, S. (2020) MARS: Multivariate Adaptive Regression Splines — How to Improve on Linear Regression? Towards Data Science. <https://towardsdatascience.com/mars-multivariate-adaptive-regression-splines-how-to-improve-on-linear-regression-e1e7a63c5eae>
- Doerr, SH, y Santín, C. (2016). Tendencias globales en incendios forestales y sus impactos: percepciones versus realidades en un mundo cambiante. *Transacciones filosóficas de la Royal Society B: Ciencias biológicas*, 371 (1696), 20150345.
- Espinosa, C. I.; M. De la Cruz; A. L. Luzuriaga y A. Escudero. 2012. Bosques tropicales secos de la región Pacífico Ecuatorial: diversidad, estructura, funcionamiento e implicaciones para la conservación. *Ecosistemas* 21 (1-2): 167-179.
- FAO. (2016). FORESTS AND AGRICULTURE: LAND-USE CHALLENGES AND OPPORTUNITIES STATE OF THE WORLD'S FORESTS. <https://www.fao.org/3/i5588e/i5588e.pdf>
- FAO. (2020). The State of the World's Forests 2020. In *The State of the World's Forests 2020*. FAO and UNEP. <https://doi.org/10.4060/ca8642en>
- Friedman, J. H. (1991). Multivariate adaptive regression splines. *The Annals of Statistics*, 19(1), 1-67. <https://doi.org/10.1214/aos/1176347963>
- GAD Macará. (2023). Plan de Desarrollo y Ordenamiento Territorial (PDOT) 2023 – 2027. Alcaldía de Macará, Macará.
- Galparsoro, L. de U., y Pita, F. S. (2010). Medidas de concordancia: el índice Kappa. *Fisterra*, 6, 1–7.
- Gascón, F., Bouzinac, C., Thépaut, O., Jung, M., Francesconi, B., Louis, J y Fernandez, V. (2017). Estado de calibración y validación de productos de Copernicus Sentinel-2A. *Teledetección*, 9(6), 584.
- Gao, J., Yi, Y., Wei, T., & Zhang, G. (2021). Sentinel-2 cloud removal considering ground changes by fusing multitemporal SAR and optical images. *Remote Sensing*, 13(19), 3998.
- García, M. (2007). Estimación y cartografía del contenido de humedad de combustible vivo a partir de imágenes NOAA/AVHRR. Departamento de Geografía.
- Ghorbanzadeh, O., Blaschke, T., Gholamnia, K., y Aryal, J. (2019). Forest fire susceptibility and risk mapping using social/infrastructural vulnerability and environmental variables. *Fire*, 2(3), 50.
- Giglio, L., Descloitres, J., Justice, C. O., y Kaufman, Y. J. (2003). An enhanced contextual fire detection algorithm for MODIS. *Remote sensing of Environment*, 87(2-3), 273-282.
- Giglio, L., Schroeder, W., y Justice, C. O. (2016). The collection 6 MODIS active fire detection algorithm and fire products. *Remote sensing of environment*, 178, 31-41.
- Gilbert, M. A. (1997). Acerca de los índices de vegetación. May 2014.

- Gómez, I., & Martín, I. (2008). Estudio Comparativo de Índices Espectrales para la Cartografía de Áreas Quemadas con Imágenes MODIS. *Revista de Teledetección: Revista de La Asociación Española de Teledetección*, 29, 15–24.
- Gómez, I., y Martín, I. (2008). Estudio Comparativo de Índices Espectrales para la Cartografía de Áreas Quemadas con Imágenes MODIS. *Revista de Teledetección*
- González, P. (2017). Impacto de los Incendios forestales en el suelo, agua, vegetación y fauna. Biblioteca del Congreso Nacional de Chile. <https://www.camara.cl/pdf.aspx?prmTIPO=DOCUMENTOCOMUNICACIONCUENTA&prmid=39186>
- González, A. J. (2020). Identificación de Áreas Quemadas por medio de Índices Espectrales utilizando imágenes SENTINEL 2 en el Municipio de Orocué, Casanare. 21. <https://repository.unimilitar.edu.co/bitstream/handle/10654/38042/GonzalezAlixJohana2020.pdf?sequence=1&isAllowed=y>
- González, M. E., Lara, A., Urrutia, R., y Bosnich, J. (2011). Cambio climático y su impacto potencial en la ocurrencia de incendios forestales en la zona centro-sur de Chile (33°-42° S). *Bosque (Valdivia)*, 32(3), 215-219.
- Guo Futao, Wang Guangyu, Su Zhangwen, Liang Huiling, Wang Wenhui, Lin Fangfang, Liu Aiqin (2016) What drives forest fire in Fujian, China? Evidence from logistic regression and Random Forests. *International Journal of Wildland Fire* 25, 505-519. <https://doi.org/10.1071/WF15121>
- Hastie, T., Tibshirani, R., y Friedman, J. (2009). *The Elements of Statistical Learning: Data Mining, Inference, and Prediction* (2nd ed.). Springer Series in Statistics. New York: Springer. <https://doi.org/10.1007/978-0-387-84858-7>
- Herbario Loja, UNISIG, CINFA. (2001). Zonificación y determinación de los tipos de Bosque seco en el suroccidente de la provincia de Loja. Informe Final. Herbario Loja — Proyecto Bosque Seco, Universidad Nacional de Loja, Ecuador.
- Hern, E. R., Lemus, D. F., y Pineda, W. D. (2019). Una propuesta metodológica para la selección de umbrales de clasificación en procesos de seroconversión y transmisión de anticuerpos a recién nacidos en Bogotá-Colombia. 12(2), 193–210.
- Hsiang, S. M., y Jina, A. S. (2014). The causal effect of environmental catastrophe on long-run economic growth: Evidence from 6,700 cyclones (No. w20352). National Bureau of Economic Research.
- Ibáñez Martín, A. (2019). Modelos de Machine Learning: Optimización y Aplicaciones. 16–25.

- INEC (Instituto Nacional de Estadísticas y Censo). 2010.
- Jain, P., Coogan, S. C. P., Subramanian, S. G., Crowley, M., Taylor, S., y Flannigan, M. D. (2020). A review of machine learning applications in wildfire science and management. *Environmental Reviews*, 28(4), 478–505. <https://doi.org/10.1139/er-2020-0019>
- Jaksic, F., y Fariña, J. (2015). Incendios, sucesión y restauración ecológica en contexto. *Anales Instituto Patagonia (Chile)*, 23-24.
- Jalilian, S., & Jouibary, S. S. (2023). Forest wildfire risk mapping, performance comparison of machine learning algorithms.
- Jiménez González, A., Macías Egas, Á. F., Ramos Rodríguez, M. P., Tapia Zúñiga, M. V., y Rosete Blandariz, S. (2019). Indicadores de sostenibilidad con énfasis en el estado de conservación del bosque seco tropical. *Revista Cubana de Ciencias Forestales*, 7(2), 197-211.
- Kalabokidis, K., Palaiologos, P., Gerasopoulos, E., Giannakopoulos, C., Kostopoulou, E., y Zerefos, C. (2015). Effect of climate change projections on forest fire behavior and values-at-risk in southwestern Greece. *Forests*, 6(6), 2214-2240. <https://doi.org/10.3390/f6062214>
- Kalantar, B., Ueda, N., Idrees, M. O., Janizadeh, S., Ahmadi, K., & Shabani, F. (2020). Forest fire susceptibility prediction based on machine learning models with resampling algorithms on remote sensing data. *Remote Sensing*, 12(22), 3682.
- Kalantar, B., Ueda, N., Idrees, MO, Janizadeh, S., Ahmadi, K. y Shabani, F. (2020). Predicción de la susceptibilidad a incendios forestales basada en modelos de aprendizaje automático con algoritmos de remuestreo en datos de teledetección. *Teledetección* , 12 (22), 3682.
- Keck, A., Gray, E., Lynch, P., O'Carroll, C., y Voiland, A. (2011). NPPNPOESS Preparatory Project Building a Bridge to a New Era of Earth Observations. 15. [https://www.nasa.gov/pdf/596329main\\_NPP\\_Brochure\\_ForWeb.pdf](https://www.nasa.gov/pdf/596329main_NPP_Brochure_ForWeb.pdf)
- Kolanek, A., Szymanowski, M., y Raczyk, A. (2021). Human Activity Affects Forest Fires: The Impact of Anthropogenic Factors on the Density of Forest Fires in Poland. *Forests*, 12(6), 728. <https://doi.org/10.3390/f12060728>
- Landa, F., Cruz, N., Coria, G., Rebolledo, G., y Hernández, S. (2014). Cohen's Kappa Index as a Tool for Noise Reduction of Brain Information in Valence Level Identification. Puebla.
- Landis, J. R., & Koch, G. G. (1977). The measurement of observer agreement for categorical data. *biometrics*, 159-174.

- Landwehr, N., Hall, M., y Frank, E. (2005). Logistic model trees. *Machine Learning*, 59(1-2), 161-205.  
<https://doi.org/10.1007/s10994-005-0466-3>
- Lavrukhin, E. V., Karsanina, M. V., & Gerke, K. M. (2023). Measuring structural nonstationarity: The use of imaging information to quantify homogeneity and inhomogeneity. *Physical Review E*, 108(6), 064128.
- LeCun, Y., Bengio, Y., y Hinton, G. (2015). Deep learning. *nature* (2015). May; 521 (7553): 436  
 10.1038/nature14539.
- Liao, D., y Valliant, R. (2012). Variance inflation factors in the analysis of complex survey data. *Survey Methodology*, 38(1), 53-62.
- Loján, J. (2020). Informe de variables que se utilizan para la generación de modelos de susceptibilidad de incendios con la identificación de sus fuentes para descarga.
- MacQueen, J. (1967, June). Some methods for classification and analysis of multivariate observations. In *Proceedings of the fifth Berkeley symposium on mathematical statistics and probability* (Vol. 1, No. 14, pp. 281-297).
- MAE (2013). Plan de contingencia de incendios forestales.
- Mataix-Solera, J., y Guerrero, C. (2007). Efectos de los incendios forestales en las propiedades edáficas. *Incendios forestales, suelos y erosión hídrica*, 5-40.
- Mendoza, Z. H. A., Valarezo, M. C., López, M. D., y Pineda, E. P. (2021). Composición florística y estructura de un remanente de bosque seco en la Estación Experimental Zapotepamba, Loja, Ecuador. *Bosques Latitud Cero*, 11(1), 97-112.
- Moncayo, L. (2013). Aprendizaje supervisado: Algoritmos de clasificación y regresión.
- Mooney, H. A., Cropper, A., Capistrano, D., Carpenter, S. R., Chopra, K., Dasgupta, P., Leemans, R., May, R. M., Pingali, P., Hassan, R., Samper, C., Scholes, R., y Watson, R. T. (2005). *Ecosystems and Human Well-being: Biodiversity Synthesis* The Cropper Foundation, Trinidad and Tobago.
- Mugridge, J., y Wang, Y. (2019). Applying decision tree in food industry—a case study. In *Advanced Manufacturing and Automation VIII* 8 (pp. 383-388). Springer Singapore.
- Joshi, R. D., y Dhakal, C. K. (2021). Predicting type 2 diabetes using logistic regression and machine learning approaches. *International journal of environmental research and public health*, 18(14), 7346.
- Muñoz C.A., Treviño E.J., Verástegui J., Jiménez J., Aguirre O.A., (2005). Desarrollo de un modelo espacial para la evaluación del peligro de incendios forestales en la sierra madre oriental de México. *Inv. Geogr.* 56: 101-117.

- Muñoz Sabater, J., Dutra, E., Agustí Panareda, A., Albergel, C., Arduini, G., Balsamo, G., ... & Thépaut, J. N. (2021). ERA5-Land: A state-of-the-art global reanalysis dataset for land applications. *Earth system science data*, 13(9), 4349-4383.
- Naderpour, M., Rizeei, H. M., y Ramezani, F. (2021). Forest Fire Risk Prediction: A Spatial Deep Neural Network-Based Framework. *Remote Sensing*, 13(13), 2513. <https://doi.org/10.3390/rs13132513>
- Novo, A., Fariñas-Álvarez, N., Martínez-Sánchez, J., González-Jorge, H., Fernández-Alonso, J. M., y Lorenzo, H. (2020). Mapping Forest Fire Risk—A Case Study in Galicia (Spain). *Remote Sensing*, 12(22), 3705. <https://doi.org/10.3390/rs12223705>
- Nowosad, J. (2021). Motif: an open-source R tool for pattern-based spatial analysis. *Landscape Ecology*, 36(1), 29–43. <https://doi.org/10.1007/s10980-020-01135-0>
- Oliveira, S., Oehler, F., San-Miguel-Ayanz, J., Camia, A., y Pereira, J. M. C. (2012). Modeling spatial patterns of fire occurrence in Mediterranean Europe using Multiple Regression and Random Forest. *Forest Ecology and Management*, 275, 117–129. <https://doi.org/10.1016/j.foreco.2012.03.003>
- Osejos, C., y Dayana, S. (2022). Identificación de zonas con susceptibilidad y amenaza a incendios forestales en la Sierra Norte del Ecuador (Bachelor's thesis, Quito: UCE).
- Ovando, G., de la Casa, A., Díaz, G., Díaz, P., Bressanini, L., & Miranda, C. (2021). Desempeño de diferentes índices de vegetación de Sentinel-2A para estimar el rendimiento de soja en agricultura de precisión. *Agriscientia*, 38(2), 1-12.
- Paredes, D. (2020). Data Science con R. Análisis de datos y algoritmos de predicción. <https://bookdown.org/dparedesi/data-science-con-r/>
- Parra, Á., y Bernal, F. (2010). Incendios de cobertura vegetal y biodiversidad. Una mirada a los impactos y efectos ecológicos potenciales sobre la diversidad vegetal. *El Hombre y la Máquina*, (35) 67-81. <https://www.redalyc.org/pdf/478/47817140008.pdf>
- Parto, F., Saradjian, M., y Homayouni, S. (2020). MODIS brightness temperature change-based forest fire monitoring. *Journal of the Indian Society of Remote Sensing*, 48(1), 163-169.
- Pausas, J. G. (2020). Incendios forestales. Los libros de la Catarata.
- Pérez-Verdín, G., Márquez-Linares, M. A., Cortés-Ortiz, A., y Salmerón-Macías, M. (2013). Análisis espacio-temporal de la ocurrencia de incendios forestales en Durango, México. *Madera Bosques*, 19(2), 37–58. <https://doi.org/10.21829/myb.2013.192339>
- Pettinari, M. L., y Chuvieco, E. (2016). Generation of a global fuel data set using the Fuel Characteristic Classification System. *Biogeosciences*, 13(7), 2061-2076. <https://doi.org/10.5194/bg-13-2061-2016>

- Prasad, A. M., Iverson, L. R., y Liaw, A. (2006). Newer classification and regression tree techniques: bagging and random forests for ecological prediction. *Ecosystems*, 9, 181-199.
- Proyecto Bosque Seco. 1998. Diagnóstico socio ambiental e institucional de los cinco cantones sur-occidentales de Loja. INEFAN/ SNV, Loja. 159 pp
- Ramírez Flores, Vania Alejandra Aranda Delgado, L., y Rico Gray, V. (2018). La resiliencia del bosque seco tropical: un seguro de vida para su conservación. *CONABIO, Biodiversitas*, 137: 12–16.
- Ramos-Rodríguez, M. P., Medranda-Mendieta, J. A., Manrique-Toala, T. O., Grás-Rodríguez, R., y Estévez-Valdés, I. (2020). Comportamiento histórico de los incendios forestales en el Cantón Rocafuerte, provincia Manabí, Ecuador, en el periodo 2016-2019. *Revista Forestal Mesoamericana Kurú*, 17(41), 37-46.
- Reid, C. E., Brauer, M., Johnston, F. H., Jerrett, M., Balmes, J. R., y Elliott, C. T. (2016). Critical review of health impacts of wildfire smoke exposure. *Environmental health perspectives*, 124(9), 1334-1343.
- Reyes Bueno, F. (2017). *Manual de Prácticas de Ordenación Territorial*.
- Reyes Bueno, F., y Balcázar Gallegos, C. (2021). Factores que inciden en la probabilidad de ocurrencia de incendios forestales en Ecuador. *FIGEMPA: Investigación y Desarrollo*, 11(1), 50–60. <https://doi.org/10.29166/revfig.v11i1.2634>
- Reyes Bueno, F., y Loján Córdova, J. (2022). Assessment of Three Machine Learning Techniques with Open-Access Geographic Data for Forest Fire Susceptibility Monitoring-Evidence from Southern Ecuador. *Forests*, 13(3), 1–14. <https://doi.org/10.3390/f13030474>
- Reynosa, N. (2016). Índices espectrales de vegetación para la detección de áreas quemadas. *La Calera*, 16(27), 111-114. <https://lcalera.una.edu.ni/index.php/CALERA/article/view/258/252>
- Riaño, D., Chuvieco, E., Salas, J., y Aguado, I. (2003). Assessment of different topographic corrections in Landsat-TM data for mapping vegetation types (2003). *IEEE Transactions on geoscience and remote sensing*, 41(5), 1056-1061.
- Rodríguez, D. (2012). Efecto del fuego en el crecimiento de *Eucalyptus globulus*. *Serie Ciencias Forestales y del Ambiente*, 8(1), 71-74. <https://www.redalyc.org/pdf/629/62980108.pdf>
- Rojas, N., Soto, C., Tuesta, S., Silva, J., y Sáenz, G. (2023). Probabilidad de ocurrencia de incendios forestales en Apurímac. *Hatun Yachay Wasi* 2(2), 85–97. <https://doi.org/10.57107/hyw.v2i2.49>
- SADMQ, (2013). *Los incendios forestales en el Distrito Metropolitano de Quito evaluación 2012*.
- Sancho Caparrini, F. (2020). *Aprendizaje supervisado y no supervisado. Ingeniería Investigación y Tecnología*.



- Sandoval Serrano, L. J. (2018). Algoritmos de aprendizaje automático para análisis y predicción de datos. *Revista Tecnológica*; no. 11.
- Schauenberg, T. (9 de enero de 2020). Incendios forestales: los humanos aumentan el riesgo global. *Deutsche Welle*. <https://www.dw.com/es/incendios-forestales-el-cambio-clim%C3%A1tico-y-la-deforestaci%C3%B3n-aumentan-el-riesgo-global/a-51946276>
- Schiks, T. J., Wotton, B. M., y Martell, D. L. (2024). Remote Sensing Active Fire Detection Tools Support Growth Reconstruction for Large Boreal Wildfires. *Fire*, 7(1), 26.
- Schnell, A. (2020). What Is Kappa and How Does It Measure Inter-Rater Reliability.
- Schroeder, W., Oliva, P., Giglio, L., y Csiszar, I. A. (2014). The New VIIRS 375 m active fire detection data product: Algorithm description and initial assessment. *Remote Sensing of Environment*, 143, 85-96
- Schroeder, W., Oliva, P., Giglio, L., y Csiszar, I.A. (2008). The New VIIRS 375m active fire detection data product: Algorithm description and initial assessment. *Remote Sensing of Environment*, 143, 85-96. <https://doi.org/10.1016/j.rse.2013.12.008>
- Shrestha, N. (2020). Detecting multicollinearity in regression analysis. *American Journal of Applied Mathematics and Statistics*, 8(2), 39-42.
- Solis, A. F., Revelo luna, D. A., Campo Ceballos, D. A., y Gaviria López, C. A. (2021). Correlación del contenido de clorofila foliar de la especie *Coffea arabica* con índices espectrales en imágenes. *Biotecnología En El Sector Agropecuario y Agroindustrial*, 19(2), 51-68. <https://doi.org/10.18684/bsaa.v19.n2.2021.1536>
- Soporte de Minitab. (s.f.). *Interprete los resultados: Resultados clave - Regresión MARS*. Minitab. Recuperado el 6 de junio de 2024, de <https://support.minitab.com/es-mx/minitab/help-and-how-to/statistical-modeling/predictive-analytics/how-to/mars-regression/interpret-the-results/key-results/>
- Stephens, S. L., Agee, J. K., Fule, P. Z., North, M. P., Romme, W. H., Swetnam, T. W., y Turner, M. G. (2013). Managing forests and fire in changing climates. *Science*, 342(6154), 41-42.
- Tallana, M. J. C., Alezandra, W., Ron, Q., Almeida, O. P., y Toulkeridis, T. (2016). IDENTIFICACIÓN DE ZONAS DE RECURRENCIA DE INCENDIOS FORESTALES MEDIANTE ANÁLISIS MULTITEMPORAL Y APLICACIÓN DE ÍNDICES ESPECTRALES, EN EL DISTRITO METROPOLITANO DE QUITO. *Revista de Ciencias de Seguridad y Defensa*, 1(3), 7-7.
- Toledo, E., Ochoa-Moreno, W. S., Alvarado, R., Cuesta, L., Murshed, M., y Rehman, A. (2022). Forest Area: Old and New Factors That Affect Its Dynamics. *Sustainability (Switzerland)*, 14(7). <https://doi.org/10.3390/su14073888>

- Tran, T. V., Reef, R., y Zhu, X. (2022). A review of spectral indices for mangrove remote sensing. *Remote Sensing*, 14(19), 4868.
- Úbeda, X y Francos, M. 2018. Incendios Forestales, un fenómeno global. Revista Bibliográfica de Geografía y Ciencias Sociales. Departamento de Geografía, Universidad de Barcelona, España.
- UNITED NATIONS OFFICE FOR OUTER SPACE AFFAIRS (UNOOSA). UN-SPIDER Knowledge Portal: Data Application of the Month: Vegetation Indices. United Nations Platform for Disaster Management and Emergency. Recuperado el 9 de julio de 2024, from <https://www.un-spider.org/links-and-resources/data-sources/daotm/daotm-vegetation>
- Vadrevu, K., Eaturu, A. y Hauenstein, E. (2010). Environmental Monitoring and Assessment, 166 (1-4), 223-239
- Valladolid, J. y Z. Vidal. 1990. Identificación y descripción de los subsistemas agroforestales en la provincia de Loja. Tesis Ingeniería Forestal. Facultad de Ciencias Agrícolas, Universidad Nacional de Loja, Loja. 122 p.
- Vapnik, V. (1995). The nature of statistical learning theory. *Springer science y business media*.
- En: Vásquez, M. A., Freile, J. F. y Suárez, L. (Eds.). Biodiversidad en los bosques secos de la zona de Cerro Negro- Cazaderos, occidente de la provincia de Loja: un reporte de las evaluaciones ecológicas y socioeconómicas rápidas. Pp. 91-116. EcoCiencia, MAE y Proyecto Bosque Seco, Quito. Ecuador.
- Vásquez, M. Larrea, L. Suárez y P. Ojeda (Eds.). Biodiversidad en los Bosques Secos del Sur-Occidente de la Provincia de Loja. EcoCiencia, Ministerio del Ambiente, Herbario LOJA y Proyecto Bosque Seco, Quito. Ecuador.
- Verdú, F., y Salas, J. (2011). Caracterización De Variables Biofísicas En Los Incendios Forestales Mayores De 25 Ha. 79–100.
- Viegas, D. X., Bovio, G., Ferreira, A., Nosenzo, A., y Sol, B. (1999). Comparative study of various methods of fire danger evaluation in southern Europe. *International Journal of wildland fire*, 9(4), 235-246.
- Villers Ruíz, M. D. L. (2006). Incendios forestales. Ciencias, (081).
- Wang, W., Qu, J. J., Hao, X., Liu, Y., y Sommers, W. T. (2007). An improved algorithm for small and cool fire detection using MODIS data: A preliminary study in the southeastern United States. *Remote sensing of Environment*, 108(2), 163-170.
- Xiong, X., y Butler, J. J. (2020). MODIS and VIIRS calibration history and future outlook. *Remote Sensing*, 12(16), 2523.
- Zucarelli, E. (2021). Performance Metrics in Machine Learning-Part 3: Clustering. *Towards Data Science*

## 11. Anexos

### Anexo 1. Base de datos

INCENDIO	access_cen	access_pob	access_AP	access_vias	access_ZA	dist_CE	dist_rios	dist_vias	dist_ZA	dist_AP	ARVI	BSI	GNDVI	MSI	NBR	NDMI	NDWI	NDVI	SAVI	Moisture	orientación	elevación	pendiente
1	38.86	18.90	42.77	16.02	3.00	7617.47	161.56	263.03	0.00	4297.18	-0.39	0.23	0.34	1.59	-0.09	-0.23	-0.34	0.21	0.32	-0.19	143.68	920.62	15.32
1	35.89	29.33	34.51	5.20	1.72	4218.10	941.24	111.80	0.00	3327.46	-0.46	0.29	0.31	1.92	-0.21	-0.31	-0.31	0.21	0.31	-0.26	0.19	1129.69	34.43
1	49.63	40.39	45.25	36.42	2.17	3505.97	183.58	742.46	0.00	1210.79	-0.34	0.17	0.42	1.33	0.04	-0.14	-0.42	0.30	0.45	-0.10	338.91	1092.92	32.68
1	56.40	47.15	52.01	43.18	1.54	3267.40	270.01	873.01	0.00	1227.79	-0.39	0.20	0.44	1.52	-0.01	-0.21	-0.44	0.36	0.54	-0.14	341.52	1179.15	32.15
1	64.28	55.04	59.90	50.34	3.00	3427.93	483.33	923.11	0.00	1508.42	-0.32	0.18	0.36	1.29	0.07	-0.13	-0.36	0.21	0.32	-0.09	327.09	1122.00	15.66
1	58.81	52.83	62.18	53.35	2.36	3280.87	543.43	990.19	0.00	1548.48	-0.31	0.18	0.38	1.22	0.09	-0.10	-0.38	0.23	0.34	-0.05	304.71	1188.08	30.32
1	26.84	22.04	25.46	12.31	1.72	4679.83	56.57	272.02	0.00	1656.52	-0.42	0.26	0.36	1.64	-0.10	-0.24	-0.36	0.20	0.30	-0.19	74.70	719.46	17.32
1	34.12	29.32	32.74	8.80	1.80	4857.04	234.08	196.47	0.00	1593.91	-0.40	0.22	0.46	1.47	-0.05	-0.19	-0.46	0.33	0.50	-0.19	162.68	786.85	16.69
1	28.12	14.64	12.01	4.34	0.64	2232.70	610.35	92.20	0.00	20.00	-0.45	0.28	0.39	1.76	-0.16	-0.28	-0.39	0.25	0.38	-0.25	147.29	1988.00	29.78
1	27.45	13.98	11.34	3.93	2.44	2252.90	623.96	94.87	0.00	36.05	-0.47	0.29	0.40	1.81	-0.18	-0.29	-0.40	0.27	0.40	-0.24	157.96	1982.46	27.04
1	29.50	19.56	30.23	24.55	1.91	4623.47	143.17	864.49	0.00	1259.89	-0.44	0.27	0.43	1.65	-0.02	-0.24	-0.43	0.26	0.39	-0.15	67.40	673.08	10.99
1	29.84	24.76	23.30	10.07	3.07	6442.18	850.03	211.88	0.00	898.03	-0.40	0.22	0.52	1.43	0.04	-0.18	-0.52	0.32	0.48	-0.12	250.06	1394.62	37.89
1	23.53	18.55	33.65	15.66	2.36	2301.17	230.22	320.13	0.00	3900.92	-0.45	0.28	0.28	1.94	-0.26	-0.32	-0.28	0.18	0.26	-0.26	350.35	761.77	28.44
1	13.42	13.42	23.54	8.92	8.45	2012.29	289.99	141.42	59.99	3657.93	-0.30	0.14	0.36	1.30	0.02	-0.13	-0.36	0.30	0.45	-0.16	326.74	815.77	30.68
1	31.71	31.62	30.33	26.73	27.49	18926.49	527.98	371.23	710.66	11184.37	-0.32	0.12	0.56	1.14	0.16	-0.07	-0.56	0.49	0.74	-0.02	25.22	470.08	20.13
1	16.42	6.74	15.04	3.78	2.36	15280.75	53.85	80.62	0.00	7205.45	-0.29	0.18	0.35	1.23	0.05	-0.10	-0.35	0.17	0.26	-0.06	20.38	552.54	19.02
1	19.27	9.59	17.89	7.08	2.55	15563.58	111.80	155.25	0.00	7263.74	-0.51	0.34	0.27	2.24	-0.35	-0.38	-0.27	0.16	0.24	-0.29	350.77	541.31	8.99
1	41.98	31.27	3.00	25.83	2.44	7072.56	189.98	552.22	0.00	0.00	-0.40	0.18	0.57	1.38	0.06	-0.16	-0.57	0.50	0.75	-0.10	152.23	1238.77	19.79
1	12.28	7.94	16.11	6.13	1.99	3395.91	605.40	142.12	0.00	4685.28	-0.30	0.12	0.49	1.15	0.15	-0.07	-0.49	0.42	0.62	-0.02	226.48	1307.00	26.79
1	37.25	35.37	35.87	21.93	13.02	4059.13	707.09	311.12	139.99	4322.64	-0.38	0.22	0.44	1.43	0.04	-0.18	-0.44	0.25	0.37	-0.12	291.75	1157.15	35.93
1	46.67	44.35	56.79	18.87	2.17	2812.89	171.18	781.63	0.00	4360.43	-0.35	0.20	0.40	1.38	0.03	-0.16	-0.40	0.23	0.35	-0.12	294.65	715.15	20.89
1	24.60	24.60	28.43	10.08	2.17	1376.78	866.76	212.11	0.00	4893.04	-0.40	0.22	0.42	1.52	-0.04	-0.21	-0.42	0.30	0.45	-0.20	257.91	1586.69	19.41
1	9.88	4.16	5.50	2.96	1.80	2485.92	92.19	58.31	0.00	113.13	-0.36	0.19	0.44	1.39	0.02	-0.16	-0.44	0.31	0.47	-0.12	345.29	751.62	15.09
1	8.92	3.20	4.54	2.51	1.35	2252.78	212.13	50.00	0.00	58.31	-0.41	0.24	0.41	1.59	-0.08	-0.23	-0.41	0.25	0.38	-0.19	36.61	703.77	13.42

1	36.22	35.50	41.01	34.74	1.80	1319.61	350.01	741.99	0.00	686.52	-0.42	0.27	0.18	1.99	-0.39	-0.33	-0.18	0.11	0.17	-0.33	300.56	1523.46	31.05
1	17.94	17.94	16.56	14.92	0.94	3469.32	394.06	590.60	0.00	1090.26	-0.38	0.22	0.34	1.55	-0.17	-0.22	-0.34	0.23	0.34	-0.21	67.28	989.23	17.37
1	27.60	27.60	26.22	24.02	1.09	3565.69	648.40	713.44	0.00	802.74	-0.42	0.25	0.36	1.70	-0.19	-0.26	-0.36	0.27	0.40	-0.16	56.10	1080.31	19.31
1	20.73	20.73	19.35	17.27	2.05	3502.86	509.87	660.67	0.00	953.43	-0.34	0.14	0.49	1.28	-0.05	-0.12	-0.49	0.45	0.67	-0.15	58.43	1033.00	23.08
1	14.12	14.01	12.74	11.81	10.24	6471.76	283.19	187.87	89.99	4422.09	-0.38	0.24	0.33	1.50	-0.05	-0.20	-0.33	0.18	0.26	-0.14	257.01	613.77	14.94
1	30.07	24.20	30.13	6.41	1.91	3706.90	629.35	114.01	0.00	2990.49	-0.37	0.22	0.38	1.44	0.01	-0.18	-0.38	0.23	0.34	-0.11	338.29	1043.54	15.68
1	20.89	16.09	19.51	2.31	2.36	4101.45	698.87	56.57	0.00	2798.65	-0.41	0.25	0.41	1.54	-0.04	-0.21	-0.41	0.26	0.40	-0.14	233.37	873.31	23.79
1	51.81	36.75	42.52	11.72	1.99	6046.86	443.81	241.64	0.00	1861.01	-0.36	0.19	0.46	1.33	0.08	-0.14	-0.46	0.32	0.48	-0.09	288.66	884.62	26.79
1	52.76	37.70	43.47	26.24	3.00	6174.78	200.26	560.35	0.00	1741.24	-0.31	0.11	0.53	1.13	0.19	-0.06	-0.53	0.45	0.68	-0.02	251.49	825.92	19.35
1	45.70	27.78	40.99	28.23	1.54	4263.61	60.82	856.95	0.00	998.40	-0.41	0.24	0.42	1.53	-0.01	-0.21	-0.42	0.25	0.38	-0.18	228.54	934.23	20.28
1	69.72	51.13	79.84	46.12	3.00	6130.67	687.65	900.20	0.00	2708.04	-0.37	0.20	0.48	1.34	0.06	-0.14	-0.48	0.30	0.45	-0.08	40.71	977.38	36.57
1	14.74	10.76	21.22	5.91	2.36	2640.62	521.97	126.48	0.00	2218.14	-0.44	0.28	0.44	1.67	-0.05	-0.25	-0.44	0.24	0.36	-0.17	40.80	1163.62	26.80
1	30.24	28.06	36.73	17.48	12.29	2823.15	1059.83	300.15	106.30	2756.59	-0.41	0.21	0.52	1.43	0.04	-0.18	-0.52	0.41	0.62	-0.08	136.90	1415.46	18.14
1	21.78	16.79	20.64	14.19	2.36	6103.64	189.98	317.82	0.00	1682.42	-0.32	0.19	0.40	1.28	0.08	-0.12	-0.40	0.23	0.35	-0.05	131.62	906.46	11.46
1	86.79	76.78	86.44	52.08	22.83	8949.53	941.98	740.95	255.52	5776.73	-0.39	0.21	0.47	1.48	0.01	-0.19	-0.47	0.34	0.52	-0.11	166.60	885.08	26.01
1	40.85	25.79	31.57	13.70	1.99	5102.01	793.08	290.67	0.00	2041.69	-0.38	0.20	0.38	1.49	-0.01	-0.20	-0.38	0.31	0.47	-0.14	127.37	1008.31	32.26
1	78.12	78.12	16.24	47.48	22.56	6186.32	67.08	834.05	380.11	2499.8	-0.45	0.29	0.15	2.11	-0.36	-0.36	-0.15	0.08	0.13	-0.32	30.96	795.00	6.91
1	14.61	13.76	24.73	12.70	1.54	515.47	92.19	272.01	0.00	1811.18	-0.43	0.25	0.42	1.64	-0.04	-0.24	-0.42	0.32	0.48	-0.14	251.88	1038.23	9.96
1	16.67	16.29	17.56	13.37	1.22	3582.70	409.96	268.31	20.00	110.46	-0.26	0.09	0.35	1.20	0.08	-0.09	-0.35	0.35	0.52	-0.06	337.37	663.08	35.66
0	72.30	52.34	76.20	49.45	11.21	7676.74	280.72	714.00	113.13	3745.22	-0.35	0.15	0.43	1.35	0.03	-0.15	-0.43	0.44	0.66	-0.10	41.91	1013.23	25.81
0	73.48	66.92	72.11	49.02	43.49	4250.75	82.46	708.52	572.66	4092.08	-0.33	0.13	0.45	1.28	0.08	-0.12	-0.45	0.43	0.64	-0.01	345.63	1122.54	19.62
0	33.24	30.33	33.30	22.65	1.54	3961.23	64.03	452.76	0.00	1062.13	-0.16	-0.09	0.60	0.80	0.35	0.11	-0.60	0.70	1.05	0.11	327.85	951.62	19.65
0	59.46	50.21	53.06	46.24	20.27	3278.41	277.83	744.01	289.97	594.66	0.01	-0.25	0.67	0.56	0.58	0.28	-0.67	0.77	1.16	0.34	225.44	1236.54	23.04
0	48.31	43.62	51.96	43.33	9.14	2861.91	643.29	822.93	102.96	1493.49	-0.11	-0.16	0.73	0.66	0.52	0.21	-0.73	0.80	1.20	0.27	187.54	1304.69	19.68
0	51.21	49.87	51.27	35.50	7.21	3896.93	193.14	588.23	80.62	1817.34	-0.22	-0.02	0.61	0.89	0.36	0.06	-0.61	0.67	1.00	0.16	302.68	984.08	29.74
1	36.00	20.94	26.71	9.63	1.35	5077.30	858.78	213.78	0.00	1969.84	-0.34	0.18	0.43	1.34	0.06	-0.14	-0.43	0.30	0.44	-0.09	168.80	1089.69	24.31
0	43.23	28.17	33.94	18.28	6.71	6224.70	250.01	740.02	50.00	1670.77	-0.13	-0.12	0.63	0.74	0.44	0.15	-0.63	0.71	1.06	0.21	171.64	854.62	18.16
1	12.55	12.55	11.17	2.13	1.91	3663.08	460.39	50.00	0.00	1469.89	-0.37	0.20	0.43	1.45	0.03	-0.18	-0.43	0.30	0.45	-0.07	54.31	806.15	3.85
0	3.33	3.33	1.95	1.59	0.79	2752.12	166.42	133.42	0.00	1019.71	-0.10	-0.15	0.60	0.71	0.44	0.17	-0.60	0.73	1.10	0.27	2.29	707.69	4.40
0	41.75	31.46	40.37	27.52	13.28	3251.84	121.66	396.22	145.61	2658.99	-0.15	-0.09	0.62	0.77	0.39	0.13	-0.62	0.71	1.07	0.16	182.60	891.62	28.53

0	77.97	73.17	60.49	28.32	19.00	4974.29	451.24	412.28	259.97	902.47	-0.05	-0.20	0.66	0.61	0.45	0.24	-0.66	0.79	1.18	0.18	246.00	996.54	32.89
0	44.22	30.74	28.10	21.75	14.18	1782.15	494.79	357.36	158.11	313.85	0.01	-0.26	0.71	0.54	0.58	0.30	-0.71	0.81	1.21	0.31	311.97	1872.92	19.27
0	22.87	9.39	6.07	3.85	1.77	3142.46	10.00	100.00	0.00	138.93	-0.03	-0.22	0.68	0.59	0.54	0.26	-0.68	0.80	1.20	0.29	280.49	1983.62	8.41
1	4.63	4.29	5.61	1.36	1.53	3452.17	129.99	20.00	0.00	194.16	-0.25	0.11	0.48	1.03	0.20	-0.01	-0.48	0.32	0.48	-0.03	260.69	575.15	15.92
0	63.60	63.60	28.55	54.39	44.47	3600.35	360.68	1070.43	822.86	241.66	-0.11	-0.15	0.71	0.67	0.48	0.20	-0.71	0.80	1.19	0.22	146.52	892.23	19.22
0	30.03	24.95	29.50	20.89	21.51	6837.98	226.71	296.98	336.00	1554.89	-0.25	0.02	0.56	0.96	0.28	0.02	-0.56	0.60	0.90	0.08	348.86	995.69	27.36
0	72.08	66.70	72.80	67.12	12.81	4430.28	824.55	1379.19	140.36	1704.62	-0.11	-0.14	0.67	0.69	0.45	0.18	-0.67	0.77	1.16	0.21	99.65	848.85	18.99
0	16.82	16.82	26.94	13.04	9.60	1420.18	266.26	232.60	89.44	3123.57	-0.02	-0.19	0.56	0.61	0.46	0.24	-0.56	0.69	1.03	0.19	309.07	876.38	22.83
0	15.41	11.96	25.53	10.00	7.17	1713.92	58.31	220.92	50.00	3007.30	-0.18	-0.04	0.55	0.86	0.27	0.07	-0.55	0.62	0.93	0.10	278.29	849.85	24.64
0	5.71	4.86	4.34	0.36	1.49	18818.47	76.15	10.00	652.97	10745.08	-0.33	0.14	0.49	1.19	0.12	-0.09	-0.49	0.41	0.62	-0.04	49.77	424.54	29.91
0	38.04	28.37	36.66	24.01	3.76	15083.67	357.78	380.80	40.00	6742.11	-0.22	0.00	0.55	0.95	0.29	0.03	-0.55	0.61	0.91	0.07	246.16	650.54	22.44
0	40.93	17.25	39.56	27.82	5.63	15283.95	417.72	509.10	28.28	6744.99	-0.23	0.00	0.56	0.97	0.30	0.02	-0.56	0.61	0.92	0.04	220.36	607.77	17.90
0	29.93	14.44	3.60	11.40	2.44	6951.25	613.95	238.54	0.00	0.00	-0.03	-0.24	0.73	0.57	0.57	0.27	-0.73	0.83	1.24	0.27	123.74	1418.62	25.86
0	67.50	37.49	66.12	51.38	17.83	4015.12	490.05	740.10	174.93	3754.12	-0.04	-0.20	0.66	0.61	0.49	0.25	-0.66	0.76	1.14	0.26	274.95	1015.92	29.31
0	32.09	26.22	34.79	22.65	5.99	3224.66	248.38	480.21	64.03	3971.37	-0.15	-0.11	0.70	0.75	0.43	0.15	-0.70	0.75	1.13	0.14	94.01	1045.54	16.54
0	64.28	56.95	74.40	51.07	33.27	3356.84	509.30	763.23	389.96	5000.87	-0.37	0.19	0.45	1.41	-0.01	-0.17	-0.45	0.36	0.54	-0.10	0.07	820.77	31.58
0	39.95	39.95	38.57	36.04	7.52	1309.13	1431.42	751.59	50.00	4768.57	-0.17	-0.04	0.60	0.83	0.35	0.09	-0.60	0.61	0.91	0.09	297.87	2037.54	49.59
0	35.66	29.95	4.79	25.76	15.06	3500.49	458.81	438.27	199.98	0.00	-0.23	0.02	0.56	0.94	0.28	0.03	-0.56	0.55	0.82	0.06	300.07	1025.15	26.87
0	20.37	20.37	23.19	18.15	3.00	1858.27	316.24	403.10	0.00	1212.67	-0.38	0.20	0.47	1.41	0.01	-0.17	-0.47	0.32	0.49	-0.12	111.60	875.85	29.07
0	48.96	48.96	58.08	48.06	17.65	1096.51	264.20	899.36	200.01	852.28	-0.12	-0.14	0.70	0.71	0.45	0.17	-0.70	0.79	1.18	0.27	262.20	1496.77	26.24
0	62.98	59.85	5.81	52.02	13.78	3783.88	578.72	851.42	143.18	58.31	-0.28	0.08	0.54	1.08	0.20	-0.04	-0.54	0.48	0.72	0.02	14.06	1193.00	26.73
0	58.71	58.71	28.44	56.97	2.44	3176.53	1006.41	1260.52	0.00	431.38	-0.11	-0.11	0.65	0.70	0.45	0.18	-0.65	0.66	1.00	0.19	101.93	1484.31	30.46
0	11.17	11.17	9.79	9.43	2.36	2813.60	240.40	1028.43	0.00	1792.19	-0.08	-0.12	0.66	0.65	0.47	0.21	-0.66	0.65	0.98	0.18	20.70	961.38	20.31
0	53.14	50.62	51.77	47.87	47.09	5736.50	600.77	680.04	600.30	3872.99	-0.35	0.18	0.42	1.33	0.06	-0.14	-0.42	0.30	0.46	-0.08	255.17	899.00	28.42
0	21.86	15.99	23.67	11.98	1.43	2914.60	10.00	213.78	0.00	3415.86	-0.20	-0.02	0.57	0.87	0.35	0.07	-0.57	0.62	0.93	0.12	18.86	812.92	3.02
0	33.04	22.63	31.67	16.92	1.09	4418.28	161.25	311.44	0.00	3287.75	-0.43	0.25	0.44	1.60	-0.01	-0.23	-0.44	0.31	0.46	-0.15	250.65	821.38	24.46
0	35.58	20.52	26.29	10.63	3.29	5735.13	481.65	296.80	63.24	1880.74	-0.27	0.08	0.52	1.03	0.23	-0.02	-0.52	0.47	0.71	0.03	250.43	1005.46	23.91
0	28.38	13.32	19.09	3.30	3.43	5585.98	855.84	44.72	117.05	1586.25	-0.06	-0.17	0.65	0.63	0.49	0.22	-0.65	0.73	1.10	0.26	240.37	1164.54	30.59
0	55.22	39.28	45.93	28.12	0.64	4389.64	285.99	585.88	0.00	1189.93	-0.17	-0.07	0.63	0.77	0.41	0.13	-0.63	0.70	1.05	0.16	42.14	1019.00	1.25
0	106.76	97.20	105.38	58.67	29.62	6832.09	192.34	818.42	335.27	1980.64	-0.22	0.04	0.50	0.96	0.26	0.02	-0.50	0.48	0.71	0.07	353.64	1000.38	21.58

0	70.15	67.97	76.63	47.10	50.73	2933.00	749.47	691.99	598.03	3205.37	-0.27	0.08	0.51	1.06	0.19	-0.03	-0.51	0.44	0.65	0.04	274.78	1299.00	35.73
0	23.02	20.89	29.56	10.60	20.67	1946.20	407.94	147.64	360.52	2246.07	-0.30	0.14	0.43	1.19	0.11	-0.09	-0.43	0.34	0.51	-0.03	269.65	1120.69	45.13
0	39.62	34.63	38.49	31.85	10.77	5884.65	94.33	568.50	99.99	1839.18	-0.33	0.17	0.40	1.33	0.06	-0.14	-0.40	0.29	0.43	-0.11	228.65	826.46	20.61
0	59.23	44.71	58.88	17.06	9.69	9178.79	332.39	290.66	102.96	5342.86	-0.37	0.20	0.42	1.43	0.01	-0.18	-0.42	0.31	0.46	-0.12	46.81	864.54	18.98
0	37.04	21.98	27.75	2.04	2.53	5542.51	687.66	40.00	0.00	2358.27	-0.43	0.23	0.46	1.59	-0.02	-0.23	-0.46	0.40	0.60	-0.15	133.69	1050.08	27.63
0	9.49	7.65	16.17	7.45	1.02	1282.81	183.83	182.49	0.00	1471.26	-0.27	0.04	0.59	1.01	0.24	-0.01	-0.59	0.62	0.93	0.04	223.87	1068.69	15.39
0	66.76	66.76	11.82	61.21	61.72	6536.34	339.70	1251.50	1015.34	127.28	-0.23	-0.01	0.59	0.94	0.29	0.03	-0.59	0.65	0.97	0.09	315.68	716.08	20.13
0	51.88	51.88	22.25	48.90	37.21	3453.25	691.12	721.74	480.08	284.61	-0.19	0.02	0.35	1.05	0.18	-0.02	-0.35	0.40	0.60	0.06	273.19	891.62	43.62

## Anexo 2. Script de estado de vegetación para el cantón Macará

```
//Capa de 8 kilómetros buffer (límite cantonal_8km)
var forma = ee.FeatureCollection("users/lojanjulia/GP_oct21_feb22/limite_disuelto");

var ColSentinel2= ee.ImageCollection ('COPERNICUS/S2_SR')
////////////////////////////////////
//¡¡¡IDENTIFICACIÓN DEL PERÍODO TEMPORAL DE ANÁLISIS!!!
.filterDate ('2019-03-07', '2019-03-10')
////////////////////////////////////
.filterBounds (forma);
print(ColSentinel2);
var Sentinel2Filtro = ee.Image(ColSentinel2.mean());
var Sentinel2AOI = Sentinel2Filtro.clip (forma);

//Calculo del Indice ARVI
var ARVI = Sentinel2AOI.expression ('float ((NIR - (2 * Red) + Blue) / (NIR + (2 * Red) + Blue))',{
'NIR': Sentinel2AOI.select ('B8'),
'Blue': Sentinel2AOI.select ('B2'),
'Red': Sentinel2AOI.select ('B11')});

//Calculo del Indice BSI
var BSI = Sentinel2AOI.expression ('float(((Red+SWIR)-(NIR+Blue))/((Red+SWIR)+(NIR+Blue)))',
{'Red': Sentinel2AOI.select('B11'),
'NIR': Sentinel2AOI.select('B8'),
'SWIR': Sentinel2AOI.select('B4'),
'Blue': Sentinel2AOI.select('B2')});

//Calculo del Indice GNDVI
var GNDVI = Sentinel2AOI.normalizedDifference (['B8', 'B3']);

//Calculo del Indice MSI
var MidIR = Sentinel2AOI.select('B11');
var NIR = Sentinel2AOI.select('B8');
var MSI = MidIR.divide(NIR);

//Calculo del Indice NBR
var NBR = Sentinel2AOI.normalizedDifference (['B8', 'B12']);

//Calculo del Indice NDMI
var NDMI = Sentinel2AOI.normalizedDifference (['B8', 'B11']);

//Calculo del Indice NDWI
var NDWI = Sentinel2AOI.normalizedDifference (['B3', 'B8']);

//Calculo del Indice NDVI
var NDVI = Sentinel2AOI.normalizedDifference (['B8', 'B4']);

//Calculo del Indice SAVI
var SAVI = Sentinel2AOI.expression ('float (((NIR - RED) / (NIR + RED + L))*(1+L))',{
'L': 0.5,
'NIR': Sentinel2AOI.select ('B8'),
'RED': Sentinel2AOI.select ('B4')});

//Calculo del Indice Moisture
var Moisture = Sentinel2AOI.normalizedDifference (['B8A', 'B11']);

//Exportar imagen a la carpeta de Google Drive
Export.image.toDrive({image:ARVI, description: 'ARVI_fecha', scale:10, region:forma,crs:'EPSG:32717', folder: 'indices_completo'})
Export.image.toDrive({image:BSI, description: 'BSI_fecha', scale:10, region:forma,crs:'EPSG:32717', folder: 'indices_completo'})
Export.image.toDrive({image:GNDVI, description: 'GNDVI_fecha', scale:10, region:forma,crs:'EPSG:32717', folder: 'indices_completo'})
Export.image.toDrive({image:ARVI, description: 'MSI_fecha', scale:10, region:forma,crs:'EPSG:32717', folder: 'indices_completo'})
Export.image.toDrive({image:ARVI, description: 'NBR_fecha', scale:10, region:forma,crs:'EPSG:32717', folder: 'indices_completo'})
Export.image.toDrive({image:ARVI, description: 'NDMI_fecha', scale:10, region:forma,crs:'EPSG:32717', folder: 'indices_completo'})
Export.image.toDrive({image:ARVI, description: 'NDWI_fecha', scale:10, region:forma,crs:'EPSG:32717', folder: 'indices_completo'})
Export.image.toDrive({image:ARVI, description: 'NDVI_fecha', scale:10, region:forma,crs:'EPSG:32717', folder: 'indices_completo'})
Export.image.toDrive({image:ARVI, description: 'SAVI_fecha', scale:10, region:forma,crs:'EPSG:32717', folder: 'indices_completo'})
Export.image.toDrive({image:ARVI, description: 'Moisture_fecha', scale:10, region:forma,crs:'EPSG:32717', folder: 'indices_completo'})
```

**Anexo 3.** Certificado de traducción del abstract

Mgs. Mónica Jimbo Galarza

## **C E R T I F I C O:**

Haber realizado la traducción de español – inglés del resumen del Trabajo de Integración Curricular previo a la obtención del título de Ingeniero Ambiental, titulado “**Zonas susceptibles a incendios forestales basado en algoritmos de aprendizaje automático (Machine Learning) en el cantón Macará, Loja – Ecuador.**” de autoría de Daniel Eduardo Samaniego Herrera CI: 1150146767.

Se autoriza al interesado hacer uso de la misma para los trámites que crea conveniente.

Es todo cuanto puedo certificar en honor a la verdad.

Emitida en Loja, a los 26 días del mes de noviembre 2024.



Firmado electrónicamente por:  
**MONICA CECILIA  
JIMBO GALARZA**

Mgs. Mónica Jimbo Galarza

**MAGÍSTER EN ENSEÑANZA DE INGLÉS COMO LENGUA EXTRANJERA**

**REGISTRO EN LA SENEYCYT N° 1021-2018-1999861**