



Universidad
Nacional
de Loja

Universidad Nacional de Loja

Facultad Agropecuaria y de Recursos Naturales Renovables

Carrera de Ingeniería Ambiental

**Machine Learning para la predicción de zonas susceptibles a incendios
forestales en el cantón Pindal, Ecuador**

Trabajo de Integración Curricular previa a
la obtención del título de Ingeniería
Ambiental

AUTOR:

Angel Estalin Alvarez Vega

DIRECTOR:

Ing. Carlos Guillermo Chunchu Morocho Mg. Sc.

Loja – Ecuador

2025

Certificación

Loja, 07 de abril de 2025

Ing. Carlos Guillermo Chuncho Morocho Mg.Sc

DIRECTOR DE TRABAJO DE INTEGRACIÓN CURRICULAR

Certifico:

Que he revisado y orientado todo el proceso de la elaboración del Trabajo de Integración Curricular denominado: **Machine Learning para la predicción de zonas susceptibles a incendios forestales en el cantón Pindal, Ecuador**, de autoría del estudiante **Angel Estalin Alvarez Vega**, con cédula de identidad No. **1104957582**, 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.



Ing. Carlos Guillermo Chuncho Morocho Mg.Sc

DIRECTOR DEL TRABAJO DE INTEGRACIÓN CURRICULAR

Autoría

Yo, **Angel Estalin Alvarez Vega**, 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 Integración Curricular, en el Repositorio Digital Institucional – Biblioteca Virtual.

Firma:

A handwritten signature in blue ink, appearing to be 'A. Alvarez Vega', written over a faint yellow rectangular background.

Cédula de indentidad: 1104957582

Fecha: 08 de abril de 2025

Correo electrónico: angel.e.alvarez@unl.edu.ec

Teléfono: 0989763591

Carta de autorización por parte del autor, para consulta, reproducción parcial o total y publicación electrónica del texto completo, del Trabajo de Integración Curricular.

Yo, **Angel Estalin Alvarez Vega**, declaro ser autor del Trabajo de Titulación denominado: **Machine Learning para la predicción de zonas susceptibles a incendios forestales en el cantón Pindal, Ecuador**, como requisito para optar por 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 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 ocho días del mes de abril del dos mil veinte y cinco.

Firma:



Autor: Angel Estalin Alvarez Vega

Cédula: 1104957582

Dirección: Simón Bolívar Y Celica

Correo electrónico: angel.e.alvarez@unl.edu.ec

Celular: 0989763591

DATOS COMPLEMENTARIOS:

Director del Trabajo de Integración Curricular:

Ing. Carlos Guillermo Chunchu Morocho Mg.Sc

Dedicatoria

A mi familia, quienes han sido mi mayor apoyo y motivación en este camino:

A mi padre, Angel Polivio Alvarez, por ser mi ejemplo de dedicación y trabajo. Gracias por tus consejos, tu apoyo y por mostrarme el valor de la disciplina y la constancia.

A mi madre, Esperanza De Jesús Vega Godoy, por ser mi guía, mi fortaleza y mi inspiración. Gracias por tu amor incondicional, por creer en mí incluso en los momentos más difíciles y por enseñarme que con esfuerzo y perseverancia todo es posible.

A mi hermano Juan Alvarez, por sus consejos, por sus risas, su complicidad y por estar siempre ahí, en las buenas y en las malas.

Esta tesis es el resultado de todo lo que me han dado: amor, valores y la fuerza para seguir adelante.

Les dedico este logro, porque sin ustedes no habría sido posible.

Con todo mi cariño y gratitud,

Angel Estalin Alvarez Vega

Agradecimiento

Quiero manifestar mi más sincero agradecimiento a la carrera de Ingeniería Ambiental y a todo su cuerpo docente, cuya orientación y conocimientos han sido faros que han guiado mi trayecto académico. Las vivencias y aprendizajes que me han proporcionado permanecerán conmigo como un tesoro invaluable en mi vida profesional y personal.

A mis padres, pilares fundamentales de mi vida, les expreso mi eterno agradecimiento por su amor incondicional, su apoyo constante y sus sabios consejos. Han sido mi inspiración y mi fuerza para enfrentar cada reto, y espero que este logro les haga sentirse orgullosos de la persona en la que me he convertido, gracias a su ejemplo y dedicación.

A ti, Brenda Guazha, mi compañera en este camino lleno de aprendizaje. Gracias por tu paciencia, por tu respaldo inquebrantable y por estar a mi lado en cada momento, compartiendo tanto las alegrías como las dificultades. Tu amor y comprensión han sido esenciales para alcanzar esta meta, y por eso, esta tesis también es tuya.

De manera especial, extiendo mi más profundo agradecimiento al Ing. Fernando Alexis González Soto, Mg. Sc., cuya mentoría y orientación fueron clave para la realización de este Trabajo de Titulación. Su dedicación y sabiduría han dejado una marca imborrable en mi formación. Igualmente, agradezco al Centro de Investigaciones Territoriales por los conocimientos y oportunidades que me brindaron, los cuales enriquecieron mi formación y fueron determinantes para el desarrollo de este proyecto.

Este logro no habría sido posible sin el apoyo de quienes me rodean, y por eso, les llevo conmigo en cada paso que doy.

Angel Estalin Alvarez Vega

Índice de contenidos

| | |
|---|------------|
| Portada | i |
| Certificación | ii |
| Autoría | iii |
| Carta de autorización | iv |
| Dedicatoria | v |
| Agradecimiento | vi |
| Índice de contenidos | vii |
| Índice de tablas..... | ix |
| Índice de figuras | x |
| Índice de ecuaciones..... | xii |
| Índice de anexos | xiii |
| 1. Título | 1 |
| 2. Resumen | 2 |
| Abstract..... | 3 |
| 3. Introducción | 4 |
| 4. Marco teórico | 6 |
| 4.1 Incendios forestales | 6 |
| 4.1.1 Bosques secos en Ecuador..... | 8 |
| 4.1.2 Probabilidad de incendios forestales | 9 |
| 4.2 Machine learning | 11 |
| 4.2.1 Objetivos del Machine learning | 11 |
| 4.2.2 Modelos de aprendizaje automático | 12 |
| 4.2.3 Métodos de muestreo de datos de machine learning | 13 |
| 4.2.4 Uso de machine learning como predictor..... | 13 |
| 4.3 Algoritmos de aprendizaje automático supervisado..... | 14 |
| 4.4 Satélites y sensores utilizados en estudio de incendios forestales..... | 15 |
| 4.4.1 Sensores utilizados en estudios de incendios forestales..... | 15 |
| 4.4.2 Sensor VIIRS – Satélite Suomi NPP..... | 16 |
| 4.4.3 Sensor MSI..... | 17 |

| | |
|---|-----------|
| 4.5 Utilidad del análisis de los incendios forestales | 17 |
| 5. Metodología..... | 18 |
| 5.1 Descripción de la zona de estudio | 18 |
| 5.2 Características biofísicas del territorio | 18 |
| 5.2.1 Relieve..... | 18 |
| 5.2.2 Tipo de Suelo | 19 |
| 5.2.3 Uso Actual del Suelo y Cobertura Vegetal | 19 |
| 5.2.4 Información Climática..... | 19 |
| 5.2.5 Incendios forestales en cantón Pindal | 20 |
| 5.3 Software y plataformas..... | 21 |
| 5.4 Metodología para la Elección de Variables de Importancia..... | 22 |
| 5.4.1 Selección de variables | 24 |
| 5.5 Generación de mapas..... | 26 |
| 5.5.1 Etapa I: Elaboración de la Base de Datos | 27 |
| 5.5.2 Etapa II: Desarrollo y Aplicación del Modelo | 32 |
| 5.5.3 Etapa III: Evaluación del modelo..... | 33 |
| 5.6 Delimitación de las áreas..... | 36 |
| 6. Resultados | 39 |
| 6.1 Establecer una línea base de las variables predictivas para la determinación de la ocurrencia de incendios forestales en el cantón Pindal | 39 |
| 6.2 Evaluar algoritmos de Machine Learning para la generación de un modelo de susceptibilidad a incendios forestales en el cantón Pindal..... | 45 |
| 6.3 Automatizar el modelo de susceptibilidad a incendios forestales para mapeo de zonas de riesgo a incendios forestales en el cantón Pindal | 50 |
| 7. Discusión | 57 |
| 8. Conclusiones | 64 |
| 9. Recomendaciones | 65 |
| 10. Bibliografía | 66 |
| 11. Anexos | 74 |

Índice de tablas

| | |
|---|-----------|
| Tabla 1. Regiones con mayor pérdida de cobertura arbórea debido a incendios en Ecuador ... | 8 |
| Tabla 2. Factores ambientales que favorecen en la ocurrencia y propagación del fuego | 10 |
| Tabla 3. Diferencias de aprendizaje automático respecto al enfoque tradicional | 12 |
| Tabla 4. Nivel de Amenaza en las localidades del cantón. | 20 |
| Tabla 5. Softwares y Plataformas online para el modelo en el cantón Pindal | 21 |
| Tabla 6. Variables topográficas, de interacción antrópica y estado de vegetación | 23 |
| Tabla 7. Coste de movilidad según la clase de superficie | 31 |
| Tabla 8. Algoritmos supervisados y sus funciones en RStudio | 32 |
| Tabla 9. Clases para la reclasificación según la probabilidad de incendio. | 33 |
| Tabla 10. Clases para la reclasificación de la probabilidad de ocurrencia de incendios..... | 35 |
| Tabla 11. Resultados del Factor de Inflación de Varianza en las variables para los modelos RL, LMT y MARS | 46 |
| Tabla 12. Importancia de las variables en la modelación de probabilidad de ocurrencia de incendios forestales utilizando en los modelos RL, LMT y MARS | 46 |
| Tabla 13. Rendimiento de los modelos MARS, RL y LMT | 48 |
| Tabla 14. Porcentajes de zonificación del riesgo a incendios forestales, basado en un análisis espacio temporal, para el cantón Pindal, enero - diciembre del 2023 | 53 |

Índice de figuras

| | |
|--|----|
| Figura 1. Historial de alertas de incendios en Ecuador | 6 |
| Figura 2. Alertas de incendio semanales en Ecuador..... | 7 |
| Figura 3. Reducción de la cobertura arbórea debido a incendios en Ecuador | 7 |
| Figura 4. División político administrativo del cantón Pindal | 18 |
| Figura 5. Identificación de las variables de importancia requeridas | 25 |
| Figura 6. Fases para la generación del mapa de probabilidad..... | 26 |
| Figura 7. Metodología para la obtención de puntos de muestreo | 28 |
| Figura 8. Distribución geográfica (incendio y no incendio) | 28 |
| Figura 9. Proceso para la obtención de información de las variables | 29 |
| Figura 10. Diagrama de flujo del proceso de cálculo de accesibilidad..... | 29 |
| Figura 11. Comparación antes y después de la digitalización de vías | 30 |
| Figura 12. Matriz de confusión | 35 |
| Figura 13. Proceso del análisis espacio – temporal para la zonificación | 37 |
| Figura 14. Grado de susceptibilidad..... | 38 |
| Figura 15. Proceso para modelos de susceptibilidad | 38 |
| Figura 16. Variables topográficas | 40 |
| Figura 17. Variables de interacción antrópica (distancia)..... | 41 |
| Figura 18. Variables de interacción antrópica (accesibilidad) | 43 |
| Figura 19. Variables del estado de la vegetación | 45 |
| Figura 20. Variables que no presentan multicolinealidad para los modelos | 47 |
| Figura 21. Número de datos de los sets de entrenamiento (E) y de validación (V) que fueron clasificados como correctos (aciertos) e incorrectos (errores) para los modelos MARS, RL y LMT | 49 |

Figura 22. Mapeo de probabilidad de ocurrencia de incendios forestales para el cantón Pindal utilizando algoritmos de aprendizaje automático supervisado. a) Regresión Logística (RL), b) Splines de Regresión Adaptativa Multivariante (MARS) y c) Árboles de Decisión Logística (LMT)..... **50**

Figura 23. Identificación de clústers en las imágenes ráster de probabilidad de ocurrencia de incendios forestales del cantón Pindal **51**

Figura 24. Zonificación del riesgo a incendios forestales, basado en un análisis espacio temporal, para el cantón Pindal, enero - diciembre del 2023 **52**

Figura 25. Inhomogeneidad, distinción y calidad global de cada clúster **54**

Figura 26. Mapeo de la calidad global, inhomogeneidad y distinción del análisis clúster para la zonificación del riesgo de incendios forestales **55**

Figura 27. Mapa de identificación de áreas susceptibles a incendios forestales para el cantón Pindal..... **56**

Índice de ecuaciones

| | |
|--|-----------|
| Ecuación 1. Modelo regresión lineal | 14 |
| Ecuación 2. Modelo arboles de decisión logística | 14 |
| Ecuación3. Modelo Splines de Regresión Adaptativa Multivariante | 15 |
| Ecuación 4. Factor de Inflación de Varianza | 24 |
| Ecuación 5. Tasa de verdaderos positivos | 34 |
| Ecuación 6. Especificidad de los datos | 34 |
| Ecuación 7. Índice kappa | 34 |
| Ecuación 8. Calidad Global | 37 |

Índice de anexos

| | |
|---|-----------|
| Anexo 1. Variables topográficas | 74 |
| Anexo 2. Variables de interacción antrópica | 75 |
| Anexo 3. Variables de estado de vegetación (Índices espectrales) | 77 |
| Anexo 4. Base de datos establecida | 80 |
| Anexo 5. Certificado de traducción del abstract | 81 |

1. Título

Machine Learning para la predicción de zonas susceptibles a incendios forestales en el cantón Pindal, Ecuador

2. Resumen

El uso inadecuado del fuego ha provocado incendios que han transformado progresivamente los paisajes en Ecuador. En 2021 se registraron 600 incendios forestales, afectando 3.520,45 hectáreas, de las cuales el 19,07 % correspondieron a la provincia de Loja, donde el cantón Pindal presentó 133,8 hectáreas quemadas ese año, ubicándose entre las más afectadas del país. Ante esta problemática, esta investigación modeló la susceptibilidad de ocurrencia de incendios forestales en el cantón Pindal. Mediante el Factor de Inflación de la Varianza, se identificaron dos variables de entrada asociadas a factores ambientales y antrópicos (Moisture y NDVI). Se implementaron tres algoritmos de aprendizaje automático supervisado (RL, MARS y LMT) en un conjunto de datos compuesto por 88 muestras etiquetadas como incendio y no incendio, correspondientes al período 2018-2021. Los datos se dividieron en subconjuntos de entrenamiento (75%) y validación (25%) para desarrollar y evaluar el rendimiento de los modelos. El algoritmo MARS mostró el mejor rendimiento, con un AUC de 0,929 en el conjunto de entrenamiento y 0,893 en el conjunto de validación. Con este modelo, se generó un mosaico de probabilidad de ocurrencia de incendios forestales para el periodo enero-diciembre de 2023, con el fin de realizar la zonificación del riesgo mediante un análisis espacio-temporal. La zonificación del riesgo de incendios forestales identificó a la parroquia de Los Órganos como una zona de riesgo muy alto, especialmente durante la temporada seca de agosto a enero. Las zonas urbanas mantienen una alta probabilidad de incendios durante todo el año debido a presencia constante de factores antrópicos. La evaluación de la ocurrencia de incendios mediante algoritmos de aprendizaje automático resulta ser un método integral para la gestión, extinción y prevención de incendios.

Palabras clave: Bosque seco, Incendios forestales, Probabilidad, Splines de regresión adaptativa multivariante, Zonificación.

Abstract

The inappropriate use of fire has caused fires that have progressively transformed landscapes in Ecuador. In 2021, 600 forest fires were recorded, affecting 3,520.45 hectares, of which 19.07% corresponded to the province of Loja, where the Pindal canton presented 133.8 hectares burned that year, ranking among the most affected in the country. In view of this problem, this research modeled the susceptibility of forest fire occurrence in the Pindal canton. Using the Variance Inflation Factor, two input variables associated with environmental and anthropogenic factors (Moisture and NDVI) were identified. Three supervised machine learning algorithms (RL, MARS and LMT) were implemented on a dataset composed of 88 samples labeled as fire and non-fire, corresponding to the period 2018-2021. The data were divided into training (75%) and validation (25%) subsets to develop and evaluate model performance. The MARS algorithm showed the best performance, with an AUC of 0.929 in the training set and 0.893 in the validation set. With this model, a forest fire occurrence probability mosaic was generated for the period January-December 2023, in order to perform risk zoning by means of a spatio-temporal analysis. The forest fire risk zoning identified the parish of Los Órganos as a very high risk zone, especially during the dry season from August to January. Urban areas maintain a high probability of fires throughout the year due to the constant presence of anthropogenic factors. The evaluation of fire occurrence by means of machine learning algorithms turns out to be an integral method for fire management, extinction and prevention.

Key words: Dry forest, Forest fires, Probability, Multivariate adaptive regression splines, Zoning.

3. Introducción

El fuego, como elemento natural, ha ejercido una influencia significativa en los ecosistemas, desempeñando un papel crucial en la estructura, funcionamiento y dinámica de los medios terrestres (Villers, 2006). Es una fuerza que regula los paisajes, impactando la diversidad de especies y la distribución de la vegetación (Castillo, 2019). No obstante, cuando el fuego se propaga de manera descontrolada en los ecosistemas, se transforma en un incendio forestal, un fenómeno impredecible y complejo tanto en su origen como en sus efectos (Pausas, 2020).

Estos sucesos afectan a numerosas regiones del mundo, desde las selvas tropicales hasta las zonas áridas y templadas, generando impactos significativos en los ecosistemas. Estos incluyen la alteración del suelo (modificaciones en su pH, erosión, incremento de la desertificación y/o reducción de su capacidad de conducción eléctrica), contaminación de las fuentes de agua y modificaciones en la composición atmosférica (Alkhatib et al., 2023). El aumento en la frecuencia e intensidad de los incendios forestales en los últimos años se atribuye parcialmente al cambio climático, que está generando condiciones más secas y calurosas en muchas áreas (Pausas, 2020). A pesar de que solo el 4% de estos eventos son ocasionados por causas naturales, el 96% restante es provocado por actividades antrópicas (Reyes y Balcázar, 2021).

En Ecuador, se pierden anualmente entre 15.000 y 21.000 hectáreas de bosques nativos y plantaciones forestales (MAATE, 2022). Entre 2012 y 2019, se registraron 14.557 incendios que devastaron 164.262 hectáreas, con el 80% de estos desastres registrados en la región andina, un 18% en la región costera y un 2% en la Amazonía (SNGRE, 2021). Solo en 2021, se registraron 600 eventos de incendios forestales a nivel nacional, impactando un área total de 3.520,45 hectáreas de vegetación (MAATE, 2022). Durante ese año, la provincia de Loja se fue la más impactada, con 114 incendios forestales registrados, los cuales afectaron 672 hectáreas (19.07% del área total dañada a nivel nacional). Este porcentaje refleja su posición crítica como una de las regiones con mayor recurrencia de daños asociados a incendios, fenómeno exacerbado por la predominancia de ecosistemas frágiles en su territorio, cuya baja resiliencia los hace especialmente propensos a la degradación provocada por las llamas (Dirección de Gestión de Información de Riesgos, 2019).

En Loja, el 31% del territorio corresponde a bosque seco, ecosistema frágil que registró mayor afectación en 2016, 2019 y 2020, con una pérdida promedio de 4000 ha/año, superando a otras provincias de la sierra. Esta vulnerabilidad se asocia a la actividad agrícola y al cambio de

uso de suelo, factores clave en su degradación (Muñoz et al., 2019). Los bosques secos, altamente susceptibles a incendios, se transforman en matorrales que incrementan la carga de combustible y la intensidad del fuego. No obstante, cumplen roles ecológicos críticos: restauración de hábitats, protección de suelos y regulación de ciclos naturales (Cawson et al., 2024). Esta dualidad exige abordar los incendios como prioridad ambiental y de seguridad pública (Castillo, 2019).

El análisis espacial, al evaluar la distribución y patrones de ecosistemas y las áreas afectadas por incendios, proporciona datos relevantes para la construcción de modelos predictivos. Estos modelos, una rama del Machine Learning, permiten a los sistemas aprender de forma automática y mejorar con la experiencia. Ofrecen un enfoque prometedor para la predicción de incendios forestales mediante el uso de imágenes satelitales (Mohajane, 2021). Varios estudios han investigado la predicción de incendios forestales utilizando diferentes algoritmos de aprendizaje automático. Por ejemplo, Valdez et al. (2017) investigaron el uso de algoritmos como MaxEnt, Redes Neuronales Artificiales (ANN), Random Forest (RF) y Máquinas de Soporte Vectorial (SVM). Además, Reyes y Loján (2022) proponen al aprendizaje supervisado como árboles de decisión (LMT), regresión logística (RL) y splines de regresión adaptativa multivariada (MARS) para resolver este problema.

Con estos antecedentes surge la siguiente interrogante:

¿Es efectivo utilizar técnicas de Machine Learning para crear un modelo predictivo que pueda detectar y cartografiar las áreas susceptibles a incendios forestales en el cantón Pindal?

El objetivo general de este estudio fue Desarrollar un sistema de mapeo de susceptibilidad a incendios forestales basado en Machine Learning aplicado al cantón Pindal, Loja – Ecuador. Para lograr este propósito, se plantean los siguientes objetivos específicos: establecer una línea base de las variables predictivas para la determinación de la ocurrencia de incendios forestales en el cantón Pindal; evaluar algoritmos de Machine Learning para la generación de un modelo de susceptibilidad; y finalmente, automatizar el modelo de susceptibilidad a incendios forestales para mapeo de zonas de riesgo.

4. Marco teórico

4.1 Incendios forestales

Los incendios forestales son fenómenos impredecibles, tanto por sus causas como por sus efectos en los ecosistemas y la economía. Si bien algunos incendios pueden surgir de manera espontánea (4%), la mayoría son originados por actividades antropogénicas (96%) (González *et al.*, 2023). De ahí la importancia de identificar las estaciones y zonas que representan mayores riesgos para advertir a las autoridades, agilizar los medios de vigilancia y extinción disponibles (Lucas *et al.*, 2023). Para ello, se recomienda analizar los cuatro factores básicos involucrados, a saber: clima, tipo de cobertura vegetal, topografía y actividad humana (Pham, 2020).

Los primeros tres factores han sido analizados en diversas publicaciones, convergiendo en que cuando no se dispone de información sobre el tipo de vegetación, es posible aproximarse utilizando los índices espectrales de vegetación; la topografía, con factores de altitud, pendiente y orientación del terreno; y las condiciones meteorológicas, con variables relevantes como temperatura, humedad relativa del aire, viento, precipitaciones y presión de vapor de agua (Lizcano y Santa, 2023). Todas estas condiciones tienen el potencial de impulsar o, por el contrario, retrasar la propagación del fuego (Abid, 2020).

En la Figura 1 se muestra el historial de incendios, donde, desde el 2 de enero de 2012 hasta el 3 de junio de 2024, se registraron en Ecuador un total de 87,144 alertas de incendios detectadas por el sistema VIIRS. Este sistema, forma parte de la suite de instrumentos de imágenes por radiometría visible e infrarroja.

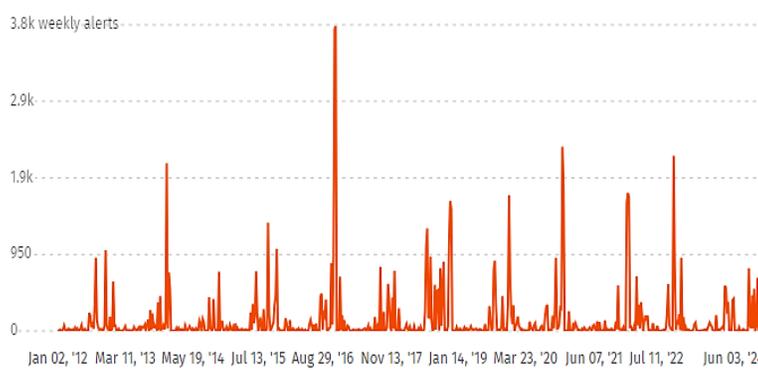


Figura 1. Historial de alertas de incendios en Ecuador

Nota: Adaptado de Global Forest Resources Assessment por Global Forest Watch (2024)

Aproximadamente el 75% de la masa continental de Ecuador estaba cubierta por bosques naturales en 2010, con un total de 18,9 Mha. Sin embargo, su cubierta forestal disminuyó 41,0 kha en 2023, lo que generó unas emisiones de 30,3 Mt de CO₂. El período más crítico de incendios forestales en Ecuador, generalmente inicia a mediados de septiembre y se extiende por aproximadamente 18 semanas. Entre el 5 de junio de 2023 y el 3 de junio de 2024, se registraron 15,720 alertas de incendios a través del sistema VIIRS como se observa en la Figura 2. Esta cifra se considera normal al compararla con los datos de años previos, retrocediendo hasta el año 2012.

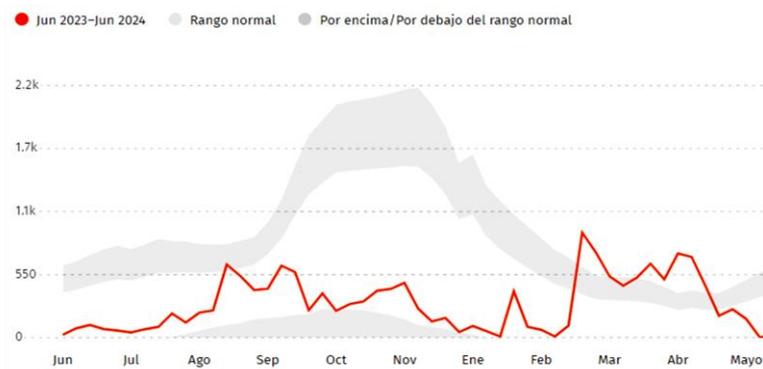


Figura 2. Alertas de incendio semanales en Ecuador

Nota: Adaptado de Global Forest Resources Assessment por Global Forest Watch (2024)

En la Figura 3 se puede evidenciar que entre 2001 y 2023, la deforestación en Ecuador debido a incendios forestales resultó en una reducción de 66 mil hectáreas de bosques, mientras que otros factores contribuyeron a una disminución adicional de 931 mil hectáreas. El año más crítico fue 2017, cuando los incendios forestales fueron responsables de la desaparición de 6.01 mil hectáreas.

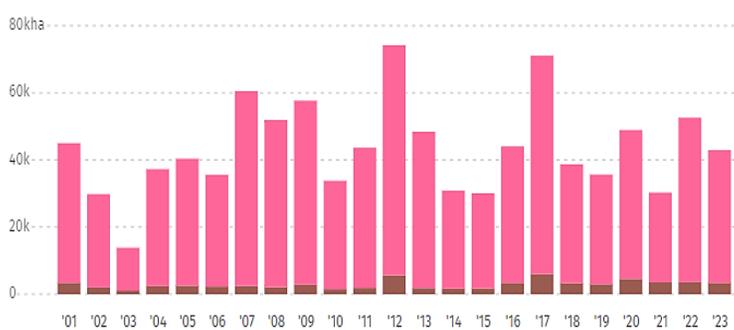


Figura 3. Reducción de la cobertura arbórea debido a incendios en Ecuador

Nota: Adaptado de Global Forest Resources Assessment por Global Forest Watch (2024)

La Tabla 1 presenta las regiones con mayor pérdida de cobertura arbórea debido a incendios en Ecuador entre 2001 y 2023, Loja se encontró en cuarto lugar por estos sucesos, con un promedio anual de 161 hectáreas desaparecidas.

Tabla 1. *Regiones con mayor pérdida de cobertura arbórea debido a incendios en Ecuador*

| Provincia | Hectáreas perdida por incendios forestales |
|------------------|--|
| Sucumbíos | 471 ha |
| Orellana | 464 ha |
| Morona Santiago | 205 ha |
| Loja | 161 ha |
| Zamora Chinchipe | 130 ha |
| Pastaza | 121 ha |
| Napo | 108 ha |
| Manabí | 99 ha |
| Guayas | 98 ha |

Nota: Adaptado de Global Forest Resources Assessment por Global Forest Watch (2024)

Los incendios forestales, tradicionalmente analizados en climas templados mediante índices como NFDRS, FFDI y FWI (basados en datos meteorológicos), carecen de adaptación a zonas tropicales como Ecuador, donde no consideran interacciones antrópicas (Saha, 2023). Los enfoques han evolucionado desde modelos de regresión hacia metodologías multicriterio y algoritmos de aprendizaje automático (ANN, RF, SVM), e incluso el uso de máxima entropía, originalmente aplicado en ecología (Pourghasemi, 2020; Mohajane, 2021).

En Ecuador, la variabilidad climática estacional con períodos húmedos y secos diferenciados por región y altitud favorece incendios casi todo el año (Reyes, 2021). Los modelos incorporan variables como cobertura vegetal, proximidad a infraestructuras y densidad poblacional, pero enfrentan limitaciones por datos meteorológicos de baja resolución (ej. ERA5-Land, con 1.11 km/pixel) y escasa investigación local (Pham, 2020). Un caso destacado es el DMQ, donde FlamMap reveló carencias en información base, subrayando la necesidad de modelos calibrados a contextos locales (Reyes, 2021).

4.1.1 Bosques secos en Ecuador

Los bosques secos del suroeste ecuatoriano (Loja, Santa Elena, Guayas, Manabí, El Oro) son ecosistemas prioritarios por su biodiversidad única y adaptación a condiciones áridas. En la provincia de Loja, el Bosque Seco se extiende a través de los límites político-administrativos de

siete cantones: Zapotillo, Pindal, Macará, Puyango, Celica, Sozoranga y Paltas con altitudes entre 300 y 800 m, influenciados por las corrientes de Humboldt y El Niño, lo que genera precipitaciones variables (300-1500 mm/año) y temperaturas medias de 24-26°C en tierras bajas. Sus suelos volcánicos con estratos marinos sustentan una flora y fauna resiliente, aunque frágil ante incendios (Piedra, 2021; Velasco y Guaranga, 2022; Rivas et al., 2021).

El fuego tiene un rol dual en estos bosques: promueve la regeneración de especies mediante la germinación, pero, cuando es intenso, altera su estructura y degrada suelos (Mendoza et al., 2021; Mendoza y Córdova, 2021). Las sequías prolongadas y la acumulación de biomasa seca incrementan su vulnerabilidad, facilitando la propagación de incendios (Piedra, 2021; Arias et al., 2024). Actividades humanas como la deforestación agrícola y quemas descontroladas agravan el riesgo, fragmentando hábitats y reduciendo resiliencia (Velasco y Guaranga, 2022).

El cambio climático exacerba esta dinámica: el aumento de temperaturas y la alteración de patrones pluviales prolongan las temporadas de incendios, mientras la degradación ambiental genera un ciclo vicioso de mayor frecuencia e intensidad (Armenteras et al., 2020; Mieles, 2020). Esto amenaza no solo la biodiversidad, sino también los servicios ecosistémicos clave, como la protección de suelos y regulación hídrica.

4.1.2 Probabilidad de incendios forestales

Es un tema complejo que involucra diversos factores ambientales y humanos. Elementos como la temperatura durante el trimestre más seco, la velocidad promedio del viento, la incidencia del fenómeno El Niño-Oscilación del Sur son algunos de los factores ambientales que pueden afectar la variabilidad de los incendios en el espacio y en el tiempo. Además, el calentamiento global ha contribuido a incrementar su intensidad y la frecuencia. Se ha observado un aumento en la cantidad de eventos y en las áreas afectadas en los últimos años, lo cual se ha visto impulsado por la ocurrencia más frecuente de olas de calor, períodos de sequía prolongados especialmente en regiones con climas y paisajes secos (Hervas, 2023).

Por otro lado, se estima que al menos un 96 % de estas catástrofes tienen su origen en actividades humanas, ya sean intencionadas o accidentales. La ignición de estos incendios suele ser consecuencia de prácticas negligentes o deliberadas, aunque en muchos casos resulta difícil determinar la proporción exacta (Ruelas, 2024).

La Tabla 2 proporciona una descripción detallada de cómo estos factores influyen en la aparición y expansión del fuego.

Tabla 2. Factores ambientales que favorecen en la ocurrencia y propagación del fuego

| Factores | Descripción |
|---|---|
| Factores Topográficos: Pendiente y elevación | El impacto de la elevación está directamente ligado al uso del suelo y a la accesibilidad, por ejemplo, áreas con elevaciones más bajas muestran un mayor riesgo de ignición cuando tienen una accesibilidad mejorada y más fácil, mientras que las zonas con elevaciones más altas presentan un mayor riesgo cuando están afectadas por la presencia de matorrales o actividades agrícolas (Calviño <i>et al.</i> , 2017). |
| Factores Meteorológicos: Temperatura y precipitación | La temperatura y la precipitación son factores meteorológicos que desempeñan un papel crucial en el aumento de la incidencia de incendios forestales. Su interacción conduce a condiciones propicias para la propagación de incendios. Un estudio llevado a cabo en la Amazonía brasileña respalda esta conexión, demostrando que los incendios tienden a aumentar durante épocas de sequía intensa (Bilbao <i>et al.</i> , 2020). |
| Cobertura vegetal | Un estudio en áreas quemadas entre 1900 y 2000, revelando que el 86 % de los incendios ocurrieron en pastizales y sabanas. Además, la deforestación ha contribuido a la propagación del fuego hacia los trópicos, hasta 2015 se perdieron 178 millones de hectáreas de bosques, con el 55,06 % de esta pérdida atribuida a incendios en zonas tropicales (FAO, 2020). La estructura de la vegetación permite clasificarla en distintos tipos según la carga de combustible, la inflamabilidad y la continuidad del mismo. El tipo de cobertura del suelo está asociado a factores humanos, como la proximidad de asentamientos, lo que influye en el riesgo de ignición de diferentes tipos de |

vegetación, especialmente en áreas de interfaz urbano-forestal (Calviño *et al.*, 2017).

Se estima que para el año 2050 estos eventos podrían aumentar en un 30 %, y para finales de siglo, en un 50 %. Esto plantea un desafío significativo para la gestión de riesgos y la protección de los ecosistemas forestales (Cueva, 2021).

4.2 Machine learning

Machine learning generalmente se considera que abarca procedimientos informáticos automáticos basados en operaciones lógicas o binarias que aprenden una tarea a partir de un conjunto de ejemplos. Aquí sólo nos ocupamos de la clasificación, y es discutible qué debería incluirse bajo el paraguas del aprendizaje automático (Bobadilla, 2021). La atención tiene centrado en enfoques de árbol de decisiones. Estos son capaces de representar el problema más complejo con datos suficientes (Cerezo, 2022).

Actualmente se están desarrollando activamente otras técnicas, como los algoritmos genéticos y los procedimientos de lógica inductiva (ILP), que en principio permitirían tratar con tipos de datos más generales. Se superponen capas de aprendizaje, con una estructura jerárquica de atributos y clases, etc (Greener, 2022).

4.2.1 *Objetivos del Machine learning*

Machine Learning tiene como objetivo generar expresiones de clasificación lo suficientemente simples como para que el ser humano las entienda fácilmente. La Tabla 3 presenta las diferencias del aprendizaje automático y el enfoque tradicional del procesamiento de datos. Deben imitar el razonamiento humano lo suficiente como para proporcionar información sobre el proceso de decisión (Hinestroza, 2018). Al igual que los enfoques estadísticos, en el desarrollo se pueden aprovechar los conocimientos previos.

Tabla 3. *Diferencias de aprendizaje automático respecto al enfoque tradicional*

| Variable | Modelización Tradicional | Machine Learning |
|------------------------|--|---|
| Fuentes de Información | Datos históricos y reglas predefinidas. | Grandes conjuntos de datos, tanto estructurados como no estructurados. |
| Técnicas y Algoritmos | Conjunto de instrucciones específicas codificadas, como miles de IF anidados para casos específicos. | Algoritmos que aprenden de los datos, como redes neuronales, árboles de decisión y máquinas de vectores de soporte. |
| Aprendizaje | Basado en reglas lógicas y decisiones predefinidas. | Capacidad de aprender y adaptarse a nuevos escenarios a medida que se presentan datos adicionales. |
| Sistemas y Software | Programas que ejecutan tareas específicas y bien definidas. | Sistemas que evolucionan su comportamiento basado en la exposición a nuevos datos y patrones. |

Nota: Adaptado de Machine learning and deep learning applications a vision. Global Transitions Proceedings por *Sharma* (2021)

El campo del aprendizaje automático se estructura en tres objetivos fundamentales del machine learning (*Sharma et al.*, 2021). Los estudios orientados a tareas se centran en desarrollar y analizar sistemas de aprendizaje para resolver conjuntos específicos de problemas, adoptando un enfoque práctico (*Alfaro y Ospina*, 2021). La simulación cognitiva se dedica a la investigación y modelado computacional de los procesos de aprendizaje humano, buscando comprender mejor cómo aprendemos (*Díaz*, 2021). Finalmente, el análisis teórico se adentra en la exploración abstracta del espacio de posibles métodos y algoritmos de aprendizaje, sin atarse a dominios de aplicación específicos, buscando fundamentos y principios generales (*Géron*, 2020).

4.2.2 Modelos de aprendizaje automático

Desde la predicción de tendencias hasta el diagnóstico avanzado y la personalización de recomendaciones en ámbitos ambientales, han demostrado su capacidad para encontrar patrones complejos de extensas bases de datos y utilizar esta información para hacer predicciones precisas (*Varoquaux y Colliot*, 2023). En este sentido, el aprendizaje automático ha emergido como una herramienta fundamental en la era de los datos, brindando nuevas oportunidades y soluciones innovadoras en una variedad de campos y sectores (*Rojas E.*, 2020).

4.2.3 Métodos de muestreo de datos de machine learning

Los métodos de muestreo se utilizan para seleccionar una muestra representativa de un conjunto de datos más grande. Ante ello se asegura que se haga de una manera efectiva y generalice bien a datos no vistos (Álvarez, 2023). Uno de los métodos comunes es el muestreo aleatorio, donde se seleccionan observaciones al azar del conjunto de datos original. Este enfoque es simple y fácil de implementar, pero puede no ser adecuado para conjuntos de datos desequilibrados, donde una clase es mucho más prevalente que otras (Ghorbani y Ghousi, 2020).

Otro método es el muestreo estratificado, donde se divide el conjunto de datos en estratos basados en alguna característica relevante, como la clase objetivo, y luego se toma una muestra de cada estrato (Zhang *et al.*, 2022). El muestreo por racimos (cluster) es otra técnica, donde en lugar de seleccionar observaciones individuales, se seleccionan grupos de observaciones al azar y se utiliza toda la información dentro de cada uno (Chiza, 2021).

Además, existen métodos avanzados de muestreo como el muestreo ponderado, donde se asignan pesos a las observaciones acorde a su importancia relativa, y el muestreo adaptativo, donde la probabilidad de selección de una observación puede cambiar en función de las observaciones previamente seleccionadas (Greener, 2022).

Donde se pueden utilizar diferentes métricas como la Curva Característica Operativa del Receptor (ROC), que se emplea en modelos de clasificación, y el índice Kappa para determinar el performance o efectividad del método.

4.2.4 Uso de machine learning como predictor

A nivel global, plataformas como Active Fire Data y Global Forest Watch utilizan sensores como MODIS para detectar anomalías térmicas en tiempo real, optimizando la gestión preventiva de incendios mediante análisis espaciales (Martínez y Inchausti, 2023; Pourghasemi, 2020).

En Ecuador, el esquema nacional de evaluación de susceptibilidad integra variables ambientales y antrópicas, permitiendo adaptar escalas geográficas para priorizar zonas críticas (Coello, 2023; Reyes, 2021). Paralelamente, técnicas predictivas combinan SIG, teledetección y algoritmos de análisis de datos para identificar patrones complejos en la propagación del fuego, incorporando variables como distancia a núcleos poblacionales e hidrología local (Arif *et al.*, 2021; Sharma, 2021; Regadera, 2021).

4.3 Algoritmos de aprendizaje automático supervisado

Aprende patrones y relaciones entre los datos de entrada y salida. Un dato etiquetado es un conjunto de datos que contiene muchos ejemplos de funciones y objetivos. El aprendizaje supervisado utiliza algoritmos que aprenden la relación entre las características y el objetivo del conjunto de datos. Este proceso se conoce como Entrenamiento o Adaptación (Singh, 2022).

4.3.1 Regresión Logística (RL)

Según Guo et al. (2016) la Regresión Logística es ampliamente utilizada en estudios que exploran los factores que influyen en la aparición de eventos, siendo reconocida por su eficacia en términos de capacidad predictiva, aunque su aplicación se ve restringida por los supuestos de normalidad y relaciones lineales.

Es una técnica estadística utilizada para modelar la probabilidad de que ocurra un evento binario (como "sí" o "no", representado por 1 y 0, respectivamente). En tu caso, se aplica para predecir la probabilidad de que ocurra un incendio forestal (Ecuación 1):

Ecuación 1. Modelo regresión lineal

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

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)

4.3.2 Árboles de decisión logística (LMT)

Estos modelos se utilizan principalmente en problemas de clasificación, donde se busca predecir la pertenencia de una observación a una o varias categorías. La generación de este modelo implica la creación de un árbol de decisión (Menes, 2021).

Divide el espacio de características en regiones (nodos) utilizando reglas de decisión basadas en las características de entrada. En cada nodo hoja (terminal), en lugar de asignar una clase directamente (como en un árbol de decisión clásico), se ajusta un modelo de regresión logística para predecir la probabilidad de pertenecer a una clase (Ecuación 2):

Ecuación 2. Modelo arboles de decisión logística

$$P\left(y = \frac{1}{x}\right) = \left(\frac{1}{1 + e - (\beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_n x_n)}\right)$$

Donde:

$P(y=1/x)$, que representa la probabilidad de la clase 1; los coeficientes del modelo $\beta_0, \beta_1, \dots, \beta_n$; las características de entrada x_1, x_2, \dots, x_n ; y la constante e , que es la base del logaritmo natural, aproximadamente 2.71.

4.3.3 *Splines de Regresión Adaptativa Multivariante (MARS)*

Según Vanegas y Vásquez (2017) el algoritmo MARS (Multivariate Adaptive Regression Splines) es una herramienta altamente adaptable que automatiza el proceso de construcción de modelos predictivos. Ofrece la capacidad de seleccionar variables relevantes, transformarlas si es necesario, identificar interacciones entre ellas y manejar los valores faltantes. Además, realiza un autoajuste para evitar el sobreajuste del modelo (Ecuación 3):

Ecuación 3. Modelo Splines de Regresión Adaptativa Multivariante

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

Donde:

En este modelo, y_t representa la variable respuesta en el instante t , y β_i son los parámetros del modelo correspondientes a las variables x_{it} , donde $i=1, \dots$, El término β_0 denota el intercepto. Las funciones base $B(x_{it})$ dependen de las variables x_{it} y pueden expresarse como $B(x_{it}) = \max(0, x_{it} - c)$, donde c es un valor umbral. Aquí, k indica el número de variables explicativas, incluyendo las interacciones entre las variables predictoras.

4.4 Satélites y sensores utilizados en estudio de incendios forestales

Los sistemas satelitales de monitoreo de incendios emplean algoritmos basados en temperatura de brillo (BT), utilizando canales infrarrojos (MIR y TIR) para detectar focos de fuego, y canales visibles/NIR para filtrar falsos positivos (Saha, 2023; Arias, 2024). La teledetección infrarroja, clave por su sensibilidad a radiación térmica, ha evolucionado con métodos como el FRP (Potencia Radiante de Fuego) para mitigar errores en detección diurna (Valeri, 2022).

Además, técnicas como el análisis biespectral de superficies quemadas (Briz, 2021) y algoritmos de subpíxeles con datos MODIS optimizan la precisión en medición de tamaño y temperatura de incendios, especialmente en áreas remotas (Paz et al., 2015).

4.4.1 *Sensores utilizados en estudios de incendios forestales*

Uno de los sensores destacados es el VIIRS (Visible Infrared Imaging Radiometer Suite), un instrumento a bordo de satélites como Suomi National Polar-orbiting Partnership (Suomi NPP)

y NOAA-20. El VIIRS recopila datos visibles e infrarrojos que permiten obtener observaciones detalladas de la Tierra, incluyendo áreas propensas a incendios. Su capacidad para detectar anomalías térmicas y cambios en la cobertura vegetal permite la identificación y monitoreo de incendios forestales en tiempo de actualización de cada 5 días (Cisneros, 2024).

Otro sensor relevante es el MSI (Multispectral Instrument), utilizado en el programa espacial Copernicus de la Unión Europea. El MSI opera a través de múltiples bandas espectrales, lo que le permite capturar información detallada sobre la superficie terrestre. Su capacidad para generar imágenes lo convierte en una herramienta valiosa para el monitoreo de incendios (Vásquez, 2021).

Tanto el VIIRS como el MSI permiten la vigilancia de incendios forestales a escala global, proporcionando datos precisos y actualizados que permiten el monitoreo contante y la creación de alertas tempranas para estos eventos. Su capacidad para detectar cambios en la temperatura superficial y la cobertura vegetal contribuye significativamente a la comprensión de la dinámica lo que facilita la adopción de medidas de gestión para mitigar los riesgos asociados con estos desastres naturales (Mohajane, 2021).

4.4.2 Sensor VIIRS – Satélite Suomi NPP

El VIIRS es un sensor a bordo de los satélites polares (NOAA-20 y NOAA-21), diseñado y fabricado por Raytheon Company (Pawan y Follette, 2020). Este instrumento es uno de los cinco instrumentos clave a bordo del Suomi NPP. VIIRS recopila imágenes visibles e infrarrojas, junto con observaciones globales de la tierra, la atmósfera, la criosfera y el océano de la Tierra (Zou *et al.*, 2020). Extiende los registros observacionales recopilados por instrumentos similares en satélites previamente lanzados, como el Espectrorradiómetro de Imágenes de Resolución Moderada (MODIS) de la NASA y el Radiómetro de Muy Alta Resolución Avanzada (AVHRR) de la NOAA (Li, 2020).

El VIIRS está equipado con cinco canales de alta resolución (I-bands), 16 canales de resolución moderada (M-bands) y un canal específico para la observación diurna y nocturna (Day/Night Band, DNB). La información que genera es esencial para una amplia gama de aplicaciones, como el monitoreo de incendios forestales, la evaluación de la calidad del aire, y la observación de fenómenos meteorológicos extremos (CONAE, 2024). Asimismo, los algoritmos de cobertura del suelo de VIIRS han sido diseñados para ser compatibles con los conjuntos de datos

de MODIS (Li, Zhang, Kondragunta, y Csiszar, 2018), garantizando así la continuidad entre los productos de datos de MODIS y VIIRS. (Yang, 2021) (Zheng, 2023).

4.4.3 Sensor MSI

El sensor MSI de los satélites Sentinel-2 (ESA) captura imágenes en 13 bandas espectrales (visible a SWIR), clave para detectar incendios, evaluar severidad y mapear áreas quemadas mediante el análisis del red-edge y transición espectral que identifica cambios abruptos en la reflectancia de vegetación sana vs. afectada (Ouma, 2020; Chastain, 2019). Índices como NDVI y EVI, derivados de estas bandas, permiten diferenciar vegetación dañada, quemada o en recuperación, optimizando la gestión post-incendio (Chaves et al., 2020; Mohajane, 2021).

Además de incendios, el MSI monitorea vegetación, recursos hídricos y calidad del agua, gracias a su rango espectral que incluye infrarrojo cercano (NIR) y térmico, capturando propiedades como superficies afectadas o tierra desnuda (Dos Santos et al., 2022; Barraza, 2022).

4.5 Utilidad del análisis de los incendios forestales

Es fundamental porque los impactos de los incendios forestales varían según los ecosistemas en los que ocurren, y su evaluación implica costos económicos significativos asociados con la cobertura de las áreas afectadas (Jain *et al.*, 2020). Actualmente, las estrategias de investigación probabilística que utilizan la teledetección se utilizan para reducir los costos financieros, gestionar eficazmente los recursos necesarios para responder a las áreas de alto riesgo, entre otros (Pan *et al.*, 2016).

Debido a la complejidad de las variables y conjuntos de datos involucrados en el proceso de modelado y análisis, es útil utilizar algoritmos de minería de datos lo que ha arrojado resultados significativos en la determinación de ocurrencia (Reyes y Balcazar, 2021). La principal utilidad de este análisis es actuar como una herramienta de gobernanza regional que promueve la toma de decisiones centralizada (Oliveira *et al.*, 2012). Su correcto pronóstico ayuda a identificar áreas de mayor peligro que requieren una mayor asignación de recursos para la prevención y extinción de incendios, lo que ayuda a planificar y aplicar medidas adaptadas a la situación real de la zona y al ecosistema de incendios local (Van *et al.*, 2018).

5. Metodología

5.1 Descripción de la zona de estudio

El cantón se sitúa en la zona occidental de Loja y sus coordenadas geográficas son: Latitud: -4.1161, Longitud: -80.1076, 4° 6' 58" Sur, 80° 6' 27" Oeste. Con una extensión de 194 km² y una población estimada de 8645 habitantes, Pindal limita al norte con el cantón Celica, al sur con los cantones Zapotillo y Puyango, al este con el cantón Olmedo, y al oeste con el cantón Puyango (GAD Pindal, 2023).

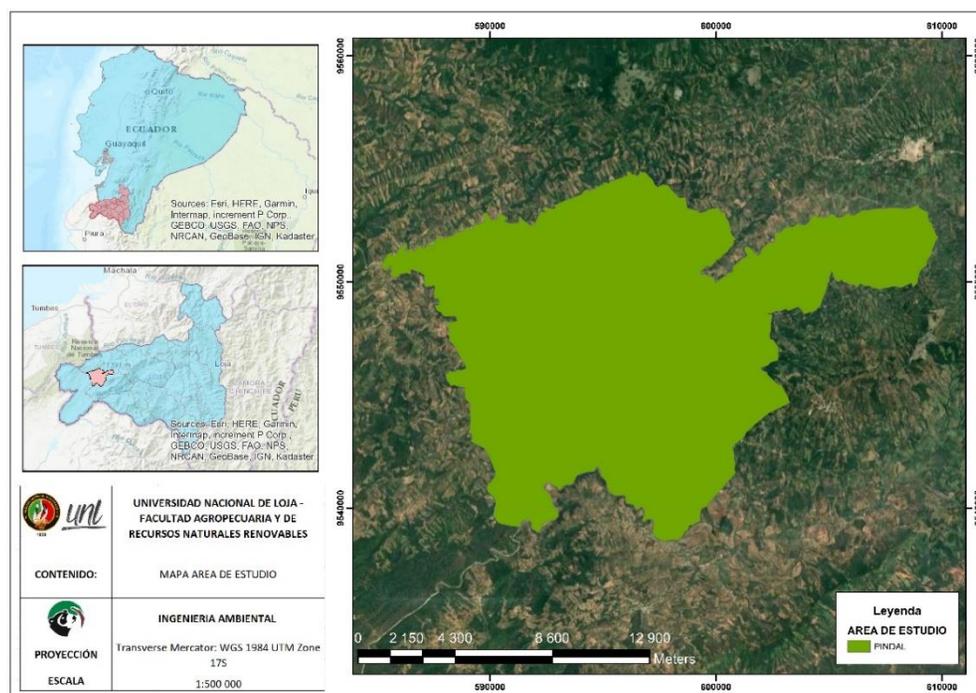


Figura 4. División político-administrativo del cantón Pindal

5.2 Características biofísicas del territorio

5.2.1 Relieve

El cantón Pindal se caracteriza por su compleja topografía andina, moldeada por la Cordillera Oriental y procesos morfodinámicos asociados a actividad volcánica y sedimentaria (López, 2017). Su relieve incluye coluviones, depósitos de roca y suelo arrastrados por pendientes abruptas, fracturas geológicas y alta pluviosidad que generan movimientos en masa. Estos depósitos, compuestos por bloques heterogéneos y material meteorizado, coexisten con un paisaje

aluvial reciente, donde destacan terrazas fluviales de escasa extensión, evidencia de la dinámica hidrogeomorfológica local (Carrion et al., 2023).

5.2.2 Tipo de Suelo

Según la información proporcionada por el GAD Pindal (2024), en el cantón Pindal, los dos principales tipos de suelo son: Inceptisoles que constituyen el 61,70 %, estos suelos se caracterizan por ser poco desarrollados. Los Alfisoles, que representan el 30,87 %, son suelos con un horizonte superficial claro y generalmente pobres en materia orgánica, estos suelos son propensos a la erosión.

5.2.3 Uso Actual del Suelo y Cobertura Vegetal

El cantón Pindal presenta un uso del suelo diversificado, donde la agricultura domina la región, ocupando el 54,38 % del territorio con cultivos temporales y un adicional 1,05 % con cultivos bajo riego. Los pastizales también son una característica prominente, abarcando el 25,18 % de la tierra, especialmente en la parroquia Chaquinal. La zona urbana y los cuerpos de agua representan una porción menor, con el 0,75 % y el 0,64 %, respectivamente. En contraste, las plantaciones forestales constituyen apenas el 0,01 % del área total (PDOT Pindal, 2024). La cobertura vegetal cubre el 12,33 % del cantón, lo que equivale a 2.491,63 hectáreas en sectores como Faical y Papalango. La vegetación arbustiva ocupa el 5,66 %, con 1.142,81 hectáreas en áreas como Matalavcnga (GAD Pindal, 2023).

En años recientes, la deforestación ha impactado drásticamente al bosque natural, disminuyendo su extensión en tres cuartas partes a causa del avance de las áreas de cultivo, en particular para la siembra de maíz. Esta expansión ha comprometido la calidad física y química del suelo, reduciendo su fertilidad y aumentando la necesidad de fertilizantes químicos para sostener los niveles de producción (GAD Pindal, 2023). Por ende, es esencial adoptar estrategias que promuevan la seguridad alimentaria y la autonomía del cantón (Senplades, 2014).

5.2.4 Información Climática

El clima es diverso y está definido por dos zonas climáticas principales:

- Ecuatorial Mesotérmico Semi-Húmedo: Predominante en las parroquias de Chaquinal y 12 de diciembre, con temperaturas que oscilan entre 18°C y 23°C.
- Tropical Mesotérmico Seco: Presente en las parroquias de Pindal y Milagro, con un rango de precipitación anual de 600 mm a 1.500 mm.

La lluvia varía a lo largo del año, siendo los meses de julio a diciembre los más calurosos y enero a abril los más lluviosos, con un pico de precipitación entre febrero y abril. La temperatura se mantiene más alta de febrero a noviembre, con una ligera disminución en diciembre y enero debido a las primeras lluvias. Más del 80% del territorio mantiene temperaturas entre 21 a 23°C.

5.2.5 Incendios forestales en cantón Pindal

Anchaluiza (2013), menciona que la evaluación técnica de la amenaza de incendios forestales se clasifica en distintos niveles, los cuales se determinan en función de una serie de factores y condiciones específicas del entorno. Estos niveles permiten establecer un sistema de alerta y respuesta adecuado para prevenir y combatir los incendios de manera efectiva, estos niveles son:

- **Nivel Bajo:** Posibilidad de que ocurra el evento y que pueden surgir de manera excepcional debido a anomalías naturales específicas y poco frecuentes.
- **Nivel Medio:** Indica una probabilidad moderada de incendios, generalmente como resultado de la interacción habitual de factores naturales cíclicos.
- **Nivel Alto:** Corresponde a una situación donde se encuentran presentes todas las condiciones estáticas necesarias que podrían dar lugar a incendios forestales.
- **Nivel Muy Alto:** Se asigna cuando no solo están presentes todas las condiciones estáticas necesarias, sino que también existen procesos de ignición en estado latente que podrían activarse y conducir a incendios.

El PDOT (2019) del cantón Pindal señala que los agricultores suelen quemar campos antes del invierno para eliminar malezas y preparar el terreno para la siembra. Bajo este contexto, La Tabla 4 presenta el Nivel de Amenaza en el cantón según datos históricos periodo 2000 - 2020.

Tabla 4. Nivel de Amenaza en las localidades del cantón.

| Nivel de Amenaza | Sectores | Área (Has) | % |
|------------------|---|------------|-------|
| Bajo | Guayabal, La Palmira, Gayacan | 12.511,23 | 61,94 |
| Medio | Matalanga, Caminuma, El Papayo, Yapali, Chaquinal, Faical, Gramales, Jorupe, 12 de diciembre, EL Aji, Tabacales, Misama, Papalango, San José, La Chorrera, Varas Blancas, La leona, La Rota, Guarapales, Flores, Milagros, Tacuri, Soledad, El Ceibo, Bellavista. | 2.582,79 | 12,79 |
| Alto | El Sauco, Las Peñas, el Huasimo El Higerón, La Tuna, El Guando, Añancal | 4.118,43 | 20,39 |

| | | | |
|--------------|---------|------------------|---------------|
| Muy Alto | Organos | 2,68 | 0,01 |
| TOTAL | | 20.200,25 | 100,00 |

Nota: Adaptado de Plan de Desarrollo y Ordenamiento Territorial por GAD Pindal. (2023).

El Manejo Integral del Fuego (MIF) en el cantón Pindal representa un enfoque contemporáneo para una adecuada gestión. Este enfoque reconoce tanto los aspectos negativos del fuego, como las alteraciones en los regímenes naturales de incendios, como sus beneficios, cuando se comprende y se utiliza adecuadamente en los ecosistemas. El MIF implica un conocimiento profundo del fuego, su planificación, regulación y monitoreo de impacto (GAD Pindal, 2023).

5.3 Software y plataformas

En el campo de la predicción de zonas susceptibles a incendios forestales mediante Machine Learning, el uso de herramientas especializadas es fundamental. Software como QGIS y SAGA GIS proporcionan capacidades robustas para el análisis y visualización de datos geoespaciales, permitiendo a los investigadores manipular y modelar información geocientífica con precisión. Por otro lado, el lenguaje de programación R se destaca por su potencia en el análisis estadístico, siendo una herramienta esencial para el procesamiento de información. Plataformas como Google Earth Engine (GEE) ofrecen un entorno en la nube a gran escala, mientras que los geos portales y visores geográficos facilitan el acceso a datos espaciales.

La Tabla 5 proporciona una descripción detallada de Softwares y Plataformas online para la aplicación del modelo predictivo de machine learning.

Tabla 5. *Softwares y Plataformas online para el modelo en el cantón Pindal*

| Softwares | Función |
|---|--|
| QGIS 3.36.3 | Software libre y de código abierto. |
| SAGA GIS 2.1.4 | Sistema Especializado en Análisis y Modelado de Datos Geo científicos y SIG. |
| R studio 2024.04.2 | Software y un lenguaje de programación para análisis estadístico. |
| Plataformas online | Función |
| Google Earth Engine | Plataforma geoespacial a escala del planeta. |
| Geo portales y Visores Geográficos | Herramientas en línea para visualizar datos de diferentes fuentes. |

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

5.4 Metodología para la Elección de Variables de Importancia

La técnica utilizada para identificar las variables esenciales en la elaboración de mapas que predicen la susceptibilidad de incendios forestales varía en función de los objetivos específicos de la investigación y los métodos aplicados. Se ha establecido una relación clara entre la frecuencia de incendios y una serie de elementos como la configuración del terreno (relieve y geografía), las condiciones climáticas, los fenómenos meteorológicos entre otros en la región analizada (Jain *et al.*, 2020; Llorens *et al.*, 2021).

Dentro del marco del cantón Pindal, se ha realizado un estudio detallado de información existente con el fin de detectar los factores determinantes. Para estructurar este análisis, se empleó una matriz que vincula las variables identificadas con modelos de machine learning, así como con los investigadores que llevaron a cabo dicho estudio.

En la investigación realizada, se adoptó la metodología propuesta por Reyes-Bueno y Loján-Córdova (2021), así como índices espectrales derivados del satélite Sentinel 2A. Se analizaron un total de 23 variables independientes (cuyos detalles se amplían en los Anexos 1,2 y 3) y se condensan en la Tabla 6 para una referencia rápida y clara.

Tabla 6. *Variables topográficas, de interacción antrópica y estado de vegetación*

| <i>Variable</i> | <i>Función</i> |
|-------------------------------------|--|
| <i>Topográficas</i> | |
| Elevación | Altura de un punto sobre el nivel del mar. |
| Pendiente | Grado de inclinación del terreno. |
| Orientación | Dirección en la que se enfrenta una pendiente, afectando la exposición al sol y al viento. |
| <i>Interacción antrópica</i> | |
| Accesibilidad al centro económico | Facilidad de movimiento desde cualquier punto del cantón hasta el centro económico. |
| Accesibilidad a áreas protegidas | Facilidad hasta áreas protegidas. |
| Accesibilidad a zonas pobladas | Facilidad hasta poblados. |
| Accesibilidad a vías | Proximidad y facilidad de acceso a carreteras del cantón. |
| Accesibilidad a zonas antrópicas | Facilidad de acceso a áreas modificadas por la actividad humana del cantón. |
| Distancia desde el c.e. | Medida de alejamiento de la principal área de actividad económica. |

| | |
|----------------------------------|--|
| Distancia a ríos | Proximidad a cursos de agua, importante para recursos hídricos y actividades económicas. |
| Distancia a vías | Lejanía a carreteras y caminos principales del cantón. |
| Distancia desde áreas protegidas | Distancia desde cualquier punto del cantón hasta las áreas protegidas |
| Distancia a zonas antrópicas | Lejanía a áreas desarrolladas o modificadas por el ser humano. |

Estado de vegetación

| | |
|----------|--|
| ARVI | Atmospherically Resistant Vegetation Index NDVI corregido para efectos de dispersión atmosférica |
| BSI | Bare Soil Index Identificar zonas sin cobertura vegetal |
| GNDVI | Green Normalized Difference Vegetation Index Versión del NDVI más sensible a la variación del contenido de clorofila y nitrógeno en el cultivo. |
| MSI | Moisture Stress Index Determinar el estrés hídrico de la vegetación |
| NBR | Normalized Burn Ratio Estimar la cantidad y desarrollo de áreas incendiadas |
| NDWI | Normalized Difference Water Index Identificar masas de agua y zonas de elevada humedad. |
| NDMI | Normalized Difference Moisture Index Determinar el contenido de agua de la vegetación |
| NDVI | Normalized Difference Vegetation Index Facilidad con la que el fuego se propaga en la vegetación. |
| SAVI | Soil Adjusted Vegetation Index Analizar la vegetación en etapas decrecimiento inicial o dispersa. |
| Moisture | Normalized Difference Moisture Index Estimar el contenido de humedad de la vegetación. |

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).”

5.4.1 Selección de variables

La exposición detalla las fuentes de los factores evaluados y las variables resultantes del procesamiento geoespacial en QGIS 3.36.3, que se utilizó para calcular la elevación, la distancia y la accesibilidad. Además, se utilizó GEE para la estimación de índices espectrales. El Modelo Digital de Elevación requerido se obtuvo del satélite Alos Palsar, disponible a través de la plataforma Earth Data de la NASA. Para identificar las áreas propensas a incendios, se recogieron datos de puntos clave de las zonas de calor activo. Los datos incluyeron aspectos como la altitud del terreno, la proximidad a zonas influenciadas por la presencia humana, la cercanía a cursos de agua y vías de tránsito, y la facilidad de acceso a centros de actividad económica. También se tomaron en cuenta índices espectrales específicos, tales como el Índice de Suelo Desnudo (BSI), el Índice de Vegetación de Diferencia Normalizada (NDVI) y el índice de contenido de humedad (Moisture). Esta información fue obtenida de las imágenes captadas por el satélite Sentinel 2A justo antes de la ocurrencia de los incendios.

Inicialmente, se realizó un análisis de correlación para evitar la multicolinealidad entre las variables predictoras, un requisito metodológico clave para garantizar la independencia estadística de los factores asociados a incendios (Reyes-Bueno y Loján-Córdova, 2022). Este proceso permitió seleccionar aquellas con menor interdependencia, optimizando así la validez estadística del modelo.

Posteriormente, se realizó un test de multicolinealidad utilizando el Factor de Inflación de Varianza (VIF), como lo indican Reyes-Bueno y Loján-Córdova (2022). Este test evalúa el nivel de correlación entre las variables previamente identificadas. Según Rojas et al. (2023), la colinealidad entre factores puede disminuir la eficacia estadística del modelo, llevando a un sobreajuste y aumentando la incertidumbre de los resultados.

Ecuación 4. Factor de Inflación de Varianza

$$VIF = \frac{1}{1 - R^{2d}}$$

Donde:

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

d: Se refiere a todas las demás variables explicativas

Según Reyes-Bueno y Loján-Córdova (2022), un alto valor del Factor de Inflación de Varianza (VIF) sugiere una mayor probabilidad de multicolinealidad. En la evaluación mediante la prueba VIF, se consideran críticos los valores superiores a 10, indicando un nivel problemático de colinealidad.

La Figura 5 destaca los elementos naturales y antropogénicos considerados para la selección de variables significativas. Este procedimiento se fundamentó en un análisis meticuloso de fuentes bibliográficas, la disponibilidad de datos relevantes y la ejecución de un análisis de multicolinealidad, tal como lo describen Reyes-Bueno y Loján-Córdova (2022), con la finalidad de descartar aquellas variables independientes que presentaran una correlación elevada entre ellas.

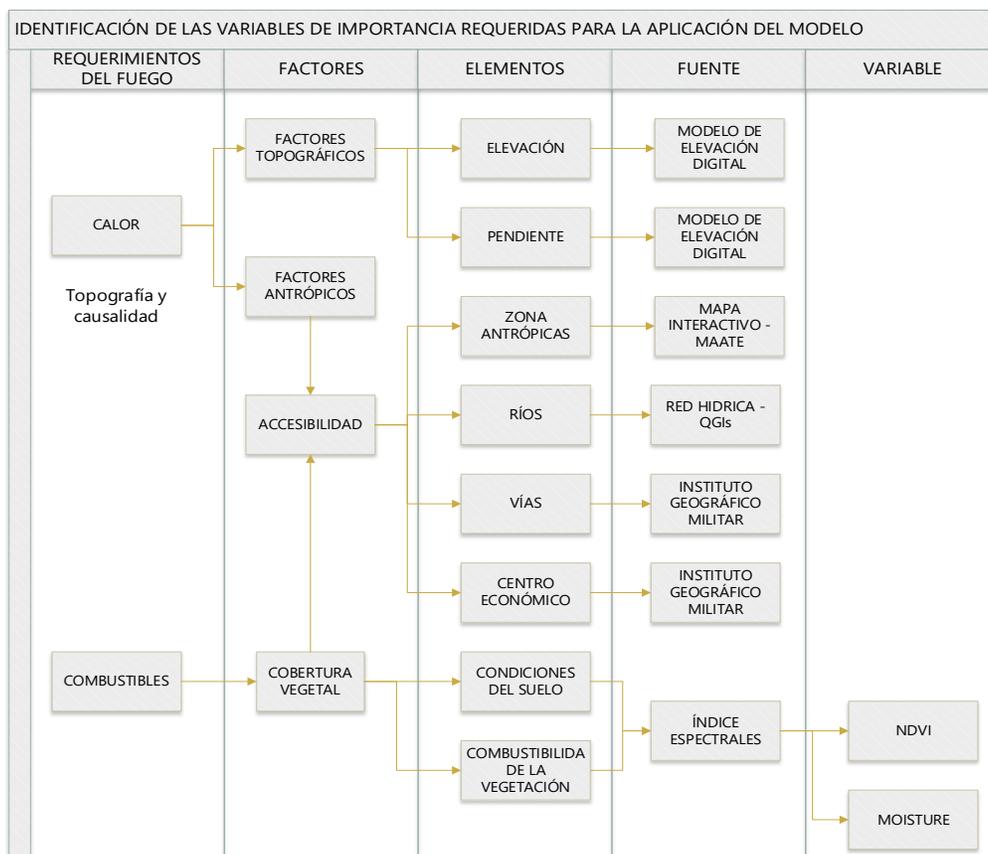


Figura 5. Identificación de las variables de importancia requeridas para la aplicación del modelo

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).

5.5 Generación de mapas

El diseño del mapa que predice la susceptibilidad en el cantón Pindal se llevó a cabo mediante un método organizado en tres etapas distintas, como se muestra en la Figura 6.

1. Organización de la Base de Datos: En esta etapa inicial, se realizó una limpieza de datos tanto ambientales como humanos, los cuales formaron las variables fundamentales para el modelo predictivo.
2. Construcción y Ejecución del Modelo: Para la modelización, se seleccionaron y aplicaron tres técnicas de aprendizaje automático supervisado: LR, MARS y LMT.
3. Valoración de la Eficacia del Modelo: La última fase consistió en la valoración de la precisión del modelo, utilizando dos indicadores clave: el área bajo la curva (AUC) de la característica operativa del receptor (ROC), que determina la capacidad predictiva general del modelo, y la índice kappa de Cohen, que mide la consistencia y fiabilidad.

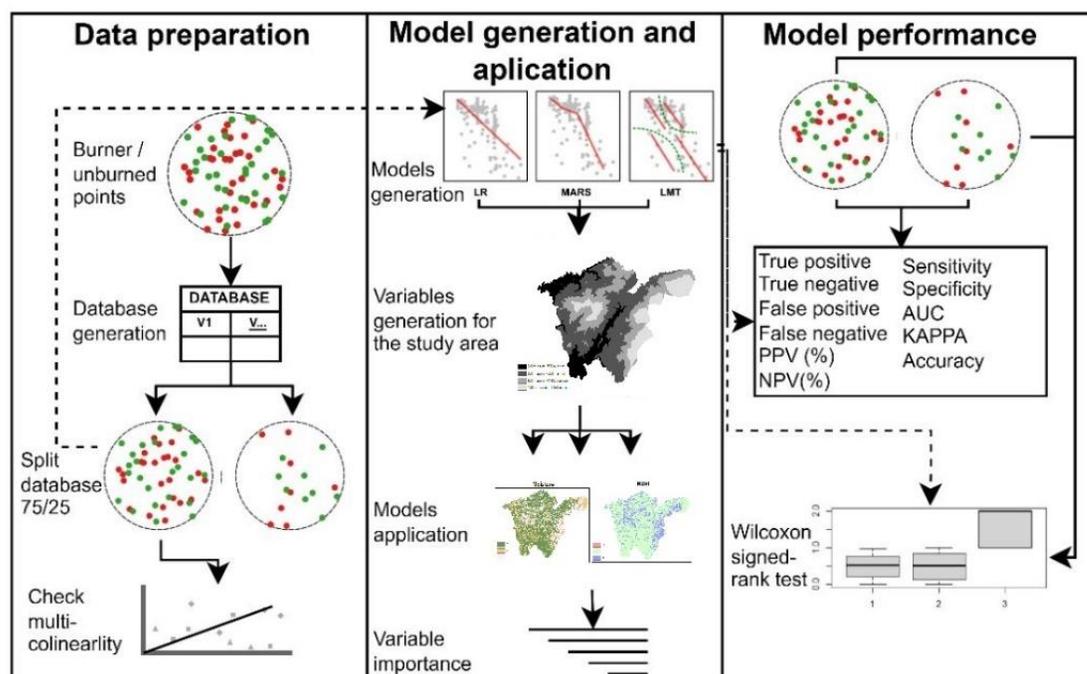


Figura 6. Fases para la generación del mapa de probabilidad

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).

5.5.1 Etapa I: Elaboración de la Base de Datos

5.5.1.1 Recopilación de Puntos de Muestreo.

Se registraron 189 puntos de calor, durante el lapso comprendido entre diciembre de 2018 y diciembre de 2021. Estos eventos se localizaron en un área de influencia de 8 kilómetros del cantón. La información fue obtenida de FIRMS (Fire Information for Resource Management System), un sistema de información de incendios para la gestión de recursos de la NASA. La selección del intervalo temporal para el estudio estuvo determinada por la disponibilidad de imágenes del satélite Sentinel 2A pertinentes a la zona en cuestión.

FIRMS proporciona datos de puntos de calor detectados por los sensores MODIS (a bordo de los satélites Aqua y Terra) y VIIRS. Esta información fue filtrada meticulosamente mediante verificación manual, utilizando imágenes de alta resolución del satélite Sentinel-2A, para confirmar la correlación entre los puntos detectados y áreas efectivamente afectadas por incendios. Los parámetros establecidos para elegir los datos apropiados de FIRMS se basaron en los siguientes criterios:

- Hora de Registro: Se seleccionó el primer foco registrado al inicio del incendio.
- Nivel de Confianza: Se priorizaron los focos con un valor de "confidence" alto (h) o nominal (n), es decir, con un nivel de confianza superior al 30% (Alperen, 2022).
- Poder Radiactivo (FRP): Se priorizaron los focos con un valor superior a 9 MW, dado que estudios indican que valores menores sugieren una baja probabilidad de ser incendios (SNGR, 2019).

Se procedió a descartar aquellos puntos de calor detectados en zonas donde las nubes obstruían la visibilidad previa al evento del incendio. Para complementar el análisis, se incorporaron 44 puntos adicionales que representaban áreas no afectadas por incendios, verificadas a través de imágenes del satélite Sentinel 2A tomadas después de la fecha en que se identificaron los puntos de calor. La figura 7 muestra la metodología aplicada para este procedimiento.

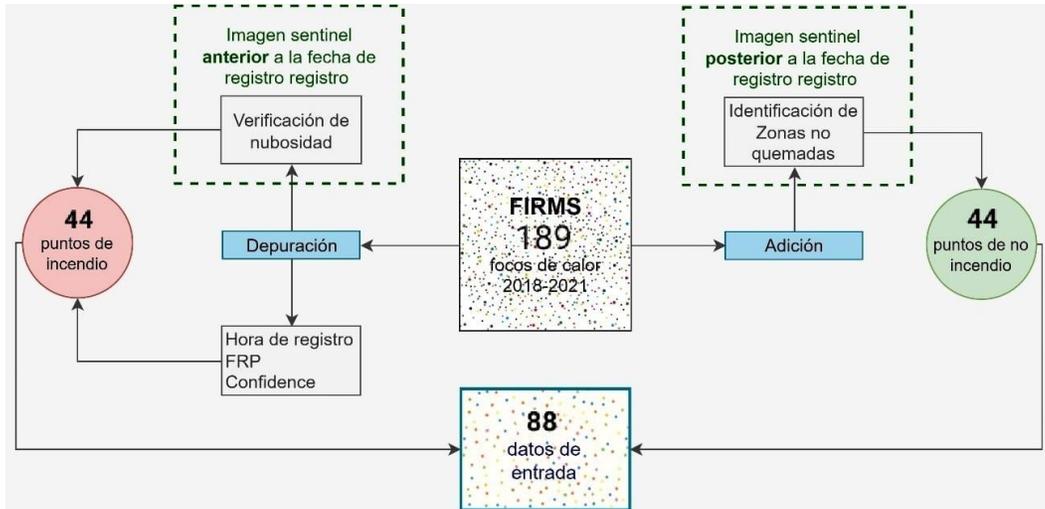


Figura 7. Metodología para la obtención de puntos de muestreo

Nota: Adaptado de “Assessment oh Three Machine Learning Techniques with Open-Acess Geographic Data for Forest Fire Susceptibility Monitoring-Evidence form Southern Ecuador” por Reyes y Loján (2022).

Los puntos de no incendio se localizaron en áreas no afectadas, situadas a una distancia no mayor de 2 km de su contraparte. En la Figura 8 se muestra la distribución geográfica de ambos puntos identificados en Pindal.

Mapa de Distribución geográfica (incendio y no incendio)

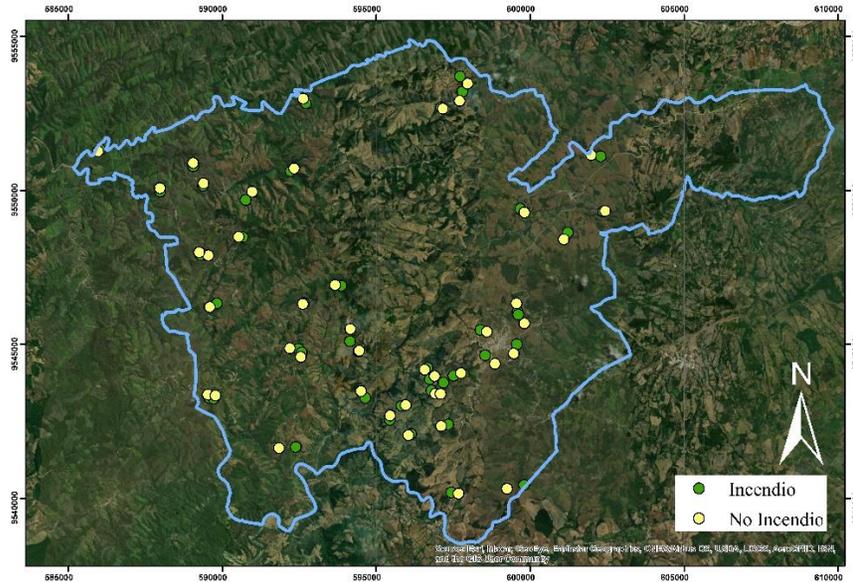


Figura 8. Distribución geográfica (incendio y no incendio)

5.5.1.2 Recopilación de datos de las Variables Identificadas.

La sección en cuestión detalla la metodología empleada para derivar las variables incorporadas en el modelo predictivo, ilustrado en la Figura 9. Además, se explica cómo se conformó la base de datos, que consiste en los puntos de muestreo o focos de calor.



Figura 9. Proceso para la obtención de información de las variables

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

5.5.1.3 Obtención de la Capa de Accesibilidad.

El cálculo de la superficie de fricción y accesibilidad se realizó siguiendo la metodología propuesta por Reyes-Bueno (2017) en el “Manual de Prácticas de Ordenación Territorial”, como se muestra en la Figura 10.

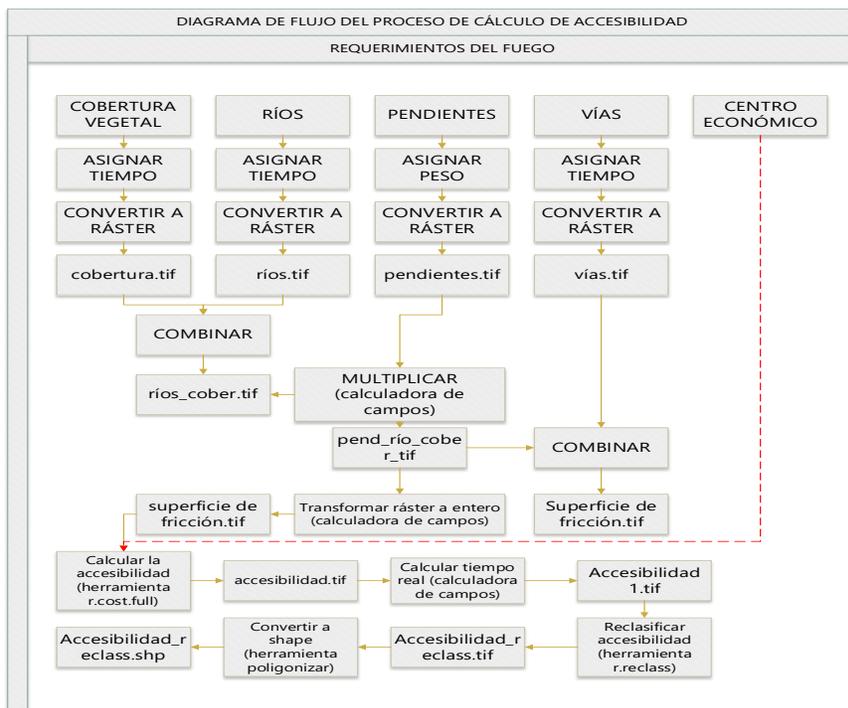


Figura 10. Diagrama de flujo del proceso de cálculo de accesibilidad

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

Para determinar la accesibilidad a los centros económicos, se requirieron diversas capas de datos (vegetación, la red de carreteras, localización de centros económicos). La información sobre el tipo de vegetación se adquirió a través del mapa interactivo proporcionado por el MAATE. Por otro lado, los datos referentes a las carreteras y los centros económicos se obtuvieron del Geoportal del Instituto Geográfico Militar. Sin embargo, fue esencial actualizar los datos de las carreteras, dado que la última actualización registrada en el archivo shapefile data de marzo de 2013.

Para incrementar la exactitud y la representación adecuada de la información sobre accesibilidad, se procedió a una actualización de forma manual de vías proporcionado por el instituto geográfico militar Ecuatoriano, como se visualiza en la Figura 11. Esta actualización se realizó utilizando las imágenes satelitales más recientes de Google del año 2024, aplicando el plugin “QuickMapServices” disponible en QGIS 3.22. Adicionalmente, se organizó la información vial en tres niveles distintos: vías principales (autopistas), vías secundarias (calles urbanas) y vías terciarias (caminos rurales), detallando el ancho de cada tipo de vía en metros.

Capa de vías instituto geográfico militar

Capas de vías realizadas con satélites de Google



Figura 11. Comparación antes y después de la digitalización de vías

Para crear datos sobre la accesibilidad, es imprescindible calcular una superficie de fricción. Esta superficie asigna un valor de tiempo, expresado en minutos, que representa el coste de desplazamiento a través del área. Este cálculo implica la reclasificación de ciertos parámetros. Según Reyes-Bueno (2017), es fundamental determinar la velocidad de desplazamiento admisible en cada sector del terreno, considerando que variables clave como la cobertura vegetal, la pendiente del suelo, la red vial y los cursos de agua condicionan significativamente la movilidad. La Tabla 7 detalla el tiempo asignado a cada capa, basado en la velocidad de tránsito requerida.

Tabla 7. Coste de movilidad según la clase de superficie

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

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

Las capas correspondientes a la vegetación, los cursos de agua y las infraestructuras viales fueron reorganizadas de acuerdo a los costos de movilidad especificados en la Tabla 7. Se identificó la inclinación del terreno como un elemento restrictivo, ya que la velocidad de desplazamiento se reduce con el incremento de la pendiente. En consecuencia, se asignaron valores de 1 a 3 a la pendiente, donde 1 corresponde a inclinaciones menores o iguales al 25%, 2 a inclinaciones mayores al 25% pero menores o iguales al 40%, y 3 a inclinaciones superiores al 40%.

La distancia a elementos clave como ríos, carreteras y zonas antrópicas se calculó mediante el análisis de proximidad con la herramienta “r.grow.distance” en QGIS (versión 3.36.3). Los índices espectrales se derivaron de las imágenes del satélite Sentinel 2A, utilizando un script personalizado en GEE, que tomó en cuenta la delimitación del sitio, la misión específica de Sentinel 2A, el intervalo de tiempo relevante y el cálculo de los índices. Para integrar la información contenida en los archivos ráster resultantes, se aplicó la herramienta “point sampling tool” de QGIS 3.22, facilitando la recopilación de cada variable en los puntos de interés.

5.5.2 Etapa II: Desarrollo y Aplicación del Modelo

Para la construcción del modelo predictivo, se seleccionaron tres métodos de aprendizaje automático supervisado que son ampliamente reconocidos por su eficacia en el análisis de datos y la generación de pronósticos: RL, MARS y LMT.

El desarrollo del modelo se llevó a cabo utilizando RStudio y el paquete caret. Se dividió el conjunto de datos, destinando un 75% para el entrenamiento del modelo y el restante 25% para su validación. En modelos LMT y MARS se implementaron con los paquetes weka y earth. En el caso del LMT, se estableció el número de iteraciones a través de una validación cruzada, manteniendo los demás parámetros en sus valores predeterminados. Para el MARS, se optó por un método de reducción progresiva y se estableció un nivel de interacción. Los detalles operativos de estos modelos están resumidos en la Tabla 8.

Tabla 8. Algoritmos supervisados y sus funciones en RStudio

| <i>Algoritmo</i> | <i>Función en R</i> | <i>Argumentos</i> |
|--|--|--|
| Regresión | lm(formula, data) | Lm() |
| Logística (LR) | glm(formula,familia,data) | Fórmula: Descripción simbólica del modelo. Data: Base de datos que contiene las variables del modelo. Glm() Fórmula: Descripción simbólica del modelo. Familia: "binomial": Función de probabilidad estadística utilizada para ajustar el modelo. |
| Árboles de decisión logística (LMT) | LMT(formula, data, subset, na.action, control, options = NULL) | La fórmula es una representación simbólica del modelo, mientras que la data son la colección de variables utilizadas en dicho modelo. |
| RWeka | | Un "subset" es un vector opcional que define un conjunto específico de observaciones. "na.action" es una función que determina cómo deben manejarse los valores ausentes (NA) en los datos. "control" es un objeto de la clase Weka_control, mientras que "options" es una lista nombrada que contiene otras configuraciones. Paquete RWeka (Hornik <i>et al.</i> , 2009). |

| | | |
|---|---|--|
| Splines de Regresión Adaptativa Multivariante (MARS) Paquete Earth | earth (formula, data, glm, pmethod, degree) | La "fórmula" representa el modelo de manera simbólica, mientras que "Data" contiene las variables utilizadas en el modelo. "glm" es una lista que contiene los parámetros de ajuste del modelo. "pmethod" indica el método utilizado para la poda en el ajuste del modelo. "degree" representa el grado máximo de interacción, siendo el valor por defecto. Estos elementos se encuentran en el paquete "earth" (Milborrow). Utiliza utilidades en Fortran de Alan Miller junto con el wrapper de "leaps" de Thomas Lumley, actualizado en 2021. |
|---|---|--|

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

Para la evaluación de la relevancia de cada variable, se utilizó la función “varImp” dentro del paquete “caret”. Con la función “predict”, se generaron mapas de predicción con base en modelos calibrados. Luego, se recalibraron los resultados de los modelos, asignándoles una escala de uno a cinco, basada en las categorías de probabilidad de incendios definidas previamente. Como paso final, se produjeron visualizaciones en formato raster (.tif) utilizando estos datos recalibrados como se muestra en la Tabla 9.

Tabla 9. Clases para la reclasificación según la probabilidad de incendio.

| Probabilidad | Reclasificación | Clase |
|---------------------|------------------------|--------------|
| $X \leq 0,2$ | 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 del Manual de Prácticas de ordenación Territorial por Reyes (2017).

5.5.3 Etapa III: Evaluación del modelo

En la fase de comprobación del modelo, se decidió asignar el 75% de datos para el entrenamiento y la validación de los modelos usados en el presente estudio: RL, MARS y LMT. La verificación se efectuó utilizando el 25% de los datos restantes. Se emplearon medidas

estadísticas (AUC y ROC) y el índice Kappa de Cohen para evaluar la precisión y la capacidad de los modelos en su función de clasificación.

El AUC es una medida que evalúa la capacidad de un modelo para clasificar de manera acertada las observaciones individuales. De acuerdo con lo establecido por Amat (2020), el AUC varía de 0.5 a 1.0 y se interpreta en cinco niveles distintos. Un AUC en el intervalo de 0.9 a 1.0 indica una alta exactitud del modelo, mientras que un AUC entre 0.5 y 0.6 refleja una precisión mínima (Arabameri *et al.*, 2020).

La sensibilidad es la medida que indica qué tan bien el modelo identifica correctamente los casos positivos y es calculada por la fracción de verdaderos positivos entre la suma de verdaderos positivos y falsos negativos. Esta relación se establece para entender la efectividad del modelo al detectar los casos de interés y se formula matemáticamente en la Ecuación 5.

Ecuación 5. Tasa de verdaderos positivos

$$\text{Sensibilidad} = \frac{VP}{VP + FN}$$

La especificidad indica la proporción de datos correctamente identificados como "verdaderos negativos" (VN) respecto al total de datos clasificados como negativos, es decir, FP más VN. Su cálculo se basa en la Ecuación 6.

Ecuación 6. Especificidad de los datos

$$\text{Especificidad} = \frac{VN}{FP + VN}$$

El índice de Kappa, es un método estadístico utilizado para medir la concordancia entre dos observadores o herramientas de medición en la evaluación de un mismo fenómeno. Este coeficiente ajusta la proporción de concordancia esperada para tener en cuenta el efecto del azar, proporcionando una medida más precisa de la concordancia real (Galparsoro y Pita, 2010). La Ecuación 7 ilustra cómo se calcula este coeficiente, destacando su capacidad para ofrecer una evaluación robusta de la fiabilidad de las observaciones.

Ecuación 7. Índice kappa

$$\text{Kappa} = \frac{P_0 - P_e}{1 - P_e}$$

Donde:

P_0 = proporción de concordancia observada

P_e = proporción de concordancia esperada por el azar

El índice Kappa se deriva como un estadístico asociado con la matriz de confusión, que refleja la proporción de concordancia observada en relación con la concordancia máxima posible (Abraira, 2001). Este coeficiente varía de 0 a 1, siendo valores superiores a 0.9 indicativos de una concordancia casi perfecta (Landis y Koch, 1977). La matriz de confusión (Figura 9) consiste en una tabulación cruzada de las clases observadas y pronosticadas, lo que facilita la visualización del rendimiento del modelo (Paredes, 2020).

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

Figura 12. Matriz de confusión

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

La matriz de confusión proporcionó información adicional, como la exactitud (la proporción de casos que el modelo predijo correctamente en relación con todos los casos evaluados), así como la sensibilidad y la especificidad. La Tabla 10 muestra las principales funciones utilizadas en R para calcular estas medidas.

Tabla 10. Clases para la reclasificación de la probabilidad de ocurrencia de incendios

| <i>Descripción</i> | <i>Función en R</i> | <i>Argumentos</i> |
|-------------------------------------|--|--|
| Curva de ROC: paquete (pROC) | <code>roc (predictor, response)</code> | El "Predictor" corresponde a las probabilidades estimadas para cada clase, mientras que el "Response" es un valor numérico o de caracteres que indica la clase verdadera a la que pertenece cada observación, codificada como "0" para controles y "1" para casos. |
| Área bajo la curva AUC | <code>auc(roc)</code> | Objeto de la función ROC. |

| | | |
|----------------------------|--|---|
| Matriz de confusión | <code>confusionMatrix</code> (<code>data_prediccion</code> , <code>output_real</code> , <code>positivo = ""</code>) | "Data_prediccion" representa un objeto o factor que contiene las clases previstas, mientras que "Output_real" es un objeto o factor que contiene las clases verdaderas a las que pertenece cada observación. "Positivo" es una cadena de caracteres opcional que identifica el nivel de factor asociado con un resultado clasificado como "positivo". |
|----------------------------|--|---|

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

5.6 Delimitación de las áreas

La literatura ofrece múltiples métodos para la delimitación o comúnmente llamada zonificación. Un método implica ponderar áreas de riesgo basándose en factores antrópicos, topográficos y de combustibilidad, correlacionándolos con la frecuencia histórica de incendios (Xu *et al.*, 2006). Otro método analiza patrones espaciales y temporales de incendios, considerando causas y la alternancia entre periodos de alta y baja incidencia (Hering *et al.*, 2009). También se ha propuesto definir el riesgo como el producto de la susceptibilidad y la probabilidad anual de incendios de cada píxel, usando mapas estructurales y estacionales (Bergonse *et al.*, 2022).

Investigaciones actuales han utilizado el Índice de Moran, descubriendo una relación espacial importante en la probabilidad de incendios, mostrando patrones de concentración (Shao, Wang y colaboradores, 2022; Vergara y Molina, 2020). En nuestro enfoque, aplicamos técnicas de agrupamiento para identificar patrones tanto espaciales como temporales, un método que se detalla en la Figura 13.

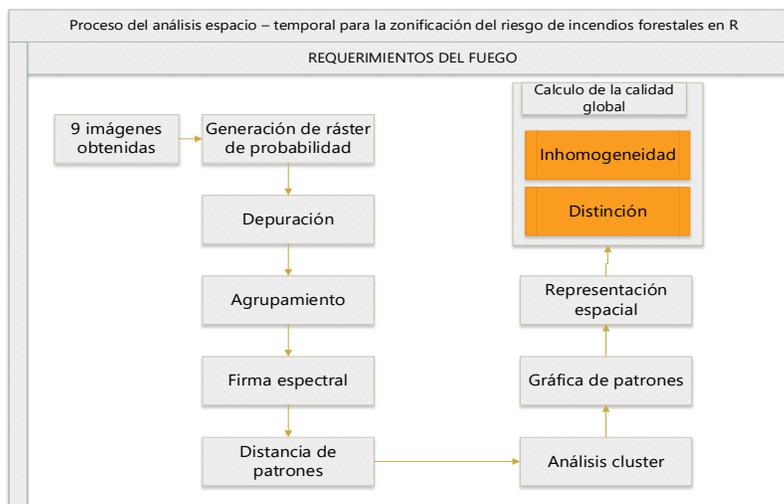


Figura 13. Proceso del análisis espacio – temporal para la zonificación

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).

El modelo MARS, seleccionado por su óptimo rendimiento (mayor especificidad y precisión), se utilizó para generar mapas mensuales de probabilidad de incendios en 2023 mediante Google Earth Engine (GEE). En la etapa de postprocesamiento, los píxeles afectados por nubosidad en las imágenes se reemplazaron con valores nulos utilizando QGIS 3.36.3, garantizando la integridad espacial de los datos. El agrupamiento cronológico de los archivos raster se llevó a cabo utilizando el paquete "motif" de R (Nowosad, 2021), que permite identificar patrones en series temporales (Andrienko *et al.*, 2010). Para calcular la firma espectral de una ventana de 25 píxeles, se utilizó el método de divergencia de Jensen-Shannon para calcular la distancia entre los patrones de cada zona. Posteriormente, se realizó un análisis de clúster utilizando el método de Ward 2 (varianza mínima de Ward). La calidad global de la agrupación se calculó por medio de la inhomogeneidad y distinción, a través de la Ecuación 8.

Ecuación 8. Calidad Global

$$Calidad\ global = 1 - \left(\frac{inhomogeneidad}{distinción} \right)$$

La inhomogeneidad es una medida que indica el grado de distancia entre los objetos dentro del clúster, con valores que oscilan entre 0 y 1. Valores cercanos a 0 indican patrones consistentes dentro del clúster, mientras que la distinción representa la distancia media entre el clúster en cuestión y los demás.

Para evaluar los resultados, se pueden utilizar diversas herramientas de visualización que facilitan el análisis del modelo, resaltando las zonas con mayor riesgo de incendios forestales según diferentes grados de susceptibilidad. Además, el modelo se puede actualizar y mejorar continuamente a medida que se disponen de nuevos datos, aumentando así su precisión y capacidad predictiva con el tiempo. Estas predicciones son esenciales para tomar decisiones informadas y planificar acciones futuras de manera más eficaz, como se observa en la Figura 14.

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

Figura 14. Grado de susceptibilidad

Nota: Adaptado de “Assessment oh Three Machine Learning Techniques with Open-Access Geographic Data for Forest Fire Susceptibility Monitoring-Evidence form Southern Ecuador” por Reyes y Loján (2022).

La Figura 15 detalla todo el proceso de generación de los modelos de susceptibilidad a incendios forestales. Estas predicciones se integran en Google Earth App, ofreciendo una herramienta valiosa para la gestión de riesgos de incendios forestales.

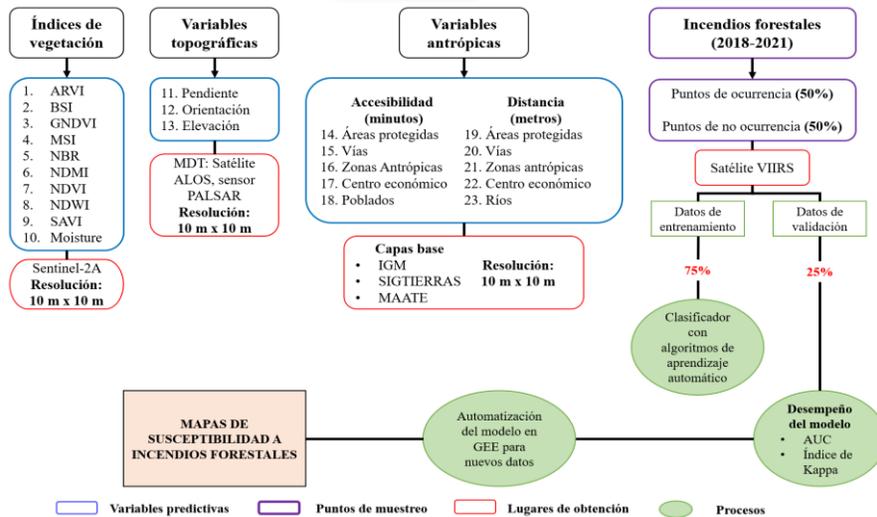


Figura 15. Proceso para modelos de susceptibilidad

Nota: Adaptado de “Assessment oh Three Machine Learning Techniques with Open-Access Geographic Data for Forest Fire Susceptibility Monitoring-Evidence form Southern Ecuador” por Reyes y Loján (2022).

6. Resultados

6.1 Establecer una línea base de las variables predictivas para la determinación de la ocurrencia de incendios forestales en el cantón Pindal

Se desarrolló una base de datos espacial del período 2018 -2021 (Anexo 4), siguiendo la metodología establecida por Reyes y Loján (2022). Esta metodología clasifica las variables en tres categorías principales: variables topográficas (Figura 16), variables de interacción antrópica (Figuras 17 y 18) y variables relacionadas con el estado de la vegetación, comúnmente referidas como índices espectrales (Figura 19). Esta categorización permite un análisis detallado y estructurado de los diferentes factores que influyen en el riesgo de incendios forestales.

El cantón Pindal presenta un predominio de elevaciones entre 340 y 800 m s.n.m., abarcando el 67% de su superficie. Estas zonas se clasifican en: Franjas bajas (340-600 m s.n.m.): Accesibilidad óptima para respuesta rápida ante incendios. Franjas medias (600-800 m s.n.m.): Facilitan intervenciones operativas, aunque con limitaciones moderadas por pendientes variables. En contraste, las áreas elevadas (800-1670 m s.n.m.), que cubren el 33% del territorio, presentan un relieve accidentado (quebradas pronunciadas, laderas empinadas), lo que dificulta el acceso de equipos de emergencia y extinción, prolongando los tiempos de respuesta.

En el cantón Pindal, la distribución de la orientación del terreno muestra una homogeneidad notable, con cada rango de dirección abarcando una cuarta parte de su superficie total. No obstante, en este contexto ecuatorial, las laderas orientadas entre 190° y 360° (53.36% del área total) reciben radiación solar directa durante las horas vespertinas periodo de máximas temperaturas y mínima humedad relativa, lo que incrementa la temperatura superficial y reduce la humedad de la biomasa, elevando así la propensión a incendios. Por el contrario, las orientaciones entre 0° y 180° presentan menor incidencia solar en las horas críticas, mitigando la sequedad del combustible vegetal. Dada la predominancia de un clima cálido-seco en la zona, las exposiciones al suroeste y oeste asociadas a mayor insolación acumulada registran el riesgo más alto de ignición, debido a la sinergia entre aridez, calor prolongado y acumulación de material combustible.

La variación en la pendiente del cantón Pindal se clasifica principalmente como moderada: el 85.78% de su territorio presenta inclinaciones $\leq 20\%$ (equivalente a $\leq 11.3^\circ$), consideradas aptas para actividades preventivas convencionales. Las pendientes entre 21% y 40% (12.58% del área,

≈11.3°-21.8°) representan zonas de riesgo intermedio, donde la implementación de medidas de control requiere estrategias adaptadas a la topografía, como cortafuegos en curvas de nivel o sistemas de riego móvil. Cabe destacar que, en el contexto local, las pendientes agrícolas suelen superar el 100% (≈45°), comunes en áreas de cultivo en laderas. Sin embargo, el estudio actual solo registra pendientes >40% (≈21.8°) en el 1.64% del área analizada, las cuales, aunque técnicamente no son escarpadas en comparación con la realidad provincial, presentan desafíos operativos por la acumulación de material combustible en microvertientes y la limitada accesibilidad para equipos de respuesta.

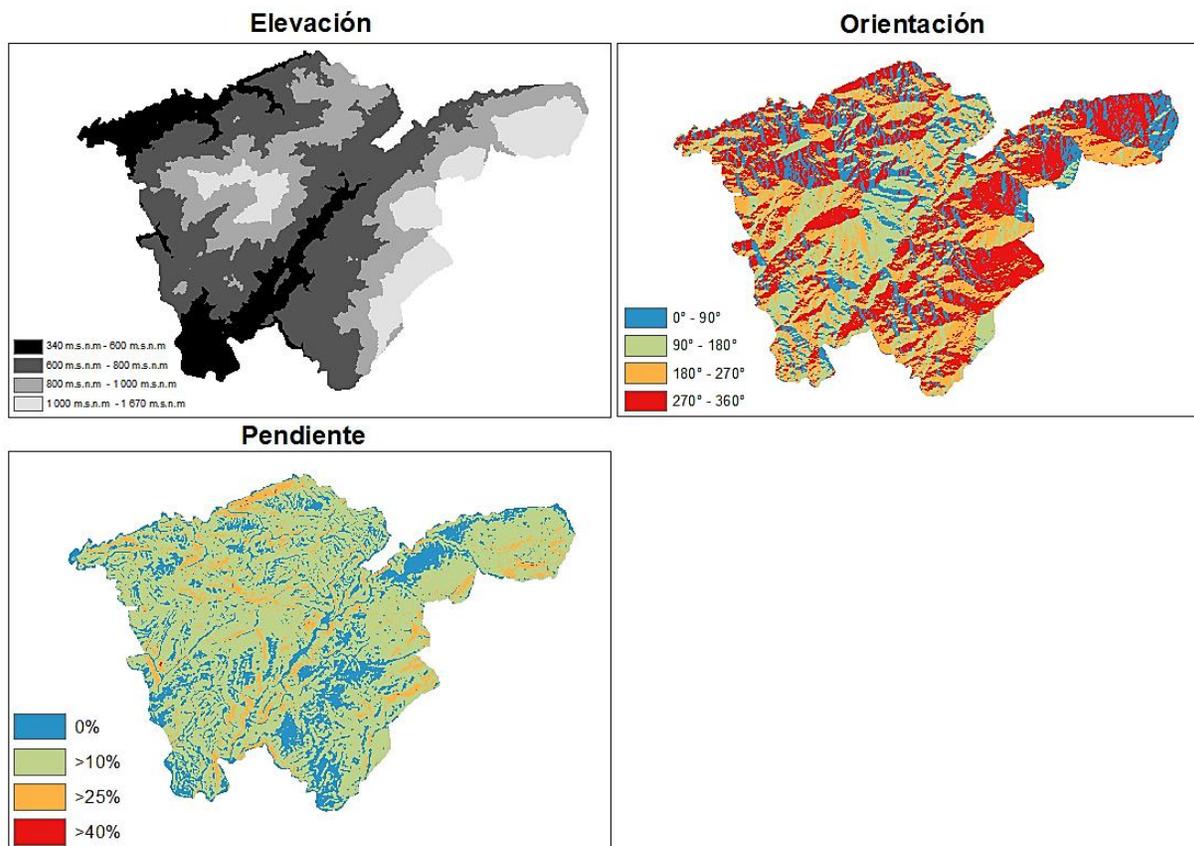


Figura 16. Variables topográficas

La Figura 17 ilustra las variables de interacción antrópica relacionadas con las distancias, fundamentales para identificar áreas de alto riesgo. El 81,34 % del territorio, representado en azul, se encuentra en proximidad a zonas antrópicas, lo que facilita una intervención rápida. En contraste, las áreas en rojo, que abarcan solo el 5,73 % del territorio, presentan mayores desafíos logísticos

para la movilización de recursos y personal. Adicionalmente, en cuanto a la distancia a centros económicos, se determinó que el 47,38 % del territorio, también representado en azul, está muy cerca de estos centros, lo que optimiza el acceso a recursos. Por otro lado, el 6,57 % del territorio, señalado en rojo, podría enfrentar retrasos significativos en la respuesta debido a su lejanía.

El 85,24 % del territorio, ubicado a una distancia de entre 0 y 300 metros de las vías principales, permite un acceso rápido para la contención de incendios. Sin embargo, el 1,23 % del área, representado en rojo, enfrenta desafíos significativos para una respuesta ágil. Por otro lado, un 75,74 % del territorio, situado a distancias de entre 0 y 450 metros de los ríos, facilita el acceso a recursos hídricos esenciales para combatir incendios. En contraste, el 9,58 % del área se encuentra a más de 900 metros de distancia, lo que podría dificultar la obtención rápida de agua.

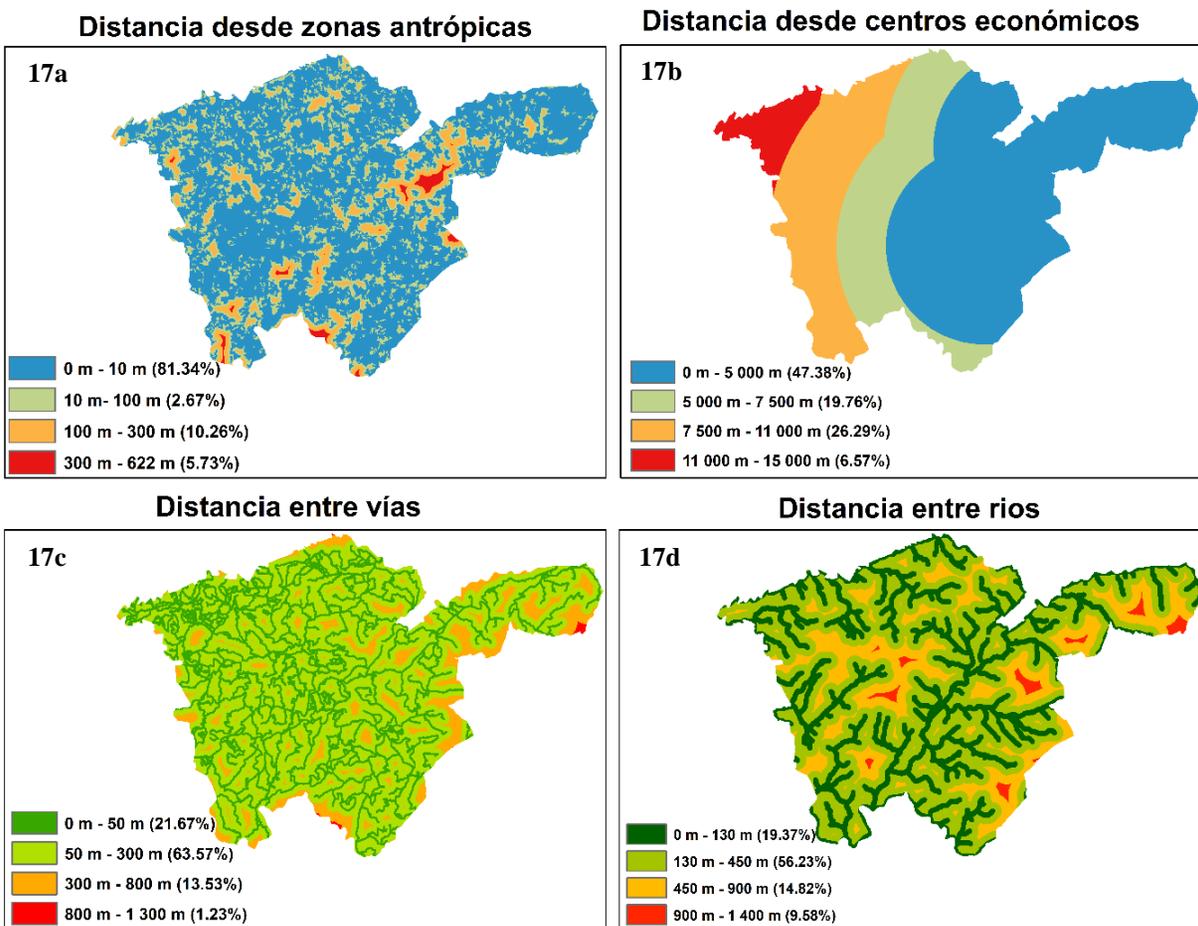


Figura 17. Variables de interacción antrópica (distancia)

La Figura 18 presenta las variables de interacción antrópica, enfocadas específicamente en la accesibilidad, un factor crucial para una respuesta rápida y efectiva ante incendios forestales. Sin embargo, es importante destacar que la proximidad a diversas áreas también puede aumentar la probabilidad de incendios debido a la intensificación de la actividad humana y el uso de recursos naturales. En cuanto a la accesibilidad a poblados, el 46,27 % del territorio, representado en azul, permite una movilización rápida de ayuda, mientras que solo el 0,21 % del área, marcado en rojo, presenta dificultades de acceso, lo que puede retrasar la respuesta en situaciones de emergencia. En relación con la accesibilidad a centros económicos, se ha identificado que el 29,34 % del territorio, situado a entre 0 y 40 minutos de distancia, cuenta con una capacidad de respuesta más efectiva, facilitando el acceso rápido a recursos y personal. Por otro lado, el 54,57 % del área, señalada en rojo, enfrenta mayores desafíos para acceder a los sitios, lo que complica las intervenciones en caso de incendios.

En el cantón Pindal, la proximidad a zonas antrópicas se emplea como indicador clave de vulnerabilidad a incendios: el 48.13% del territorio, ubicado a <30 minutos de acceso a estas áreas, evidencia alta exposición a factores antrópicos (quemadas agrícolas, tránsito humano), mientras que el 48.34% (a <20 minutos) refleja máxima susceptibilidad por su cercanía inmediata a actividades humanas. En contraste, el 6.33% (acceso >60 minutos) corresponde a zonas aisladas con bajo riesgo de ignición antrópica, pero con desafíos en detección y control por limitada infraestructura. Por otro lado, el 6.41% (acceso >40 minutos) combina aislamiento moderado con vegetación densa en laderas remotas, generando escenarios de propagación rápida ante eventos naturales como rayos, lo que exige estrategias específicas de monitoreo proactivo.

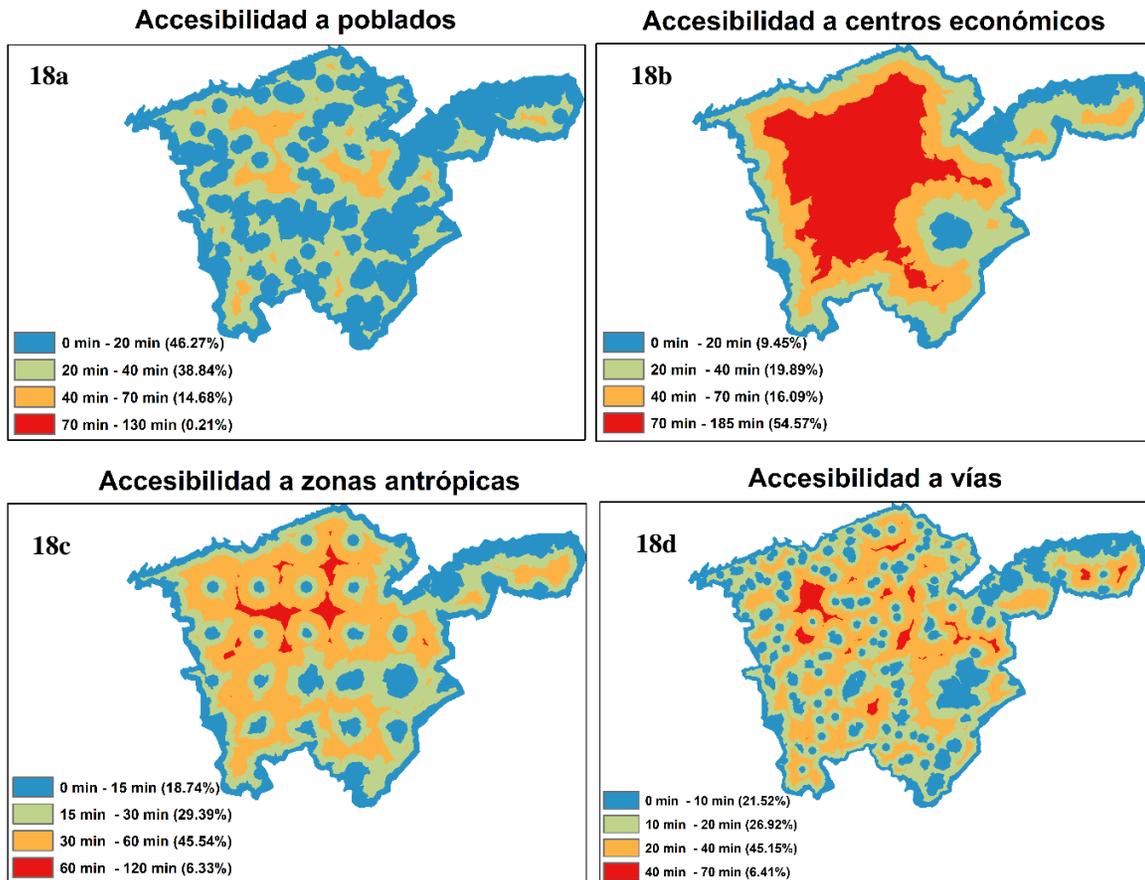


Figura 18. Variables de interacción antrópica (accesibilidad)

Debido a la notable variabilidad temporal de las variables climáticas, influenciada por las características del terreno, es más efectivo utilizar variables relacionadas con la vegetación en lugar de datos climáticos en un modelo de evaluación. Los índices de vegetación son más estables y accesibles, proporcionando una representación precisa del estado del combustible vegetal, que es el principal factor que determina la susceptibilidad de los ecosistemas al fuego.

La Figura 19 presenta las variables asociadas con el estado de la vegetación, evaluadas mediante índices espectrales. Estos índices son herramientas para analizar la salud y el estrés de la vegetación, ofreciendo información sobre la densidad de la cobertura vegetal, la humedad del suelo y la presencia de materia vegetal seca, estos factores que afectan directamente la inflamabilidad de una zona. A continuación, se detallan y analizan cada uno de estos índices:

Se determinó que el Índice de Estrés Hídrico (MSI) indica que las áreas representadas en morado oscuro experimentan un mayor estrés hídrico, lo que refleja una vegetación más seca y,

por lo tanto, más susceptible a incendios. En contraste, las zonas en morado claro presentan menor estrés hídrico y una vegetación más saludable. El Índice de Vegetación de Diferencia Normalizada (NDVI) destaca las regiones con alta biomasa, donde las áreas en morado representan una mayor densidad de vegetación, mientras que las zonas en verde y rosado muestran una menor densidad. El Índice de Relación de Normalización (NBR) revela que las regiones en marrón oscuro presentan una mayor severidad de quemado, mientras que las áreas en amarillo han sido menos afectadas por incendios recientes. El Índice de Agua de Diferencia Normalizada (NDWI) muestra que las áreas en azul tienen una mayor disponibilidad de agua, lo que reduce su inflamabilidad, mientras que las áreas en rojo indican un menor contenido de agua.

El Índice de Vegetación de Diferencia Normalizada de Verde (GNDVI) revela que las áreas en azul oscuro tienen un mayor contenido de clorofila y una vegetación más saludable, mientras que las zonas en azul claro presentan una vegetación menos densa. El Índice de Suelo de Diferencia Normalizada (BSI) indica que las áreas en azul oscuro tienen una mayor presencia de suelo expuesto, lo que incrementa el riesgo de erosión y disminuye la humedad del suelo. El Índice de Humedad de Diferencia Normalizada (NDMI) evalúa la humedad del suelo, con áreas en verde oscuro mostrando suelos más secos y áreas en verde claro indicando suelos más húmedos. El Índice de Humedad (Moisture) señala que las áreas en blanco presentan mayor humedad, mientras que las áreas en verde tienen una menor humedad, lo que incrementa la susceptibilidad al fuego. El Índice de Vegetación Ajustado al Suelo (SAVI) muestra que las áreas en rojo oscuro tienen una alta densidad de vegetación, mientras que las áreas en rosado claro presentan una menor densidad. Finalmente, el Índice de Vegetación de Relación Ajustada (ARVI) corrige los efectos atmosféricos, con áreas en rojo oscuro indicando vegetación más densa y saludable, y áreas en rosado sugiriendo vegetación menos densa.

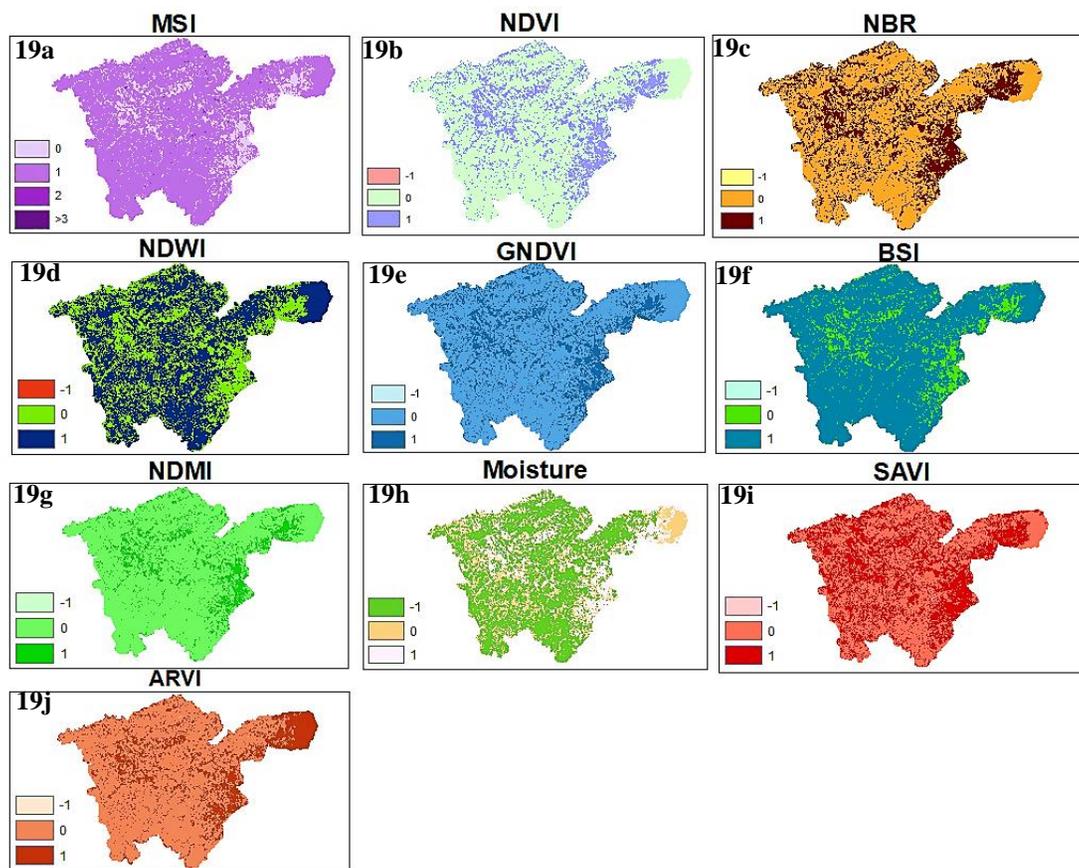


Figura 19. Variables del estado de la vegetación

6.2 Evaluar algoritmos de Machine Learning para la generación de un modelo de susceptibilidad a incendios forestales en el cantón Pindal

Después de llevar a cabo el análisis de multicolinealidad en los modelos de Regresión Logística (RL), Árboles de Decisión Logística (LMT) y Splines de Regresión Adaptativa Multivariante (MARS) para el cantón Pindal, se excluyeron variables con Factor de Inflación de Varianza (VIF) > 10 , entre ellas MSI, NBR, NDWI, GNDVI, BSI, NDMI, SAVI y ARVI, por su alta correlación. Las variables que cumplieron el umbral de VIF < 10 , garantizando independencia estadística, fueron los índices espectrales NDVI y Moisture, detallados en la Tabla 11 como predictores válidos para el estudio.

La multicolinealidad ocurre cuando una variable en un modelo de regresión puede ser predicha en gran medida por las otras variables independientes. Esto puede causar problemas en la estimación de los coeficientes de regresión. El VIF mide cuánta inflación existe en la varianza de

un coeficiente de regresión debido a la colinealidad con otras variables en el modelo. Valores de VIF altos (superiores a 10) indican una fuerte multicolinealidad y sugieren que los coeficientes estimados son inestables y pueden no ser interpretables. Según Reyes y Loján (2022), valores de VIF superiores a 10 se consideran críticos y requieren atención. En este caso, los valores de VIF de los índices NDVI y Moisture son menores a 10, lo que indica que no presentan problemas de multicolinealidad significativos. Esto significa que estos índices son fiables para incluir en el análisis sin riesgo significativo de multicolinealidad.

Tabla 11. *Resultados del Factor de Inflación de Varianza en las variables para los modelos RL, LMT y MARS*

| Variables | VIF |
|------------------|------------|
| NDVI | 6,338 |
| Moisture | 7,904 |

Como se observa en la Tabla 12, los índices de vegetación, específicamente NDVI y Moisture, fueron identificados como las variables más importantes en los modelos de Regresión Logística (RL), Splines de Regresión Adaptativa Multivariante (MARS) y Árboles de Decisión Logística (LMT). Estos índices destacan por su capacidad para captar variaciones en la humedad, temperatura, precipitación del suelo y la vegetación, lo que los convierte en indicadores clave para el análisis de la susceptibilidad a incendios forestales.

Tabla 12. *Importancia de las variables en la modelación de probabilidad de ocurrencia de incendios forestales utilizando en los modelos RL, LMT y MARS*

| Variables | Importancia |
|------------------|--------------------|
| Moisture | 1,8177942 |
| NDVI | 1,7987872 |

Nota: Para obtener la importancia de las variables se utilizó el comando varImp del paquete Caret en R especificado por Reyes y Loján (2022).

En la Figura 20 se presentan las variables utilizadas en los modelos RL, LMT y MARS. Entre las variables destacadas se encuentran los índices espectrales, que fluctúan en función de las condiciones del suelo y la vegetación, reflejando así su naturaleza dinámica. Debido a esta

característica, estos índices pueden actualizarse periódicamente para reflejar cambios en las condiciones ambientales, asegurando que el modelo mantenga su precisión y relevancia a lo largo del tiempo. Esta capacidad de actualización permite que las predicciones y análisis sean coherentes con las condiciones actuales del entorno. Además, el uso de índices espectrales en estos modelos subraya la importancia de incorporar datos variables y adaptativos en modelos predictivos, mejorando su capacidad de respuesta a los cambios en el ecosistema del cantón Pindal. Esto asegura que la generación de modelos de susceptibilidad de incendios forestales sea siempre basada en la información más actualizada y precisa disponible.

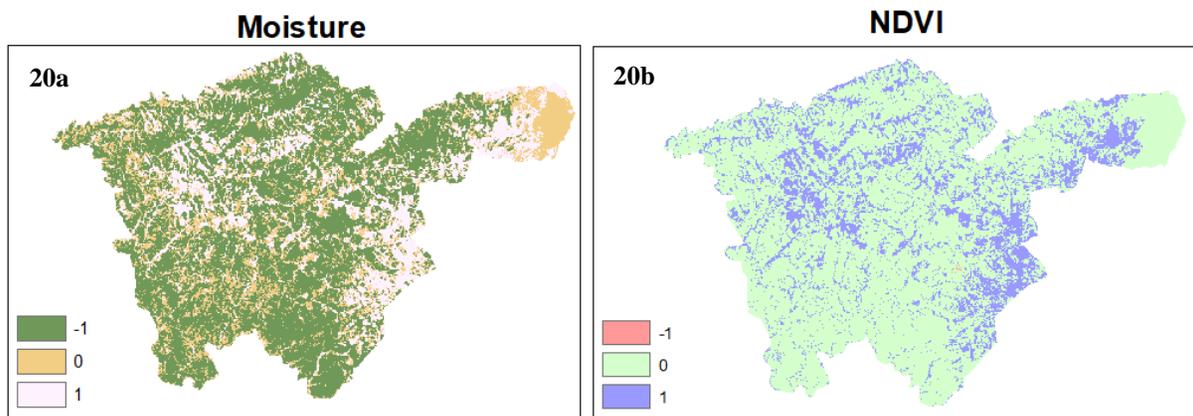


Figura 20. Variables que no presentan multicolinealidad para los modelos RL, LMT y MARS
Nota: Los mapas fueron generados en ArcMap. Los índices corresponden al 02 de noviembre del 2021.

Los resultados de la validación de los modelos se presentan en la Tabla 13. Para el conjunto de entrenamiento, el modelo de Árboles de Decisión Logística (LMT) mostró un nivel de precisión moderado, con un AUC entre 0,6 y 0,7. Este rango se mantuvo para el conjunto de validación. El modelo de Regresión Logística (RL) presentó un AUC entre 0,7 y 0,8 tanto para el conjunto de entrenamiento como para el de validación, lo que indica una mayor precisión. Por otro lado, el modelo de Splines de Regresión Adaptativa Multivariante (MARS) demostró una mayor capacidad para clasificar los datos, con un AUC entre 0,8 y 0,9 en ambos conjuntos de datos. En base a la medida estadística del Área Bajo la Curva (AUC), el modelo MARS se destacó como el más preciso, seguido por el modelo RL, y finalmente el modelo LMT, que resultó ser el menos fiable en términos de precisión.

En cuanto al índice de Kappa, ¿los resultados para el conjunto de entrenamiento mostraron que el modelo LMT tenía un nivel de precisión bajo? con un Kappa inferior a 0,4, manteniendo este nivel en el conjunto de validación. El modelo RL mostró un Kappa inferior a 0,7 en el conjunto de entrenamiento, disminuyendo a un Kappa inferior a 0,4 en el conjunto de validación. En contraste, el modelo MARS presentó un Kappa superior a 0,7 tanto en el conjunto de entrenamiento como en el de validación.

Según el índice Kappa, el modelo MARS fue el más eficaz en la clasificación de datos, seguido por el modelo RL, con el modelo LMT siendo el menos fiable. La consistencia en el desempeño del modelo MARS resalta su capacidad superior para manejar los datos del cantón Pindal, tanto en términos de AUC como de Kappa.

Tabla 13. Rendimiento de los modelos MARS, RL y LMT

| Medias estadísticas | Set de entrenamiento | | | Set de validación | | |
|--------------------------|----------------------|--------|--------|-------------------|--------|--------|
| | MARS | RL | LMT | MARS | RL | LMT |
| Área bajo la curva (AUC) | 0,929 | 0,8565 | 0,6538 | 0,8935 | 0,8358 | 0,6295 |
| Precisión | 0,8846 | 0,7540 | 0,6386 | 0,8571 | 0,7129 | 0,6046 |
| Índice Kappa | 0,7692 | 0,675 | 0,3077 | 0,7538 | 0,6483 | 0,3395 |
| Sensibilidad | 0,9231 | 0,814 | 0,6923 | 0,8846 | 0,8075 | 0,6948 |
| Especificidad | 0,8462 | 0,836 | 0,6154 | 0,8432 | 0,8291 | 0,6394 |

Nota: Los resultados se obtuvieron en R mediante la aplicación del comando AUC del paquete pROC y confusion Matrix del paquete caret

En la Figura 21 se presenta una el número total de datos clasificados correctamente como puntos de incendio y puntos de no incendio (control), obtenidos a partir de las matrices de confusión generadas en R como resultado del entrenamiento y la validación de los modelos.

Conjunto de Entrenamiento:

- El modelo de LMT clasificó correctamente 37 datos, mientras que cometió errores en 29 datos.
- El modelo RL clasificó correctamente 40 datos en el conjunto de entrenamiento, con 26 errores.
- El modelo MARS fue el más destacado por su precisión, clasificando correctamente 55 datos y cometiendo solo 11 errores.

Conjunto de Validación:

- El modelo LMT clasificó correctamente 13 datos y cometió errores en 9 casos.
- El modelo RL tuvo 15 clasificaciones correctas y 7 errores
- El modelo MARS mantuvo su buen desempeño, clasificando correctamente 19 datos y cometiendo solo 3 errores.

Estos resultados resaltan la eficacia del modelo MARS en comparación con los otros modelos, tanto en el entrenamiento como en la validación, mostrando mejores clasificaciones con menos errores.

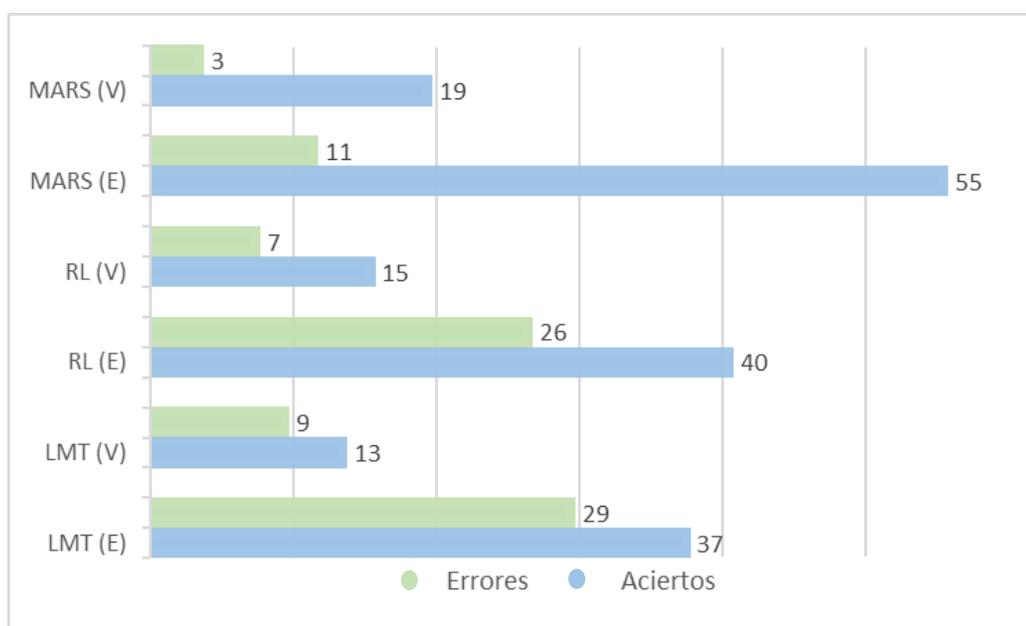


Figura 21. Número de datos de los sets de entrenamiento (E) y de validación (V) que fueron clasificados como correctos (aciertos) e incorrectos (errores) para los modelos MARS, RL y LMT

Los resultados de los modelos, presentados en la Figura 22, revelaron que los modelos LMT y RL experimentaron un ajuste limitado, lo que se tradujo en predicción bajas y no precisas para las zonas con probabilidad de ocurrencia de incendios. Por otro lado, el modelo MARS logró un ajuste más relevante a los datos, permitiendo una identificación más precisa de las áreas con diferentes probabilidades de ocurrencia de incendios. La escala utilizada, que va del 1 al 5, clasifica los valores de los píxeles en clases de probabilidad de ocurrencia de incendios, desde muy baja (1) hasta muy alta (5). Esta clasificación permite una visualización clara y fácil de las zonas con mayor

y menor riesgo de incendios, lo que es fundamental para la toma de decisiones efectiva en la gestión de riesgos y la protección de los ecosistemas.

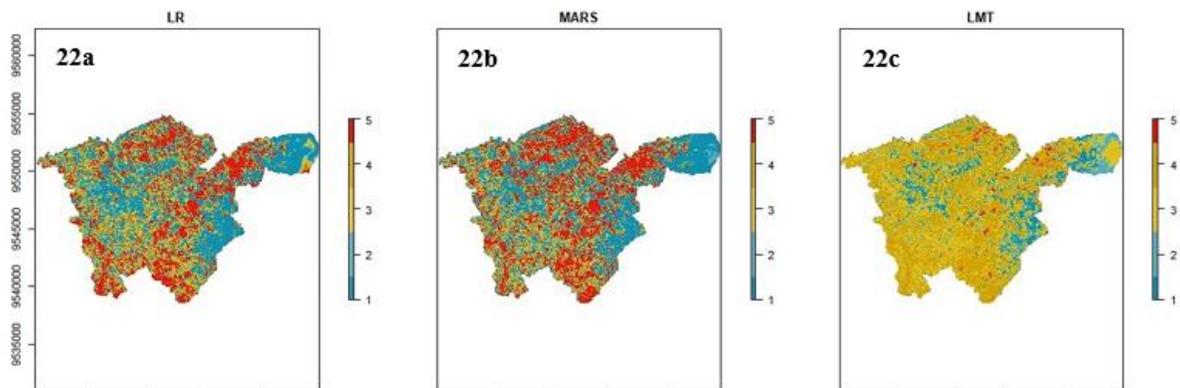


Figura 22. Mapeo de probabilidad de ocurrencia de incendios forestales para el cantón Pindal utilizando algoritmos de aprendizaje automático supervisado. a) Regresión Logística (RL), b) Splines de Regresión Adaptativa Multivariante (MARS) y c) Árboles de Decisión Logística (LMT)

6.3 Automatizar el modelo de susceptibilidad a incendios forestales para mapeo de zonas de riesgo a incendios forestales en el cantón Pindal

Para reconocer los patrones de agrupamiento, se calcularon las firmas espectrales de un mosaico compuesto por nueve imágenes de ráster de probabilidad de incendios forestales, generadas en Google Earth Engine (GEE) para el período de enero a diciembre de 2023. Se aplicó el modelo MARS debido a su mayor capacidad de predicción en comparación con otros modelos. El agrupamiento se definió en cinco clases, logrando una buena separación entre los datos.

La Figura 23 ilustra la identificación de grupos de píxeles según sus firmas espectrales. El clúster con la mayor cantidad de píxeles es el clúster cuatro, que comprende 690 píxeles y cubre el 25,17 % de la superficie del cantón Pindal, equivalente a 4312.5 hectáreas. En segundo lugar, se encuentra el clúster dos, con 658 píxeles, que abarca el 24,01 % de la superficie del cantón, es decir, 4112.5 hectáreas. El clúster uno ocupa el tercer lugar, con 650 píxeles que representan el 23,71 % de la superficie del cantón, equivalentes a 4062.5 hectáreas. En cuarto lugar, está el clúster tres, con 482 píxeles, cubriendo el 17,58 % de la superficie del cantón, lo que corresponde a 3012.5 hectáreas. Finalmente, el clúster cinco, cuenta con 261 píxeles, cubriendo el 9,52 % de la superficie del cantón, lo que equivale a 1631.5 hectáreas.

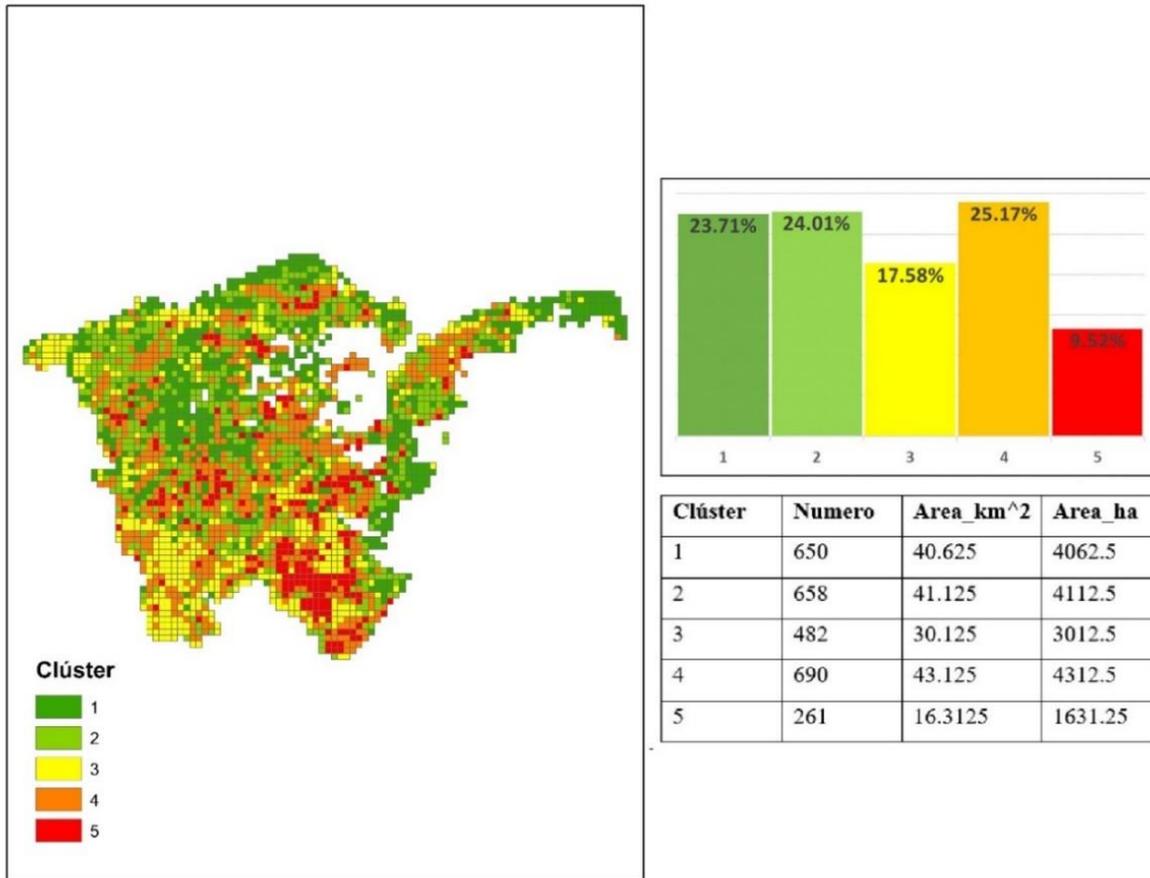


Figura 23. Identificación de clústers en las imágenes ráster de probabilidad de ocurrencia de incendios forestales del cantón Pindal

Nota: Gráfica obtenida en R utilizando la función “lsp_add_clusters”. El clustering fue jerárquico utilizando el método de Ward.

La Figura 24 muestra el análisis espacio-temporal de los clústeres para cada período evaluado durante el periodo enero a diciembre del 2023. En esta figura se evidencia que la probabilidad de incendios forestales varía a lo largo del cantón Pindal. Los meses de septiembre a enero presentan una mayor probabilidad de ignición, mientras que, de febrero a agosto, la probabilidad de ignición es menor.

El análisis identifica áreas con baja probabilidad de ocurrencia de incendios, clasificadas como clase 1, y áreas con alta probabilidad de ocurrencia, clasificadas como clase 5. Las zonas de alta probabilidad están predominantemente ubicadas cerca de las áreas urbanas del cantón, donde

los factores antrópicos son más significativos. Esta zonificación destaca la influencia de la actividad humana en la susceptibilidad a los incendios forestales.

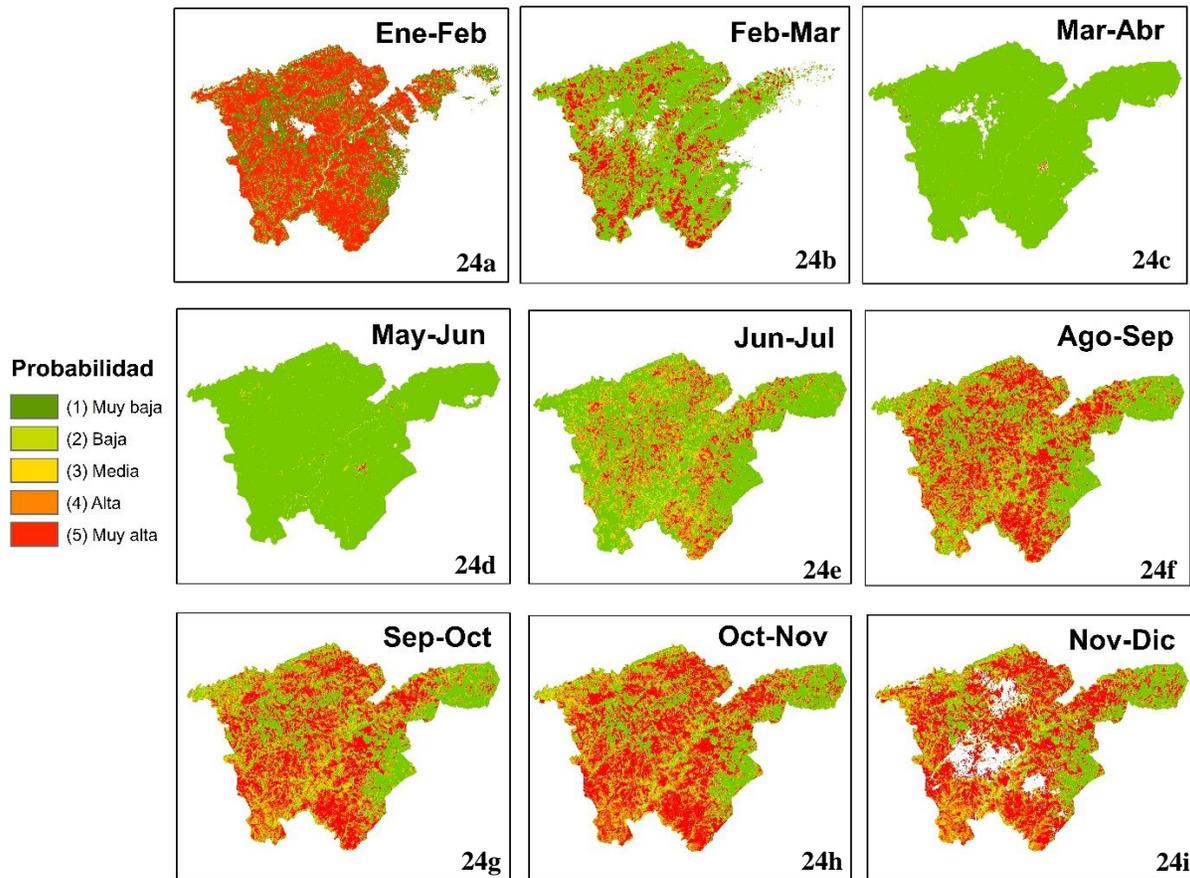


Figura 24. Zonificación del riesgo a incendios forestales, basado en un análisis espacio temporal, para el cantón Pindal, enero - diciembre del 2023

Nota: Gráfica generada en R, a partir de las imágenes reclasificadas (modelo RL) obtenidas de GEE en donde se eliminaron los píxeles (función “cloud.mask”) que presentan una probabilidad > 40 % de presencia de nubes. Las imágenes se reclasifican en 5 clases de probabilidad de ocurrencia de incendios.

La Tabla 14 muestra el análisis espacio-temporal porcentual de los clústeres de probabilidad de incendios forestales en el cantón Pindal durante el año 2023. Los períodos con mayor probabilidad de incendios se destacan: septiembre-octubre (29,51 %), octubre-noviembre (34,68 %), noviembre-diciembre (34,66 %), enero-febrero (54,16 %) y febrero-marzo (17,82 %). En contraste, los períodos con menor probabilidad de incendios se encuentran: marzo-abril (0,11 %), mayo-junio (0,10 %), junio-julio (7,83%), y agosto-septiembre (29,36 %). Además, se observa que

la nubosidad es un factor relevante, con los valores más altos presentes en noviembre-diciembre (7,96 %) y enero-febrero (7,55 %), lo cual puede influir en la variabilidad de la probabilidad de incendios. Estos resultados se asemejan a las condiciones propias de la zona expuestas en por el GAD municipal de Pindal en 2023 como las temporadas de lluvias y sequías, además las áreas de alta probabilidad de incendios están predominantemente ubicadas cerca de las zonas urbanas y vías principales.

Tabla 14. *Porcentajes de zonificación del riesgo a incendios forestales, basado en un análisis espacio temporal, para el cantón Pindal, enero - diciembre del 2023*

| Ene-Feb | Area_km^2 | Porcentaje | Feb-Mar | Area_km^2 | Porcentaje | Mar-Abr | Area_km^2 | Porcentaje |
|--------------|-----------|------------|--------------|-----------|------------|--------------|-----------|------------|
| Nubosidad | 14.6449 | 7.55% | Nubosidad | 11.9513 | 6.16% | Nubosidad | 6.43 | 3.31% |
| (1) Muy baja | 47.409 | 24.44% | (1) Muy baja | 111.46 | 57.45% | (1) Muy baja | 182.2955 | 93.97% |
| (2) Baja | 7.2831 | 3.75% | (2) Baja | 14.368 | 7.41% | (2) Baja | 4.2656 | 2.20% |
| (3) Media | 6.6333 | 3.42% | (3) Media | 10.6262 | 5.48% | (3) Media | 0.5304 | 0.27% |
| (4) Alta | 12.9505 | 6.68% | (4) Alta | 11.0219 | 5.68% | (4) Alta | 0.2622 | 0.14% |
| (5) Muy alta | 105.0792 | 54.16% | (5) Muy alta | 34.5726 | 17.82% | (5) Muy alta | 0.2163 | 0.11% |
| May-Jun | Area_km^2 | Porcentaje | Jun-Jul | Area_km^2 | Porcentaje | Ago-Sep | Area_km^2 | Porcentaje |
| Nubosidad | 1.389 | 0.72% | Nubosidad | 1.0062 | 0.52% | Nubosidad | 0.8857 | 0.46% |
| (1) Muy baja | 187.71 | 96.76% | (1) Muy baja | 114.2332 | 58.88% | (1) Muy baja | 72.3746 | 37.31% |
| (2) Baja | 3.1751 | 1.64% | (2) Baja | 20.2317 | 10.43% | (2) Baja | 16.8135 | 8.67% |
| (3) Media | 0.8417 | 0.43% | (3) Media | 19.769 | 10.19% | (3) Media | 16.8205 | 8.67% |
| (4) Alta | 0.681 | 0.35% | (4) Alta | 23.569 | 12.15% | (4) Alta | 30.1457 | 15.54% |
| (5) Muy alta | 0.2032 | 0.10% | (5) Muy alta | 15.1909 | 7.83% | (5) Muy alta | 56.96 | 29.36% |
| Sep-Oct | Area_km^2 | Porcentaje | Oct-Nov | Area_km^2 | Porcentaje | Nov-Dic | Area_km^2 | Porcentaje |
| Nubosidad | 0.891 | 0.46% | Nubosidad | 0.4711 | 0.24% | Nubosidad | 15.4464 | 7.96% |
| (1) Muy baja | 51.4167 | 26.50% | (1) Muy baja | 50.5061 | 26.03% | (1) Muy baja | 46.0537 | 23.74% |
| (2) Baja | 21.7866 | 11.23% | (2) Baja | 17.8228 | 9.19% | (2) Baja | 17.1597 | 8.85% |
| (3) Media | 23.1204 | 11.92% | (3) Media | 21.7937 | 11.23% | (3) Media | 19.1759 | 9.88% |
| (4) Alta | 39.5315 | 20.38% | (4) Alta | 36.1311 | 18.62% | (4) Alta | 28.9216 | 14.91% |
| (5) Muy alta | 57.2538 | 29.51% | (5) Muy alta | 67.2752 | 34.68% | (5) Muy alta | 67.2427 | 34.66% |

En la figura 25 muestra la calidad de agrupamiento de clústeres utilizando tres índices: Inhomogeneidad, Distinción, y Calidad global. Estos índices permiten evaluar la consistencia interna, la separación entre clústeres y la calidad general.

La Inhomogeneidad mide la variabilidad dentro de cada clúster. En la figura 25, los valores de inhomogeneidad varían entre 0,136 y 0,186 para todos los clústeres: estos valores, cercanos a 0, indican una buena consistencia interna dentro de cada clúster, sugiriendo que los datos dentro de cada grupo son similares y están bien definidos. La Distinción mide la diferencia entre los clústeres, con valores que oscilan entre 0,234 y 0,375: estos valores indican una separación moderada entre

los clústeres. El Clúster 5 destaca por tener la mayor distinción (0,375), lo que sugiere que es el más separado de los otros grupos.

La Calidad es un índice integral que evalúa la efectividad del agrupamiento, considerando tanto la inhomogeneidad como la distinción. Los valores de calidad para los clústeres varían entre 0,324 y 0,598: estos valores reflejan una buena calidad general de los clústeres.

El Clúster 5 tiene la calidad más alta (0,598), seguido del Clúster 1 (0,571), indicando que estos clústeres son los más efectivos en términos de agrupación. Se observa que el clúster 5 presenta los mejores resultados en términos de calidad (0,598) y distinción (0,375), lo que indica que está bien definido y claramente diferenciado de los otros clústeres. El clúster 1 también muestra una alta calidad (0,571) a pesar de tener una distinción moderada (0,317), lo que sugiere que los datos dentro de este clúster están bien agrupados. Por otro lado, el clúster 2 muestra la calidad más baja (0,324), lo que podría indicar una menor efectividad en su definición o separación respecto a los otros clústeres.

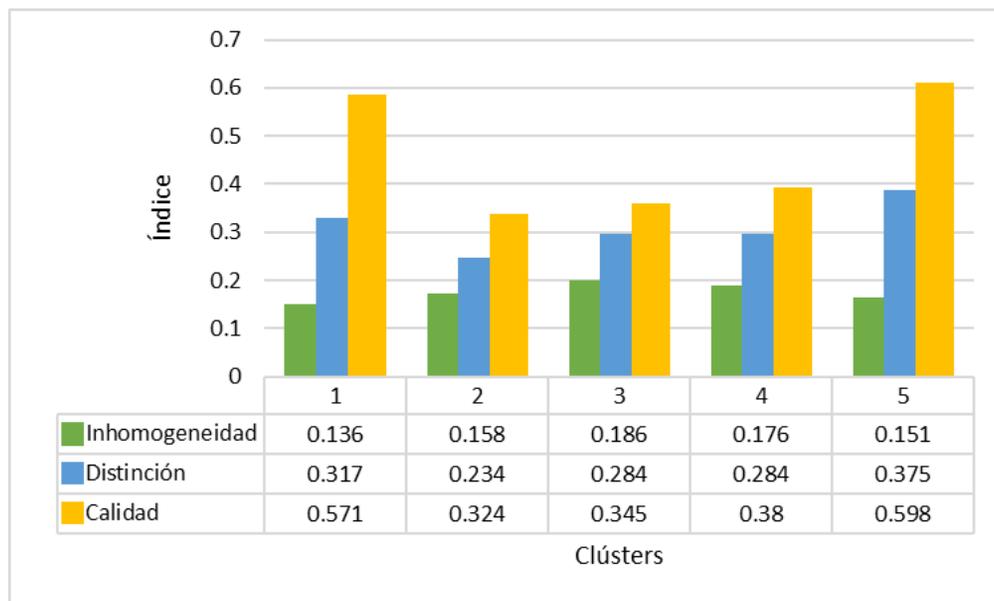


Figura 25. Inhomogeneidad, distinción y calidad global de cada clúster

Nota: La información se generó en R utilizando el paquete “motif”

La Figura 26 presenta los mapas de la calidad global de los clústeres en el cantón Pidal, proporcionando una visión integral de sus características clave: distribución geográfica, calidad del agrupamiento, inhomogeneidad interna, y distinción entre clústeres. La calidad del agrupamiento es alta en ciertas áreas (verde oscuro), indicando clústeres bien definidos y consistentes

internamente, mientras que la inhomogeneidad menor (morado) señala clústeres más cohesionados y homogéneos. La distinción varía, con áreas de alta distinción (marrón) facilitando la identificación y diferenciación clara de los clústeres, mientras que áreas de menor distinción (amarillo) muestran menos separación entre ellos, lo que puede dificultar su identificación.

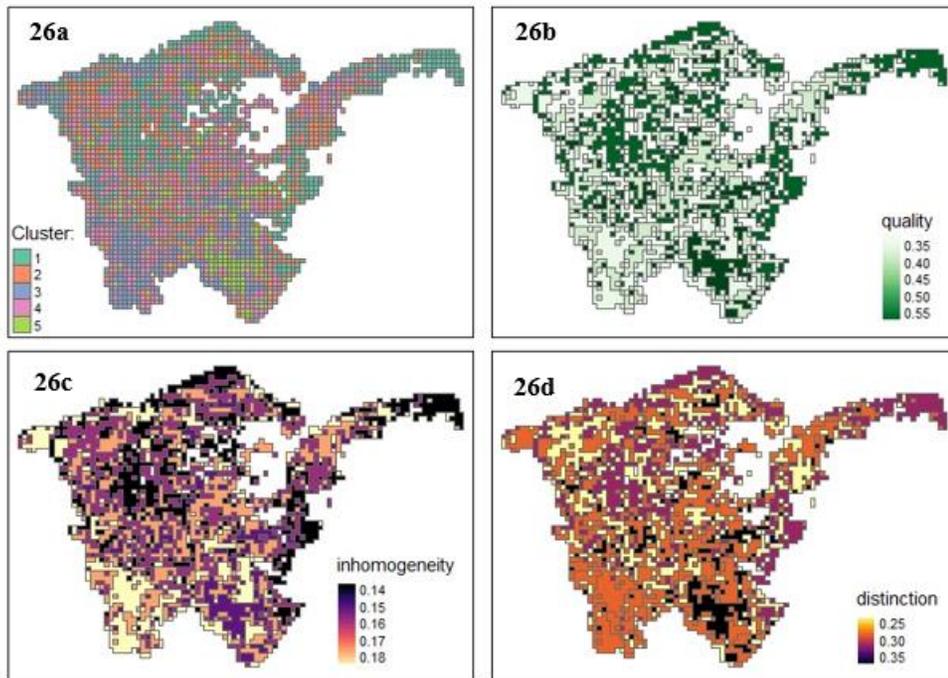


Figura 26. Mapeo de la calidad global, inhomogeneidad y distinción del análisis clúster para la zonificación del riesgo de incendios forestales

En la Figura 27 se muestra el mapa interactivo de identificación de áreas susceptibles, este es una herramienta de identificación de incendios forestales en el cantón Píndal. Desarrollado por la Universidad Nacional de Loja y la Universidad Técnica Particular de Loja, en colaboración con el Servicio Nacional de Gestión de Riesgos y Emergencias, este mapa utiliza datos satelitales de Sentinel-2 que se actualizan cada 5 días para evaluar y visualizar la probabilidad de incendios forestales en diferentes regiones del cantón. El mapa clasifica las áreas en cinco grados de susceptibilidad y muestra las variaciones en la susceptibilidad entre dos fechas específicas y los cambios en la probabilidad de incendios.

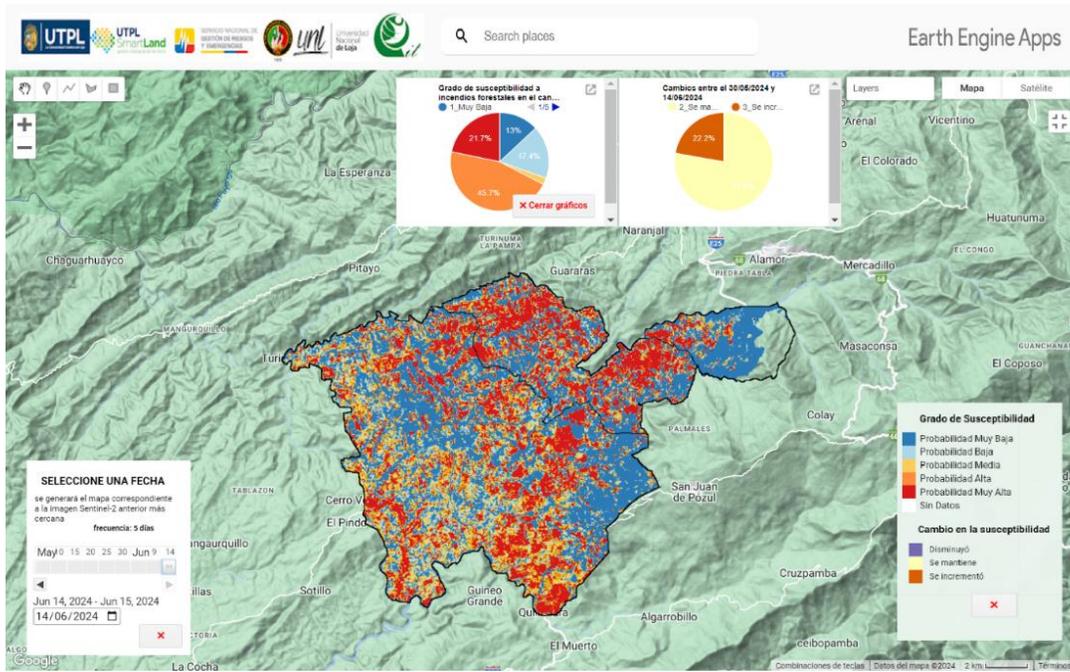


Figura 27. Mapa de identificación de áreas susceptibles a incendios forestales para el cantón Pindal

7. Discusión

Los resultados de este estudio evidenciaron la eficacia del modelo MARS (Splines de Regresión Adaptativa Multivariante) en la predicción de incendios forestales en el cantón Pindal. Al igual que en investigaciones previas (Amatulli et al., 2007; Reyes-Bueno y Loján-Córdova, 2022), que reportaron valores de AUC cercanos a 0.9, este trabajo obtuvo rangos de 0.8 a 0.9, confirmando un rendimiento predictivo robusto para la ignición. Sin embargo, la precisión del modelo se vio parcialmente limitada por la nubosidad recurrente en Pindal (2018-2021). Según Reyes-Bueno y Loján-Córdova (2022), cuando hay nubes, es imposible obtener datos de una zona específica y la severidad de incendios, ya que el satélite Sentinel-2A no puede atravesar la cobertura nubosa. Esto provoca una pérdida considerable de información crucial para los estudios.

Los hallazgos de este estudio concuerdan con las conclusiones de Priyadarshini y Puri (2021) y Hai et al. (2023), quienes destacan que los modelos MARS ofrecen alta precisión en la evaluación de riesgos ambientales, como incendios forestales, gracias a su capacidad para modelar interacciones no lineales entre variables múltiples (climáticas, topográficas, etc.). Esta característica es clave para capturar la dinámica compleja de fenómenos como la propagación del fuego. En esta investigación, la integración de variables críticas (ej: humedad del suelo, pendiente, cobertura vegetal) y técnicas avanzadas de selección de características (como el análisis de importancia basado en ganancia de información) permitió alcanzar valores del índice Kappa superiores a 0.7, lo que refleja una concordancia excelente en la clasificación de riesgo. La similitud metodológica con estudios previos especialmente en la inclusión de predictores ambientales estratégicos explica los resultados comparables reportados en la literatura.

Adicionalmente, el modelo de regresión logística demostró un desempeño destacado, con valores de Kappa >0.7 (75% en entrenamiento, 25% en validación), consistentes con los hallazgos de Galparsoro y Pita (2010). Estos autores subrayan que valores de Kappa ≥ 0.7 , respaldados por variables ambientales relevantes y un muestreo riguroso, indican alta fiabilidad en modelos de susceptibilidad a incendios.

Por otra parte, estudios de Adab et al. (2013), Reyes-Bueno y Loján-Córdova (2022), Sari (2024) y Zhang et al. (2023) aplicaron el Factor de Inflación de la Varianza (VIF) donde se descarta las variables dependientes que presentan valores superiores a diez, señal de alta colinealidad. En el presente estudio, se utilizó una metodología similar, donde tras realizar el análisis de

multicolinealidad y calcular el VIF, se identificaron cómo las variables más relevantes a los índices espectrales NDVI (Índice de vegetación de diferencia normalizada) y Moisture (Índice de humedad diferencial normalizado), ya que se adaptan de mejor manera al modelo MARS.

Las variaciones locales en el cantón Pindal, reportadas en el GAD de Pindal (2024), incluyen cambios en el uso del suelo, como la conversión de áreas forestales a tierras agrícolas; variaciones en las prácticas agrícolas, como el uso de diferentes técnicas de riego y tipos de cultivos; y la construcción de infraestructuras que alteran el paisaje natural. Los resultados mostraron que áreas con baja cobertura vegetal y vegetación estresada presentan una mayor susceptibilidad a incendios debido a la mayor cantidad de material combustible seco. Esta observación coincide con estudios como el de Reyes-Bueno y Loján-Córdova (2022), que destacan cómo la disminución de la humedad y la degradación de la vegetación aumentan el riesgo de incendios y resaltan la necesidad de un modelo predictivo que se ajuste a estas variaciones.

El modelo MARS demostró mayor precisión y robustez al ajustarse a las variaciones locales del cantón Pindal, en comparación con los modelos de RL y LMT. Esta superioridad puede atribuirse a su flexibilidad en la selección de variables y su capacidad de adaptarse a la estructura de los datos, lo cual es crucial en áreas con influencia antrópica significativa. En estos entornos, la actividad humana ha modificado considerablemente el entorno natural, afectando patrones de uso del suelo, prácticas agrícolas y urbanización.

Sanikhani et al. (2018), en su investigación sobre información geográfica como predictores de modelos, concluyen que la capacidad de MARS para manejar grandes conjuntos de datos con múltiples variables y su adaptabilidad a diferentes condiciones locales lo hacen especialmente útil en el análisis de impacto antropogénico y en la planificación de políticas de prevención y desarrollo sostenible. Priyadarshini (2021) menciona que el modelo MARS, con su capacidad para manejar interacciones no lineales y seleccionar variables de manera más flexible, se adapta mejor a estas variaciones, proporcionando una predicción más precisa y robusta en comparación con los modelos RL y LMT.

Reyes-Bueno y Loján-Córdova (2022) evaluaron la capacidad predictiva de modelos basados en RL, MARS y LMT para determinar la probabilidad de ocurrencia de incendios forestales. Utilizando una base de datos que incluía puntos quemados y no quemados y siete variables condicionantes, encontraron que los modelos LMT y MARS obtuvieron valores de AUC

superiores para los conjuntos de datos de entrenamiento y validación. Aunque el modelo LMT mostró diferencias estadísticas significativas respecto a RL, MARS tuvo el rendimiento más alto en comparación. En estudios similares, como el de Zacharakis y Tsihrintzis (2023) sobre modelos y factores integrados de peligro de incendios forestales, se ha reportado que los modelos más rígidos, como LMT y RL, tienden a subestimar la probabilidad de eventos en entornos dinámicos y heterogéneos. Estos modelos tradicionales, con sus supuestos lineales y estructuras menos flexibles, no se adaptan adecuadamente a la complejidad de los datos, resultando en predicciones inferiores.

La implementación de un enfoque multidimensional que incorpora diversos índices espectrales ha sido esencial para capturar la complejidad del entorno natural y sus interacciones con el fuego. Por ejemplo, la alta resolución espacial y temporal, junto con el análisis de series temporales de las imágenes satelitales utilizadas en el presente estudio, permitieron un monitoreo preciso y oportuno de las condiciones ambientales. Esto es especialmente relevante en áreas donde los cambios en la vegetación y la humedad pueden ser sutiles pero críticos para la prevención de incendios forestales. Los resultados obtenidos son congruentes con las conclusiones de Tran et al. (2018) en su investigación titulada “Evaluación de índices espectrales para evaluar la gravedad de los incendios en los bosques templados”. Este estudio subraya la necesidad de utilizar múltiples índices espectrales para obtener una representación más precisa del entorno natural. Entre los índices que presentaron mejores resultados se encuentran el NDVI y Moisture.

Los índices espectrales, como el NDVI y Moisture, fueron fundamentales en el presente modelo, reafirmando la importancia de estos índices en la monitorización de la vegetación y la humedad para predecir incendios. Este hallazgo está respaldado por estudios previos (Carrillo *et al.*, 2012; González *et al.*, 2023; Karimi *et al.*, 2021; Michael *et al.*, 2021; Oliveira *et al.*, 2012). En el presente estudio, el NDVI proporcionó información detallada sobre la cantidad y condición de la biomasa verde, permitiendo identificar áreas con vegetación densa y saludable frente a áreas estresadas o degradadas. Este índice es calculado a partir de la reflectancia en las bandas roja y del infrarrojo cercano, y su valor oscila entre -1 y 1, donde valores más altos indican mayor densidad de vegetación. El NDVI ha demostrado ser un indicador clave en la evaluación de la vigorosidad de la vegetación y su susceptibilidad al estrés hídrico, lo cual es crítico para la predicción de incendios forestales.

Estos resultados son consistentes con lo reportado por Bento et al. (2020) en su investigación titulada “Los roles del NDVI y la temperatura de la superficie terrestre cuando se utiliza el índice de salud de la vegetación durante regiones secas”, donde se destaca la importancia de estos índices en la evaluación de la salud de la vegetación en regiones áridas. De manera similar, Syphard et al. (2018), en su estudio "Mapeando la probabilidad futura de incendios bajo el cambio climático: ¿Importa la vegetación?", concluyen que el NDVI es esencial en la predicción de incendios forestales, ya que la variabilidad en la vegetación influye directamente en la probabilidad de ocurrencia y propagación de incendios. Estos estudios subrayan que una vegetación saludable y densa actúa como un amortiguador, mientras que una vegetación estresada o degradada puede aumentar significativamente el riesgo de incendios.

Los estudios de Zacharakis y Tsihrintzis (2023) sobre los modelos y factores integrados de peligro de incendios forestales, así como la investigación de Hong et al. (2019) titulada “Predicción de patrones espaciales de susceptibilidad a incendios forestales en el condado de Huichang”. El estudio de Zacharakis y Tsihrintzis (2023) destaca el papel crítico de la humedad en los modelos de peligro de incendios forestales. La capacidad de los índices de humedad para reflejar las variaciones en la disponibilidad de agua en el paisaje los convierte en herramientas esenciales para la monitorización y gestión de riesgos. De igual manera, la investigación de Hong et al. (2019) subraya la eficacia de estos índices en predecir patrones espaciales de susceptibilidad a incendios forestales, integrando múltiples indicadores paisajísticos para proporcionar una evaluación holística del riesgo. En el caso de Pindal, donde la vegetación xerofítica prevalente aumenta el riesgo de incendios. Esta vegetación, adaptada a condiciones áridas, suele tener una baja capacidad de retención de agua, lo que incrementa su inflamabilidad. Por lo tanto, el índice de humedad es fundamental para comprender las integraciones complejas de este entorno y predecir el riesgo de incendios de manera precisa.

Los resultados del estudio confirmaron que la integración de índices espectrales derivados de datos de teledetección en los modelos predictivos mejora de manera significativa tanto la precisión como la confiabilidad de las predicciones de incendios forestales. En particular, se observó que la combinación de NDVI y Moisture en el modelo MARS estableció una base sólida para la identificación de áreas de alto riesgo en el cantón Pindal. Este hallazgo está alineado con las conclusiones de Sharma y Dhakal (2021) en su estudio sobre la estimación del peligro de

incendio a partir del contenido de humedad del suelo, demostraron que estos índices son esenciales especialmente en ecosistemas de bosques secos. El NDVI proporciona una medida precisa de la cantidad y salud de la biomasa verde, mientras que Moisture ofrece información crítica sobre el contenido hídrico del suelo, ambos factores fundamentales en la predicción de incendios. La combinación de estos índices permite una evaluación robusta del riesgo de incendios, al considerar tanto el estado de la vegetación como la disponibilidad de humedad, factores que influyen directamente en la propagación de incendios.

La dependencia de los índices espectrales presenta limitaciones para detectar cambios sutiles en el entorno, lo que resalta la necesidad de integrar factores adicionales como variables topográficas e interacciones antrópicas en los modelos de predicción de incendios forestales. Investigaciones como las de Zhu et al. (2018) y Zhu et al. (2019) sobre la fusión espaciotemporal de múltiples fuentes de datos de teledetección subrayan la importancia de considerar factores adicionales, tales como vías de acceso, áreas pobladas y medidas avanzadas de detección remota. Estos factores mejoran significativamente la capacidad para monitorear amplias áreas y detectar cambios sutiles en la vegetación y la humedad. La integración de estos datos permite una monitorización continua y detallada, capturando variaciones espaciales y temporales, y teniendo en cuenta factores antropogénicos que influyen en la susceptibilidad a incendios.

Simoes et al. (2021) recomiendan el uso de tecnologías avanzadas como sensores hiperespectrales y LiDAR (Light Detection and Ranging), que mejoran la precisión en la identificación de áreas de alto riesgo y facilitan la implementación de estrategias de mitigación más efectivas. Sin embargo, la aplicación de estas recomendaciones en el presente estudio se vio limitada debido a restricciones en la infraestructura para la investigación y la recolección de datos en la zona de estudio.

Durante la investigación, se identificaron varias limitaciones, incluyendo la omisión de factores influyentes como la topografía, las actividades humanas y las variables meteorológicas. La mayoría de los estudios revisados coinciden en que los incendios forestales son causados por una variedad de factores, destacándose particularmente las variables meteorológicas (Volts, 2021). Estas variables son esenciales para los modelos de probabilidad de incendios forestales, representando hasta un 60% de la importancia en dichos modelos, ya que su inclusión podría proporcionar una mayor sensibilidad a las condiciones ambientales cambiantes (Muñoz *et al.*,

2005). En Ecuador, el acceso a información espacial de alta resolución y actualizada constantemente es limitado y, a menudo, costoso. Además, los datos disponibles suelen estar a escalas amplias y se actualizan con frecuencia semanal o mensual, lo que puede debilitar en lugar de fortalecer los modelos predictivos. Diversos estudios han demostrado que la disponibilidad de variables meteorológicas es crucial, dado que en muchos países existe una amplia disponibilidad y fácil acceso a datos espaciales, facilitando su integración en modelos predictivos (Rojas *et al.*, 2023).

La presente investigación ha demostrado la utilidad de los índices espectrales en la predicción de incendios forestales, pero reconoce que un análisis multitemporal, que considere variaciones interanuales, podría ofrecer una comprensión más profunda de las tendencias a largo plazo y los efectos del cambio climático. Asimismo, se ha identificado que las actividades humanas tienen un impacto significativo en la susceptibilidad a incendios forestales. Los hallazgos sugieren que una mayor exploración de este impacto, junto con el uso de tecnologías avanzadas como el aprendizaje profundo, podría optimizar los sistemas de alerta temprana y las respuestas de emergencia.

En consonancia con los resultados del presente estudio, una investigación reciente de Reyes-Bueno y Loján-Córdova (2022) señalan que la humedad de la vegetación, representada por la variable NDVI, identifica la variable de mayor importancia en los modelos generados por las tres técnicas, corroborando la observación de la relevancia de índices espectrales. Sin embargo, una diferencia notable fue la baja importancia asignada a la distancia a zonas antropogénicas en los modelos, contrastando con los resultados del presente estudio que evidenciaron una influencia significativa por la proximidad a áreas antrópicas en la probabilidad de incendios. Este contraste podría ser explorado más a fondo para entender las dinámicas regionales o las diferencias en las metodologías de modelado que podrían explicar estas discrepancias. En términos de aplicación práctica, este estudio enfatiza la necesidad de focalizar esfuerzos de prevención en áreas urbanas y en temporadas de alto riesgo. Esto está relacionado con las recomendaciones de Malik *et al.* (2021), quienes abogan por un enfoque dirigido y basado en datos para la gestión de incendios forestales.

Por otra parte, la representación gráfica del análisis espacio-temporal del clúster en la zona de estudio para el año 2023 evidenció esta agrupación, revelando cinco clústeres distintos. Las áreas con baja probabilidad de ocurrencia se agruparon en la clase 1, mientras que las zonas con

alta probabilidad de ocurrencia se identificaron en la clase 5. De manera similar, Nowosad (2021) señala que la "calidad global" (quality) es una medida que combina la inhomogeneidad y la distinción para evaluar la calidad de la agrupación, proporcionando una medida única de la coherencia interna de los clústeres y la separación entre ellos, donde valores más altos indican una mayor calidad de agrupación. En este estudio, la calidad global varió entre 0,32 y 0,6, lo que indicó una calidad de agrupación moderada.

Los resultados del presente estudio revelaron una variabilidad temporal y espacial en la probabilidad de incendios. Se observó una menor frecuencia de incendios entre febrero y agosto debido a las temporadas de lluvias, mientras que se registraron picos entre septiembre y enero, coincidiendo con los períodos secos. Estos hallazgos son consistentes con patrones observados en estudios previos en regiones similares, como los de Carvalho et al. (2021), Samaniego et al. (2015), PDOT de Pindal (2019) y White (2019); estudios que coinciden que, en Pindal, el período de lluvias ocurre durante el primer y segundo trimestre del año, mientras que la estación seca se extiende durante el tercer y cuarto trimestre.

La validación del presente sistema de mapeo de susceptibilidad a incendios forestales se contrasta con los datos históricos de incendios en el cantón Pindal. Las parroquias El Sauco, Las Peñas, El Huasimo, El Higerón, La Tuna, El Guando, Añancal, Higueroncito y Guayabal fueron identificadas como áreas de alto riesgo, mientras que Los Órganos se clasificó como una zona de riesgo muy alto. En el 2020, estas áreas sumaron un total de 4,121 hectáreas quemadas. Estos hallazgos son consistentes con la información proporcionada por GAD Pindal (2024) y el SNGRE (2021).

GAD Pindal (2024) documenta que las áreas mencionadas han sido históricamente propensas a incendios debido a factores como la alta densidad de vegetación seca y la influencia de actividades humanas, como la agricultura y la expansión urbana, que aumentan la vulnerabilidad al fuego. Mientras que el estudio del SNGRE (2021) también destaca que las mismas parroquias identificadas en nuestro análisis han experimentado una mayor frecuencia e intensidad de incendios en los últimos años, lo que valida la identificación de estas áreas como de alto y muy alto riesgo en nuestro modelo. Por ello, se confirman estas observaciones al demostrar que las áreas con vegetación densa y estresada, así como aquellas con alta actividad humana, son más susceptibles a los incendios.

8. Conclusiones

Cada análisis de las variables debe ser abordado teniendo en cuenta las particularidades y condiciones específicas del territorio, en el caso del cantón Pindal, el análisis de importancia de variables indicó que los índices espectrales, como el NDVI (Índice de vegetación de diferencia normalizada) y Moisture (Índice de humedad diferencial normalizado) con un VIF de 6,33 y 7,90 respectivamente, tienen una influencia muy alta en la probabilidad de ocurrencia de incendios forestales, superando en importancia en el presente estudio a otras variables como las topográficas y de interacción antrópica.

El modelo Splines de regresión adaptativa multivariadas (MARS) mostró un rendimiento superior con un AUC de (E) 0,92 y (V) 0,89, Kappa de (E) 0,77 y (V) 0,75 y una precisión de (E) 0,88 y (V) 0,85, en comparación con los modelos de Regresión Logística (RL) y Árboles de Decisión Logística (LMT) que presentaron valores inferiores. Adaptándose mejor a la zona de estudio debido a su menor linealidad en comparación a los otros modelos en esta zona en específico.

En el análisis de clúster, la zonificación se realizó en una ventana de 250 x 250 metros, obteniendo un resultado cartográfico detallado y comprensible. La zonificación de riesgo ha identificado meses con alta probabilidad de incendios forestales, especialmente durante la temporada seca de agosto a enero. En particular, enero es el mes con el mayor número de zonas con probabilidad muy alta de ignición, alcanzando un 54,16%, seguido de noviembre y diciembre con probabilidad del 34,68%. Además, existen zonas específicas en constante peligro de muy alta probabilidad, como la parroquia Pindal y Milagros, mientras que otras parroquias como Guayabal y Palmira, presentan una constante probabilidad baja.

9. Recomendaciones

El principal problema en el uso de imágenes satelitales para el monitoreo de incendios forestales es la obstrucción causada por la presencia de nubes. Estas nubes dificultan el procesamiento completo de la información del cantón Pindal, obligando a seccionar las imágenes, como se hizo en el presente estudio, para utilizar únicamente aquellas que no introduzcan ruido en el aprendizaje, validación y no afecten su capacidad predictiva. Por lo tanto, la recomendación principal para futuros estudios sobre este tema es implementar nuevas técnicas que permitan un análisis integral sin tener que descartar datos que podrían ser importantes en un análisis acumulativo. Además, se sugiere ampliar el rango de estudio de los 3 años utilizados en este estudio a 5 o 10 años, dependiendo del tamaño de la zona de estudio y sus características específicas.

10. Bibliografía

- Abid, F. (2020). A survey of machine learning algorithms based forest fires prediction and detection systems. *Fire technology*, 559-590.
- Adab, H.; Kanniah, K.D.; Solaimani, K. (2013). Modeling forest fire risk in the northeast of Iran using remote sensing and GIS techniques. *Natural Hazards* 65, 1723–1743.
- Alfaro, A., y Ospina, J. (2021). Revisión sistemática de literatura: Técnicas de aprendizaje automático (machine learning). *Cuaderno activa*, 13(1), 113-121.
- Alkhatib, R., Sahwan, W., Alkhatieb, A., y Schütt, B. (2023). A brief review of machine learning algorithms in forest fires science. *Applied Sciences*, 13(14), 8275.
- Álvarez, R. (2023). Estudio comparativo de modelos clásicos de series temporales y métodos de machine learning para la predicción de la temperatura diaria de Gijón.
- Amatulli, G., Pérez-Cabello, F., y de la Riva, J. (2007). Mapping lightning/humancaused wildfires occurrence under ignition point location uncertainty. *Ecological Modelling*, 200(3–4), 321–333. <https://doi.org/10.1016/j.ecolmodel.2006.08.001>
- Arias, P. C. (2024). Susceptibilidad para incendios de cubierta vegetal: una evaluación desde los métodos multicriterio y radiofrecuencia. *Cotacachi*.
- Arif, M., Alghamdi, K., Sahel, S., Alosaimi, S., Alsahft, M., Alharthi, M., y Arif, M. (2021). Role of machine learning algorithms in forest fire management: A literature review. *J. Robot. Autom*, 5, 212-226.
- Barraza, F. A. (2022). Estimation of chlorophyll-a concentrations in Lanalhue Lake using Sentinel-2 MSI satellite images. *Remote Sensing*, 56-47.
- Bento, V. A., Gouveia, C. M., DaCamara, C. C., Libonati, R., y Trigo, I. F. (2020). The roles of NDVI and Land Surface Temperature when using the Vegetation Health Index over dry regions. *Global and Planetary Change*, 190, 103198. <https://doi.org/10.1016/j.gloplacha.2020.103198>
- Bobadilla, J. (2021). *Machine learning y deep learning: usando Python, Scikit y Keras*. Cali: Ediciones de la U.
- Briz, S. S. (2021). Thermal characterization of clouds using simple bispectral infrared imaging systems. In *Thermosense: Thermal Infrared Applications XLIII* . SPIE, 227-235.
- Carrillo García, R. L., Rodríguez Trejo, D. A., Tchikoué, H., Monterroso Rivas, A. I., y Santillan Pérez, J. (2012). Análisis espacial de peligro de incendios forestales en Puebla, México. *Interciencia*, 37, 678–683. <https://www.redalyc.org/pdf/339/33925502012.pdf>
- Carvalho, N. S., Anderson, L. O., Nunes, C. A., Pessôa, A. C. M., Junior, C. H. L. S., Reis, J. B. C., Shimabukuro, Y. E., Berenguer, E., Barlow, J., y Aragão, L. E. O. C. (2021). Spatio-

- temporal variation in dry season determines the Amazonian fire calendar. *Environmental Research Letters*, 16(12), 125009. <https://doi.org/10.1088/1748-9326/ac3aa3>
- Castillo, M. P. (2019). Incendios forestales y medio ambiente: una síntesis global. . *Revista Ambiente y Desarrollo*, 44-53.
- Cawson, J., Collins, L., Parks, S., Nolan, R., y Penman, T. (2024). Atmospheric dryness removes barriers to the development of large forest fires. *Agricultural and Forest Meteorology*, 350, 109990.
- Cerezo, M. V. (2022). Challenges and opportunities in quantum machine learning. . *Nature Computational Science*, 567-576.
- Chastain, R. H. (2019). Empirical cross sensor comparison of Sentinel-2A and 2B MSI, Landsat-8 OLI, and Landsat-7 ETM+ top of atmosphere spectral characteristics over the conterminous United States. *Remote Sensing*, 59-60.
- Chiza, L. (2021). Predicción del Margen de Estabilidad de Corredores de Transmisión Aplicando Criterios de Minería de datos y Algoritmos de Machine Learning. *Revista Técnica energía*, 37-47.
- Cisneros, C. C. (2024). Análisis espacial y temporal de incendios forestales en el Ecuador utilizando datos de sensores remotos. . *Colombia forestal*, 10-13.
- Coello, J. (2023). Comparación y análisis estadístico entre modelos de probabilidad de ocurrencia de incendios forestales para Honduras. Año 2019. . *Ciencias Espaciales*, 14(2), 19-37.
- CONAE. (2024, Mayo). Guía para el Usuario de Productos VIIRS/SUOMI-NPP Nivel 1. Retrieved from <https://catalogos4.conae.gov.ar/npp/Docs/Guia-para-el-Usuario-de-Productos-NPP-Nivel1.pdf>
- Cueva, J. (2021). Valoración Económica Social y Ambiental de Incendios Forestales . *Universdiad Tecnica de Ambato*.
- Díaz, J. (2021). Aprendizaje automático y aprendizaje profundo. *Ingeniare. Revista chilena de ingeniería*, 29(2), 180-181.
- Dirección de Gestión de Información de Riesgos. (2019). Informe de incendios.
- FAO. (2020). Global Forest Resources Assessment . Retrieved from <https://doi.org/10.4060/ca9825en>
- GAD Pindal. (2023). Plan de Desarrollo y Ordenamiento Territorial (PDOT) 2023 – 2027. *Alcaldía de Pindal, Loja*.
- Galparsoro, L. de U., y Pita, F. S. (2010). Medidas de concordancia: el índice Kappa. *Fisterra*, 6, 1-7.

- Géron, A. (2020). *Machine Learning: Aprende machine learning con scikit-learn, keras y tensorflow*. España: Anaya.
- Ghorbani, R., y Ghousi, R. (2020). Comparing different resampling methods in predicting students' performance using machine learning techniques. *IEEE Access*, , 67899-67911.
- Gong, T. S. (2023). Temperature measurement of SO₂ based on mid-infrared laser absorption spectroscopy. *Microwave and Optical Technology Letters*,, 37-47.
- González Gutiérrez, I., Farfán Gutiérrez, M., Morales Manilla, L. M., Pérez Salicrup, D. R., Garza Saldaña, J. J., y Medina Puente, A. (2023). Índices y modelos para la predicción de la ocurrencia de incendios forestales: una revisión para México. *Revista Geográfica de América Central*, 2(71), 193–219. <https://doi.org/10.15359/rgac.71-2.7>
- González, I., Farfán, M., Morales, L., Pérez, D., Garza, J., y Medina, A. (2023). Índices y modelos para la predicción de la ocurrencia de incendios forestales: una revisión para México. *Revista Geográfica de América Central*, (71), 193-220.
- Greener, J. G. (2022). A guide to machine learning for biologists. *Nature reviews Molecular cell biology*, 40-55.
- Guede, F. M. (2021). A deep learning based object identification system for forest fire detection. *Fire*, 75-78.
- Hai, T., Theruvil Sayed, B., Majdi, A., Zhou, J., Sagban, R., Band, S. S., y Mosavi, A. (2023). An integrated GIS-based multivariate adaptive regression splines-cat swarm optimization for improving the accuracy of wildfire susceptibility mapping. *Geocarto International*, 38(1), 2167005. <https://doi.org/10.1080/10106049.2023.2167005>
- Hart, G. L. (2021). Machine learning for alloys. *Nature Reviews Materials*, 730-755.
- Hervas, J. (2023). Causas y origen de los incendios forestales en el Ecuador. *INNDEV-Innovation y Development Ciencias del Sur*, 11-21.
- Hong, H., Jaafari, A., y Zenner, E. K. (2019). Predicting spatial patterns of wildfire susceptibility in the Huichang County, China: An integrated model to analysis of landscape indicators. *Ecological Indicators*, 101, 878-891. <https://doi.org/10.1016/j.ecolind.2019.01.056>
- Hu, Y. Z. (2022). Fast forest fire smoke detection using MVMNet. *Knowledge-Based Systems*, , 55-61.
- Jones, V. y. (2022). Análisis de las técnicas de machine learning aplicadas en la detección de fraudes bancarios. *Revista Científica Ciencia y Tecnología*, 12-17.
- Karimi, A., Abdollahi, S., Ostad-Ali-Askari, K., Eslamian, S., y Singh, V. P. (2021). Predicting fire hazard areas using vegetation indexes, case study: Forests of Golestan Province, Iran. *Journal of Geography and Cartography*, 4(1), 1-6 . <https://doi.org/10.24294/jgc.v4i1.451>

- Li, F., Zhang, X., Kondragunta, S., y Csiszar, I. (2018). Comparison of fire radiative power estimates from VIIRS and MODIS observations. *Journal of Geophysical Research: Atmospheres*, 123(9), 4545-4563.
- Li, S. X. (2020). S-NPP and N20 VIIRS RSB bands detector-to-detector calibration differences assessment using a homogeneous ground target. . In *Earth Observing Systems XXV* , 357-367.
- Lizcano, V., y Santa, R. (2023). Diseño de un picosatélite para el monitoreo y predicción del comportamiento de incendios forestales. *Revista Ingeniería, Matemáticas y Ciencias de la Información*, 10(19), 127-133.
- Lucas, F., Araujo, E., Fiedler, N., da Silva, S., y Tetto, A. (2023). Perspective: scientific gaps on forest fires in Brazilian protected areas. . *Forest Ecology and Management*, 529, 120739.
- MAATE. (2022). Plan Nacional de Sequía. Retrieved from <https://drive.google.com/file/d/116DUbtXBBSnAeoMoMhHUyWgWB11oZM/view>
- Malik, A., Rao, M. R., Puppala, N., Koori, P., Thota, V. A. K., Liu, Q., Chiao, S., y Gao, J. (2021). Data-Driven Wildfire Risk Prediction in Northern California. *Atmosphere*, 12(1), 109 . <https://doi.org/10.3390/atmos12010109>
- Martínez, A., y Inchausti, P. (2023). Predicción de incendios forestales mediante modelos de machine learning. In *XXVIII Congreso Argentino de Ciencias de la Computación (CACIC)*.
- Menes, I. A. (2021). Desempeño de algoritmos de minería en indicadores académicos: Árbol de Decisión y Regresión Logística. . *Revista Cubana de Ciencias Informáticas*, 104-117.
- Michael, Y., Helman, D., Glickman, O., Gabay, D., Brenner, S., y Lensky, I. M. (2021). Forecasting fire risk with machine learning and dynamic information derived from satellite vegetation index time-series. *Science of The Total Environment*, 764, 142844. <https://doi.org/10.1016/j.scitotenv.2020.142844>
- Mohajane, M. C. (2021). Application of remote sensing and machine learning algorithms for forest fire mapping in a Mediterranean area. . *Ecological Indicators*, 42-45.
- 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, J., Armijos, D., y Erazo, S. (2019). Flora y fauna del Bosque Seco de la provincia de Loja, Ecuador. *Ediloja*, Loja.
- Muros, J. Á. (2021). Learning expressive numerical planning domains by integrating machine learning techniques . *Granada*.

- 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>
- Ouma, O. N. (2020). Modelling reservoir chlorophyll-a, TSS, and turbidity using Sentinel-2A MSI and Landsat-8 OLI satellite sensors with empirical multivariate regression. . *Journal of Sensors*, 1-21.
- Pausas, J. (2020). Incendios forestales. Los libros de la Catarata.
- Pawan, G., y Follette, M. (2020, Octubre 22). Transición de MODIS a VIIRS para Aplicaciones de la Calidad del Aire. Retrieved from <https://appliedsciences.nasa.gov/get-involved/training/english/arset-modis-viirs-transition-air-quality-applications>
- PDOT (2019). Plan de Desarrollo y Ordenamiento Territorial (PDOT) 2019-2023. Pindal, Ecuador.
- Pérez, P. T. (2021). Predicción del Composite Requerido en el Diseño de un Recipiente Toroidal Mediante una Red Neuronal Artificial. . *Investigación, Tecnología e Innovación*, 45-53.
- Pérez, P. T. (2021). Predicción del Composite Requerido en el Diseño de un Recipiente Toroidal Mediante una Red Neuronal Artificial.
- Pham, B. T.-A. (2020). Performance evaluation of machine learning methods for forest fire modeling and prediction. . *Symmetry*, 10-22.
- Pineda, J. (2022). Modelos predictivos en salud basados en aprendizaje de maquina (machine learning). *Revista Médica Clínica Las Condes*, 583-590.
- Pourghasemi, H. R. (2020). Application of learning vector quantization and different machine learning techniques to assessing forest fire influence factors and spatial modelling. . *Environmental research*, 18-21.
- Priyadarshini, I., y Puri, V. (2021). Mars weather data analysis using machine learning techniques. *Earth Science Informatics*, 14(4), 1885-1898. <https://doi.org/10.1007/s12145-021-00643-0>
- Rabiei, J., Khademi, M. S., Bagherpour, S., Ebadi, N., Karimi, A., y Ostad-Ali-Askari, K. (2022). Investigation of fire risk zones using heat–humidity time series data and vegetation. *Applied Water Science*, 12(9), 216. <https://doi.org/10.1007/s13201-022-01742-z>
- Regadera, J. (2021). Cálculo de la vida útil restante de un turbofán mediante Machine Learning. Lima.

- Reyes Bueno, F. (2017). Manual de Prácticas de Ordenación Territorial.
- Reyes, F., y Balcázar, C. (2021). Factores que inciden en la probabilidad de ocurrencia de incendios forestales en Ecuador. *FIGEMPA: Investigación y Desarrollo*, 11(1), 50-60.
- 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), 474 .
<https://doi.org/10.3390/f13030474>
- Rojas, E. (2020). Machine Learning: análisis de lenguajes de programación y herramientas para desarrollo. *Revista Ibérica de Sistemas e Tecnologías de Informação*, 586-599.
- Rojas, L. (2022). Una comparación empírica de algoritmos de aprendizaje automático versus aprendizaje profundo para la detección de noticias falsas en redes sociales. . *Ingeniare. Revista chilena de ingeniería*, 403-415.
- 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>
- Ruelas, R. (2024). Tendencia de la deforestación ocasionada por incendios forestales durante el periodo 2015-2022 mediante imágenes satelitales, en los distritos de Llalli y Cupi–Puno.
- Saha, S. B. (2023). Prediction of forest fire susceptibility applying machine and deep learning algorithms for conservation priorities of forest resources. . *Remote Sensing Applications: Society and Environment*, 100-102.
- Samaniego, N., Eguiguren, P., Maita, J., y Aguirre, N. (2015). Diversidad de briófitos de los Páramos de Cajanuma del Parque Nacional Podocarpus. In *Cambio climático y Biodiversidad: Estudio de caso de los páramos del Parque Nacional Podocarpus, Ecuador*.
<https://doi.org/10.13140/RG.2.1.5009.1921>
- Sanikhani, H., Deo, R. C., Samui, P., Kisi, O., Mert, C., Mirabbasi, R., Gavili, S., y Yaseen, Z. M. (2018). Survey of different data-intelligent modeling strategies for forecasting air temperature using geographic information as model predictors. *Computers and Electronics in Agriculture*, 152, 242-260. <https://doi.org/10.1016/j.compag.2018.07.008>
- Sari, F. (2021). Forest fire susceptibility mapping via multi-criteria decision analysis techniques for Mugla, Turkey: A comparative analysis of VIKOR and TOPSIS. *Forest Ecology and Management*, 480(2020), 118644. <https://doi.org/10.1016/j.foreco.2020.118644>
- Sari, F. (2024). Assessment of the effects of different variable weights on wildfire susceptibility. *European Journal of Forest Research*, 0123456789. <https://doi.org/10.1007/s10342-023-01643-z>

- Sharma, N., Sharma, R., y Jindal, N. (2021). Machine learning and deep learning applications-a vision. *Global Transitions Proceedings*, 2(1), 24-28.
- Sharma, S., y Dhakal, K. (2021). Boots on the Ground and Eyes in the Sky: A Perspective on Estimating Fire Danger from Soil Moisture Content. *Fire*, 4(3), 45. <https://doi.org/10.3390/fire4030045>
- Simoës, R., Camara, G., Queiroz, G., Souza, F., Andrade, P. R., Santos, L., Carvalho, A., y Ferreira, K. (2021). Satellite Image Time Series Analysis for Big Earth Observation Data. *Remote Sensing*, 13(13), 2428. <https://doi.org/10.3390/rs13132428>
- Singh, A. T. (2022). A review of supervised machine learning algorithms. n 2016 3rd international conference on computing for sustainable global development, 1310-1315.
- SNGRE. (2021). Informe de Situación No. 23 de Incendios Forestales a nivel Nacional. Servicio Nacional de Gestión de Riesgos y Emergencias (SNGREb), 10, 1–4. https://www.gestionderiesgos.gob.ec/wp-content/uploads/2021/09/SITREP-No-10-Incendios_Forestales-21092021.pdf
- Syphard, A. D., Sheehan, T., Rustigian-Romsos, H., y Ferschweiler, K. (2018). Mapping future fire probability under climate change: Does vegetation matter? *PLOS ONE*, 13(8), e0201680. <https://doi.org/10.1371/journal.pone.0201680>
- Tran, B. N., Tanase, M. A., Bennett, L. T., y Aponte, C. (2018). Evaluation of Spectral Indices for Assessing Fire Severity in Australian Temperate Forests. *Remote Sensing*, 10(11), 1680. <https://doi.org/10.3390/rs10111680>
- Trujillano, J. S. (2022). Aproximación a la metodología basada en árboles de decisión. *Gaceta Sanitaria*, 65-72.
- Usmadi, D. (2023). Maximum entropy application in predicting the vulnerability of land and forest fires in South Sumatra Province, Indonesia. *IOP Conference Series: Earth and Environmental Science*, 1183(1). <https://doi.org/10.1088/1755-1315/1183/1/012105>
- Valerii, H. (2022). BISPECTRAL METHOD OF MEASURING THE TEMPERATURE OF THE POLE WINDINGS OF ELECTRIC MACHINES. In *The III International Science Conference «Modern science and practice»*, 11-15.
- Vargas, S. M. (2021). Machine Learning como Herramienta para Determinar la Variación de los Recursos Hídricos. . *Scientific Research Journal CIDI*, 56-69.
- Varoquaux, G., y Colliot, O. (2023). Evaluating machine learning models and their diagnostic value. *Machine Learning for Brain Disorders* , 601-630.
- Vásquez, F. (2021). Arquitectura de Big Data para la gestión de incendios forestales en la región de La Araucanía. *Revista científica*, 304-314.
- Villers Ruíz, M. D. L. (2006). Incendios forestales. *Ciencias*, (081).

- Voltas, X. R. (2021). Creación de un modelo de predicción de riesgos de incendios forestales usando una red neuronal convolucional sobre datos históricos de meteorología de California. *Ciencias de Datos*.
- White, B. (2019). Satellite detection of wildland fires in South America. *Floresta*, 49, 851-858. <https://doi.org/10.5380/rf.v49i4.60117>
- Yang, Y. A. (2021). Phenological corrections to a field-scale, ET-based crop stress indicator: An application to yield forecasting across the US Corn Belt. *Remote Sensing of Environment*.
- Zacharakis, I., y Tsihrintzis, V. A. (2023). Environmental Forest Fire Danger Rating Systems and Indices around the Globe: A Review. *Land*, 12(1), 194. <https://doi.org/10.3390/land12010194>
- Zacharakis, I., y Tsihrintzis, V. A. (2023). Integrated wildfire danger models and factors: A review. *Science of The Total Environment*, 899, 165704. <https://doi.org/10.1016/j.scitotenv.2023.165704>
- Zhang, X., Lan, M., Ming, J., Zhu, J., y Lo, S. (2023). Spatiotemporal Heterogeneity of Forest Fire Occurrence Based on Remote Sensing Data: An Analysis in Anhui, China. *Remote Sensing*, 15(3). <https://doi.org/10.3390/rs15030598>
- Zhang, X., Tian, Y., Chen, L., Hu, X., y Zhou, Z. (2022). Machine learning: a new paradigm in computational electrocatalysis. *The Journal of Physical Chemistry Letters*, 13(34), 7920-7930.
- Zhao, N. L. (2022). Vibration acoustic modulation for bolt looseness monitoring based on frequency-swept excitation and bispectrum. . *Smart Materials and Structures*, 28-32.
- Zheng, Y. Z. (2023). Research on Progress of Forest Fire Monitoring with Satellite Remote Sensing. . *Agricultural y Rural Studies*, 61-63.
- Zhu, X., Cai, F., Tian, J., y Williams, T. K.-A. (2018). Spatiotemporal Fusion of Multisource Remote Sensing Data: Literature Survey, Taxonomy, Principles, Applications, and Future Directions. *Remote Sensing*, 10(4), 527. <https://doi.org/10.3390/rs10040527>
- Zhu, Z., Zhou, Y., Seto, K. C., Stokes, E. C., Deng, C., Pickett, S. T. A., y Taubenböck, H. (2019). Understanding an urbanizing planet: Strategic directions for remote sensing. *Remote Sensing of Environment*, 228, 164-182. <https://doi.org/10.1016/j.rse.2019.04.020>
- Zou, C., Zhou, L., Lin, L., Sun, N., Chen, Y., Flynn, L., y Goldberg, M. (2020). The reprocessed Suomi NPP satellite observations. *Remote Sensing*, 12(18), 2891.

11. Anexos

Anexo 1. Variables topográficas

| Variable | Descripción | Proceso de obtención | Metadatos de la capa |
|----------|-------------|---|---|
| 1 | Elevación | Altura sobre el nivel del mar. | Se importa un archivo .kml con los límites del cantón de interés y se realiza la búsqueda de Modelos de Elevación Digital (DEM) disponibles en la web de ALOS PALSAR para la zona. |
| | | | SRC: EPSG:32717 Resolución espacial: 10 x 10 metros Rango de valores: 0 – 3668 Unidades: m.s.n.m. |
| 2 | Pendiente | Grado de inclinación del terreno. | Al DEM obtenido en la web de ALOS PALSAR , se le aplica un filtro de suavizado en QGIS herramienta SAGA (Simple Filter, Smooth 3). Después de aplicar el filtro de suavizado, se utiliza la herramienta GRASS (r.slope.aspect, percent) |
| | | | SRC: EPSG:32717 Resolución espacial: 10 x 10 metros Rango de valores: 0 – 375 Unidades: porcentaje (%) |
| 3 | Orientación | Dirección de pendiente descendente que presenta cada celda. | Al DEM obtenido en la web de ALOS PALSAR , se le aplica un filtro de suavizado en QGIS herramienta SAGA (Simple Filter, Smooth 3). Después de aplicar el filtro de suavizado, se utiliza la herramienta GRASS (r.slope.aspect) |
| | | | SRC: EPSG:32717 Resolución espacial: 10 x 10 metros Rango de valores: 0 – 360 Unidades: grados (°) |

Anexo 2. Variables de interacción antrópica

| Variable | Descripción | Proceso de obtención | Metadatos de la capa |
|----------|-----------------------------------|---|---|
| 4 | Accesibilidad al centro económico | Facilidad de movimiento desde cualquier punto del cantón hasta el centro económico. | Utilizando la herramienta GRASS r.cost.full, se configura como punto(s) objetivo(s) la capa de centro económico descargada en el portal del SNI . SRC: EPSG:32717 Resolución espacial: 10 x 10 metros Rango de valores: 0 – 140 Unidades: minutos |
| 5 | Accesibilidad a áreas protegidas | Facilidad de movimiento desde cualquier punto del cantón hasta áreas protegidas. | Utilizando la herramienta GRASS r.cost.full, se configura como punto(s) objetivo(s) la capa de áreas protegidas descargada en el Mapa Interactivo Ambiental . SRC: EPSG:32717 Resolución espacial: 10 x 10 metros Rango de valores: 0 – 140 Unidades: minutos |
| 6 | Accesibilidad a zonas pobladas | Facilidad de movimiento desde cualquier punto del cantón hasta poblados. | Utilizando la herramienta GRASS r.cost.full, se configura como punto(s) objetivo(s) la capa de poblados descargada en el portal del SNI . SRC: EPSG:32717 Resolución espacial: 10 x 10 metros Rango de valores: 0 – 130 Unidades: minutos |
| 7 | Accesibilidad a vías | Facilidad de movimiento desde cualquier punto del cantón hasta vías. | Utilizando la herramienta GRASS r.cost.full, se configura como punto(s) objetivo(s) la capa de vías digitalizada de manera manual en Google Maps Satelite. SRC: EPSG:32717 Resolución espacial: 10 x 10 metros Rango de valores: 0 – 145 Unidades: minutos |

| | | | | |
|----|-------------------------------------|---|--|--|
| 8 | Accesibilidad a zonas antrópicas | Facilidad de movimiento desde cualquier punto del cantón hasta zonas pobladas | Utilizando la herramienta GRASS r.cost.full, se configura como punto(s) objetivo(s) la capa de cobertura vegetal descargada en el Mapa Interactivo Ambiental . | SRC: EPSG:32717 Resolución espacial: 10 x 10 metros Rango de valores: 0 – 120 Unidades: minutos |
| 9 | Distancia desde el centro económico | Distancia desde el centro económico. | Utilizando la herramienta GRASS r.grow.distance, se configura como punto(s) objetivo(s) la capa de centro económico descargada en el portal del SNI . | SRC: EPSG:32717 Resolución espacial: 10 x 10 metros Rango de valores: 0 – 20 597 Unidades: metros |
| 10 | Distancia a ríos | Distancia desde ríos. | Utilizando la herramienta GRASS r.grow.distance, se configura como punto(s) objetivo(s) la capa ríos generada a partir del DEM. | SRC: EPSG:32717 Resolución espacial: 10 x 10 metros Rango de valores: 0 – 1141 Unidades: metros |
| 11 | Distancia a vías | Distancia desde vías | Utilizando la herramienta GRASS r.grow.distance, se configura como punto(s) objetivo(s) la capa vías digitalizada de manera manual en Google Maps Satelite. | SRC: EPSG:32717 Resolución espacial: 10 x 10 metros Rango de valores: 0 – 4157 Unidades: metros |
| 12 | Distancia desde áreas protegidas | Distancia desde áreas protegidas | Utilizando la herramienta GRASS r.grow.distance, se configura como punto(s) objetivo(s) la capa áreas protegidas descargada en el Mapa Interactivo Ambiental . | SRC: EPSG:32717 Resolución espacial: 10 x 10 metros Rango de valores: 0 – 12322 Unidades: metros |

| | | | | |
|----|------------------------------|---|---|--|
| 13 | Distancia a zonas antrópicas | Distancia desde zonas pobladas o zonas agropecuarias. | Utilizando la herramienta GRASS r.grow.distance, se configura como punto(s) objetivo(s) la capa zonas pobladas o zonas agropecuarias. | SRC: EPSG:32717 Resolución espacial: 10 x 10 metros Rango de valores: 0 – 3820 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).

Anexo 3. Variables del estado de vegetación (Índices espectrales)

| Variable | | Descripción | Proceso de Obtención | Metadatos de la capa |
|----------|-------|---|--|--|
| 14 | ARVI | <p><i>Atmospherically Resistant Vegetation Index</i></p> <p>NDVI corregido para efectos de dispersión atmosférica</p> $ARVI = \frac{NIR - (2 * Red) + Blue}{NIR + (2 * Red) + Blue}$ <p>NIR (Near-Infrared Region) → B8 Red (Rojo, espectro visible) → B11 Blue (Azul, espectro visible) → B2</p> | Los índices espectrales o índices de vegetación son descargados mediante un script de Google Earth Engine, para ello se usa imágenes satelitales de Sentinel 2A. | SRC: EPSG:32717 Resolución espacial: 10 x 10 metros Rango de valores: -1 a 1 |
| 15 | BSI | <p><i>Bare Soil Index</i></p> <p>Identificar zonas sin cobertura vegetal</p> $BSI = \frac{(Red + SWIR) - (NIR + Blue)}{(Red + SWIR) + (NIR + Blue)}$ <p>Red (Rojo, espectro visible) → B11 SWIR (Shortwave Infrared) → B4 NIR (Near-Infrared Region) → B8 Blue (Azul, espectro visible) → B2</p> | | SRC: EPSG:32717 Resolución espacial: 10 x 10 metros Rango de valores: -1 a 1 |
| 16 | GNDVI | <p><i>Green Normalized Difference Vegetation Index</i></p> <p>Versión del NDVI más sensible a la variación del contenido de clorofila y nitrógeno en el cultivo.</p> | | SRC: EPSG:32717 Resolución espacial: 10 x 10 metros |

| | | | | |
|----|------|---|--|--|
| | | $GNDVI = \frac{NIR - SWIR}{NIR + SWIR}$ SWIR (Shortwave Infrared) → B3 NIR (Near-Infrared Region) → B8 | | Rango de valores: -1 a 1 |
| 17 | MSI | <p>Moisture Stress Index</p> Determinar el estrés hídrico de la vegetación | $MSI = \frac{MidIR}{NIR}$ MidIR (Shortwave Infrared) → B11 NIR (Near-Infrared Region) → B8 | SRC: EPSG:32717 Resolución espacial: 10 x 10 metros Rango de valores: 0 a 3+ |
| 18 | NBR | <p>Normalized Burn Ratio</p> Estimar la cantidad y desarrollo de áreas incendiadas | $NBR = \frac{NIR - SWIR}{NIR + SWIR}$ SWIR (Shortwave Infrared) → B12 NIR (Near-Infrared Region) → B8 | SRC: EPSG:32717 Resolución espacial: 10 x 10 metros Rango de valores: -1 a 1 |
| 19 | NDMI | <p>Normalized Difference Moisture Index</p> Determinar el contenido de agua de la vegetación | $NDMI = \frac{NIR - SWIR}{NIR + SWIR}$ SWIR (Shortwave Infrared) → B11 NIR (Near-Infrared Region) → B8 | SRC: EPSG:32717 Resolución espacial: 10 x 10 metros Rango de valores: -1 a 1 |
| 20 | NDWI | <p>Normalized Difference Water Index</p> Identificar masas de agua y zonas de elevada humedad. | $NDWI = \frac{NIR - Green}{NIR + Green}$ NIR (Near-Infrared Region) → B8 Green (Verde, espectro visible) → B3 | SRC: EPSG:32717 Resolución espacial: 10 x 10 metros Rango de valores: -1 a 1 |

| | | | |
|----|----------------|--|---|
| 21 | NDVI | <p>Normalized Difference Vegetation Index</p> <p>Facilidad con la que el fuego se propaga en la vegetación.</p> $NBR = \frac{NIR - Red}{NIR + Red}$ <p>NIR (Near-Infrared Region) → B8 Red (Rojo, espectro visible) → B4</p> | <p>SRC: EPSG:32717</p> <p>Resolución espacial: 10 x 10 metros</p> <p>Rango de valores: -1 a 1</p> |
| 22 | SAVI | <p>Soil Adjusted Vegetation Index</p> <p>Analizar la vegetación en etapas decrecimiento inicial o dispersa.</p> $NBR = \frac{NIR - R}{NIR + R + L} * (1 + L)$ <p>NIR (Near-Infrared Region) → B8 Red (Rojo, espectro visible) → B4 Factor de corrección de la luminosidad del suelo → L</p> | <p>SRC: EPSG:32717</p> <p>Resolución espacial: 10 x 10 metros</p> <p>Rango de valores: -1 a 1</p> |
| 23 | Moisture Index | <p>Normalized Difference Moisture Index</p> <p>Estimar el contenido de humedad de la vegetación.</p> $Moisture = \frac{NIR - SWIR}{NIR + SWIR}$ <p>SWIR (Shortwave Infrared) → B11 NIR (Near-Infrared Region) → B8A</p> | <p>SRC: EPSG:32717</p> <p>Resolución espacial: 10 x 10 metros</p> <p>Rango de valores: -1 a 1</p> |

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).

Anexo 4. Base de datos establecida

| Inoendo | access_cen | access_pob | access_via | access_ZA | dist_CE | dist_rios | dist_vias | dist_ZA | ARVI | BSI | GNDVI | MSI | NBR | NMI | NDMI | NDVI | SAVI | Moisture | orientacion | elevacion | pendiente |
|---------|------------|------------|------------|-----------|-------------|-----------|-----------|-----------|----------|----------|----------|----------|----------|----------|----------|----------|----------|-----------|-------------|------------|-----------|
| 1 | 48.32075 | 25.53602 | 18.10257 | 32.23376 | 3973.79779 | 50.00609 | 152.27394 | 0 | -0.48054 | 0.31009 | 0.19585 | 2.30925 | -0.41223 | -0.39563 | -0.19585 | 0.13134 | 0.19695 | -0.36039 | 284.74356 | 689.22449 | 8.70573 |
| 1 | 111.70657 | 7.49779 | 15.9364 | 32.31488 | 6407.72401 | 690.4463 | 10.00122 | 10.00122 | -0.33125 | 0.18236 | 0.27843 | 1.47086 | -0.06607 | -0.19056 | -0.27843 | 0.19853 | 0.23776 | -0.16067 | 156.80141 | 321.73468 | 14.84822 |
| 1 | 72.53255 | 12.09153 | 24.56909 | 11.26873 | 5042.19702 | 383.16372 | 20.00244 | 0 | -0.41503 | 0.25766 | 0.36318 | 1.63942 | -0.13483 | -0.24226 | -0.36318 | 0.2287 | 0.34301 | -0.19357 | 166.6075 | 833.51019 | 12.26734 |
| 1 | 71.31581 | 13.18338 | 1.0864 | 40.04224 | 11461.46747 | 67.06766 | 20.00244 | 49.93264 | -0.20711 | 0.0818 | 0.2019 | 1.22385 | -0.01885 | -0.10066 | -0.2019 | 0.19734 | 0.23598 | -0.05915 | 15.9454 | 566.44897 | 11.74715 |
| 1 | 50.54197 | 16.06028 | 23.08105 | 11.94099 | 9928.63746 | 80.60686 | 31.61467 | 0 | -0.45338 | 0.29529 | 0.28254 | 1.95143 | -0.25057 | -0.32236 | -0.28254 | 0.17234 | 0.25848 | -0.25558 | 165.96376 | 704.28574 | 14.36786 |
| 1 | 46.15191 | 20.03307 | 25.19117 | 16.44099 | 10071.94388 | 135.97906 | 50.00609 | 0 | -0.44197 | 0.24146 | 0.40007 | 1.74429 | -0.13784 | -0.27121 | -0.40007 | 0.36496 | 0.54735 | -0.18084 | 177.27368 | 695.91814 | 12.66545 |
| 1 | 15.54331 | 9.32685 | 1.41213 | 7.15477 | 9487.40224 | 326.97375 | 36.04942 | 0 | -0.13962 | 0.05073 | 0.02376 | 1.31724 | -0.05022 | -0.13691 | -0.02376 | 0.0614 | 0.09209 | -0.1198 | 291.80142 | 765.26532 | 10.78616 |
| 1 | 21.68447 | 13.09135 | 14.06855 | 4.42058 | 4961.41233 | 230.02801 | 40.00487 | 0 | -0.0198 | 0.0011 | -0.03042 | 1.04466 | -0.02217 | -0.04973 | 0.03042 | -0.01653 | -0.01744 | 0.1966925 | 719.71429 | 9.63564 | |
| 1 | 104.80461 | 19.13786 | 13.38823 | 20.53417 | 4493.39455 | 287.94407 | 299.9915 | 0 | -0.01641 | -0.00305 | -0.02044 | 1.07484 | 0.02478 | -0.03607 | 0.02044 | 0.00362 | 0.00544 | -0.01767 | 102.93461 | 685.33878 | 24.42867 |
| 1 | 108.04507 | 6.71176 | 3.34706 | 21.77757 | 4763.61217 | 425.84039 | 0 | 0 | -0.00886 | -0.00612 | -0.01859 | 1.05604 | 0.04151 | -0.02726 | -0.01859 | 0.00317 | 0.00475 | -0.02686 | 187.12502 | 764.93878 | 13.96664 |
| 1 | 80.08626 | 15.72351 | 24.59558 | 22.73711 | 10875.01284 | 64.02263 | 174.89581 | 19.93403 | -0.27427 | 0.1322 | 0.25641 | 1.35479 | -0.08707 | -0.16067 | -0.25641 | 0.20587 | 0.30877 | -0.08862 | 2.48955 | 668.73959 | 10.98977 |
| 1 | 32.07852 | 16.70239 | 7.30165 | 14.03216 | 1310.02444 | 320.06907 | 216.33145 | 0 | -0.08752 | 0.0349 | 0.01811 | 1.82335 | -0.04119 | -0.08356 | -0.01811 | 0.02816 | 0.04224 | -0.0422 | 274.0856 | 834.79599 | 13.82875 |
| 1 | 93.63762 | 21.77315 | 12.77315 | 22.70071 | 6441.16431 | 226.25419 | 76.13937 | 0 | -0.05382 | 0.02054 | -0.01687 | 1.14018 | -0.00116 | -0.0655 | 0.01687 | -0.00094 | -0.00126 | 252.55261 | 785.26532 | 17.0695 | |
| 1 | 95.20898 | 14.32279 | 5.5864 | 30.15107 | 6333.61958 | 388.93569 | 72.09883 | 0 | 0.00934 | -0.01257 | -0.02685 | 1.03121 | 0.03186 | -0.01536 | 0.02685 | -0.01008 | 0.00254 | 161.58505 | 780.24487 | 14.63343 | |
| 1 | 34.38751 | 16.67371 | 27.56338 | 25.36831 | 1213.1636 | 480.79015 | 84.84532 | 262.42001 | -0.2893 | 0.14648 | 0.18752 | 1.52186 | -0.09067 | -0.20693 | -0.18752 | 0.15485 | 0.23224 | -0.15325 | 282.26477 | 922.65308 | 14.05157 |
| 1 | 17.10635 | 10.8897 | 7.05624 | 9.49043 | 1542.8123 | 94.32279 | 69.97911 | 148.67712 | -0.07983 | 0.02919 | 0.01619 | 1.85449 | -0.02732 | -0.07842 | -0.01619 | 0.03078 | 0.04617 | -0.04814 | 943.96375 | 781.7959 | 13.80828 |
| 1 | 23.07087 | 16.85422 | 3.3364 | 15.45495 | 12036.62893 | 419.64468 | 10.00122 | 0 | -0.16368 | 0.06417 | 0.08930 | 1.3219 | -0.06232 | -0.13864 | -0.08930 | 0.10415 | 0.15621 | -0.08193 | 323.47031 | 580.95917 | 20.22314 |
| 1 | 32.7158 | 53.56097 | 33.91704 | 13.00477 | 8794.97828 | 32.19027 | 0 | 0 | -0.3397 | 0.23378 | 0.41176 | 1.5125 | -0.00845 | -0.20398 | -0.41176 | 0.26862 | 0.40286 | -0.15712 | 6.00001 | 687.87756 | 21.45895 |
| 1 | 32.22525 | 29.2951 | 9.67774 | 35.30993 | 1272.8077 | 180.02314 | 111.77943 | 360.0315 | -0.4037 | 0.22161 | 0.42622 | 1.52198 | -0.05325 | -0.20697 | -0.42622 | 0.32679 | 0.49011 | -0.16803 | 193.39899 | 914.33878 | 21.55147 |
| 1 | 84.76622 | 32.39108 | 7.45036 | 25.21432 | 2957.18092 | 120.40235 | 156.18528 | 0 | -0.44959 | 0.26784 | 0.43446 | 1.74891 | -0.06395 | -0.27244 | -0.43446 | 0.28956 | 0.43428 | -0.20438 | 177.27368 | 669.87756 | 9.3738 |
| 1 | 43.12184 | 11.48838 | 25.79733 | 34.52309 | 1686.28251 | 162.74195 | 111.77943 | 0 | -0.27036 | 0.13457 | 0.13018 | -0.08822 | -0.13084 | -0.28187 | 0.20604 | 0.30899 | -0.16299 | 170.53767 | 711.87756 | 5.63072 | |
| 1 | 75.97024 | 38.32386 | 12.18198 | 42.12732 | 2424.14663 | 354.63979 | 22.36152 | 0 | -0.38032 | 0.22229 | 0.37304 | 1.52118 | -0.01262 | -0.20672 | -0.37304 | 0.23045 | 0.34564 | -0.14214 | 351.86899 | 662.81635 | 15.2454 |
| 1 | 81.14616 | 11.09741 | 17.53855 | 26.10366 | 8976.64597 | 49.98508 | 29.99105 | 0 | -0.41727 | 0.2535 | 0.31426 | 1.74073 | -0.15301 | -0.27027 | -0.31426 | 0.30404 | -0.21077 | 270 | 919.55103 | 12.48588 | |
| 1 | 36.64244 | 16.5897 | 15.6533 | 20.55546 | 4207.71341 | 117.01781 | 22.35589 | 20.00244 | -0.35712 | 0.2 | 0.33205 | 1.49352 | -0.06169 | -0.19792 | -0.33205 | 0.22778 | 0.34163 | -0.14515 | 296.56506 | 684.87756 | 7.45066 |
| 1 | 58.5531 | 5.69558 | 8.50477 | 42.46611 | 3643.22693 | 449.97686 | 36.05524 | 9.99702 | -0.39535 | 0.23858 | 0.32081 | 1.64873 | -0.10152 | -0.24492 | -0.32081 | 0.19358 | 0.29033 | -0.1683 | 321.34018 | 675.16365 | 10.7293 |
| 1 | 91.98898 | 19.91002 | 18.06396 | 41.50143 | 9438.36614 | 561.26041 | 58.2386 | 0 | -0.23838 | 0.15556 | 0.21082 | 1.51695 | -0.07219 | -0.20539 | -0.21082 | 0.15841 | 0.23759 | -0.15841 | 64.98311 | 818.0816 | 19.70394 |
| 1 | 16.02529 | 9.80863 | 1.14853 | 5.77279 | 9345.10911 | 477.63379 | 10.00122 | 0 | -0.40584 | 0.23991 | 0.34245 | 1.6085 | -0.09062 | -0.23328 | -0.34245 | 0.24271 | 0.36401 | -0.17598 | 225 | 789.14288 | 9.98834 |
| 1 | 8.95366 | 8.95366 | 11.71873 | 22.82406 | 472.00464 | 50.9758 | 9.99702 | 0 | -0.4129 | 0.25537 | 0.33486 | 1.66621 | -0.11064 | -0.24987 | -0.33486 | 0.18884 | 0.29824 | -0.18546 | 183.36646 | 753.32654 | 8.57 |
| 1 | 29.42982 | 17.05919 | 8.10937 | 11.64723 | 1253.42486 | 243.24065 | 258.09054 | 0 | -0.42357 | 0.2656 | 0.36574 | 1.67173 | -0.11943 | -0.25142 | -0.36574 | 0.20383 | 0.30571 | -0.18811 | 167.27565 | 624.53816 | 15.25915 |
| 1 | 32.51463 | 26.29797 | 18.62315 | 24.89871 | 1705.10335 | 199.9341 | 44.71177 | 185.53717 | -0.42937 | 0.26722 | 0.36752 | 1.71852 | -0.1195 | -0.26376 | -0.36752 | 0.2095 | 0.31421 | -0.22063 | 90 | 687.85712 | 19.05060 |
| 1 | 42.11311 | 18.91873 | 11.50036 | 29.55107 | 4817.32308 | 156.53067 | 92.18434 | 60.00731 | -0.4078 | 0.25952 | 0.29912 | 1.69345 | -0.14848 | -0.25746 | -0.29912 | 0.15613 | 0.23417 | -0.20882 | 190.00798 | 850.55103 | 17.37535 |
| 1 | 29.38519 | 23.16853 | 6.40919 | 21.76827 | 5227.1045 | 80.60686 | 106.29504 | 9.99702 | -0.39631 | 0.23938 | 0.31201 | 1.69265 | -0.13873 | -0.25724 | -0.31201 | 0.18186 | 0.27276 | -0.21871 | 348.69006 | 848.89685 | 10.10823 |
| 1 | 10.29331 | 4.07865 | 2.67739 | 2.67739 | 4576.06403 | 708.33367 | 84.84532 | 0 | -0.40826 | 0.24975 | 0.33728 | 1.6382 | -0.10687 | -0.24191 | -0.33728 | 0.20837 | 0.31252 | -0.19535 | 92.48956 | 1010.2041 | 11.5695 |
| 1 | 79.33778 | 17.79411 | 4.42279 | 12.80772 | 2977.00864 | 179.94628 | 22.35589 | 0 | -0.37472 | 0.23334 | 0.31634 | 1.50076 | -0.05676 | -0.20024 | -0.31634 | 0.17958 | 0.26934 | -0.12717 | 358.26428 | 723.95917 | 15.51416 |
| 1 | 61.79205 | 25.4616 | 20.90093 | 20.15955 | 4591.62592 | 335.42296 | 50.00609 | 0 | -0.39846 | 0.28091 | 0.32832 | 1.75065 | -0.10111 | -0.2729 | -0.32832 | 0.1876 | 0.28136 | -0.22224 | 293.19858 | 804.34692 | 15.18745 |
| 1 | 16.91541 | 15.70914 | 14.38892 | 22.60033 | 756.56751 | 326.50736 | 90.01096 | 0 | -0.40953 | 0.25198 | 0.35065 | 1.62923 | -0.07895 | -0.23932 | -0.35065 | 0.20818 | 0.31223 | -0.1692 | 353.65892 | 770.32654 | 10.06901 |
| 1 | 146.79138 | 34.90889 | 42.58018 | 59.61784 | 5415.33442 | 858.42919 | 367.6082 | 203.90321 | -0.38346 | 0.19192 | 0.45637 | 1.44088 | 0.01299 | -0.18974 | -0.45637 | 0.38568 | 0.57844 | -0.08045 | 171.8699 | 1074.02039 | 17.4727 |
| 1 | 42.29435 | 13.78234 | 14.77021 | 34.67844 | 9199.73571 | 130.01583 | 44.72305 | 22.35589 | -0.33812 | 0.17362 | 0.36373 | 1.91018 | 0.02852 | -0.18004 | -0.36373 | 0.28265 | 0.42392 | -0.08898 | 268.72896 | 678.61224 | 23.027 |
| 1 | 65.90409 | 31.68747 | 2.99558 | 34.92975 | 2341.14204 | 110.01339 | 0 | 0 | -0.42184 | 0.25325 | 0.42655 | 1.60526 | -0.08621 | -0.23232 | -0.42655 | 0.23919 | 0.35865 | -0.1619 | 258.69006 | 619.34652 | 12.49497 |
| 1 | 14.28731 | 8.07066 | 4.79728 | 6.67193 | 14374.03201 | 142.10824 | 0 | 29.99105 | -0.46892 | 0.32873 | 0.23623 | 2.154 | -0.25529 | -0.36536 | -0.23623 | 0.18885 | 0.17825 | -0.18633 | 304.69516 | 399.61224 | 22.74152 |
| 1 | 23.94987 | 17.73322 | 10.57774 | 16.33395 | 9076.665 | 305.23088 | 39.98066 | 0 | -0.40246 | 0.23807 | 0.36855 | 1.60528 | -0.04048 | -0.23233 | -0.36855 | 0.24375 | 0.36558 | -0.15489 | 226.78932 | 641.22449 | 19.61935 |
| 1 | 12.56447 | 9.46077 | 5.87371 | 6.9169 | 654.98021 | 72.80766 | 40.00487 | 9.99702 | -0.0113 | -0.0263 | 0.05713 | 0.99163 | 0.07335 | 0.0042 | -0.05713 | 0.08935 | 0.12832 | 0.03773 | 63.43495 | 823.12244 | 8.43855 |
| 1 | 55.95895 | 23.58381 | 18.35763 | 30.41726 | 2088.47121 | 120.40235 | 36.48601 | 20.00244 | -0.15399 | 0.04718 | 0.18129 | 1.14804 | 0.05562 | -0.06805 | -0.18129 | 0.17491 | 0.26233 | -0.06864 | 113.19859 | 698.75513 | 13.73744 |
| 1 | 34.54808 | 25.90348 | 25.86838 | 26.93216 | 7289.85872 | 308.08926 | 268.27063 | 0 | -0.27243 | 0.09795 | 0.36173 | 1.23753 | 0.06365 | -0.10616 | -0.36173 | 0.34676 | 0.52007 | -0.07164 | 126.8899 | 553.97961 | 21.03406 |
| 0 | 48.33361 | 25.54889 | 17.2539 | 32.24662 | 4085.50811 | 41.23506 | 99.97016 | 0 | -0.35459 | 0.18894 | 0.42277 | 1.36809 | 0.01998 | -0.15286 | -0.42277 | 0.30559 | 0.45834 | -0.11796 | 60.25512 | 688.93878 | |

Anexo 5. Certificado de traducción del abstract



Loja, 07 de abril del 2025

Lcda. Ménessis Marloweth Castillo Pardo
Certified English Teacher

CERTIFICA:

Que el documento aquí compuesto es fiel traducción del idioma español al idioma inglés, del resumen del trabajo de integración curricular, titulado: “Machine Learning para la predicción de zonas susceptibles a incendios forestales en el cantón Pindal, Ecuador”, el cual consta de doscientas sesenta y siete (267) palabras. El trabajo realizado es previo a la obtención del título de Ingeniero Ambiental, de la autoría del estudiante Angel Estalin Alvarez Vega , con cédula de identidad Nro.1104957582 , de la Universidad Nacional de Loja.

Lo certifica en honor a la verdad y autoriza al interesado, hacer uso del presente en lo que a sus intereses convenga.



Lcda. Ménessis Marloweth Castillo Pardo

LICENCIADA EN PEDAGOGÍA DEL IDIOMA INGLÉS

Número de registro: 1031-2023-2749324

C.I.: 1104246465