

**UNIVERSIDAD NACIONAL AUTÓNOMA DE NICARAGUA, León**

**Área de Conocimiento de Ciencias y Tecnología**

**Carrera de Biología**



**Monografía para optar al título de Licenciatura en Biología**

Modelización de riesgo de inicio de incendios forestales en el Pacífico nicaragüense  
mediante regresión logística y *Random Forest*

**AUTORES:**

Br. Luis Gustavo Zeas Zeledón

Br. Joseling Natalia Ocón López

Br. Julissa del Carmen Ocón López

**Tutor:** MSc. David Alberto Cerda

**Asesor:** Lic. Edwin José Chavarría Solís

**LEÓN DE NICARAGUA**

**Noviembre de 2024**

**"2024: 45/19, La Patria La Revolución!"**

## RESUMEN

En las últimas décadas, el aumento de la frecuencia e intensidad de los incendios forestales ha generado diversos problemas ambientales y socioeconómicos significativos, por lo que es crucial implementar una variedad de estrategias que mitiguen el riesgo de incendios y fortalezcan la resiliencia de los ecosistemas. En este contexto, se modelizó la probabilidad de riesgo de inicio de incendios forestales en el Pacífico de Nicaragua. Se generaron dos modelos de predicción; el modelo logístico y el modelo de *Random Forest* a través del software estadístico y lenguaje de programación R. Ambos modelos trabajaron con el mismo conjunto de datos que incluyen como variables independientes: datos espectrales, variables topográficas y variables antropológicas. Por su parte, la variable dependiente está conformada por puntos de calor obtenidos a través del sistema FIRMS correspondientes a los sensores VIIRS y MODIS. En el caso de MODIS, se obtuvieron los puntos de calor registrados desde el año 2000 hasta el 2024; mientras que en el caso de VIIRS desde el año 2012 hasta el 2024 que corresponden a los meses de enero a mayo. Los resultados de ambos modelos generaron un nivel de predicción de 72% para el modelo logístico y del 79% para el modelo por *Random Forest*. En ambos casos, las variables más significativas fueron las bandas B11 y B12, los índices NDMI, GNDVI y la variable de altitud. Por último, la reclasificación permitió definir áreas prioritarias con riesgo de inicio de incendio, siendo estas las zonas Norte y Sur de la Península de Cosigüina, complejo volcánico Cristobal-Casita, áreas dispersas del departamento de Rivas y la Isla de Ometepe.

## CARTA DE AUTORIZACIÓN

DAVID ALBERTO CERDA GRANADOS, Profesor Asistente de la Dirección de Biología del Área de Conocimiento de Ciencias y Tecnología de la Universidad Nacional Autónoma de Nicaragua- León (UNAN-León),

CERTIFICA QUE:

La presente monografía titulada «*Modelización de Riesgo de inicio de Incendios Forestales en el Pacífico nicaragüense mediante regresión logística y Random Forest*» presentada por BR. LUIS GUSTAVO ZEAS ZELEDÓN (18-18040-0), BR. JOSELING NATALIA OCÓN LÓPEZ (18-00929-9) y BR. JULISSA DEL CARMEN OCÓN LÓPEZ (18-00932-0) para optar al grado de Licenciado en Biología por la Universidad Nacional Autónoma de Nicaragua-León, ha sido realizada bajo mi dirección y que hallándose concluida,

AUTORIZO:

Su presentación para que pueda ser juzgada por el tribunal correspondiente.

Dado en la ciudad de León, departamento de León, el 18 de octubre de 2024.

David Alberto Cerda Granados, M.Sc.

Profesor Asistente

Dirección de Biología, UNAN-León

## **Agradecimientos**

*A nuestro asesor y amigo, Edwin Chavarría, gracias por guiarnos en el mundo de los SIG desde cero y guiarnos como un excelente líder durante la carrera y nuestra monografía sin esperar nada a cambio.*

*A MSc. David Cerda, nuestro tutor y profesor por dedicarnos tiempo para corregir nuestro trabajo.*

*A PhD. María Encarnación, gracias por ver potencial en nosotros y motivarnos a alcanzar metas que no creía ser capaz de lograr.*

*A mis padres, Mayling Zeledon y Luis Adolfo Zeas, por apoyarme a lo largo de toda la carrera y ayudarme a tomar las mejores decisiones.*

*Agradezco a mi tía, Dina Gonzáles, la persona que me hizo posible estudiar una carrera universitaria.*

*Le agradezco a Franklin Centeno, un excelente amigo que estuvo presente apoyándonos desde el inicio, la culminación de este logro al día de hoy no hubiese sin tu ayuda.*

*A mis amigas y compañeras de monografía, Joseling y Julissa Ocón López, para mí ha sido un gusto y honor trabajar con ustedes, considero que no he tenido mejor equipo de trabajo que ustedes. De igual manera agradezco la hospitalidad de sus padres Oneyda López y Nelson Ocón por hacerme sentir como uno más de la familia.*

*A los maestros que hicieron de la carrera una experiencia grata y transmiten sus conocimientos con ánimo y entusiasmo: MSc. David Cerda, PhD. María Encarnación, MSc. Indiana Coronado, PhD. Lily Orozco, PhD. María Eugenia Cerda, Lic. Aquiles Reyes, PhD. Oscar González y Lic. Blas Hernández.*

*A Saúl Salgado y Dariana Calero, dos buenos amigos y compañeros de clase con quienes guardo muy gratos recuerdos.*

*Finalmente, a todos mis amigos y compañeros con quienes viví momentos especiales a lo largo de esta experiencia universitaria, y a aquellos que, en los momentos más difíciles, me tendieron una mano.*

*Luis Feas*

## **Dedicatoria**

*A mis abuelos, Hernán Zeledón y Zoneyda Mairena, por ser como mis segundos padres, brindándome amor incondicional y apoyo constante a lo largo de mi vida. Su ejemplo, cariño y sabiduría han sido fundamentales en cada paso que he dado.*

*A toda mi familia, el núcleo de mi vida y la fuerza que me impulsa a superar cualquier obstáculo. Gracias por ser mi refugio en los momentos difíciles, mi inspiración en los desafíos y mi mayor alegría en los triunfos. Sin ustedes, este logro no me habría sido posible.*

*Luis Feas*

## **Agradecimientos**

*A Dios, por permitirme estar aquí escribiendo estas líneas, por obsequiarme el valioso regalo de la salud y por concederme la fortaleza y la perseverancia necesaria para ver realizado uno de mis más grandes anhelos.*

*A mis estimados profesores quienes me han acompañado y guiado a lo largo de este extenso recorrido, MSc. David Cerda, MSc. Indiana Coronado, PhD. María Eugenia Cerda, PhD. Aura Lily Orozco, PhD. Oscar González, Lic. Aquiles Reyes y especialmente a la muy apreciada PhD. María Encarnación Juárez, quien fue una de las primeras personas en depositar su confianza en mí, por lograr ver potencial en mi; infinitas gracias por su bondad, amparo y sabiduría. Agradezco profundamente a cada uno de ellos por su dedicación en la formación de futuros profesionales. Atesoraré sus enseñanzas con la admiración y respeto que se merecen.*

*A mi asesor y muy especial amigo Edwin Chavarría, quien ha sido una pieza fundamental en la realización de esta meta. Estoy infinitamente agradecida por su cariño, por haber visto mi valor como futura profesional, por sus valiosos consejos y por compartir sus conocimientos, siempre respaldados por el aprecio y sabiduría.*

*A mi mejor amiga, Melania Figueroa, quien ha sido un regalo invaluable en mi vida. Gracias por permanecer a mi lado a lo largo de todos estos años, por ese amor incondicional que me ha brindado cada día, por su constante apoyo, motivación y cuidados. Mi eterna gratitud por su amistad.*

*A mis queridas hermanas, Kenia y Karen Ramos Munguía, por su cariño que ha trascendido por todas las etapas de mi vida, la cual he tenido la dicha y el honor de atravesar a su lado. Gracias por la confianza, los consejos y su inmenso amor. Simplemente gracias.*

*A mis amigos y compañeros, Franklin Centeno, Saul Rodríguez y Dariana Calero, gracias por acompañarme durante estos años. Agradezco su apoyo, compañía y afecto, así como los momentos agradables que me brindaron, haciendo este proceso más llevadero. Agradezco especialmente a mi querido amigo y compañero de monografía, Luis Zeas,*

*por su comprensión, apoyo y humildad desde el primer día que tuve el honor de conocerlo. Eternamente agradecida con Dios y la vida por el valioso obsequio que es su amistad.*

*A mis mascotas, Max y Ares, quienes, aunque no emitan palabra alguna, con su sola compañía han hecho mi carga más liviana. Gracias porque su presencia, amor y mimos me reparan e iluminan la vida.*

*Joseling Ocón*

## Dedicatoria

*A mis padres, Nelson Ocón y Oneyda López, por ellos es quien soy, he sido y seré. Dedico a ellos todos mis logros, porque conocen un poco más que yo, lo que ha significado este camino. Su amor es invaluable y ver realizada esta meta es una firme prueba de ello. Su amor incondicional se ha traducido en sacrificios, desvelos, cuidados, seguridad, protección, apoyo, motivación y consejos que han dejado una huella imborrable en mi vida. Vida que no me bastará para extenderles mi gratitud y que no alcanzará para retribuirles todo su esfuerzo, empeño y cariño. Gracias por ser mi inspiración, mi ejemplo, mi refugio, por creer en mí, por confiar y por enseñarme que con dedicación todo lo puedo lograr. Por eso he llegado hasta aquí, dando fé de que los sueños se pueden alcanzar, con esfuerzo sí, pero no sola, sino con la motivación de quienes hoy les dedico este logro, mis padres. Los amo.*

*A mi otra mitad, mi hermana, amiga y confidente, Julissa Ocón, quien ha sido mi complemento en cada etapa de mi vida. Juntas hemos compartido alegrías, tristezas, dificultades y momentos de gozos. Hemos ido siempre de la mano en este viaje, haciéndolo más ligero y llevadero. Infinitas gracias porque al igual que yo, ha enfrentado el cansancio, las lágrimas, los desvelos y muchos sacrificios, durante los cuales me ha brindado su apoyo. Permitiendo así, nunca haber experimentado el desamparo, permitiendo sentirme fuerte, respaldada y capaz. No me atrevo a imaginar una mejor compañera de vida, que la persona que Dios me ha obsequiado para llamar hermana. Agradecimiento y amor infinito para ella.*

*A mi muy querido hermano, Kevin Ocón, quien ha sido una de mis principales razones para alcanzar esta meta. Gracias por su amor, su apoyo sin medida, por las risas compartidas, por la humildad, carisma, empatía, por mostrarme la vida yendo de su mano, por intentar alejar las dificultades y piedras de mi camino. Gracias por permitirme experimentar la grandeza del amor de hermanos; veo su significado en lo que soy y en todo lo que he logrado, porque soy su reflejo. Esperando de corazón que sea partícipe de todos mis sueños, como hoy, que le dedico este logro con todo el amor que en mi existe.*

*A mi abuela, Juana Natalia Saavedra †, una de mis mayores inspiraciones y motivaciones, quien continúa representando en mi vida la fuerza que tanto he necesitado, quien ha sido mi escudo, mi modelo a seguir, mi pilar y mi consuelo. Gracias a Dios y a la vida, porque gracias a su paso por este mundo, he conocido el verdadero significado de valentía, fortaleza y perseverancia. Infinitas gracias al ángel con forma de mamá que hoy me cuida y se enorgullece de mí desde el cielo; este logro es suyo. Te amo.*

*A mis abuelos, Ángel López y Francisco Ocón, quienes representan el significado de fortaleza, empeño, dedicación y sacrificios en mi vida. Gracias por acompañarme en mi travesía por los senderos de este mundo, por sus consejos y cariño. Mi extensa gratitud hacia ellos.*

*A toda mi familia, tíos, tías y primos, este logro también les pertenece, pues su apoyo y cariño han sido fundamentales en mi vida. Les agradezco de corazón por ser pilares incondicionales, por ofrecerme su amor sin reserva, por obsequiarme momentos de calidad que siempre me llenan de alegría. Cada risa e instante compartido con ellos han representado un alivio y un respiro que me ha permitido soltar el peso de mis preocupaciones en muchas ocasiones.*

*Joseling Ocón*

## Agradecimientos

*A Dios, por brindarme salud y sabiduría para cumplir uno de mis grandes sueños. Gracias por guiar mi vida hasta ahora y por situar en mi camino a personas maravillosas que hoy forman parte de mí y de quien soy. Espero continuar mi vida bajo tu palabra y sombra. Te agradezco por darme la vida y por permitirme ver cada día la luz del sol.*

*A mis abuelos Francisco Ocón, Ángel López y Juana Saavedra †. Por cuidarme cuando mis padres no podían, por hacerme sentir en casa cada vez que los visitaba y por sus consejos. Su apoyo y sabiduría mientras crecía me permitieron llegar hasta el día de hoy. Los amo; no importa cuánto me aleje, en mi alma y mente eternamente vivirán.*

*A mi pareja, David Salazar Pérez. Tu existencia a mi lado es uno de los mejores presentes que Dios me ha otorgado. Por tu amor sincero, tu apoyo incondicional y el tiempo que me has dedicado, me han demostrado que más que el amor, he encontrado un compañero y amigo en quien confiar. Agradezco a la vida encontrarte y por todos los recuerdos invaluable que hemos construido juntos. Mereces llegar tan lejos como tus sueños te guían y realizar cada uno de tus más profundos anhelos. En alma, mente y corazón, te amo.*

*A mis primas y hermanas del alma. Kenia Ramos y Karen Ramos. En ustedes conocí lo que es crecer con una mano amiga y un amor genuino. Que la vida me permita verlas llegar tan lejos como se lo merecen. Las amo, y aprecio todos los momentos que tuvimos juntas, en alegrías y tristezas siempre las tuve a mi lado y espero seguir teniéndolas.*

*A mis amigos Melania Figueroa, Dariana Calero, Franklin Centeno, Jennifer Oviedo y Saul Rodríguez. Por su cariño incondicional y por todos los momentos compartidos. Los quiero mucho y anhelo que cumplan cada uno de sus sueños, porque merecen alcanzar todo lo que se proponen. Muy especialmente a mi amigo y compañero de monografía, Luis Zeas. Cada frustración, desvelo y esfuerzo valieron la pena. Llevar este sueño en equipo es una de mis mejores decisiones. Te quiero y aprecio.*

*A mi amigo y asesor, Edwin Chavarría. Por ser la primera persona en creer en mí mientras estaba en la universidad, por formarnos académicamente y por siempre*

*compartir tu conocimiento con nosotros. Tu tiempo y esfuerzo para llevar a cabo este sueño lo llevare siempre conmigo, te quiero.*

*A mi mis tíos, tías, primos y primas. Desde pequeña conocí lo que es crecer rodeada de personas extraordinarias. Su fuerza, amor y apoyo durante todos estos años me empujaron e inspiraron a cumplir mis metas. A pesar de las adversidades son una familia resiliente y que nunca pierde la alegría que los caracteriza. Eternamente agradecida por su cariño, los llevo siempre conmigo.*

*A mis maestros, PhD. María Encarnación Juárez, MSc. David Cerda, PhD. María Eugenia Cerda, MSc. Indiana Coronado, Lic. Aquiles Reyes y PhD. Aura Lily Orozco. Su pasión y dedicación en cada materia han sido fundamentales para sentar las bases de mi conocimiento en la carrera. Cada lección impartida no solo me enseñó académicamente, sino que también me inspiró a perseguir mis sueños con determinación. Estoy profundamente agradecida por su apoyo y orientación. Mi respeto y admiración estarán siempre con ustedes.*

*A mis mascotas, Tyson, Max y Ares. Me han acompañado en cada etapa de mi vida. Su presencia ha llenado mis días de felicidad, brindándome consuelo tras un largo día y siendo mis compañeros en las noches de desvelo. Más que simples mascotas, son y siempre serán parte de mi familia.*

*Julissa Ocón*

## Dedicatoria

*A mis padres, Nelson Ocón Saavedra y Oneyda López Gutiérrez: ser su hija es mi más grande orgullo. La persona en la que me he convertido está completamente guiada por sus manos y consejos. Son la fuerza que me motiva cada día a levantarme, perseguir mis sueños, y a esforzarme por ser esa persona de la cual se sientan orgullosos. Su sacrificio y dedicación las llevo siempre conmigo; jamás terminaré de agradecer y compensar todo lo que han hecho por mí. Jamás me demostraron cuán cansados estaban, porque siempre recibía un abrazo de su parte, y hoy les dedico mi más grande logro. No importa qué tan lejos llegue, no olvidaré mis raíces y de dónde vengo. Los amo.*

*A mi hermana y eterna confidente, Joseling Ocón López. Crecer a tu lado es el mayor obsequio que mi existencia ha tenido. Siempre agradecida, porque en cada paso que di, tuve a alguien en quien apoyarme, refugiarme y confiar. Estoy orgullosa de ser tu hermana y de ver a la persona en la que te has formado y de la que he podido ser parte. Siempre llevare conmigo cada uno de los recuerdos que forme a tu lado, nuestras risas, nuestros juegos y tu cálido abrazo. Te amo y, si la vida me permite nacer de nuevo, espero siempre nacer acompañada por ti.*

*A mi hermano, Kevin Ocón López. Gracias por siempre cuidar de mí y por ser una presencia constante en cada paso que doy. Aunque la vida nos lleve por caminos distintos, en mi corazón siempre tendrás un lugar especial. Tu apoyo ha sido un pilar en mi vida, y valoro cada momento compartido y cada recuerdo creado. Te amo profundamente y, con el anhelo de volver a verte pronto, quiero agradecerte sinceramente por tu tiempo, tu espacio y el cariño incondicional que siempre me has brindado.*

*Julissa Ocón*

# Índice

I. INTRODUCCION .....	1
II. OBJETIVOS .....	3
Objetivo general:.....	3
Objetivos específicos: .....	3
III. MARCO TEÓRICO.....	4
3.1. Antecedentes .....	4
3.2 Incendios Forestales.....	5
3.2.1 Susceptibilidad a incendios forestales.....	5
3.3 Factores que influyen en el riesgo de inicio de incendios forestales .....	6
3.3.1 Clima.....	6
3.3.2 Topografía .....	7
3.4 Sistemas de información geográfica .....	8
3.4.1 Principales softwares utilizadas en análisis geoestadístico.....	8
3.4.2 Teledetección .....	9
3.3.3 Vegetación y combustible .....	14
3.3.4 Usos de suelo .....	14
3.3.5 Proximidad a asentamientos y carreteras .....	14
3.5 Sensores remotos:.....	15
3.5.1 Tipos de sensores: .....	15
3.5.2 Tipos de resolución de un sistema sensor:.....	16
3.6 Imagen Satelital .....	17
3.6.1 Preprocesamiento de imágenes satelitales .....	17
3.7 Bandas espectrales de Sentinel 2 .....	19
3.8 Índices espectrales .....	21
3.8.1 Índice de Vegetación de Diferencia Normalizada (NDVI) .....	21
3.8.2 Índice de Humedad de Diferencia Normalizada (NDMI) .....	22
3.8.3 Índice de vegetación de diferencia normalizada verde (GNDVI) .....	22
3.9 Modelos predictivos de incendios forestales .....	23

3.9.1 Clasificadores supervisados.....	23
3.10 Métodos de validación de la precisión de modelos.....	24
3.10.1 Matriz de confusión .....	25
3.10.2 Área bajo la curva (AUC).....	25
3.10.3 Índice de Kappa.....	26
IV. DISEÑO METODOLÓGICO .....	27
4.1 Tipo de estudio .....	27
4.2 Área de estudio.....	27
4.3 Variables independientes .....	28
4.3 Obtención de las imágenes satelitales .....	30
4.4.1 Índices espectrales.....	30
4.4.2 Bandas espectrales de Sentinel 2.....	32
4.4.3 Paisaje/Topografía .....	33
4.4.4 Antropogénicas y/o de casualidad .....	34
4.5 Variable dependiente .....	35
4.6 Análisis estadístico .....	36
4.6.1 Modelo Logístico .....	36
4.6.2 Modelo <i>Random Forest</i> .....	37
4.7 Evaluación y validación del modelo.....	37
4.7.1 Métricas de la matriz de confusión.....	38
4.8 Definición de áreas prioritarias .....	39
4.9 Elaboración de cartografía temática.....	39
V. RESULTADOS Y DISCUSION .....	41
5.1 Variables significativas de los modelos .....	41
5.2 Evaluación y validación de los modelos .....	46
5.3 Distribución espacial de los niveles de riesgo de inicio de incendio .....	49
VI. CONCLUSIONES .....	56
VII. RECOMENDACIONES.....	57
VIII. REFERENCIAS BIBLIOGRAFICAS .....	58
IX. ANEXOS .....	71

## Índice de figuras

<b>Figura 1</b> Componentes de un sistema de teledetección.....	11
<b>Figura 2</b> Espectro electromagnético .....	12
<b>Figura 3</b> Mapa de ubicación del Pacífico nicaraüense. ....	27
Figura 4 Esquema del modelo potencial de incendios .....	28
<b>Figura 5</b> Diagrama de flujo de la metodología empleada. ....	29
<b>Figura 6</b> Usos de suelo del Pacífico de Nicaragua basado en datos de INETER (2015). .....	35
<b>Figura 7</b> Diagrama de flujo del Modelo Random Forest. ....	37
<b>Figura 8</b> Extensión en hectáreas de la clasificación obtenida por el modelo logístico..	49
<b>Figura 9</b> Extensión en hectáreas de la clasificación obtenida por el modelo Random Forest. ....	50
<b>Figura 10</b> Probabilidad de riesgo de inicio de incendios correspondiente al modelo logístico. ....	51
<b>Figura 11</b> Probabilidad de riesgo de inicio de incendios correspondiente al modelo de Random Forest.....	52
<b>Figura 12</b> Índice de vegetación de diferencia normalizada (NDVI) del Pacífico de Nicaragua. ....	71
<b>Figura 13</b> Índice de humedad de diferencia normalizada (NDMI) del Pacífico de Nicaragua. ....	72
<b>Figura 14</b> Índice de vegetación de diferencia normalizada verde (GNDVI) del Pacífico de Nicaragua. ....	73
<b>Figura 15</b> Orientación del Pacífico de Nicaragua. ....	74
<b>Figura 16</b> Pendiente del Pacífico de Nicaragua.....	75
<b>Figura 17</b> Altitud del Pacífico de Nicaragua. ....	76

## Índice de tablas

<b>Tabla 1</b> Bandas espectrales de las imágenes de Sentinel 2. ....	19
<b>Tabla 2</b> Interpretación de Swets para valores del AUC. ....	26
<b>Tabla 3</b> Bandas de Sentinel 2 utilizadas .....	33
<b>Tabla 4</b> Rango de valores para la reclasificación del modelo Random Forest.....	40
<b>Tabla 5</b> Rango de valores para la reclasificación del Modelo Logístico .....	40
<b>Tabla 6</b> Evaluación de importancia de variables significativas basado en estadístico de Wald para el modelo logístico y Mean Decrease Gini para Random Forest.....	42
<b>Tabla 7</b> Matriz de confusión del modelo logístico .....	46
<b>Tabla 8</b> Matriz de confusión del modelo Random Forest.....	46
<b>Tabla 9</b> Métricas de evaluación de la matriz de confusión para el Modelo Logístico y el Modelo de Random Forest.....	47

## I. INTRODUCCION

Durante las últimas décadas, la incidencia de incendios forestales ha aumentado a nivel mundial, generando preocupaciones debido a la severidad y frecuencia con la que estos acontecen cada año (Díaz-Hormazábal y González, 2016). Los incendios tienen impacto a nivel local, regional y global. Anualmente, alrededor de 1.14 petagramos de carbono (PgC) de biomasa vegetal son consumidos por incendios de origen antrópico (Haberl et al., 2007). Esto ha provocado que diversos organismos alrededor del mundo se dediquen especialmente a la mitigación de los efectos de los incendios (Choza, 2019).

En Latinoamérica, los incendios se tornan más complejos, amenazan áreas urbanas y amplias zonas productivas, afectando la vida cotidiana y la estabilidad económica de las comunidades rurales. Sin embargo, a diferencia de los incendios que ocurren en el norte de América o Europa, estos muestran una problemática sociocultural que involucran generaciones de técnicas agropecuarias inadecuadas o una forma de protestar contra medidas en el gobierno (Food and Agriculture Organization of the United Nations [FAO], 1999).

En Nicaragua, existen zonas con un alto riesgo de incendio, donde los departamentos de León y Chinandega ocupan el tercer puesto; mientras que el departamento de Rivas ocupa el cuarto puesto, citando un problema en el sector socioeconómico del Pacífico nicaragüense (Sistema Nacional para la Prevención, Mitigación y Atención de Desastres [SINAPRED], 2007 citado por Velásquez y Benavides, 2014).

La zona del Pacífico representa un importante sector económico en el país, constituyendo la zona más habitada de todo el territorio, con un 60% del total de habitantes (Castillo Hernández et al., 2006). A consecuencia de esto, presenta bosques degradados debido al avance de la frontera agrícola y prácticas agropecuarias inadecuadas (quema de rastrojo); las cuales, son causas recurrentes en la ignición de incendios (FAO, 1999).

Por lo antes planteado, resulta de vital importancia implementar un mapa de riesgo de incendio como una herramienta de apoyo a las instituciones gubernamentales. Un

mapeo preciso de las zonas de riesgo es imprescindible para mitigar los posibles efectos de los incendios forestales (Jaiswal et al., 2002 citado por Parajuli et al. 2020).

Los incendios se han convertido en una amenaza severa y recurrente que perjudica y transforma gran parte de los ecosistemas terrestres. A nivel global ejercen influencia sobre los efectos del cambio climático; mientras que a nivel local generan degradación de suelos, daños a la cobertura vegetal, pérdida de fauna y vidas humanas, así como diversos problemas socioeconómicos (Peralta, 2010).

La evaluación de las condiciones o circunstancias para que ocurran los incendios resulta imprescindible para lograr comprender la distribución espacial y temporal de los incendios, así como sus causas (Pacheco et al., 2009).

Las tecnologías de información geográfica comprenden herramientas efectivas para la gestión del riesgo de incendios forestales, puesto que permiten una evaluación dinámica y espacialmente integrada de los factores condicionantes del fenómeno (Chuvienco et al., 2003).

Para lograr modelizar la probabilidad de riesgo de inicio de incendios se necesita tener en cuenta factores estructurales que permanecen relativamente estables durante al menos una temporada de incendios, como la topografía, el clima y las infraestructuras (densidad de carreteras, regiones habitadas, etc.), suministrando de esta forma, una evaluación a largo plazo de ciertas zonas que podrían ser más propensas a incendios (San-Miguel-Ayanz et al., 2003, citado por Oliveira et al. 2012).

Este trabajo posee un valor añadido, puesto que servirá de apoyo a los tomadores de decisiones concernientes, a orientar acciones y esfuerzos que contribuyan a planes de gestión y prevención idóneos en áreas con alto nivel de riesgo de incendio; aportando de esta forma al ahorro de valiosos recursos económicos que disminuirán costos de operación.

## II. OBJETIVOS

### Objetivo general:

Modelizar la probabilidad de riesgo de inicio de incendios forestales en el Pacífico nicaragüense mediante regresión logística y *Random Forest*.

### Objetivos específicos:

- Identificar las variables topográficas, espectrales y antropológicas relevantes en el modelo.
- Modelizar el peligro de incendios en el área de estudio mediante técnicas de geoestadística.
- Definir áreas prioritarias con riesgo de incendio en el Pacífico nicaragüense.

### III. MARCO TEÓRICO

#### 3.1. Antecedentes

Diversos investigadores en el área de incendios forestales enfocan esfuerzos a la creación de herramientas para la prevención y mitigación de este siniestro. Tal es el caso de Bella et al. (2008) donde se analizan el alcance e importancia de los principales trabajos en el campo de la teledetección en relación a áreas quemadas. Estos autores enfatizan principalmente los alcances y limitaciones de algunos productos de estos trabajos disponibles para el público general.

En el trabajo de Chuvieco et al. (2007) se generó un modelo de peligro de incendios forestales mediante teledetección y sistemas de información geográfica (SIG). Este trabajo incluye información de diversas fuentes que constituyen variables de carácter socioeconómico y topográficas que posteriormente se han cartografiado a una resolución espacial de 1 km<sup>2</sup> y se integran en un sistema de información geográfica, diseñado para este propósito. A través de esto obtuvieron una herramienta que permite estimar el peligro de ocurrencia de incendios forestales.

Los mapas de riesgo de incendios de la región suelen ser de efectividad limitada, puesto que implementan modelos de combustión o mapas de vegetación para elaborar el índice de riesgo. Sin embargo, estudios recientes se han encargado de elaborar modelos precisos para los tomadores de decisiones.

Tal es el caso de un estudio llevado a cabo en México, específicamente en la ciudad de Guadalajara en el Área de Protección de Flora y Fauna La Primavera (APFFLP) que constituye el principal regulador climático de la zona. Donde se construyó un modelo espacial que tomó en cuenta variables meteorológicas, de paisaje, de combustibles, antropogénicas y de casualidad; así como, datos históricos de la ocurrencia de incendios en un determinado periodo de tiempo. El modelo generado predice que la zona central y noreste del polígono del APFFLP posee una alta posibilidad de incendiarse. Estos resultados brindan información que podría contribuir a la generación de mapas de riesgo locales que a su vez constituirán una herramienta para la mitigación de incendios

forestales y restauración del Bosque La Primavera (Ibarra-Montoya y Huerta-Martínez, 2016).

En Nicaragua, la gestión de los incendios forestales se encuentra limitada a la inversión de esfuerzos para el control y extinción de estos. Las acciones o medidas que toman los organismos gubernamentales se centran en campañas contra incendios que contribuyen a la protección y conservación de los bosques (SICA, 2021).

### **3.2 Incendios Forestales**

Para efectos de la presente investigación, se toma por definición de “incendios forestales” el concepto descrito en Tedim y Leone (2020), que menciona incendios forestales como “cualquier incendio no planificado e incontrolado iniciado en arbustos o bosques”, abarcando también zonas agrícolas, pastizales, áreas de matorrales con vegetación densa y otras zonas silvestres.

#### **3.2.1 Susceptibilidad a incendios forestales**

La susceptibilidad a los incendios forestales se puede definir como la posibilidad de que ocurra un incendio en cierta área (Tien Bui et al., 2016). Durante los últimos años, los incendios forestales han representado grandes problemas tanto a nivel ambiental, como socioeconómico. Uno de los objetivos claves de diversos programas e investigaciones enfocadas a la prevención de los siniestros, es desarrollar estrategias que contribuyan a la identificación y limitación de las áreas susceptibles (Reyes-Bueno y Balcazar-Gallegos, 2021).

La modelización de la variabilidad espacial de la susceptibilidad a la ocurrencia de incendios forestales es fundamental, puesto que permitirá elaborar estrategias que permitirán mitigar la ignición de los incendios forestales. Para lograr un análisis de susceptibilidad a incendios forestales es esencial obtener información sobre el comportamiento y la dinámica de los incendios en su forma espacial como temporal (García Echeverri, 2021).

### 3.3 Factores que influyen en el riesgo de inicio de incendios forestales

El inicio de los incendios forestales suele atribuirse a factores naturales y ciertas actividades antropogénicas que se llevan a cabo en las áreas afectadas. Así mismo, su ocurrencia, severidad y comportamiento se ven potenciados por el inminente cambio climático, actividades antropogénicas, cambios en el uso del suelo, entre otras (García Echeverri, 2021). Aunque no se puede predecir la intervención humana de forma espacial y temporal, actualmente si se puede predecir con cierto grado confiabilidad las condiciones que pueden favorecer a la ocurrencia de incendios forestales (Yakubu et al., 2015).

#### 3.3.1 Clima

Los incendios forestales se encuentran vinculados al tiempo y al clima (Flannigan y Wotton, 2001 citado por Yakubu et al., 2015). El clima se considera uno de los factores más importantes en lo que concierne al riesgo de inicio de incendios. Los componentes climáticos que más afectan el comportamiento de un incendio son la temperatura del aire, la humedad relativa y la velocidad del viento.

- **Precipitación:** los patrones de precipitación pueden determinar cuándo y dónde pueden ocurrir los incendios forestales. De igual forma, los periodos de sequía pueden aumentar de manera significativa el número de incendios (Aragão et al., 2008).
- **Temperatura:** representa uno de los factores que más influye en el comportamiento y ocurrencia de incendios forestales. Esto influye directamente en la temperatura del combustible y por ende en la cantidad de energía térmica necesaria para elevarlo hasta su punto de ignición. También tiene efectos indirectos a través de su influencia sobre la humedad relativa de la atmósfera y las pérdidas de humedad por evaporación (Hong et al., 2017). Adicionalmente, hay estudios que evidencian correlaciones entre la ocurrencia de incendios y la extensión del área quemada con las temperaturas registradas durante el verano (Davis et al., 2017).

### 3.3.2 Topografía

Se incluyen los elementos de pendiente, orientación, elevación y configuración del terreno. Aunque es posible que la topografía no cambie con el tiempo, si afecta la forma en que cambian el combustible y el clima (Yakubu et al., 2015).

Según Taylor y Skinner (1998), la topografía no solo influye en el tamaño del área quemada por un incendio, si no también, en la magnitud con la que este ocurre.

De los tres componentes que se tomaron en cuenta para el diseño del modelo, la topografía es la más constante. Esta tiene influencia sobre otras variables, modificando la accesibilidad a determinada zona o la humedad contenida en la vegetación. Por lo tanto, la inclusión de estas variables para el diseño de un modelo de inicio de incendios es esencial para considerarse eficiente (Taylor y Skinner, 1998).

- **Elevación:** es considerado un factor muy influyente en los incendios forestales, debido a que se encuentra relacionado con la precipitación y la temperatura. Con el aumento de la elevación, las precipitaciones y la humedad tienden a aumentar, por ende, la probabilidad de incendio es menor en zonas de mayor elevación (Ghorbanzadeh et al., 2019).

- **Pendiente:** se puede definir como el grado de inclinación de la superficie de los terrenos, formando por el ángulo de los lados (Ghorbanzadeh et al., 2019). La pendiente posee un gran efecto en la velocidad y dirección de la propagación de un incendio. En Sakellariou et al. (2019) se menciona que el fuego siempre se propaga más rápido cuesta arriba que cuesta abajo ya que el calor del área a favor de la pendiente es transmitido por radiación y convección, y este es mayor en el lado opuesto debido a que existe una superficie de contacto mayor y mucho más próximo. De forma resumida, una mayor pendiente del terreno implica una mayor probabilidad de inicio de incendio (Ghorbanzadeh et al., 2019).

- **Orientación:** se define como la dirección hacia la que mira la pendiente. Este factor muestra correlación con la cantidad de energía solar recibida en el área y, por ende, es considerado como un factor que contribuye a la evolución del fuego, ya que se

encuentra influenciado por múltiples dimensiones como la radiación solar, la temperatura y la humedad del suelo (Flannigan et al. 2000, citado por Sakellariou et al., 2019). En Tehrany et al. (2019) se indica que la vegetación orientada hacia el hemisferio sur recibe mayor cantidad de radiación que en el hemisferio norte, provocando temperaturas más altas, vegetación más seca y suelos con menor contenido de humedad, facilitando el inicio de incendios.

### **3.4 Sistemas de información geográfica**

Se puede definir como herramientas informáticas capaces de gestionar y analizar información georreferenciada donde su principal objetivo radica en encontrar o mostrar soluciones a problemas medioambientales y territoriales. Los SIG están compuestos bajo dos sistemas esenciales como lo es el hardware y software. El primero no es más que el soporte físico de la informática y el segundo el soporte lógico, es decir, la programación (instrucciones y datos) (Santos, 2020).

#### **3.4.1 Principales softwares utilizadas en análisis geoestadístico**

La geoestadística nace con la necesidad de implementar herramientas estadísticas que cuantificaran el grado y escala de variación espacial de recursos. A diferencia de la estadística, la geoestadística no solo considera el valor del punto, sino que, además valora los puntos cercanos a la zona, su posición y relación con otras muestras para así obtener resultados más acertados, a partir de los cuales se desarrollan softwares orientados al análisis geoestadístico (Pla et al., 2018).

##### **3.4.1.1 QGIS**

Baghdadi et al. (2020) expresan que QGIS (Quantum GIS) es una herramienta de SIG donde su principal ventaja radica en que es de acceso libre, multiplataforma y escalable gracias al desarrollo de extensiones en lenguajes de Python y C++. Actualmente QGIS posee una amplia cantidad de funciones que permite recoger, almacenar, procesar, almacenar, entre otras funciones de manera sencilla diferentes tipos de datos espaciales y geográficos.

### **3.4.1.2 ArcGIS**

Este software es el principal componente de la suite de aplicaciones de ESRI (Environmental Systems Research Institute) y contiene las principales funcionalidades de SIG de escritorio. Es un conjunto de herramientas que permite el manejo y visualización de información geográfica. ArcGIS cuenta con diversas extensiones entre las que podemos destacar Spatial Analyst y Geostatistical Analyst (Pucha-Cofrep et al., 2017).

### **3.4.1.3 R**

R es un software potente que tiene la capacidad de trabajar con una amplia cantidad de datos. R es un entorno y lenguaje de programación empleado primordialmente para efectuar análisis estadístico de datos y construcción de gráficos, donde su única desventaja radica en que se debe aprender programación para poder trabajar con su amplia gama de funciones. En R se pueden generar mapas y análisis espacial hasta aplicar diversos análisis estadísticos a un conjunto de datos (Sánchez Villena, 2019).

## **3.4.2 Teledetección**

Según Chuvieco (1990), teledetección se define como la “técnica aplicada que permite obtener información a distancia de objetos situados sobre la superficie terrestre”, esto a través de imágenes de la superficie terrestre desde sensores instalados en plataformas espaciales.

Otros autores, como Perez y Muñoz (2006) mencionan que de forma general la teledetección puede ser entendida como el método o procedimiento de adquisición de la información sin necesidad de tener contacto con ello. Estos autores añaden que aplicado al contexto de las ciencias de la Tierra, se entiende como teledetección una técnica que tiene por objetivo la captura, procesamiento y análisis de imágenes tomadas por sensores remotos.

La teledetección ha demostrado aplicabilidad efectiva en la gestión de desastres naturales, monitorización ambiental, elaboración de cartografía, contribución a inventarios de la cobertura y usos del suelo, realización de inventarios forestales,

meteorología, entre otros; lo que la convierte en una técnica con utilidad multidisciplinaria (Chuvienco, 1990).

Ante la constante susceptibilidad de incendios forestales, surge la teledetección como una herramienta muy importante y valiosa que ha sido utilizada de forma amplia por muchos investigadores que se dedican al estudio de la predicción de ocurrencia de este fenómeno a escala global, regional y local (Rosa et al, 2019).

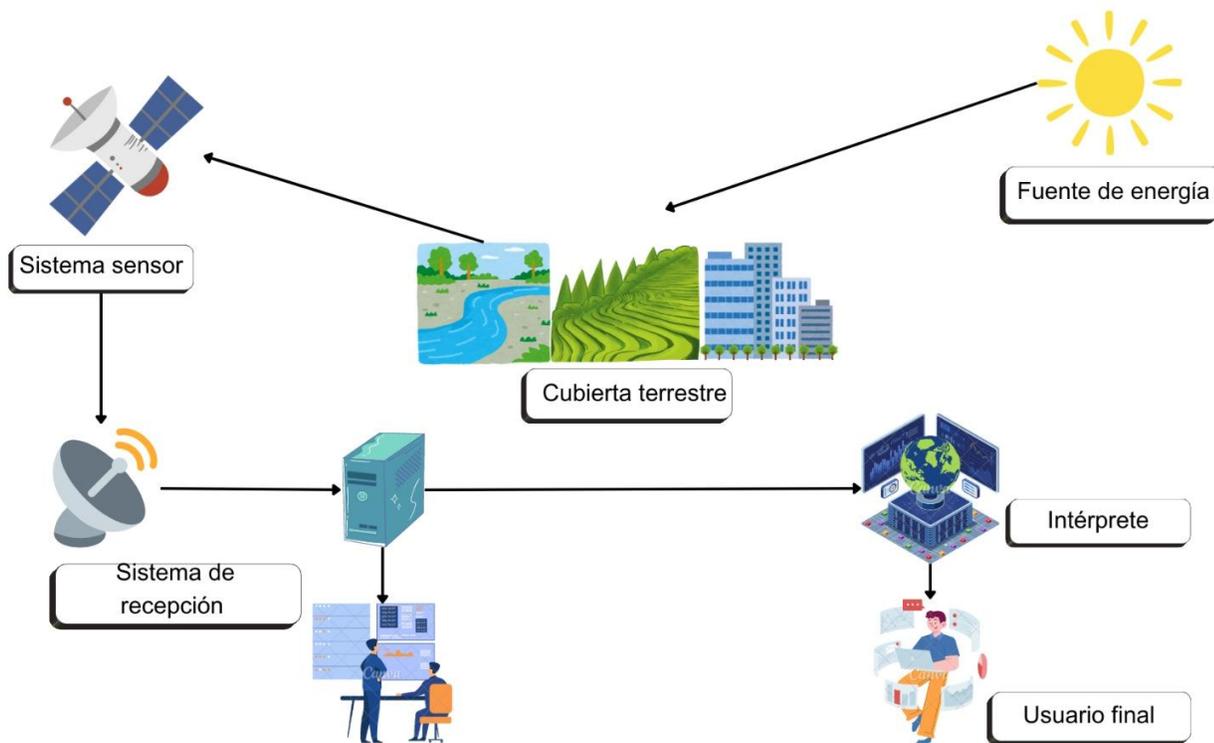
### 3.4.2.1 Componentes de un sistema de teledetección

Según Chuvienco (1990), un sistema de teledetección (Figura 1) consta de los siguientes componentes:

- **Fuente de energía:** representa el origen del flujo energético que detecta el sensor. Esta puede ser de una fuente externa al sensor o bien de un haz energético emitido por el mismo sensor. La fuente de energía más importante es la energía solar.
- **Cubierta terrestre:** está representada por las distintas masas de vegetación, construcciones humanas, suelos o agua, las cuales reciben la energía y la reflejan en dependencia de sus características físicas.
- **Sistema sensor:** conformado por el sensor y la plataforma que lo sustenta. Este tiene la función de captar la energía que proviene de las cubiertas terrestres, codificarlas y enviarlas directamente al sistema de recepción.
- **Sistema de recepción-comercialización:** es en donde se recibe la información transmitida por la plataforma, se graba en un formato adecuado, y, tras algunas correcciones, se distribuye a los intérpretes.
- **Intérprete:** Es el encargado de analizar y transformar los datos, en información temática o cuantitativa, la cual es orientada a facilitar la resolución de un problema determinado.
- **Usuario final:** es el encargado de analizar el documento resultado de la interpretación, así como de las conclusiones que se deriven.

**Figura 1**

Componentes de un sistema de teledetección.



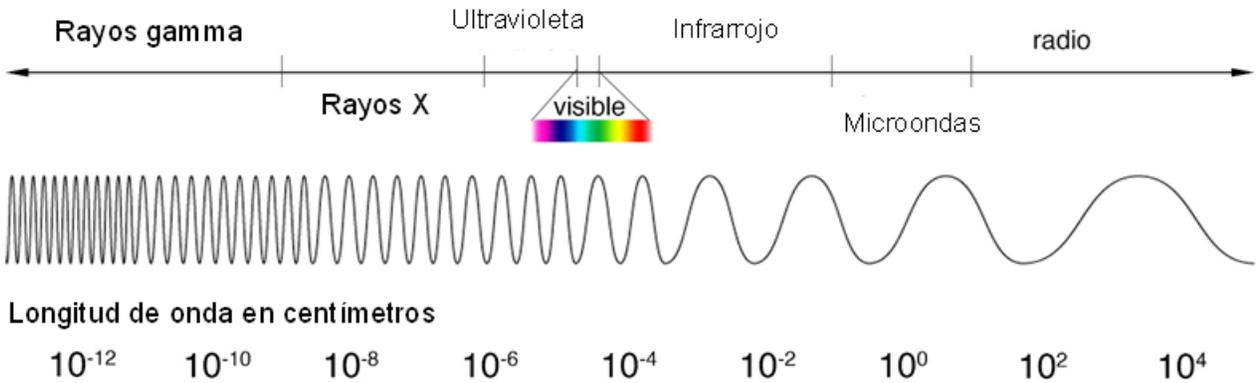
Fuente: Elaboración propia (Canva, 2024)

### 3.4.2.2 Espectro Electromagnético:

El espectro electromagnético es el rango de radiación electromagnética clasificada en función de su longitud de onda (Figura 2). Aunque la sucesión de valores de longitud de onda es continua, generalmente se establecen una serie de bandas en donde la radiación electromagnética manifiesta un comportamiento similar. Estas longitudes comprenden desde las longitudes de ondas más cortas como rayos gamma y rayos x, hasta kilométricas como las señales de radio (Sakellariou et al., 2019).

**Figura 2**

*Espectro electromagnético*



Fuente: Modificado de NASA, (2013)

### **3.4.2.3 Bandas espectrales más utilizadas para la percepción remota aplicadas a incendios forestales:**

De acuerdo con Chuvieco (1990) y Szpakowski et al. (2023) desde el punto de vista de la teledetección, se destacan una serie de bandas espectrales, que son las más utilizadas con frecuencia con la tecnología actual. La terminología más común es la siguiente:

- **Espectro visible (400 nm a 700 nm):** es la única radiación electromagnética que pueden percibir los ojos del ser humano, coincidiendo así con las longitudes de onda en donde es máxima la radiación solar. Aquí suelen distinguirse tres bandas elementales, denominadas azul, verde y rojo.
- **Borde rojo (620 nm a 700 nm):** El valor de reflectancia en esta región se encuentra relacionada con el contenido de clorofila y nitrógeno en la vegetación y por tanto por el estado de salud y vigorosidad de esta. Consecuentemente el estado de salud se encuentra relacionado con la susceptibilidad a inicio de incendios. En Evangelides y Nobajas, (2020) se emplea un índice derivado del borde rojo como medida para evaluar la severidad del daños post incendio en la república de Chipre.

- **Infrarrojo cercano (700 nm a 950 nm):** también se conoce como infrarrojo próximo, Esta adquiere importancia por su capacidad para discriminar masas vegetales de suelo descubierto, evaluar la salud de la vegetación, contenido de humedad y composición del suelo, contando con potencial para la caracterización del combustible en modelos de riesgo o bien evaluación de severidad, ejemplificado por el trabajo de Hu et al. (2021).

- **Infrarrojo medio (1,300 nm a 3,000 nm):** aquí es donde se entremezclan los procesos de reflexión de la luz solar y de emisión de la superficie terrestre. La primera banda, es denominada infrarrojo de onda corta (Short Wave Infrared, SWIR), esta se sitúa entre 1910 y 2190 nm para Sentinel 2 MSI y es una región idónea para estimar el contenido de humedad en la vegetación o los suelos, así como la detección de puntos activos de calor debido a su transparencia al humo.

- **Infrarrojo lejano o térmico (3000 nm a 1 mm):** se incluye la porción emisiva del espectro terrestre, en esta región se detecta el calor que proviene mayormente de las cubiertas terrestres.

#### **3.4.2.4 Firma espectral:**

Cuando la energía electromagnética llega a la superficie de la Tierra, interactúa con los distintos tipos de cobertura terrestre, ya sea por reflexión, absorción o transmisión, generando a partir de esto un patrón de respuesta espectral particular. Este comportamiento distintivo de cada tipo de material es aprovechado en procesos de clasificación de imágenes, siendo común referirse a él como “firma espectral” (Chuvieco et al., 2007).

En otras palabras, la firma espectral se define como el comportamiento diferencial que presenta la radiación reflejada (reflectancia) o emitida (emitancia) desde algún tipo de superficie u objeto terrestre en los distintos rangos del espectro electromagnético, es decir, una “huella dactilar” que permite identificar el estado de la cobertura terrestre (Alonso-Jimenez et al., 1999).

### **3.3.3 Vegetación y combustible**

El tipo de vegetación posee una fuerte relación con el riesgo de incendio forestal, ya que tienen diferentes tipos de combustibilidad (Sakellariou et al., 2019).

Si bien el combustible no inicia el incendio, lo cierto es que cambia el carácter de este, afectando la facilidad de ignición, así como la intensidad del fuego, por lo tanto, resulta importante tomar en cuenta el tipo de vegetación que lo conforma así como su contenido de humedad (Li, 1998, citado por Yakubu et al., 2015).

Frente a la disponibilidad limitada de datos de combustible y meteorológicos, algunos autores como Sakellariou et al. (2020), hacen uso de índices espectrales, precisamente NDVI y NDMI como medios de cuantificación de las variables de vegetación y humedad respectivamente.

### **3.3.4 Usos de suelo**

El Instituto nicaragüense de Estudios Territoriales (INETER), define a los mapas de usos de suelo como “cartografía temática que representa las diferentes formas de ocupación del territorio según un número variable de categorías predefinidas” (INETER, 2015).

Diversos estudios señalan la correlación existente entre el uso de suelo y la ocurrencia de incendios forestales. Barros y Pereira (2014) mencionan que el uso de suelos determina la estructura de la vegetación, carga de combustible y composición del combustible. Estos autores argumentan que los usos de suelo influyen sobre la capacidad de ignición y propagación de incendios forestales al representar la extensión y el tipo de cubierta vegetal existente.

### **3.3.5 Proximidad a asentamientos y carreteras**

La ocurrencia de incendios forestales es más elevada en áreas cercanas a carreteras y sitios donde se llevan a cabo numerosas actividades humanas. Esto ocurre debido a que las carreteras forman vías de acceso a áreas silvestres, facilitando el inicio

de incendios provocados por actividades como quema de residuos, colillas de cigarro y vandalismo (Morrison, 2007).

### **3.5 Sensores remotos:**

Los sensores son aparatos compuestos de una óptica y de un detector sensible a la radiación electromagnética, poseen la capacidad de captar datos a partir de la emisión y reflexión de la radiación electromagnética procedente de los atributos de una superficie terrestre (Olaya, 2014).

Estos sensores son instrumentos que pueden ser colocados en plataformas orbitales como satélites, radares, o ser aerotransportados por aviones. Los datos que registran los sensores se pueden grabar en fotográfico o digital (numérico), por lo que los datos deben estar en formato digital para poder procesarlos en computadoras (Pérez, 2007).

#### **3.5.1 Tipos de sensores:**

Existen diversos tipos de sensores adoptados a los diferentes usos, sin embargo, existe división básica que distingue entre sensores activos y sensores pasivos (Olaya, 2014).

**Activos:** estos proporcionan su propia fuente de energía para la iluminación. Prácticamente generan un haz energético hacia un objeto y luego capta su reflexión. Lo que les permite obtener y registrar los datos de la radiación electromagnética, grabarla y analizarla. Estos sensores operan en los espectros de microondas y ondas de radio dentro del espectro electromagnético, lo que permite penetrar la atmósfera bajo la mayoría de las condiciones y se pueden usar de día o de noche. Ejemplos: Altimetros de Láser, LiDAR, RADAR (Rodríguez Chávez y Arredonda Bautista, 2005).

**Pasivos:** estos aprovechan las fuentes de radiación existentes en la naturaleza, comúnmente registran la radiación del sol, limitándose solamente a capturar y medir la radiación de dichas fuentes reflejada por los elementos del medio. Dentro del espectro electromagnético, captan el visible, el infrarrojo cercano, infrarrojo medio y las longitudes

de onda del infrarrojo termal. La fotografía aérea y el satélite LANDSAT son ejemplos claros de sensores pasivos (Pérez, 2007).

### 3.5.2 Tipos de resolución de un sistema sensor:

En los sistemas sensores de teledetección se habla de cinco resoluciones distintas, esta serie de particularidades determinan las características de las imágenes que van a proporcionar (Perez y Muñoz, 2006).

**Resolución espacial:** De acuerdo a Perez y Muñoz (2006) la resolución espacial es la capacidad del sistema para distinguir objetos en función de su tamaño, se interpreta como el tamaño del objeto más pequeño que puede distinguirse en una imagen o bien el tamaño del píxel sobre el terreno; en los sensores ópticos electrónicos la resolución espacial depende de factores como la altura orbital, velocidad de exploración del satélite o el número de detectores montados en el sensor.

**Resolución espectral:** Este indica el número y anchura de las bandas espectrales que puede discriminar el sensor, es decir, que un sensor tendrá una resolución espectral más grande cuanto mayor sea el número de bandas (Pérez, 2007).

Perez y Muñoz (2006) indican que es conveniente que estas bandas sean lo suficientemente angostas con objeto de recoger la señal sobre regiones coherentes del espectro electromagnético, esto debido que cuando las bandas son muy amplias registran un valor promedio que puede encubrir la diferenciación espectral entre cubiertas de interés.

**Resolución radiométrica:** Describe la capacidad de un sensor para discriminar niveles o intensidades de radiación. La energía electromagnética que es recibida por el sensor, cuando se convierte a nivel digital, requiere un formato binario (número de bits) para lograr codificarse (Chuvieco, 1990).

Una mejor resolución radiométrica significa que el sensor es más sensible a pequeñas diferencias en energía. Cuanto mayor sea este número de bits ( $2^{\text{número de bits}}$ )

bits)=niveles de gris) reservados para almacenar el valor de la reflectividad de un píxel, más alta será la resolución radiométrica y más nítida la imagen (Perez y Muñoz, 2006).

**Resolución temporal:** Se conoce como el tiempo que tarda un satélite para completar un ciclo de órbita, también llamado “tiempo de revisita”. Con ello se determina la periodicidad de adquisición de imágenes de una misma zona. De este modo, se puede cuantificar la capacidad que posee un sensor para registrar los cambios temporales ocurridos sobre una determinada cubierta; desde esta óptica resulta de vital importancia a la hora de efectuar estudios evolutivos (Perez y Muñoz, 2006).

La resolución temporal está condicionada por el tipo de órbita, ángulo de barrido y la velocidad del satélite, así como del diseño del sensor (Chuvienco, 1990).

### **3.6 Imagen Satelital**

Espinoza Diaz (2022) define una imagen satelital como una representación visual de la superficie terrestre y sus atributos, donde su información es registrada y almacenada en un sensor remoto a bordo de un satélite artificial.

Las imágenes satelitales están compuestas por un conjunto de elementos denominados píxeles, los cuales se encuentran dispuestos en filas y columnas y cada uno de estos adquiere un valor numérico que se toma al momento que capta la intensidad y cantidad de energía transmitida por los objetos en la tierra (Espinoza Diaz, 2022).

Las imágenes satelitales pueden ser utilizadas en una amplia gama de investigaciones que brindan información detallada y precisa de las variaciones que ocurren en los ecosistemas, los cambios abruptos que acontecen en zonas urbanas y rurales producto de sucesos naturales o antrópicos como incendios e inundaciones, así como cambios estacionales o cíclicos (Requelme Vigo, 2019).

#### **3.6.1 Preprocesamiento de imágenes satelitales**

Cuando se adquiere una imagen satelital es frecuente que estas presenten diversas alteraciones en los valores de los píxeles, lo cual provoca que no coincida con

el objeto reflejado en la superficie terrestre. Debido a ello es necesario que las imágenes satelitales sean corregidas bajo parámetros geométricos, radiométricos y atmosféricos (Chuvienco et al., 2002).

**Corrección geométrica:** Este tipo de corrección se realiza con el objetivo de reducir los errores que pudieron ocurrir durante la georreferenciación. Estos suelen dividirse en dos: sistemáticos y no sistemáticos. La diferencia radica en que el primero es perceptible y se corrige conociendo las características de distorsión del sensor, mientras que el segundo, no se puede predecir puesto que son aleatorios y se puede corregir mediante el uso de puntos de control (Díaz Gonzalez et al., 2014).

**Corrección radiométrica:** La corrección radiométrica es aquella que nos permite reducir o eliminar aquellos errores relacionados a los valores de los píxeles en la imagen. Este tipo de corrección es de carácter indispensable cuando se trabaja y se compara imágenes obtenidas por diversos sensores. Esta clase de errores suelen ocurrir por fallas de los sensores y efectos atmosféricos (Lira, 2018).

**Corrección atmosférica:** Esta busca eliminar aquellos errores producidos por las distorsiones atmosféricas que capta el sensor (Avtar et al., 2021).

**Conversión de radiancia a reflectancia:** Esta conversión se realiza utilizando el ángulo del sol en el momento en que se tomó la imagen, y la distancia entre la Tierra y el Sol en ese instante; esta información se encuentra en los metadatos de la imagen. Para este proceso se elimina la luz adicional captada por el sensor al tomar la imagen y se convierten esos datos en valores que representan cuánta luz refleja realmente la superficie, en lugar de solo la luz que llega al sensor (Bravo Morales, 2017).

De acuerdo con la Agencia Espacial Europea (2024), las imágenes de Sentinel 2 cuentan con distintos niveles de procesamiento:

- **Nivel L0:** Es un procesamiento realizado en paralelo a la captura de la imagen para la preservación de la integridad de los datos, esta incluye análisis de telemetría, datación y compresión.

- **Nivel L1A:** Involucra procesos de creación de vistas de previsualización, organización de los píxeles de las bandas del SWIR y compresión con el algoritmo JPEG2000.

- **Nivel L1B:** Se generan imágenes calibradas con niveles de radiancia de “parte superior de la atmósfera”. Involucra diversos procesos de corrección tales como eliminación de píxeles defectuosos y reducción de ruido digital.

- **Nivel L2A:** Los productos de este nivel son ortoimágenes atmosféricamente corregida para niveles de reflectancia equivalentes al “fondo de la atmósfera”. El algoritmo de corrección para el nivel L2A fue desarrollado por DLR/Telespazio, comprende técnicas de “estado del arte” especialmente desarrolladas para trabajar con imágenes de Sentinel 2; incluye también algoritmos de clasificación de escenas para la identificación y enmascaramiento de zonas ocultadas por nubes.

### 3.7 Bandas espectrales de Sentinel 2

Las imágenes de Sentinel 2, están conformadas por 13 bandas que trabajan desde la región del visible (VIS) hasta el infrarrojo de onda corta (SWIR) del espectro electromagnético (tabla 1).

**Tabla 1**

*Bandas espectrales de las imágenes de Sentinel 2.*

Bandas	Resolución (m)	Longitud de onda (nm)	Región del espectro	Función
<b>B1</b>	60	443 nm	Aerosol	Utilizado ampliamente para la detección de partículas de aerosol en la atmósfera.
<b>B2</b>	10	490 nm	Azul	La clorofila de las plantas refleja esta longitud de onda de manera particular. Además, que contribuye a la diferenciación del suelo y la vegetación.

<b>B3</b>	10	560 nm	Verde	Es crucial para evaluar la salud de la vegetación, ya que es una longitud de onda donde la clorofila refleja intensamente.
<b>B4</b>	10	665 nm	Rojo	En combinación con otras bandas, ayudan a monitorizar la biomasa y la actividad fotosintética, ya que las plantas sanas absorben fuertemente la luz roja para llevar a cabo la fotosíntesis.
<b>B5</b>	20	705 nm	Borde del rojo 1	En combinación con otras bandas, se utiliza para medir la densidad, la cobertura y el estado de vegetación, ya que permite evaluar la salud y la biomasa de la vegetación.
<b>B6</b>	20	740 nm	Borde del rojo 2	En combinación con otras bandas, se utiliza para medir la densidad y condición de la vegetación. Además, permite la diferenciación entre tipos de vegetación y otras características del terreno.
<b>B7</b>	20	783 nm	Borde del rojo 3	Es eficaz para identificar áreas afectadas por incendio debido a su capacidad para penetrar a través del humo y su alta reflectancia en áreas quemadas
<b>B8</b>	10	842 nm	Infrarrojo cercano 1 (NIR)	Fundamental para evaluar la salud de la vegetación. Las plantas sanas reflejan fuertemente la luz en el NIR, lo que permite medir la biomasa y el vigor de la vegetación. Además, que ayuda a distinguir diferentes tipos de cobertura del suelo.
<b>B8A</b>	20	865 nm	Infrarrojo cercano 2 (NIR)	Es especialmente sensible a la vegetación, ya que las plantas reflejan fuertemente la luz en esta longitud de onda. También es utilizada para detectar estrés hídrico en las plantas, ya que la reflectancia en esta banda varía con el contenido de agua en la vegetación
<b>B9</b>	60	940 nm	Water vapour	Utilizado en la detección de vapor de agua y análisis de características de los cuerpos de agua.

<b>B10</b>	60	1375 nm	Cirrus	Utilizado en la detección de nubes y análisis de partículas de aerosol.
<b>B11</b>	20	1610 nm	Infrarrojo de onda corta 1 (SWIR)	Particularmente útil para analizar la humedad del suelo, la composición de la vegetación y las características de la superficie terrestre
<b>B12</b>	20	2190 nm	Infrarrojo de onda corta 1 (SWIR)	Útil para analizar la humedad del suelo, la vegetación y la discriminación de materiales en la superficie terrestre

Fuente: Modificado de Legarreta García (2020)

### 3.8 Índices espectrales

Para encontrar anomalías o estudiar determinados puntos en la superficie terrestre, es necesaria la aplicación de diversos índices espectrales para analizar estos datos. Estos índices son valores calculados a partir de mediciones de la radiación electromagnética en diferentes longitudes de onda (Xue y Su, 2017).

#### 3.8.1 Índice de Vegetación de Diferencia Normalizada (NDVI)

EL NDVI se calcula como la diferencia normalizada entre la reflectancia roja (R) e infrarroja cercana (NIR), el cual ha sido utilizado ampliamente en diversos estudios para examinar la actividad de la vegetación, así mismo, es considerado un factor importante para evaluar condiciones de humedad del combustible vivo (Ávila-Velez, 2020).

En el caso de Sentinel 2, trabaja con las bandas del rojo B4 (R) y la banda del infrarrojo cercano B8 (NIR), puesto que la clorofila absorbe fuertemente la luz visible y la estructura celular de las hojas refleja fuertemente la luz del infrarrojo cercano (CONAE, 2016).

Su rango de valores oscila entre -1 y 1 y está fuertemente ligado a la salud de la vegetación debido a que la vegetación sana absorbe la luz del rojo visible y refleja niveles del infrarrojo cercano, por el contrario, cuando la planta se enferma o se deshidrata, la capa esponjosa se deteriora y la planta absorbe más luz del infrarrojo cercano, en lugar

de reflejarla, proporcionando así una indicación precisa de la presencia de clorofila, que se correlaciona con la salud de la planta (Giraldo Colonia, 2021).

Según Goetz et al. (2006), este índice es eficiente para estudios que deseen evaluar los impactos del fuego, la recuperación del bosque y su comparación con las condiciones previas al incendio, permitiendo así detectar los cambios en la vegetación y las medidas u acciones a considerar en la zona estudiada.

En algunos estudios de predicción de incendios, como el realizado por Chuvieco et al. (2003) han utilizado el NDVI como un indicador clave para identificar áreas vulnerables, encontrando que un descenso en el NDVI puede señalar un aumento en el riesgo de incendios debido a la disminución de la humedad en la vegetación, mientras que valores de NDVI alto indica vegetación densa y saludable, lo que generalmente está asociado con una menor probabilidad de incendios.

### **3.8.2 Índice de Humedad de Diferencia Normalizada (NDMI)**

Este es un índice que utiliza las bandas de infrarrojo cercano (842nm) y el infrarrojo de onda corta (1610nm) para detectar los niveles de humedad en la vegetación, constituyendo así un excelente indicador del estrés hídrico de las plantas (CONAE, 2016).

Es uno de los índices más utilizados para monitorizar las sequías y zonas vulnerables a los incendios. Su rango de valores oscila entre -1 y 1, siendo aquellos valores negativos y cercanos a cero los que indiquen una baja humedad de la vegetación y por lo tanto condiciones más propicias para la quema (Franzpc, 2019).

### **3.8.3 Índice de vegetación de diferencia normalizada verde (GNDVI)**

Este índice es una modificación del NDVI con la diferencia que sustituye el verde visible por el rojo visible (540 a 570 nm). Este índice es ideal para estimar la actividad fotosintética en la vegetación (Xue y Su, 2017).

Los valores del GNDVI oscilan entre -1 y 1, donde aquellos valores negativos y cercanos a 0 nos indican a superficies cubiertas de agua o suelos desnudos de vegetación, valores positivos y cercanos a 1 reflejan una vegetación saludable y verde,

con un alto contenido de humedad y nutrientes. Esta vegetación, en condiciones normales, tiene menos probabilidad de arder, ya que un mayor contenido de agua y nutrientes suele significar que la planta es menos susceptible a la ignición (Alvarado et al., 2021).

### **3.9 Modelos predictivos de incendios forestales**

Un modelo procura describir o representar la realidad mediante el uso de técnicas matemático-estadísticas. Los modelos predictivos en el contexto de incendios forestales trabajan bajo técnicas cualitativas y cuantitativas que crean un índice de peligro a través de la ponderación selectiva de las variables (González Gutiérrez et al., 2023).

#### **3.9.1 Clasificadores supervisados**

Este tipo de clasificadores son ampliamente utilizados en la teledetección puesto que son más robustos que los enfoques basados en modelo. Teniendo en cuenta que el enfoque de estos es el aprendizaje se debe entrenar a este para que sea capaz de identificar estas características aprendidas en los datos no clasificados (Moreno Rubio, 2021).

##### **3.9.1.1 Algoritmo de Clasificación *Random Forest***

*Random Forest* es un algoritmo de aprendizaje automático que combina la respuesta generada por múltiples árboles de decisión para alcanzar un único resultado. A pesar de la popularidad de los árboles de decisión individuales como algoritmos de aprendizaje supervisado, estos están sujetos a errores de sesgo y sobreajuste, sin embargo, al emplearse en conjunto como lo hace *Random Forest*, se obtienen predicciones más precisas, particularmente cuando los árboles no están correlacionados entre ellos (Liu et al., 2012).

Este algoritmo supera el problema de la inestabilidad en el uso de árboles de clasificación única, lo que resulta en una mayor precisión de predicción (Breiman, 2001).

En el caso de los incendios forestales, *Random Forest* ha sido empleado anteriormente en la modelización del riesgo de incendios forestales obteniendo buena capacidad predictiva como el trabajo de Milanović et al. (2023).

La significancia individual de las variables en el modelo es evaluada mediante la disminución media de Gini. Si la variable es relevante, la disminución media de Gini tiende a dividir nodos mixtos en nodos más homogéneos. Un valor alto sugiere que la variable es más significativa para reducir la impureza en cada nodo y por lo tanto, más significativa para el modelo (Anaya et al., 2023).

### **3.9.1.2 Modelo logístico**

El modelo logístico ha sido usado previamente para estimar la probabilidad de riesgo de incendios mediante la generación de modelos tanto predictivos como explicativos. Este tipo de modelos son sencillos de comprender y aplicar, principalmente cuando la variable dependiente a predecir es dicotómica, basándose en los valores de un conjunto de variables predictoras (Cruz Espíndola et al., 2017).

Sin embargo, este modelo puede generar sesgo o no ser tan preciso cuando se abarca una cantidad de datos considerable generando que al momento de la ejecución no se pueda capturar o visibilizar la compleja relación que existe entre los datos (Saucedo y Inchausti, 2023).

La significancia individual de las variables es evaluada mediante el estadístico de Wald, éste se utiliza para identificar si un coeficiente en un modelo de regresión es significativamente diferente de cero. El test de Wald se analiza como un  $X^2$ , cuando la significancia es menor de 0,05 quiere decir que la variable correspondiente es significativa (Bisquert Perles, 2011).

## **3.10 Métodos de validación de la precisión de modelos**

Resulta imprescindible que cuando se construye un modelo, se ejecute una validación de los resultados, esto con el propósito de evaluar la capacidad predictiva del modelo con respecto a observaciones reales (Saucedo y Inchausti, 2023).

### 3.10.1 Matriz de confusión

También conocida como una matriz de error “es una tabla de contingencia que sirve como herramienta estadística para el análisis de observaciones emparejadas” (Ariza López et al., 2018).

La matriz de confusión está compuesta por un grupo de valores que contabilizan el grado de semejanza de observaciones relacionadas entre sí: un conjunto de datos bajo control (CDC) y un conjunto de datos de referencia (CDR), para los que se ha establecido una clasificación. La matriz de confusión puede crearse a partir de píxeles o bien un objeto geográfico. En otras palabras, la matriz de confusión muestra los registros de los valores obtenidos en contraste con los valores predichos por el modelo, indicando así la calidad de éste (International Business Machines [IBM], 2022).

Sin embargo, la matriz de confusión puede resultar complicada de manejar y entender por lo que se recomienda el uso de índices derivados para resumir y comprender la información que nos arroja (IBM, 2022).

### 3.10.2 Área bajo la curva (AUC)

De acuerdo a Del Valle Benavides, (2017) es considerado el estadístico por excelencia para la evaluación de la capacidad discriminante de un modelo y comparar modelos entre sí, sus rangos varían desde 0,5 a 1 donde el primero nos indica un modelo sin capacidad discriminante y el segundo un modelo con capacidad predictiva perfecta.

El área bajo la curva ROC se define bajo la siguiente fórmula:

$$AUC = \int_0^1 ROC(t) \delta t$$

Los criterios de Swets (Tabla 1) indican que valores debajo de 0,7 baja capacidad discriminante, valores bajo 0,9 indica que pueden ser útiles en casos específicos y mayor a 0,9 con una alta exactitud (Del Valle Benavides, 2017).

**Tabla 2**

*Interpretación de Swets para valores del AUC.*

Exactitud	Rangos
Baja exactitud:	[0,5- 0,7)
Útiles para algunos propósitos:	[0,7-0,9)
Exactitud alta	[0,9-1]

Fuente: Modificado de Del Valle Benavides (2017)

### **3.10.3 Índice de Kappa**

Es un índice ampliamente utilizado en la estadística que es ideal para medir “la concordancia entre dos clasificaciones de imágenes: el mapa clasificado-realidad observada y el que cabría esperar simplemente por azar” (Alzate Giraldo y Sánchez Gómez, 2018).

Este índice permite evaluar si el modelo ha discriminado las categorías correctamente y mejor a la que se hubiera obtenido con una asignación aleatoria. La estimación a través del índice de Kappa se realiza utilizando la siguiente fórmula:

$$Kappa = \frac{P_o - P_e}{1 - P_e}$$

Donde  $P_o$  es la proporción de concordancia observada,  $P_e$  es la proporción de concordancia esperada por azar y  $1 - P_e$ , representa el acuerdo o concordancia máxima posible no debida al azar. Los valores de Kappa oscilan entre 0 y 1, donde uno nos indicaría que posee un nivel de concordancia del 100% y 0 nos indicaría un nivel de concordancias nulas (Cortés-Reyes et al., 2010).

## IV. DISEÑO METODOLÓGICO

### 4.1 Tipo de estudio

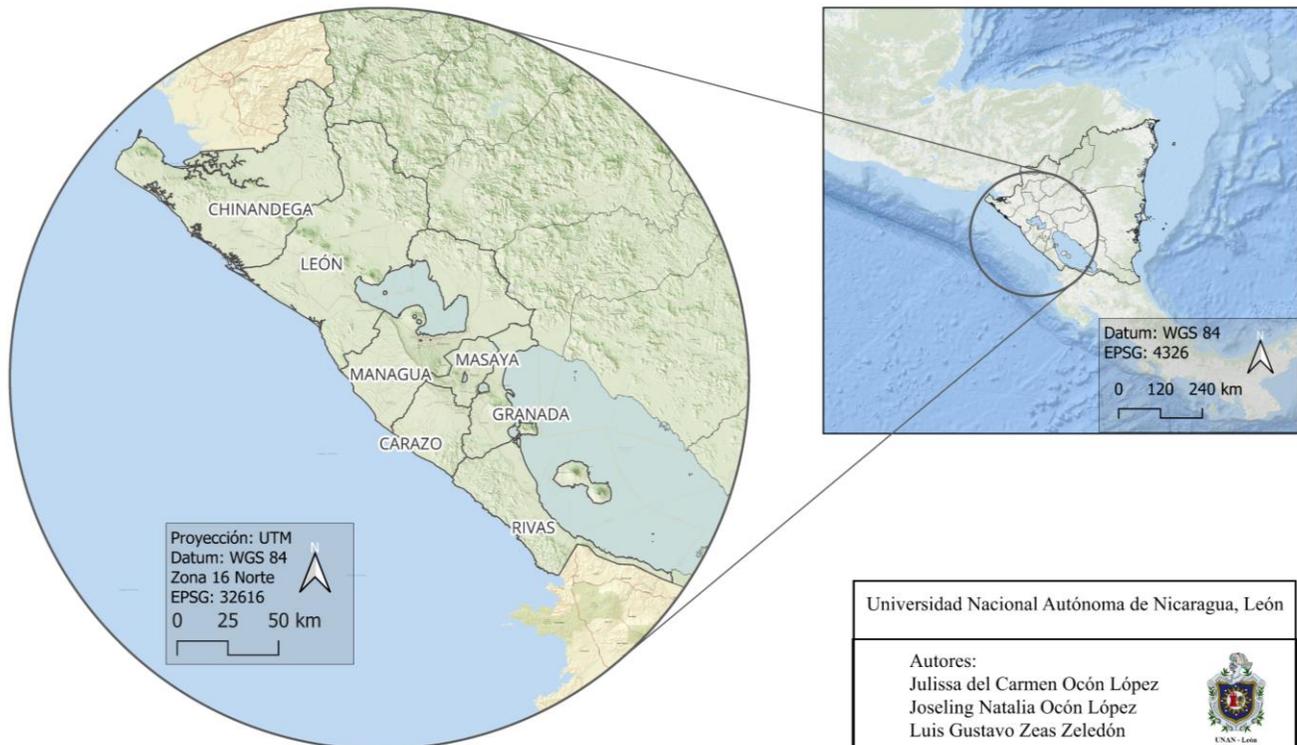
La presente investigación posee un enfoque cuantitativo no experimental con un nivel de estudio explicativo correlacional (Hernández Sampieri et al., 2014).

### 4.2 Área de estudio

La región del Pacífico se encuentra localizada en la zona occidental del país, (Figura 3) esta comprende una extensa llanura formada principalmente por planicies, cordilleras y montañas, constituyendo así más del 15% del total del territorio nacional. El Pacífico de Nicaragua cuenta con una extensión de tierra firme de 18,319 km<sup>2</sup>, caracterizada por ser la región que posee el mayor desarrollo económico y la más densamente poblada (Instituto Nacional de Información de Desarrollo [INIDE], 2022).

**Figura 3**

*Mapa de ubicación del Pacífico nicaraüense.*



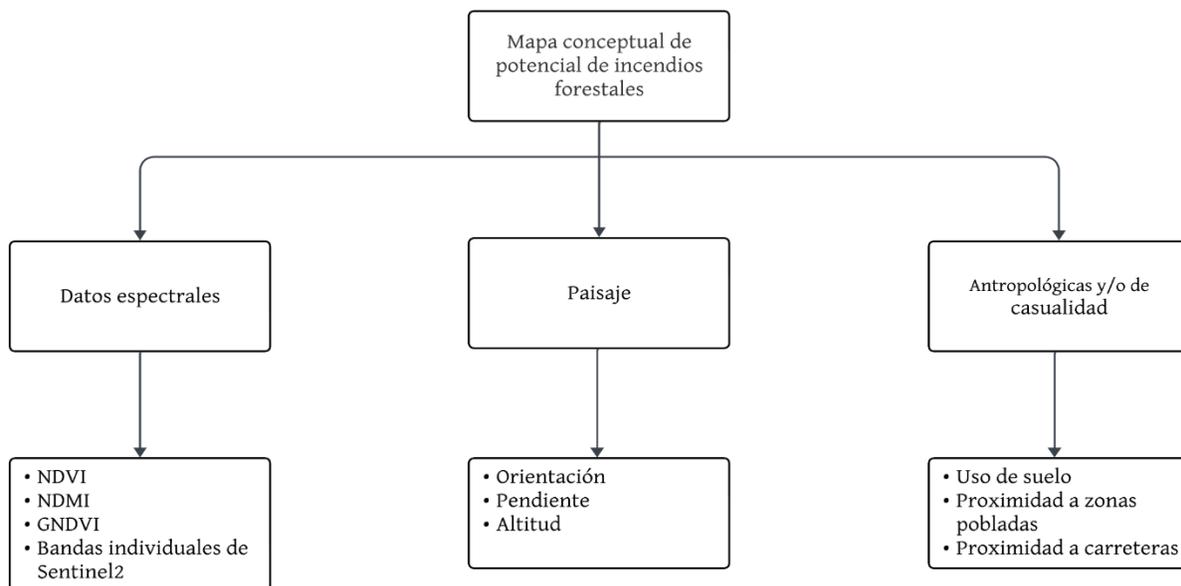
La región del Pacífico cuenta con un clima seco a semi-árido, destaca por contar con la infraestructura más desarrollada del país y suelos altamente productivos, es conocida como la Vieja Frontera Agrícola por la antigüedad de dicha actividad en la zona (FAO, 2002). Alberga uno de los ecosistemas más amenazados por la actividad antropogénica, el bosque tropical seco, que ha sido reducido en un 77% de su extensión original (Portillo-Quintero y Sánchez-Azofeifa, 2010).

### 4.3 Variables independientes

Las variables predictoras se seleccionaron a partir de su influencia sobre el riesgo de ignición en incendios. Se modificó el modelo conceptual de Pompa-García et al. (2012), tomando tres de los cuatro subíndices espaciales que utiliza para describir las variables más influyentes en la ignición y propagación del fuego (Figura 4).

**Figura 4**

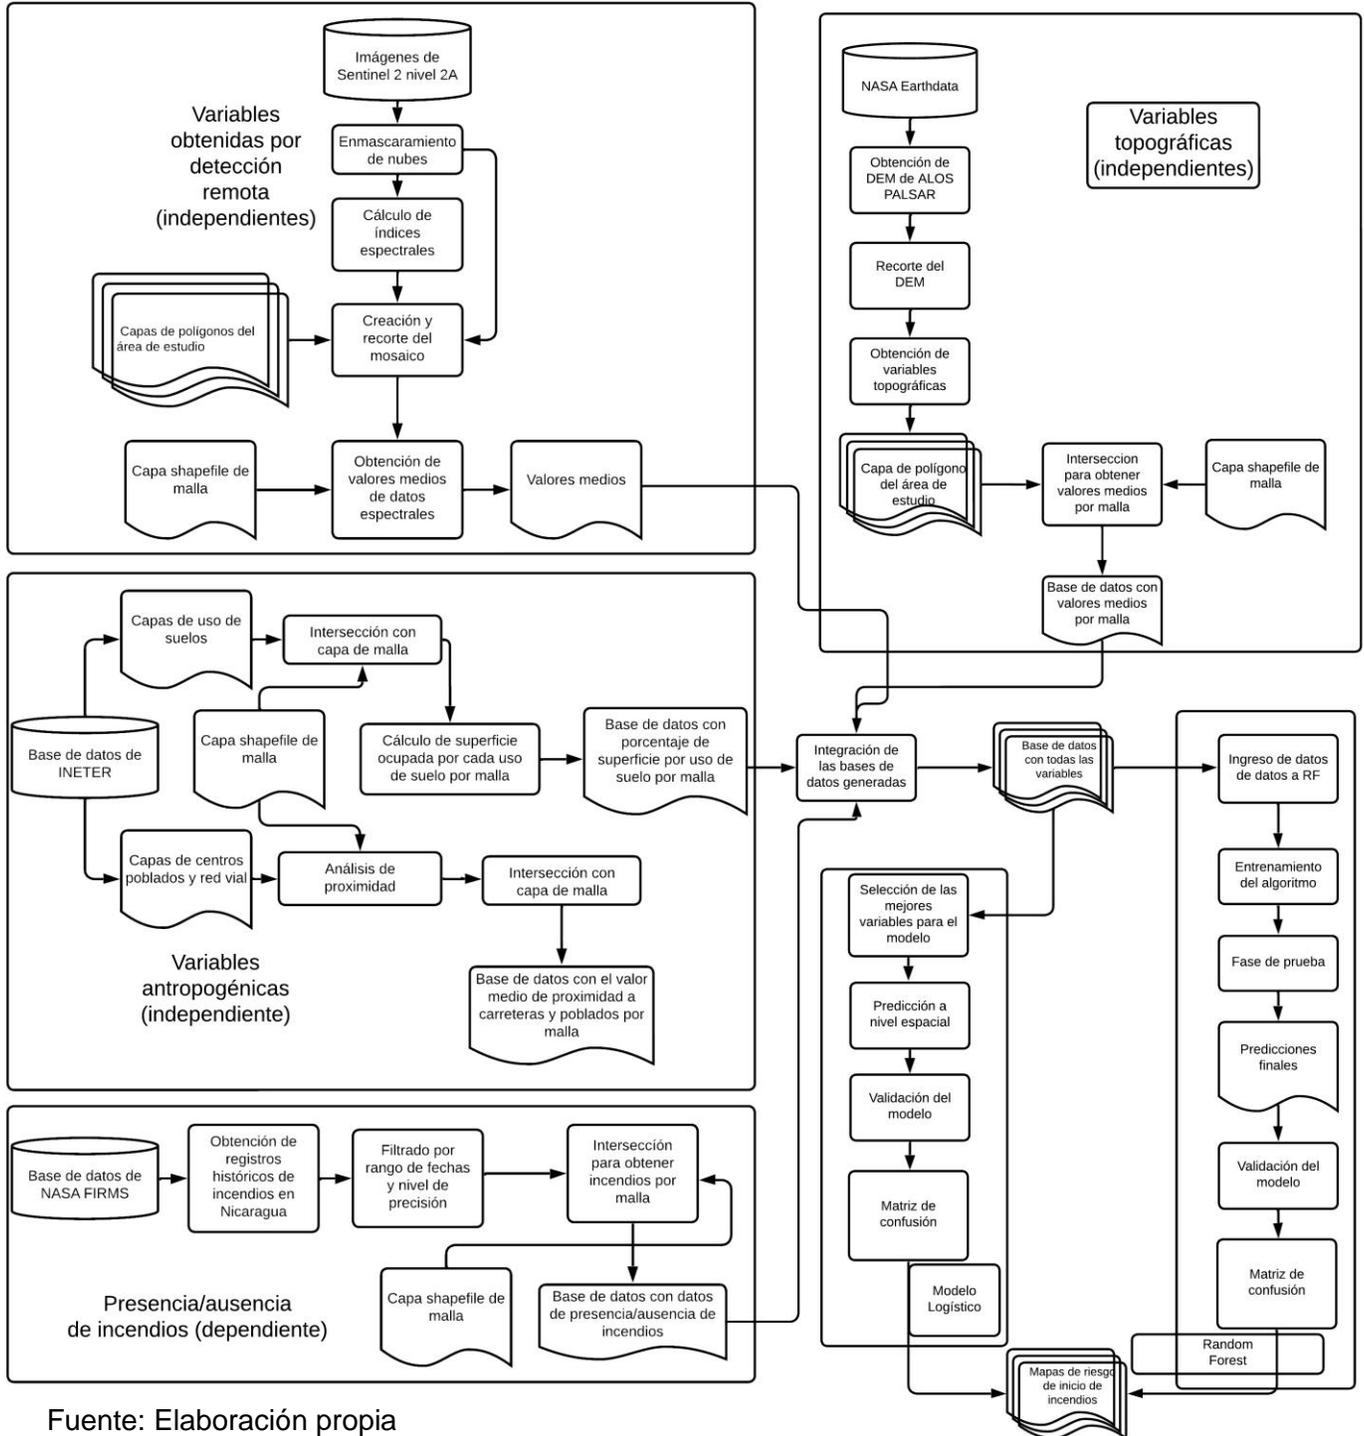
*Esquema del modelo potencial de incendios*



Fuente: modificado de Pompa (2012)

**Figura 5**

*Diagrama de flujo de la metodología empleada.*



Fuente: Elaboración propia

### **4.3 Obtención de las imágenes satelitales**

Las imágenes satelitales se obtuvieron de la plataforma Google Earth Engine que incorpora el lenguaje de programación JavaScript, el cual permite obtener imágenes libres de nubes y calcular índices espectrales antes de la descarga de los datos. Para obtener un modelo actualizado, se seleccionaron imágenes de un rango de cinco años, correspondientes a los años 2020, 2021, 2022, 2023 y 2024, de los meses de enero a mayo debido a la disponibilidad de datos, condiciones climáticas y capacidad de cómputo. Estas imágenes se obtuvieron a través del satélite Sentinel 2 con nivel 2A, las que cuentan con los criterios geométricos, radiométricos y atmosféricos apropiados para su procesamiento. Se eligió este satélite debido a la relativamente alta resolución espacial de sus imágenes (10 a 20 metros por pixel), su resolución temporal de 5 días y su disponibilidad libre de costos (Agencia Espacial Europea, 2024).

Para el manejo de los datos espectrales se generó un mosaico con el promedio de los cinco años correspondientes a las imágenes obtenidas y se recortó con la extensión del Pacífico nicaragüense.

Posteriormente se generó una malla con la extensión del área de estudio con un tamaño de cuadrícula de 1km por 1km, a través de la cual se calcularon valores medios por cuadrícula individual, sumando el valor de todos los píxeles presentes dentro de cada una de las cuadrículas y dividiéndolo entre el número de píxeles dentro de la extensión de la cuadrícula correspondiente.

#### **4.4.1 Índices espectrales**

Existe una amplia gama de índices espectrales utilizados en la modelización de riesgo de inicio de incendios. Estos son una serie de algoritmos que se basan en la evaluación de diversas bandas del espectro electromagnético sensibles a cambios en la superficie terrestre (Fornacca et al., 2018).

En este estudio se evaluaron tres índices espectrales (NDMI, NDVI y GNDVI).

#### 4.4.1.1 NDVI (Normalized Difference Vegetation Index)

El Índice de Vegetación de Diferencia Normalizada (NDVI por sus siglas en Inglés), desarrollado por Rouse et al. (1974), utiliza las bandas de reflectancia correspondientes al infrarrojo cercano (B8) y la banda del rojo visible (B4) para determinar la biomasa aérea en los ecosistemas terrestres

La fórmula que representa el NDVI es:

$$NDVI: \left( \frac{NIR - RED}{NIR + RED} \right)$$

Este índice dispone de valores entre -1 a 1, donde los valores negativos y cercanos a cero indicarían áreas con suelos desnudos, cuerpos de agua y zonas con poca vegetación; mientras que, valores positivos representan cubierta vegetal en diferentes estados (Burapapol y Nagasawa, 2016).

#### 4.4.1.2 NDMI (Normalized Difference Moisture Index)

El Índice de Humedad de Diferencia Normalizada (NDMI), detecta los niveles de humedad que se encuentran en la cobertura vegetal. Este índice se calcula con las bandas del infrarrojo cercano (B8A) y del infrarrojo de onda corta (B11).

El cálculo del NDMI está basado en la ecuación propuesta por Gao (1996):

$$NDMI: \left( \frac{NIR - SWIR}{NIR + SWIR} \right)$$

Los valores de este índice oscilan entre -1 y 1, donde los valores negativos indican zonas con poca humedad, relacionado a vegetación más propensa a incendiarse, caso contrario a valores positivos, que indican combustible húmedo, disminuyendo la probabilidad de inicio de incendio (García Echeverri, 2021).

#### **4.4.1.3 GNDVI (Green Normalized Difference Vegetation Index)**

El Índice de Vegetación de Diferencia Normalizada Verde (GNDVI) es una versión modificada del NDVI que, a diferencia de este, sustituye el rojo visible por el verde visible. A través del empleo de este índice se puede conocer la captación de agua y nitrógeno en la cobertura vegetal. La fórmula es la siguiente:

$$GNDVI: \left( \frac{NIR - GREEN}{NIR + GREEN} \right)$$

Los valores obtenidos a través de este índice, al igual que los anteriores oscilan entre -1 y 1, donde los valores negativos y cercanos a cero nos indicarían suelos desnudos o presencia de agua, mientras que valores positivos indican vegetación saludable con alto contenido de humedad y nutrientes. A diferencia del NDVI, el GNDVI muestra mayor utilidad para diferenciar niveles de vigorosidad en masas vegetales de mayor grado de desarrollo (Intriago Giler, 2022).

#### **4.4.2 Bandas espectrales de Sentinel 2**

Debido al enfoque de esta investigación se utilizaron 10 de las 13 bandas espectrales de Sentinel, estas se visualizan en la Tabla 3.

**Tabla 3***Bandas de Sentinel 2 utilizadas.*

<b>Región del espectro</b>	<b>Bandas</b>	<b>Resolución (m)</b>	<b>Longitud de onda (nm)</b>
Espectro visible (VIS)	B2	10	490 nm
	B3	10	560nm
	B4	10	665 nm
Visible e infrarrojo cercano (VNIR)	B5	20	705 nm
	B6	20	740 nm
	B7	20	783 nm
Infrarrojo cercano (NIR)	B8	10	842 nm
	B8A	20	865 nm
Infrarrojo de onda corta (SWIR)	B11	20	1610 nm
	B12	20	2190 nm

#### **4.4.3 Paisaje/Topografía**

Para la determinación de las variables topográficas (Orientación, pendiente, altitud) se obtuvo el modelo digital de elevación (DEM) a través del Satélite ALOS (Advanced Land Observing Satellite) mediante su sistema independiente PALSAR (Phased Array L-band Synthetic Aperture Radar) en formato ráster.

Al igual que los datos espectrales, se realizó una extracción de valores medios por cuadrícula de malla para las variables pendiente y altitud, en el caso de orientación se calculó el porcentaje de área ocupada por categoría por cuadrícula de malla.

#### **4.4.3.1 Orientación**

La variable orientación se calculó a partir del modelo digital de elevación, obteniendo valores desde 0 a 360 grados; posteriormente se clasificó en base a los criterios de riesgo de Sakellariou et al. (2019), considerando 90 a 315 grados (Este a Noroeste) como solana y 315 a 90 grados (Noroeste a Este) como umbría.

#### **4.4.3.2 Pendiente**

La pendiente se calculó en grados de inclinación en base al DEM, posteriormente los valores en grados fueron transformados en valores de porcentaje para obtener un rango de 0 a 100.

#### **4.4.3.3 Altitud**

La altitud se obtuvo mediante el DEM de ALOS PALSAR en formato raster con resolución de 12.5 metros.

### **4.4.4 Antropogénicas y/o de casualidad**

#### **4.4.4.1 Proximidad a asentamientos y carreteras**

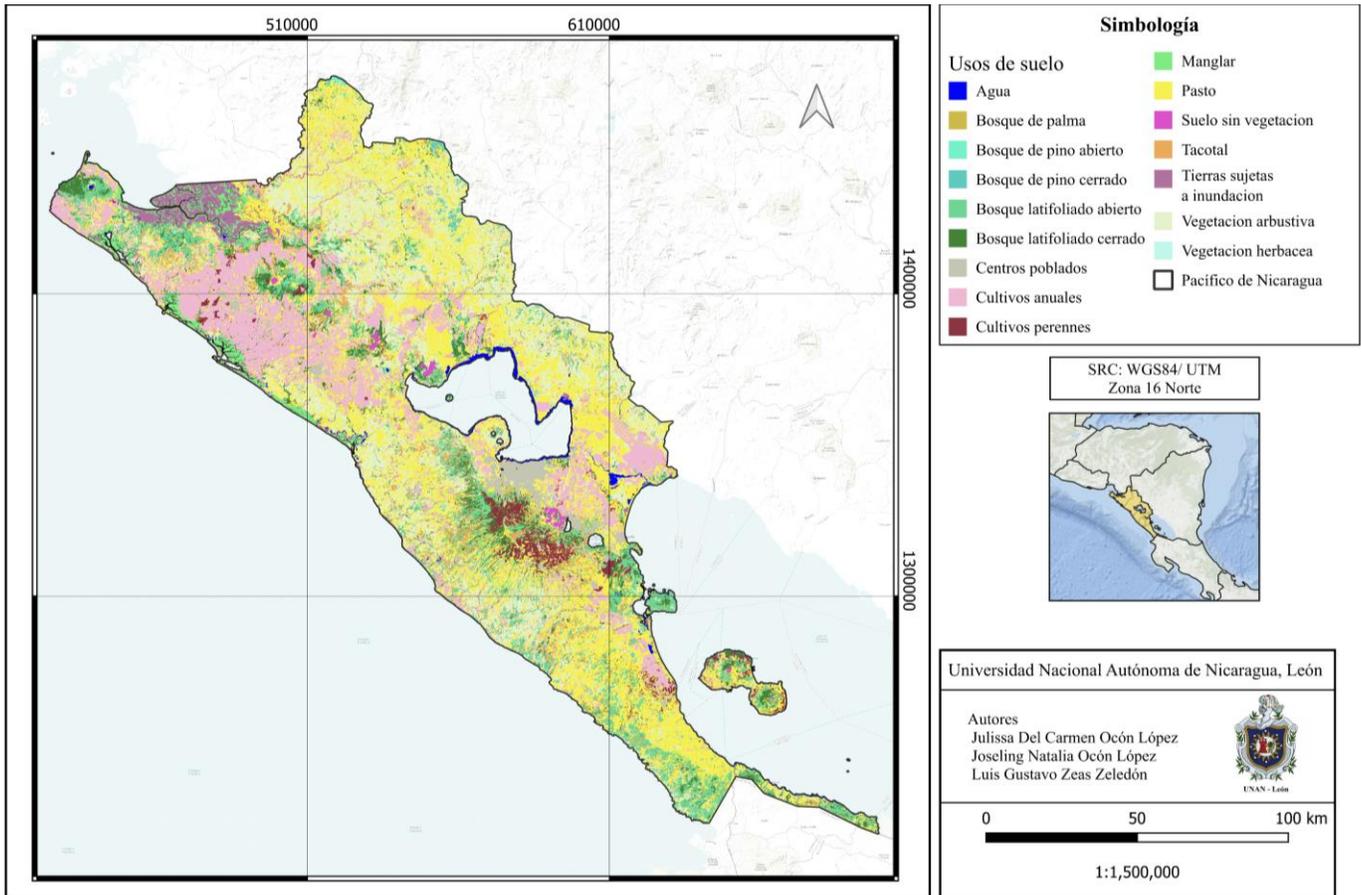
Utilizando las capas vectoriales de red vial y centros poblados se ejecutó un análisis de proximidad mediante la herramienta Euclidean Distance de ArcMap, generando una zona de influencia con distancia expresada en metros bajo resolución espacial de 10 metros por pixel.

#### **4.4.4.2 Usos de suelo**

Los datos de esta variable se obtuvieron del mapa de uso de suelos elaborado por el Instituto nicaragüense de Estudios Territoriales (INETER) en 2015, que fue elaborado sobre imágenes con resolución espacial de 30 x 30 metros a escala de 1:50,000.

**Figura 6**

*Usos de suelo del Pacífico de Nicaragua basado en datos de INETER (2015).*



#### 4.5 Variable dependiente

Para el presente estudio se consideró como variable dependiente los puntos de incendios en la zona del Pacífico nicaragüense obtenidos a través del sistema **FIRMS** (Fire Information for Resource Management System), el cual utiliza los instrumentos **MODIS** (Moderate-Resolution Imaging Spectroradiometer) y **VIIRS** (Visible Infrared Imaging Radiometer Suite) que cuentan con una resolución de 1,000 y 750 metros respectivamente. MODIS se encuentra a bordo de los satélites Aqua y Terra de la NASA, mientras que VIIRS a bordo de los satélites Suomi y NOAA de la NASA.

En el caso de MODIS, se obtuvieron los puntos de calor registrados desde el año 2000 hasta el 2024, en el caso de VIIRS desde el año 2012 hasta el 2024, así mismo,

estos puntos corresponden a los meses de enero a mayo, los cuales pertenecen a la estación seca de Nicaragua (Dirección General de Meteorología de INETER, 2024).

Posteriormente se aplicaron filtros de nivel de confianza de los puntos de calor. MODIS y VIIRS proporcionan datos de confianza que varían de 0 a 100 % con el objetivo de proporcionar datos de mayor calidad. En este estudio, se aplicó un nivel de confianza del 30%, lo que permite obtener interpretaciones precisas y, por ende, una mayor credibilidad científica que favorece la aplicación de los resultados en la gestión de incendios forestales (Alperen Coskuner, 2021).

Adicionalmente se aplicó un filtro a la variable *Type* (tipo) que discrimina los puntos de incendios categorizados como potenciales incendios forestales de puntos provenientes de fuentes alternas como volcanes activos, áreas en cuerpos de agua y otras fuentes estáticas de la superficie terrestre (NASA, 2024).

#### **4.6 Análisis estadístico**

El procesamiento y análisis de los datos fue realizado mediante el programa estadístico y lenguaje de programación R (R Core Team, 2024).

Posteriormente se ingresaron los datos al Modelo *Random Forest* y el Modelo Logístico, tomando como variable dependiente los puntos de incendios por cada cuadrícula de la malla. En el caso del Modelo *Random Forest* se ejecutaron 1,000 árboles de decisión.

##### **4.6.1 Modelo Logístico**

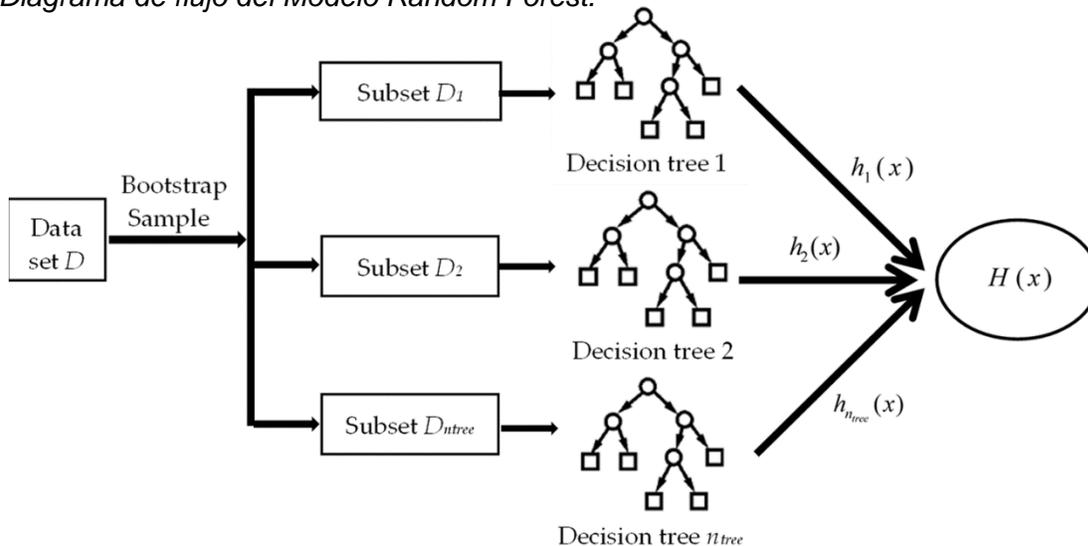
Una vez ingresados los datos al modelo, este realizó un ajuste previo ejecutándose varias veces con distintas combinaciones de variables, la efectividad de cada combinación de variables se evalúa mediante el Criterio de Información de Akaike (AIC). Posteriormente se selecciona la combinación de variables con las que el modelo obtuvo el menor valor de AIC, lo cual indica que es la configuración con la mayor capacidad predictiva bajo el menor número de variables independientes posible (Bevans, 2020).

La significancia individual de cada una de las variables fue evaluada mediante el estadístico de Wald para el Modelo Logístico

#### 4.6.2 Modelo *Random Forest*

Figura 7

Diagrama de flujo del Modelo *Random Forest*.



Fuente: Modificado de Gao et al. (2023)

Se ingresaron los datos al modelo *Random Forest*, seguidamente el algoritmo generó subconjuntos de datos del conjunto original, lo que se denomina muestreo Bootstrap. Para cada uno de los subconjuntos creados por el muestreo Bootstrap se construyó un árbol de decisión, cada árbol generó una predicción basada en los datos proporcionados, en este caso se está prediciendo si hay riesgo de incendio, generando así dos clases, el de ocurrencia o no ocurrencia. La clase que obtuvo más votos se convirtió en la predicción final del modelo (figura 7) (Cutler et al., 2007).

La significancia individual de las variables del modelo fue evaluada mediante la Disminución Media de GINI.

#### 4.7 Evaluación y validación del modelo

La capacidad predictiva de ambos modelos fue evaluada mediante una matriz de confusión, que consiste en una métrica de evaluación ampliamente usada para la

medición del rendimiento de modelos de clasificación, específicamente contrasta las predicciones realizadas por el modelo con las observaciones verdaderas, permitiendo conocer la tasa de aciertos y la proporción de fallos de tipo falsos negativos o falsos positivos (IBM, 2022).

#### 4.7.1 Métricas de la matriz de confusión

A partir de los datos obtenidos de las matrices de confusión para el modelo Logístico y el modelo de *Random Forest*, se calcularon y evaluaron las métricas de sensibilidad y especificidad en ambos casos.

**Sensibilidad:** Se define como la probabilidad de la clasificación correcta de un elemento cuyo estado real es positivo, por consecuencia también se le conoce como Fracción de Verdaderos Positivos (FVP). En contexto actual, una alta sensibilidad nos indicaría que el modelo detecta correctamente donde es probable que ocurra un incendio (Chuma Pomasqui y Coronado Cacuango, 2022).

La sensibilidad está representada por la siguiente ecuación:

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

**Especificidad:** Es la probabilidad de clasificar correctamente un elemento que en realidad se considera negativo. Esto se calcula restando de uno la Fracción de Falsos Positivos (FFP). En el riesgo de inicio de incendios, una alta especificidad significa que el sistema tiene una gran capacidad para identificar correctamente la ausencia de incendios (Chuma Pomasqui y Coronado Cacuango, 2022).

La especificidad está representada por la siguiente ecuación:

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

Debido a que el algoritmo de *Random Forest*, se genera mediante muestras de arranque (Bootstrap Sampling), no fue estrictamente necesario dividir el conjunto total de datos en partes de entrenamiento y validación.

Estas muestras de arranque son subconjuntos aleatorios del conjunto de datos original. Cada árbol de decisión se entrena utilizando una de estas muestras, donde algunos datos pueden ser seleccionados múltiples veces en una muestra, mientras que otros pueden no ser seleccionados en absoluto para un árbol específico. La parte de datos de entrenamiento que no se utiliza en la muestra Bootstrap para un árbol en particular, se denomina datos Out-of-Bag (OOB) (Guo et al., 2016).

#### **4.8 Definición de áreas prioritarias**

Los valores obtenidos por ambos modelos se reclasificaron en 5 categorías en función de su nivel de riesgo (tablas 4 y 5). La clasificación fue realizada mediante el Método de Clasificación de Cuantiles, generando un número igual de observaciones para cada clase. Este método es ampliamente utilizado en investigaciones por su eficiencia para manejar valores continuos (Tehrany et al., 2014).

Se consideraron como áreas prioritarias las zonas clasificadas bajo la categoría de “Muy alto riesgo” por ambos modelos.

#### **4.9 Elaboración de cartografía temática**

A partir de los resultados obtenidos del Modelo Logístico y el Modelo *Random Forest* a través del software QGIS 3.34.8 (QGIS.org, 2023) se elaboró cartografía temática para la representación gráfica de la distribución espacial de los niveles de riesgo de inicio de incendio.

**Tabla 4.**

*Rango de valores para la reclasificación del modelo Random Forest.*

<b>Rango</b>	<b>Nivel de riesgo</b>
0 – 0.22	Muy bajo
0.22 – 0.85	Bajo
0.85 – 0.92	Medio
0.92 – 0.96	Alto
0.96 – 1.00	Muy alto

Fuente: Elaboración propia

**Tabla 5.**

*Rango de valores para la reclasificación del Modelo Logístico.*

<b>Rango</b>	<b>Nivel de riesgo</b>
0 – 0.59	Muy bajo
0.59 – 0.73	Bajo
0.73 – 0.79	Medio
0.79 – 0.83	Alto
0.83 – 1.00	Muy alto

Fuente: Elaboración propia

## V. RESULTADOS Y DISCUSION

### 5.1 Variables significativas de los modelos

De acuerdo con los resultados obtenidos, el modelo logístico seleccionó 26 de las 33 variables ingresadas. De estas, 21 se clasificaron con una significancia muy alta, 3 una significancia alta, 1 con significancia moderada y 1 variable no resulto significativa para el modelo.

El modelo logístico identificó el índice de humedad de diferencia normalizada (NDMI) como la variable más importante en el riesgo de inicio de incendios, seguido por la banda de infrarrojo de onda corta (B11) y el índice de vegetación de diferencia normalizada verde (GNDVI). Todas estas variables presentan valores inferiores a 0.001, lo que indica su alta relevancia para el modelo (Tabla 6).

El modelo de *Random Forest* identificó la banda de infrarrojo de onda corta (B11) como la variable más significativa, con un valor de 6.624, lo que indica una contribución significativa a la reducción de la impureza en los árboles del modelo, seguido por la banda de infrarrojo de onda corta 2 (B12) y la altitud con valores de 5.875 y 5.066 respectivamente. Ambos modelos coincidieron en identificar el “Bosque de Palma” como la variable menos significativa, con un valor cercano a 1 en el modelo logístico y un valor de 0.002 en *Random Forest* (Tabla 6).

En ambos modelos, la banda espectral B11 y en *Random Forest* la banda B12, que corresponden a la región del espectro electromagnético de Infrarrojo de Onda Corta (SWIR), figuran entre las variables más significativas para ambos modelos. Según Chuvieco et al. (2002), la región del SWIR es particularmente sensible a zonas quemadas y es crucial para detectar la humedad en la vegetación y el suelo, identificar áreas secas potencialmente inflamables y capturar la radiación térmica emitida por la superficie, facilitando la detección temprana de incendios, incluso a través de humo y nubes, permitiendo una evaluación precisa de la extensión y la intensidad del fuego. Integrada con otras bandas del espectro, como el infrarrojo cercano y el visible, el SWIR mejora la precisión de los modelos predictivos y los índices de vegetación, ofreciendo una visión

más completa y precisa del estado de los ecosistemas afectados por incendios (Maxar Technologies, 2024).

**Tabla 6.**

*Evaluación de importancia de variables significativas basado en estadístico de Wald para el modelo logístico y Mean Decrease Gini para Random Forest.*

Modelo logístico		Random Forest	
Variable	Wald	Variable	Disminución Media de Gini
NDMI	< 2e-16 ***	B11	6.624
B11	< 2e-16 ***	B12	5.875
GNDVI	< 2e-16 ***	Altitud	5.066
Manglar	< 2e-16 ***	GNDVI	4.914
Cultivos anuales	< 2e-16 ***	Pendiente	4.585
Tacotal	< 2e-16 ***	NDMI	4.506
Vegetación arbustiva	< 2e-16 ***	B5	4.247
Bosque latifoliado abierto	< 2e-16 ***	B2	4.014
Pasto	< 2e-16 ***	B8A	3.99
Bosque latifoliado cerrado	7.82e-16 ***	B4	3.84
Tierras sujetas a inundación	1.94e-15 ***	B8	3.816
Agua	3.37e-14 ***	NDVI	3.716
Centros poblados	5.06e-14 ***	Cultivos anuales	3.702
Cultivos perennes	2.65e-13 ***	B3	3.7
Suelos sin vegetación	3.26e-13 ***	Pasto	3.679
Bosque de pino cerrado	3.45e-13 ***	Vegetación arbustiva	3.679
Vegetación herbácea	2.89e-12 ***	Solana	3.545
Bosque de pino abierto	2.69e-08 ***	Umbría	3.529

B8A	1.09e-07 ***	B6	3.511
B3	5.10e-06 ***	B7	3.411
Pendiente	5.67e-06 ***	Agua	2.54
B5	0.00236 **	Bosque latifoliado abierto	2.334
B8	0.00402 **	Tacotal	2.138
B6	0.00552 **	Centros poblados	2.072
B2	0.02261 *	Vegetación herbácea	1.83
Bosque de palma	0.92427ns	Bosque latifoliado cerrado	1.697
		Cultivos perennes	1.31
		Suelos sin vegetación	0.73
		Manglar	0.626
		Tierras sujetas a inundación	0.508
		Bosque de pino cerrado	0.177
		Bosque de pino abierto	0.07
		Bosque de palma	0.002

---

Nota: Niveles de significancia según Milanović et al. (2021) ns (no significativo), \* (significancia moderada <0.05), \*\* (significancia alta <0.01), \*\*\* (significancia muy alta <0.001)

El Índice de Humedad de Diferencia Normalizada (NDMI), se identificó como uno de los factores determinantes más importantes, tanto en el modelo logístico como en el modelo de *Random Forest*. Sin embargo, el modelo logístico le asignó una significancia mayor, destacándolo por encima de otros índices y omitiendo algunos como el NDVI. Esta diferencia puede deberse a una correlación positiva alta, lo que sugiere que al

aumentar la densidad y vigor de la vegetación (NDVI) de igual forma aumentará la humedad (NDMI) (Segura Herrera, 2021).

En contraste, en el modelo de *Random Forest*, el Índice de Vegetación de Diferencia Normalizada (NDVI) así como las bandas espectrales que lo miden, que corresponde a la Banda 4 y la Banda 8, aparecen con niveles de significancia relativamente altos. Este índice permite analizar la salud de la vegetación y monitorear sus cambios a lo largo del tiempo en la superficie terrestre, permitiendo identificar áreas de vegetación estresada o degradada, que son más susceptibles a los incendios. Un NDVI bajo indica vegetación en condiciones de estrés hídrico o sequía, lo que aumenta la probabilidad de ignición y propagación del fuego (Rouse et al., 1974).

El Índice de vegetación de diferencia normalizada verde (GNDVI), y una de las bandas que lo miden, la banda B3 (Green), también son relevante en ambos modelos. Este índice adquiere relevancia, puesto que permite evaluar el riesgo de incendios debido a su sensibilidad al contenido de agua en la vegetación. Según Flores Rodríguez et al. (2021), el GNDVI proporciona una evaluación más precisa del estado de salud de la vegetación, identificando áreas estresadas hídricamente que son más propensas a incendios. Por lo que, al ser integrado en modelos predictivos junto con otros datos ambientales es útil para detectar cambios en la vegetación que aumentan el riesgo de incendios.

Las variables topográficas como la Altitud, Pendiente y Orientación (umbría y solana) son importantes en el modelo *Random Forest*, reflejando la influencia del terreno en la probabilidad de incendios. Según Díaz-Delgado et al. (2004), la pendiente afecta la velocidad y dirección de propagación del incendio, que se propaga más rápido cuesta arriba y con pendientes más pronunciadas. La orientación también influye en el estado del combustible: en laderas de solana, el combustible se seca más rápidamente, siendo más seco y menos denso que en laderas de umbría. Asimismo, la altitud afecta las condiciones ambientales; a mayor altitud, las temperaturas suelen ser más bajas y la humedad relativa mayor, lo que generalmente reduce el riesgo de incendios, mientras que a menor altitud ocurre lo contrario (Rothermel, 1991).

Las Bandas B2 (Azul) y B5 (Borde Rojo) fueron clasificadas en niveles altos por orden de significancia en el modelo de *Random Forest*, destacando su relevancia en la predicción de incendios. Esto coincide con el estudio de Acosta y Ojeda (2023), quienes señalan que, junto con otras bandas espectrales, estas pueden identificar áreas con temperaturas elevadas y cambios en la vegetación, proporcionando información sobre el impacto de incendios tales como análisis de severidad y recuperación (Instituto Geográfico Nacional, 2018).

Los cultivos anuales, la vegetación arbustiva y el pasto son tomadas como muy significativas en el modelo logístico y aparecen en niveles medios en el modelo *Random Forest*. Según Wilder et al. (2021), sugiere que estos tipos de cobertura vegetal son especialmente vulnerables o contribuyen significativamente a la propagación de incendios. Estos usos de suelo suelen tener periodos específicos de crecimiento y sequía, lo que aumenta la cantidad de material seco e inflamable en ciertas épocas del año, favoreciendo la rápida propagación de incendios en áreas abiertas.

El bosque de palma tiene un valor p no significativo en el Modelo Logístico y figura en el último nivel por orden de significancia en *Random Forest*, sugiriendo que esta variable no es relevante para ninguno de los modelos. De manera similar, las tierras sujetas a inundación, suelos sin vegetación, manglar y los bosques de pino cerrado, muestran valores bajos en *Random Forest* en contraste con el modelo Logístico. Esto podría indicar que estas variables tienen un impacto más evidente en el modelo Logístico, donde las relaciones entre las variables y la variable dependiente son más directas y lineales. En contraste, el modelo de *Random Forest*, al ser basado en la construcción de múltiples árboles de decisión, el efecto de la variable podría no ser tan destacado o podría mezclarse con los efectos de otras variables (Cucchiara, 2012).

## 5.2 Evaluación y validación de los modelos

Para validar la precisión de ambos modelos, se elaboró una matriz de confusión para cada uno, obteniendo para el Modelo Logístico 855 verdaderos negativos, 13,190 verdaderos positivos, 77 falsos positivos y 77 falsos negativos (Tabla 7). En el caso de *Random Forest*, se obtuvieron 2951 verdaderos negativos, 12,374 verdaderos positivos, 3112 falsos positivos y 893 falsos negativos (Tabla 8).

**Tabla 7.**

*Matriz de confusión del modelo logístico*

		Valores predichos	
		No incendio	Incendio
Valores observados	No incendio	855	77
	Incendio	5208	13,190

Fuente: Elaboración propia

**Tabla 8.**

*Matriz de confusión del modelo Random Forest*

		Valores predichos	
		No incendio	Incendio
Valores observados	No incendio	2951	3112
	Incendio	893	12,374

Fuente: Elaboración propia

Los datos de la matriz de confusión revelan que el modelo logístico cuenta con una precisión global de 72%. Esto coincide con el estudio realizado por Bisquert Perles (2011) en el cual se realizó y evaluó el riesgo de incendio forestales en Galicia y Asturias mediante un modelo de regresión logística. Este modelo logró clasificar correctamente el 70% de las observaciones.

En cambio, el modelo *Random Forest* cuenta con una capacidad predictiva del 79%. Este resultado es consistente con el estudio de Anzola et al. (2024) que obtuvo una precisión aproximada del 75%. Estos hallazgos sugieren que los modelos generados por

el algoritmo *Random Forest* son eficaces para manejar grandes volúmenes de datos con características complejas, ya que son capaces de gestionar la multicolinealidad y reducir el riesgo de sobreajuste.

Los datos que proceden de las matrices de confusión del modelo logístico y el modelo de *Random Forest* se utilizaron para evaluar la sensibilidad y especificidad como métricas clave para evaluar el rendimiento de ambos modelos. Estas métricas permiten medir la eficacia de los modelos en la identificación correcta de situaciones de riesgo, diferenciando entre casos positivos y negativos (Chingal Huaca y Anrango Torres, 2019).

**Tabla 9.**

*Métricas de evaluación de la matriz de confusión para el Modelo Logístico y el Modelo de Random Forest.*

	<b>Sensibilidad %</b>	<b>Especificidad %</b>
<b>Modelo Logístico</b>	71.6	91.7
<b><i>Random Forest</i></b>	93.2	48.6

Fuente: Elaboración propia

Ambos modelos presentaron diferencias significativas para ambas métricas de evaluación (Tabla 9). La sensibilidad para el Modelo logístico y el Modelo de *Random Forest* fue de 71.6% y 93% respectivamente. Por el contrario, la especificidad para el Modelo logístico y el Modelo de *Random Forest* fue de 91.7% y 48.6% correspondientemente.

Estos resultados son similares al estudio llevado a cabo por Díaz Timoté (2020) donde la sensibilidad del modelo fue superior al 90%. Este trabajo menciona que se catalogan como modelos con sensibilidad significativas a aquellos con un porcentaje superior al 70%. Estos resultados indican que ambos modelos poseen una buena capacidad para la detección de zonas con probabilidad de riesgo de inicio de incendios.

Sin embargo, los resultados en cuanto a efectividad son significativamente diferente en ambos modelos. En el contexto actual, el Modelo Logístico a pesar de tener una mayor especificidad tiene una sensibilidad menor, lo que indica que el modelo es más susceptible a presentar falsos negativos en puntos con riesgo de inicio que requieren

atención. Por su parte el modelo de *Random Forest* posee una especificidad considerablemente menor, lo que indicaría mayor tendencia a falsos positivos. No obstante, la alta sensibilidad de ambos modelos cobra mayor significancia para la gestión efectiva del riesgo de inicio de incendios (Nieto Gonzalez, 2018).

Es crucial destacar como la cantidad y calidad de los datos influyen en los modelos y como estos pueden afectar su precisión. Según Denham y Cortés Fité (2007), la exactitud y la capacidad predictiva de los modelos dependen en gran medida de la calidad de los datos de entrada, especialmente en aquellos modelos que manejan datos complejos, como los que predicen el riesgo de inicio de incendios; estos autores enfatizan que la disponibilidad de datos meteorológicos es fundamental para la calidad de los resultados, puesto que estos datos están directamente relacionados con la ignición y propagación de los incendios. Adicionalmente, Castillo et al. (2019) mencionan que las condiciones extremas de temperatura, humedad relativa, velocidad del viento, entre otros factores, pueden reducir la humedad de los combustibles forestales y alterar las condiciones del suelo, aumentando así el riesgo de inicio de incendios.

Milanović et al. (2021) realizaron un estudio similar en el que evaluaron la probabilidad de incendios forestales en el este de Serbia utilizando regresión logística, con la diferencia que incorporaron cuatro componentes en su modelo, incluidos los datos meteorológicos específicos de la zona de estudio. Este enfoque les permitió lograr una capacidad predictiva del 0.9%.

Se observa una diferencia en la precisión entre ambos modelos. Según estudios como los de Milanović et al. (2021) y Milanović et al. (2023), los métodos basados en regresión logística presentan limitaciones cuando se aplican a conjuntos de datos amplios, siendo más adecuados para datos binarios que predicen la ausencia o presencia del fuego. En contraste, el modelo de *Random Forest* demuestra ser muy eficaz para capturar relaciones no lineales y complejas entre variables. Además, ofrece un buen equilibrio entre precisión y sensibilidad, y es capaz de manejar grandes volúmenes de datos de manera eficiente.

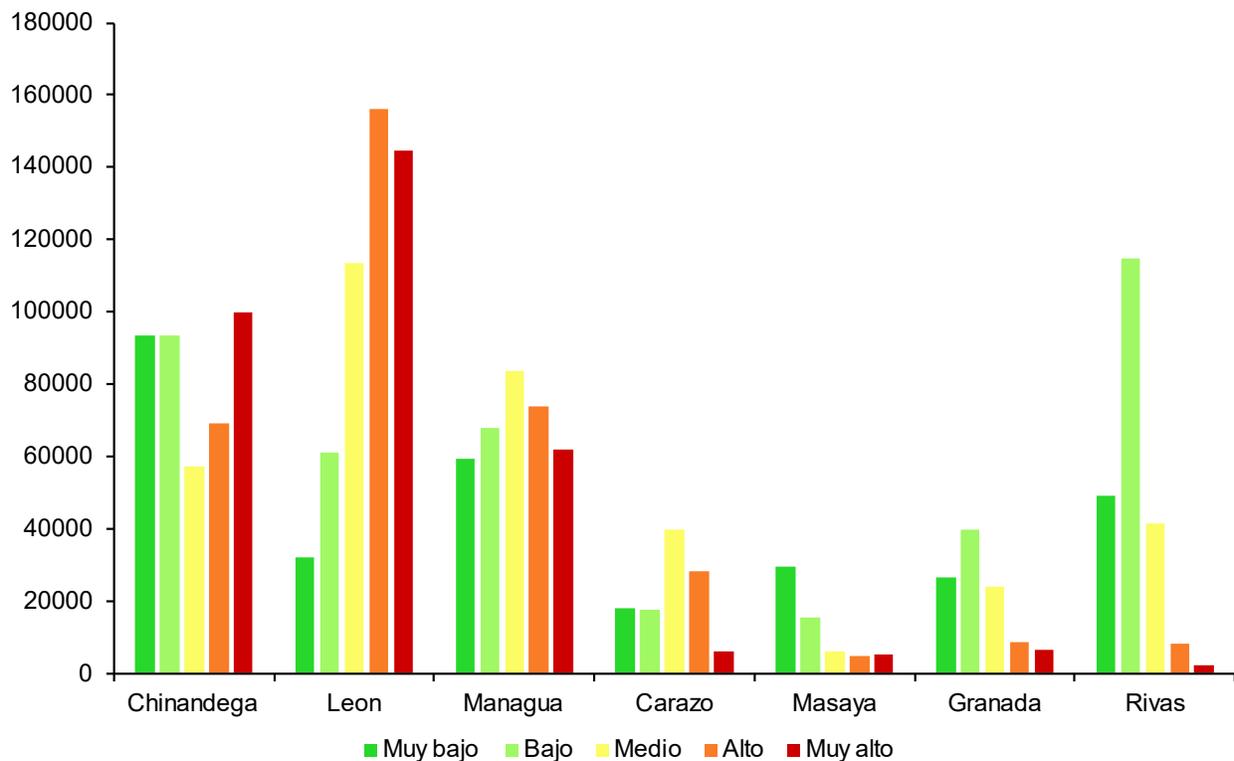
### 5.3 Distribución espacial de los niveles de riesgo de inicio de incendio

En las Figuras 8 y 9, se observa la extensión en hectáreas (ha) de las áreas clasificadas bajo los distintos niveles de riesgo obtenidas por el modelo Logístico y *Random Forest*. Se observa que Chinandega y León presentan la mayor extensión de áreas de alto y muy alto riesgo en ambos modelos; en cambio, el departamento de Rivas en el caso del modelo Logístico y Masaya en el caso de *Random Forest* comprenden los departamentos con menor extensión de áreas muy alto riesgo en cada modelo.

En las Figuras 10 y 11 se presenta la distribución espacial de los niveles de riesgo generados por el modelo Logístico y el modelo *Random Forest* respectivamente. Se evidencia un comportamiento similar en ambos modelos para la clasificación de las áreas bajo distintos niveles de riesgo, teniendo las diferencias más evidentes en el departamento de Rivas.

**Figura 8**

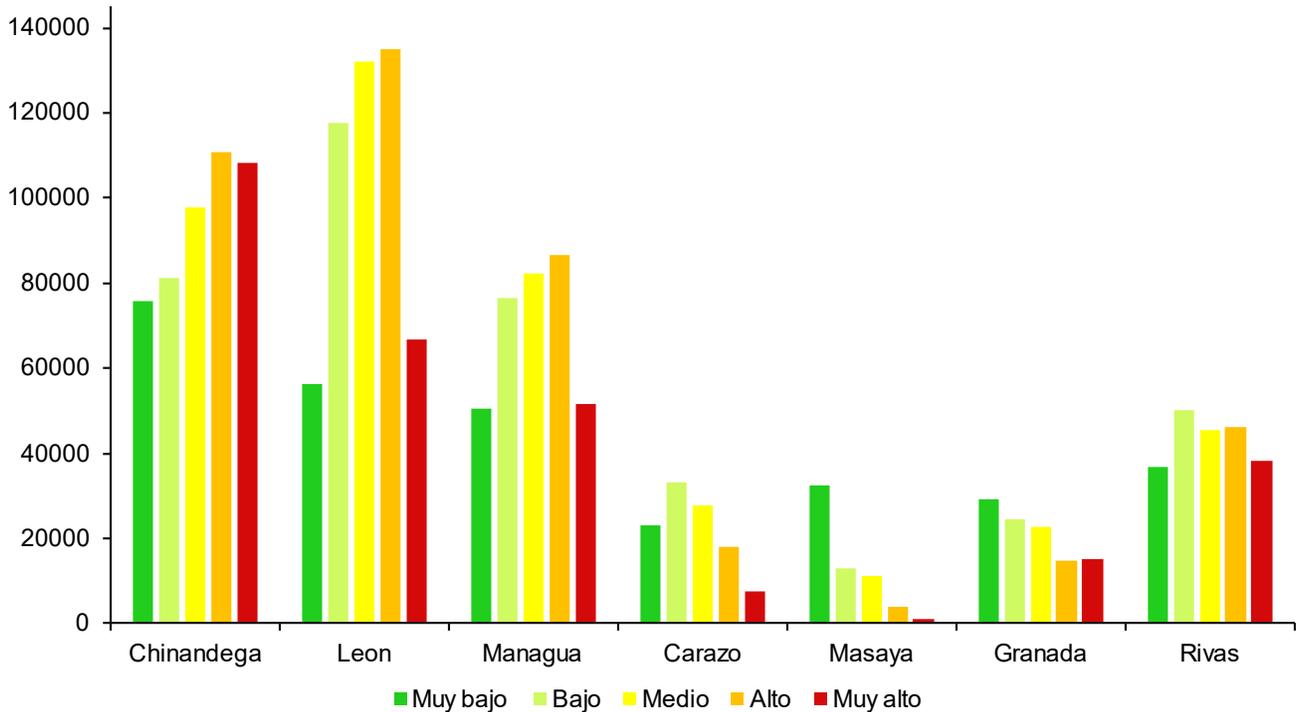
*Extensión en hectáreas de la clasificación obtenida por el modelo logístico*



Fuente: Elaboración propia

**Figura 9**

*Extensión en hectáreas de la clasificación obtenida por el modelo Random Forest.*



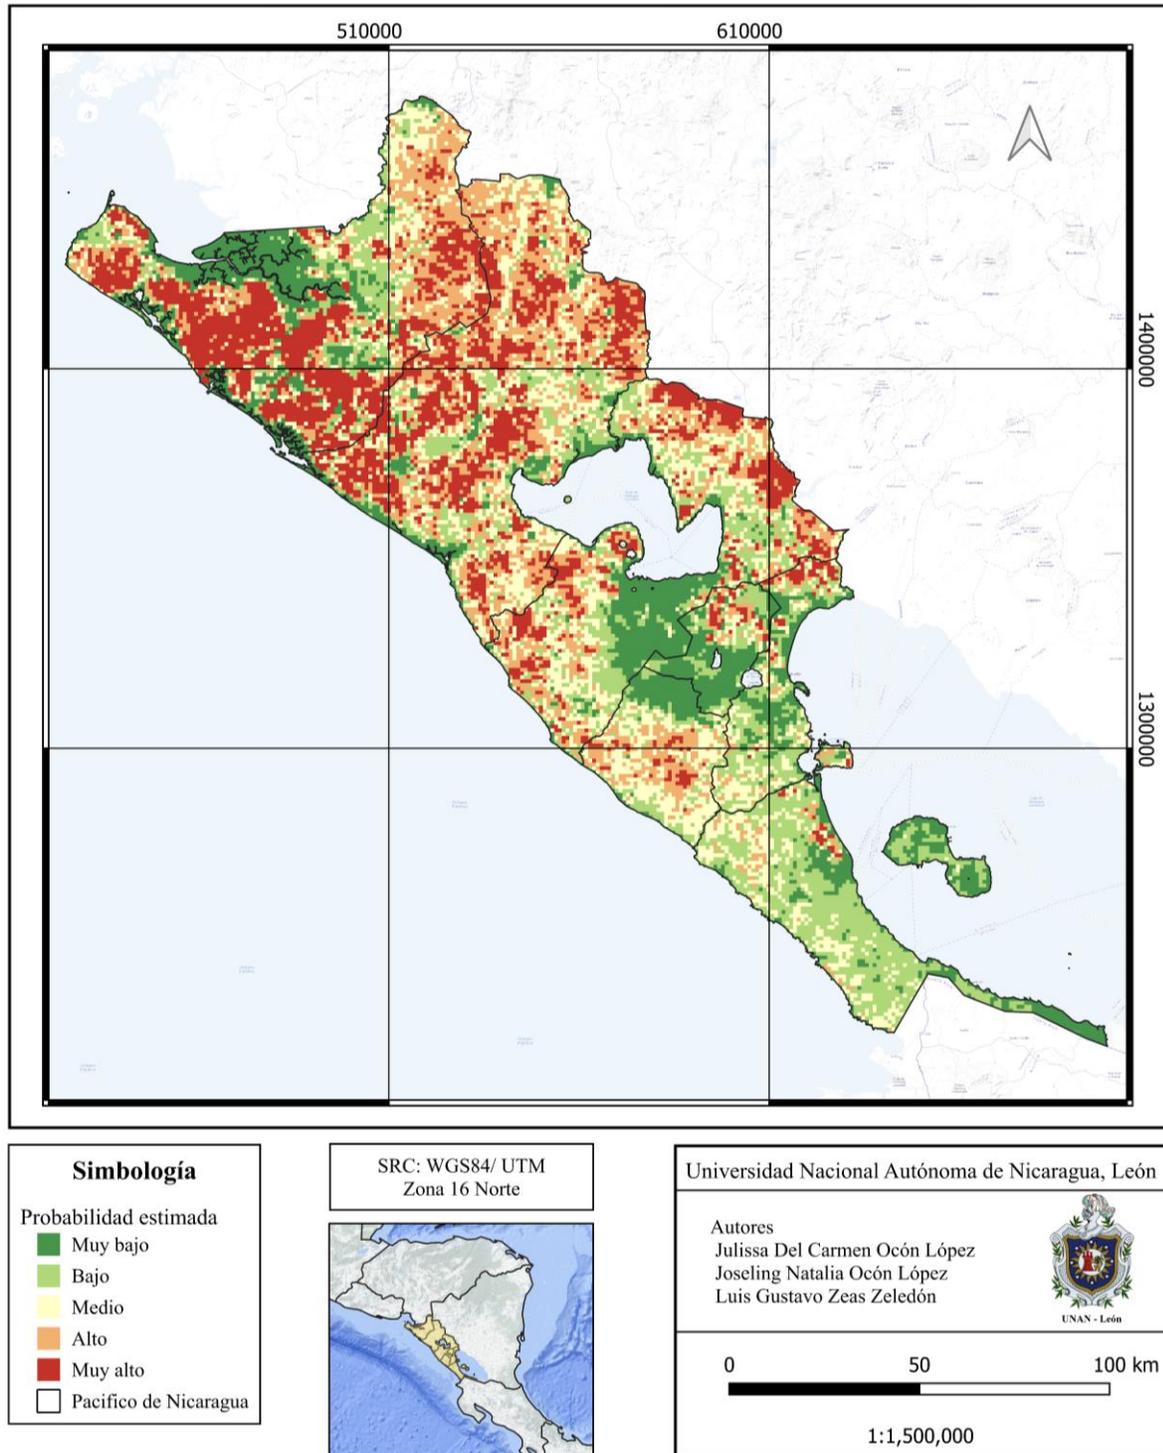
Fuente: Elaboración propia

En el caso de Chinandega, cuenta con 99,751 ha de zonas de muy alto riesgo identificadas por el modelo Logístico y 108,192 ha por el modelo *Random Forest*, correspondientes al 24 y 22% de su superficie respectivamente. Se observa que en ambos modelos las áreas de muy alto riesgo se concentran en la zona oeste del departamento, abarcando áreas dentro del complejo volcánico Cristobal-Casita así como zonas colindantes, así como territorio dentro de la península de Cosigüina, incluyendo la Reserva Natural Volcán Cosigüina.

Para el departamento de León el modelo Logístico clasificó 144,771 ha como áreas de muy alto riesgo, mientras que el modelo *Random Forest* corresponden a 66,769 ha de extensión clasificada bajo la misma categoría. Dichas zonas de riesgo se observan asociadas a zonas colindantes con las áreas protegidas Complejo Volcánico Telica – Rota y Pilas – El Hoyo; así como zonas de la región Este del departamento.

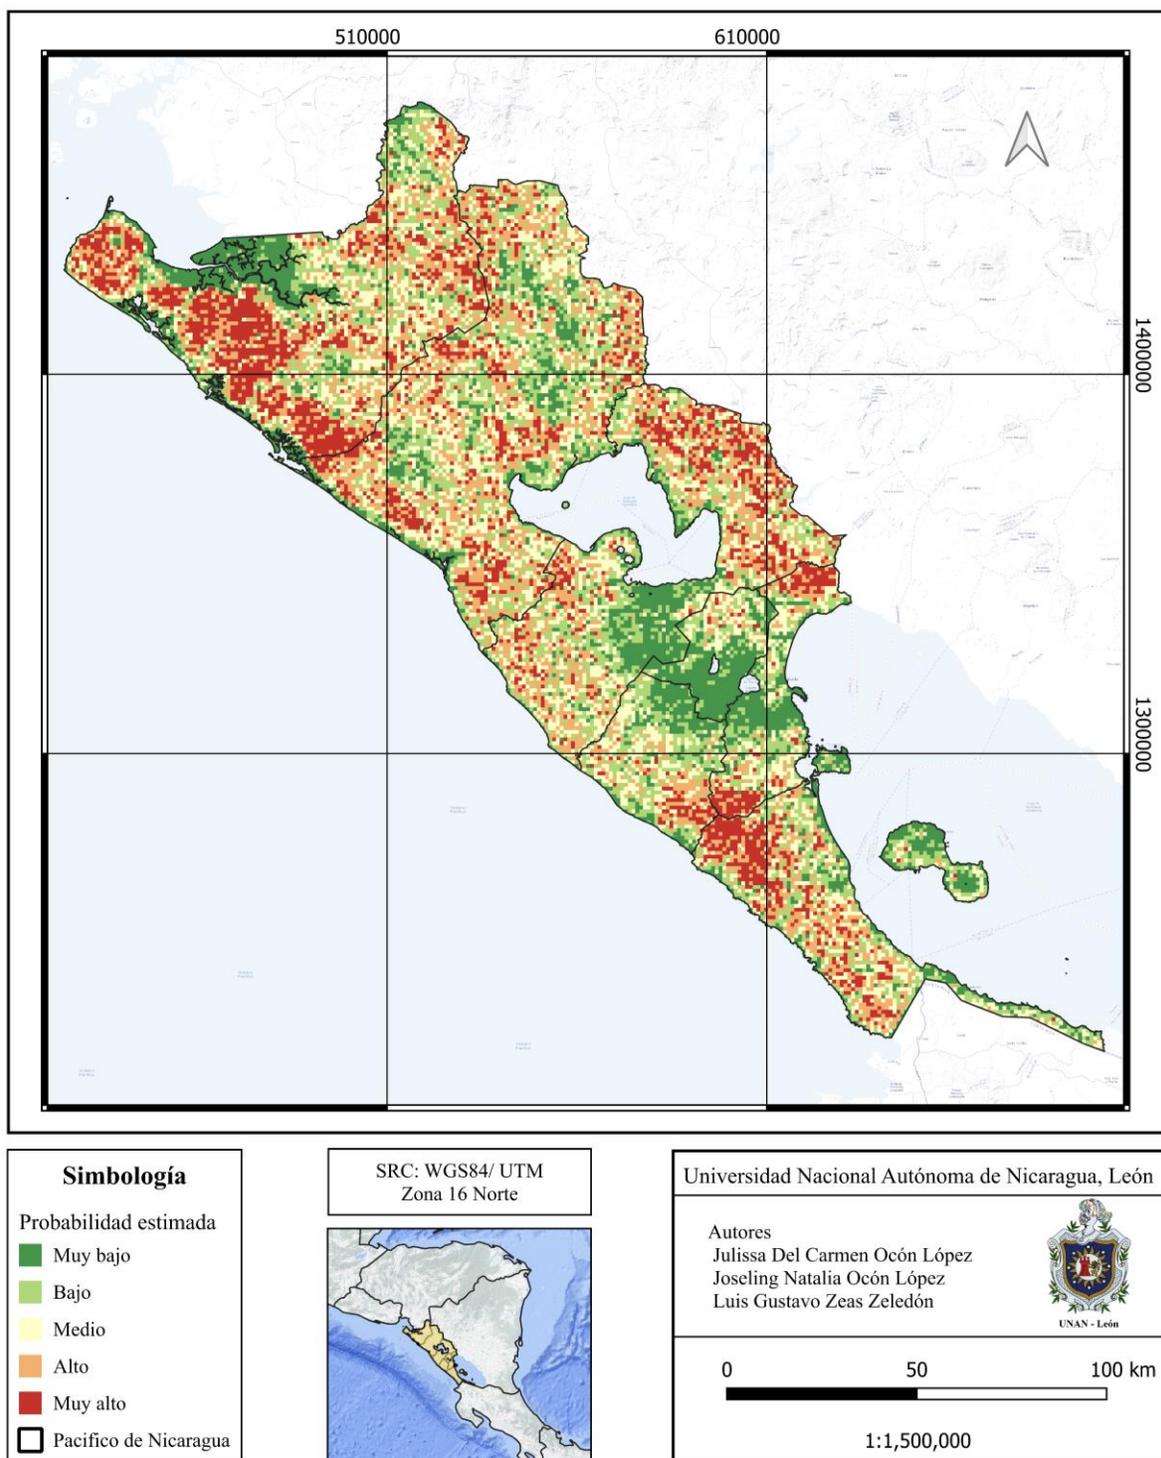
**Figura 10**

*Probabilidad de riesgo de inicio de incendios correspondiente al modelo logístico.*



**Figura 11**

*Probabilidad de riesgo de inicio de incendios correspondiente al modelo de Random Forest.*



Un potencial factor explicativo de la distribución de los niveles de riesgo obtenida en ambos modelos, es la extensión de zonas cultivadas en los departamentos con mayor riesgo, teniendo Chinandega y León un 25 y 15% de su superficie respectivamente, ocupada por cultivos anuales de acuerdo con datos de usos de suelo de INETER del 2015.

La Oficina de las Naciones Unidas para la Reducción del Riesgo de Desastres (2023) estima que alrededor del 90% de los incendios forestales a nivel global son iniciados por actividad humana. En el caso de Nicaragua, las zonas destinadas a la agricultura cobran particular atención como puntos críticos para el inicio de incendios forestales, especialmente debido a prácticas como la quema de rastrojos en cultivos prevalentes del Pacífico como la caña de azúcar (FAO, 1999).

Estos resultados coinciden con un monitoreo satelital reciente de incendios en Nicaragua, realizado por la Fundación del Río en 2024 (Onda Local, 2024). El informe señala que el Occidente del país, precisamente los departamentos de León y Chinandega, es una de las regiones más afectadas por los incendios forestales. Estos incendios han sido provocados por la quema de rastrojo y la quema de malezas previa a los cultivos.

De igual manera, la División de Recursos Forestales de la FAO reporta una pérdida de alrededor de 3,000 ha de bosque seco que fueron destruidas por incendios forestales en zonas cercanas al Volcán Cosigüina, encabezando una lista de reportes de prensa sobre incendios forestales en Nicaragua (Goldammer et al., 2001).

Adicionalmente a lo anterior planteado, el Ministerio del Ambiente y los Recursos Naturales (2018) hace énfasis en los incendios forestales como una de las amenazas más severas a la conservación de los recursos naturales en áreas protegidas, citando entre las causas de éstos, la caza de fauna silvestre y prácticas agrícolas inapropiadas que involucran el uso del fuego. Se menciona para el caso particular de Chinandega el

impacto del monocultivo de la caña de azúcar debido a la utilización del fuego durante la zafra.

En las Figuras 10 y 11 se destaca la extensión de las zonas de muy bajo riesgo de los departamentos de Managua, Masaya, Granada y Carazo, que alcanza un total de 133,888 ha para el modelo Logístico y 135,115 ha para *Random Forest*. La extensión de dichas zonas se aprecia en forma de un área casi continua que cubre parte de las Sierras de Managua, parque nacional Volcán Masaya y reserva natural Volcán Mombacho.

Un factor explicativo de dicha extensión de las áreas de muy bajo riesgo comprende las características de paisaje y topología. Las sierras de Managua constituyen una de las zonas más altas del departamento con niveles mayores a 1500msm, lo que proporciona áreas elevadas que suelen tener climas más húmedos, menor actividad humana y vegetación más saludable con menor probabilidad a incendiarse (Espinoza et al., 2013).

La Reserva Natural Volcán Mombacho se caracteriza por estar compuesto en su mayoría de un bosque nuboso, siendo este el 81.47 % del total del área protegida. Con altitudes arriba de los 800 msnm hasta los 1,150 msnm, este bosque se distingue por su alta humedad y vegetación densa. Las nubes y la niebla ayudan a mantener la humedad en el suelo y la vegetación, lo que reduce el riesgo de incendio (MARENA, 2020).

En el Parque Nacional Volcán Masaya, se han registrado amenazas de incendios forestales; sin embargo, su clasificación de “muy bajo” riesgo podría deberse a la presencia de autoridades competentes y a la rápida movilización de unidades de extinción, lo que posiblemente impide que los siniestros se desarrollen completamente. Estos incendios atendidos, han tenido diversas causas, como la extracción artesanal de miel, colillas de cigarro desechadas sin cuidado y la caza de garrobos en la zona (Artículo 66, 2024).

En el caso de la clasificación realizada para el departamento de Rivas, el Modelo *Random Forest* clasificó una mayor extensión de superficie con nivel de riesgo muy alto en comparación al modelo Logístico. Mientras que el modelo Logístico clasificó 2,386 ha,

equivalentes al 1.1% del departamento como zonas de muy alto riesgo, el modelo *Random Forest* clasificó 38,347 ha, equivalentes al 17.7% de la superficie del departamento como zonas de muy alto riesgo, abarcando incluso porciones de la Isla de Ometepe.

Estos resultados se respaldan en diversos reportes de incendios forestales en diferentes puntos del departamento de Rivas. Destaca especialmente la Isla de Ometepe, donde se han registrado varios incendios, provocados por la caza no controlada de garrobo, quemas agrícolas y otras actividades que carecen de precaución (Hernandez, 2024).

La diferencia en los patrones de distribución de las áreas de riesgo obtenida por ambos modelos, particularmente en el departamento de Rivas, podría explicarse por las limitantes del Modelo Logístico al trabajar en áreas geográficas heterogéneas, ya que el modelo asume las variables explicativas como constantes y estables en todo el espacio (Su et al., 2021), siendo estas de carácter altamente heterogéneo a través del espacio (Chuvieco et al., 2004). Adicionalmente, Xu et al. (2024) menciona que *Random Forest* cuenta con mejor capacidad para el manejo de variables con relaciones no lineales y datos extensos, comparado con otros modelos tradicionales.

## VI. CONCLUSIONES

- Las variables más significativas identificadas comprenden el índice NDMI, banda B11 y el índice GNDVI para el modelo logístico y las bandas B11, B12 y la altitud para el modelo *Random Forest*, demostrando una gran importancia de la región del SWIR, los índices espectrales y la topografía para la identificación de áreas con riesgo de inicio de incendios.

- Se modelizó el riesgo de inicio de incendios en el Pacífico nicaragüense mediante dos modelos geoestadísticos, obteniendo una precisión del 71% por el modelo logístico y 79% para *Random Forest*, lo cual indica una capacidad predictiva adecuada para ambos enfoques en la identificación de áreas de riesgo de incendios.

- Se definieron como áreas prioritarias con riesgo de inicio de incendios las zonas clasificadas como muy alto riesgo por el modelo *Random Forest* y el modelo Logístico, destacando la península de Cosigüina, complejo volcánico Cristobal-Casita y la Isla de Ometepe.

## **VII. RECOMENDACIONES**

- Utilizar datos actualizados de usos de suelo y meteorológicos que reflejen con mayor precisión las condiciones actuales de la zona de estudio.
- Integrar datos de áreas quemadas para mejorar la precisión del modelo.
- Implementar el modelo en las regiones Central y del Caribe para analizar su impacto y efectividad en estos ámbitos geográficos.
- Aplicar otros tipos de modelos de aprendizaje automático para comparar los resultados y evaluar su capacidad de predicción.

## VIII. REFERENCIAS BIBLIOGRAFICAS

- Agencia Espacial Europea. (2024). S2 Processing. SentiWiki. <https://sentiwiki.copernicus.eu/web/s2-processing>
- Alonso-Jimenez, C., Moreno, V., & Rodríguez, E. (1999). Determinación experimental de la firma espectral de la vegetación. Una sencilla práctica de introducción a la teledetección. *Teledetección. Avances y Aplicaciones.*, 429-432.
- Alperen Coskuner, K. (2021). Assessing the performance of MODIS and VIIRS active fire products in the monitoring of wildfires: A case study in Turkey. *iForest - Biogeociencias y silvicultura*, 15(2), 85-94. <https://doi.org/10.3832/ifor3754-015>
- Alvarado, C., Leandro, A., & Sarango, D. (2021). Comparación de Índices de Vegetación con imágenes Landsat usando la computación en la nube: Zona Pampa de Majes-Siguas, Arequipa Perú (Periodo: Jun 1984 a Nov 2018). *Revista de Investigación de Física*, 22(1), 27-34. <https://doi.org/10.15381/rif.v22i1.20280>
- Alzate Giraldo, G. A., & Sánchez Gómez, D. P. (2018). *Análisis multitemporal por teledetección del cambio de coberturas en las veredas Pantanillo y Las Palmas del municipio de Envigado en el periodo comprendido entre los años 1997 y 2016.* <https://repositorio.ucm.edu.co/bitstream/10839/2134/1/Gustavo%20Adolfo%20Alzate%20Giraldo.pdf>
- Anaya, J. A., Rodríguez-Buriticá, S., & Londoño, M. C. (2023). Clasificación de cobertura vegetal con resolución espacial de 10 metros en bosques del Caribe colombiano basado en misiones Sentinel 1 y 2. *Revista de Teledetección*, 61, Article 61. <https://doi.org/10.4995/raet.2023.17655>
- Anzola, J. D., Fuentes, L. D., & Rodríguez, E. M. (2024). *Desarrollo de un modelo de estimación para la prevención de incendios forestales en Colombia* [Proyecto final de Pregrado, Barranquilla, Universidad del Norte 2024]. <https://manglar.uninorte.edu.co/handle/10584/11968>
- Aragão, L. E. O. C., Malhi, Y., Barbier, N., Lima, A., Shimabukuro, Y., Anderson, L., & Saatchi, S. (2008). Interactions between rainfall, deforestation and fires during recent years in the Brazilian Amazonia. *Philosophical Transactions of the Royal Society B: Biological Sciences*, 363(1498), 1779-1785. <https://doi.org/10.1098/rstb.2007.0026>

- Ariza López, F. J., Rodríguez Avi, J., & Alba Fernández, M. V. (2018). Control estricto de matrices de confusión por medio de distribuciones multinomiales. *Geofocus: Revista Internacional de Ciencia y Tecnología de la Información Geográfica*, 21, 215-226. <http://dx.doi.org/10.21138/GF.591>
- Artículo 66. (2024, febrero 19). *Empiezan incendios forestales en Nicaragua*. Artículo 66. <https://www.articulo66.com/2024/02/19/empiezan-incendios-forestales-nicaragua-actuar-autoridades-orteguistas/>
- Ávila-Velez, E. F. Á. (2020). Propuesta metodológica para cuantificar áreas afectadas por incendios forestales utilizando imágenes satelitales Sentinel-2. Caso de estudio páramo del Almorzadero, Colombia. *UD y la geomática*, 15, Article 15. <https://doi.org/10.14483/23448407.15260>
- Avtar, R., Kouser, A., Kumar, A., Singh, D., Misra, P., Gupta, A., Yunus, A. P., Kumar, P., Johnson, B. A., Dasgupta, R., Sahu, N., & Besse Rimba, A. (2021). Remote Sensing for International Peace and Security: Its Role and Implications. *Remote Sensing*, 13(3), Article 3. <https://doi.org/10.3390/rs13030439>
- Baghdadi, N., Mallet, C., & Zribi, M. (2020). *QGIS y las herramientas genéricas*. ISTE Group.
- Barros, A. M. G., & Pereira, J. M. C. (2014). Wildfire Selectivity for Land Cover Type: Does Size Matter? *PLOS ONE*, 9(1), e84760. <https://doi.org/10.1371/journal.pone.0084760>
- Bella, C. M. D., Posse, G., Beget, M. E., Fischer, M. A., Mari, N., & Veron, S. (2008). La teledetección como herramienta para la prevención, seguimiento y evaluación de incendios e inundaciones: *Ecosistemas*, 17(3), Article 3. <https://www.revistaecosistemas.net/index.php/ecosistemas/article/view/85>
- Bevans, R. (2020, marzo 26). *Akaike Information Criterion | When & How to Use It (Example)*. Scribbr. <https://www.scribbr.com/statistics/akaike-information-criterion/>
- Bisquert Perles, M. del M. (2011). *Una metodología para la estimación del riesgo de incendio empleando imágenes del sensor MODIS/TERRA* [Http://purl.org/dc/dcmitype/Text, Universitat de València]. <https://dialnet.unirioja.es/servlet/tesis?codigo=93162>
- Bravo Morales, N. (2017). *Teledetección espacial, LANDSAT, SENTINEL 2, ASTER L1T y MODIS*. [https://acolita.com/wp-content/uploads/2018/01/Teledeteccion\\_espacial\\_ArcGeek.pdf](https://acolita.com/wp-content/uploads/2018/01/Teledeteccion_espacial_ArcGeek.pdf)

- Breiman, L. (2001). Random Forests. *Machine Learning*, 45(1), 5-32. <https://doi.org/10.1023/A:1010933404324>
- Burapapol, K., & Nagasawa, R. (2016). *Mapping wildfire fuel load distribution using Landsat 8 Operational Land Imager (OLI) data in Sri Lanna National Park, northern Thailand* (No. 4). The Japanese Agricultural Systems Society. [https://doi.org/10.14962/jass.32.4\\_133](https://doi.org/10.14962/jass.32.4_133)
- Castillo Hernández, Calderón Palma, Delgado Quezada, Flores Meza, & Salvatierra Suárez. (2006). Situación de los recursos hídricos en Nicaragua. *Boletín Geológico y Minero*, 117(1), 127-146.
- Castillo, Saavedra, & Brull. (2019). Fire severity in mega wildfires in Chile in 2017: Actions to improve the protection system. *Territorium: Revista Portuguesa de riscos, prevenção e segurança*, 26 (1), 5-18. [https://doi.org/10.14195/1647-7723\\_26-1\\_1](https://doi.org/10.14195/1647-7723_26-1_1)
- Chingal Huaca, M. C., & Anrango Torres, S. A. (2019). *Zonificación de cobertura vegetal propensa a incendios en el cantón Ibarra, provincia de Imbabura* [bachelorThesis]. <https://repositorio.utn.edu.ec/handle/123456789/9802>
- Choza, J. (2019). *Herramientas SIG y de teledetección aplicadas al incendio de Las Peñuelas (Huelva): Previsión de riesgo y valoración de daños* [Universidad de Sevilla]. [https://biblus.us.es/bibing/proyectos/abreproy/92383/descargar\\_fichero/TFG-2383-CHOZA.pdf](https://biblus.us.es/bibing/proyectos/abreproy/92383/descargar_fichero/TFG-2383-CHOZA.pdf)
- Chuma Pomasqui, L. P., & Coronado Cacuango, P. D. (2022). *Zonificación de cobertura vegetal propensa a incendios en el cantón Cotacachi provincia de Imbabura* [bachelorThesis]. <https://repositorio.utn.edu.ec/handle/123456789/12641>
- Chuvieco, E. (1990). *Fundamentos de teledetección espacial* (1. ed). Ediciones Rialp.
- Chuvieco, E., Aguado, I., Yebra, M., Nieto, H., Vilar, L., Vega, J., & Padrón Paredes, D. (2007). *Generación de un Modelo de Peligro de Incendios Forestales mediante Teledetección y SIG*. [https://www.researchgate.net/publication/237810521\\_Generacion\\_de\\_un\\_Modelo\\_de\\_Peligro\\_de\\_Incendios\\_Forestales\\_mediante\\_Teledeteccion\\_y\\_SIG](https://www.researchgate.net/publication/237810521_Generacion_de_un_Modelo_de_Peligro_de_Incendios_Forestales_mediante_Teledeteccion_y_SIG)
- Chuvieco, E., Allgöwer, B., & Salas, J. (2003). Integration of physical and human factors in fire danger assessment. En *Wildland fire danger estimation and mapping: The role of remote sensing data* (pp. 197-218). World Scientific.

- Chuvieco, E., Cocero, D., Riaño, D., Martín, P., Martínez-Vega, J., De La Riva, J., & Pérez, F. (2004). Combining NDVI and surface temperature for the estimation of live fuel moisture content in forest fire danger rating. *Remote Sensing of Environment*, 92(3), 322-331. <https://doi.org/10.1016/j.rse.2004.01.019>
- Chuvieco, E., Martín, M. P., & Palacios, A. (2002). Assessment of different spectral indices in the red-near-infrared spectral domain for burned land discrimination. *International Journal of Remote Sensing*, 23(23), 5103-5110. <https://doi.org/10.1080/01431160210153129>
- CONAE. (2016). *Índices Espectrales derivados de imágenes satelitales Landsat 8 Sensor OLI*.
- Cortés-Reyes, É., Rubio-Romero, J. A., & Gaitán-Duarte, H. (2010). Métodos estadísticos de evaluación de la concordancia y la reproducibilidad de pruebas diagnósticas. *Revista Colombiana de Obstetricia y Ginecología*, 61(3), 247-255.
- Cruz Espíndola, M. Á., Rodríguez Trejo, D. A., Villanueva Morales, A., Santillán Pérez, J., Cruz Espíndola, M. Á., Rodríguez Trejo, D. A., Villanueva Morales, A., & Santillán Pérez, J. (2017). Factores sociales de uso del suelo y vegetación asociados a los incendios forestales en Hidalgo. *Revista mexicana de ciencias forestales*, 8(41), 139-163.
- Cucchiara, A. (2012). Applied Logistic Regression. *Technometrics*, 34, 358-359. <https://doi.org/10.1080/00401706.1992.10485291>
- Cutler, D. R., Edwards Jr., T. C., Beard, K. H., Cutler, A., Hess, K. T., Gibson, J., & Lawler, J. J. (2007). Random Forests for Classification in Ecology. *Ecology*, 88(11), 2783-2792. <https://doi.org/10.1890/07-0539.1>
- Davis, R., Yang, Z., Yost, A., Belongie, C., & Cohen, W. (2017). The normal fire environment—Modeling environmental suitability for large forest wildfires using past, present, and future climate normals. *Forest Ecology and Management*, 390, 173-186. <https://doi.org/10.1016/j.foreco.2017.01.027>
- Del Valle Benavides, A. R. (2017). *Curvas ROC (Receiver-Operating-Characteristic) y sus aplicaciones* [Trabajo final de Grado, Universidad de Sevilla]. <https://idus.us.es/handle/11441/63201>
- Denham, M. M., & Cortés Fité, A. (2007). *Predicción de incendios forestales basada en algoritmos evolutivos guiados por los datos* [Universitat Autònoma de Barcelona]. <https://core.ac.uk/download/pdf/13283059.pdf>

- Díaz. (2020). *Descripción del régimen de incendios del bosque seco tropical de la cuenca alta del Río Magdalena y su relación con la variación climática* [Universidad Distrital Francisco José de Caldas]. <http://hdl.handle.net/11349/23232>
- Díaz Gonzalez, F. A., Quintero Torres, S. V., Triana Correa, J. S., & Morón Hernández, D. C. (2014). *Aproximaciones a los sistemas de percepción remota en satélites pequeños*. Universidad Sergio Arboleda. <https://repository.usergioarboleda.edu.co/handle/11232/545>
- Díaz-Delgado, R., Lloret, F., & Pons, X. (2004). Spatial patterns of fire occurrence in Catalonia, NE, Spain. *Landscape Ecology*, 19(7), 731-745. <https://doi.org/10.1007/s10980-005-0183-1>
- Díaz-Hormazábal, I., & González, M. E. (2016). Análisis espacio-temporal de incendios forestales en la región del Maule, Chile. *Bosque (Valdivia)*, 37(1), 147-158. <https://doi.org/10.4067/S0717-92002016000100014>
- Dirección General de Meteorología de INETER. (2024). *Clima de Nicaragua*. <https://www.ineter.gob.ni/met>
- Espinoza Diaz, G. E. (2022). *Implementación del sistema de información geográfica para la gestión de incendios forestales del parque arqueológico de Machupicchu, Cusco, 2021*. [Universidad César Vallejo]. [https://repositorio.ucv.edu.pe/bitstream/handle/20.500.12692/92326/Espinoza\\_DGE-SD.pdf?sequence=1&isAllowed=y](https://repositorio.ucv.edu.pe/bitstream/handle/20.500.12692/92326/Espinoza_DGE-SD.pdf?sequence=1&isAllowed=y)
- Espinoza, G., Ayala, I., Santana, J., & Peña, R. (2013). La zonificación morfotectónica-volcánica en el análisis morfoestructural del relieve: El caso del municipio de Managua, Nicaragua. *Investigaciones geográficas*, 87, 118-140.
- Evangelides, C., & Nobajas, A. (2020). Red-Edge Normalized Difference Vegetation Index (NDVI705) from Sentinel-2 imagery to assess post-fire regeneration. *Remote Sensing Applications: Society and Environment*, 17, 100283. <https://doi.org/10.1016/j.rsase.2019.100283>
- Flores, A. G., Flores, J., González, D., Gallegos, A., Zarazúa, P., & Mena, S. (2021). Análisis comparativo de índices espectrales para ubicar y dimensionar niveles de severidad de incendios forestales. *Investigaciones geográficas*, 106, 1291. <https://doi.org/10.14350/rig.60396>
- Food and Agriculture Organization of the United Nations. (1999). *FAO Meeting on Public Policies Affecting Forest Fires: Rome, 28-30 October 1998 : Proceedings*. Food & Agriculture Org.

- Food and Agriculture Organization of the United Nations FAO. (2002). *Estado de la información forestal en Nicaragua*. <http://www.fao.org/3/a-ad412s.pdf>
- Fornacca, D., Ren, G., & Xiao, W. (2018). Evaluating the Best Spectral Indices for the Detection of Burn Scars at Several Post-Fire Dates in a Mountainous Region of Northwest Yunnan, China. *Remote Sensing*, 10(8), 1196. <https://doi.org/10.3390/rs10081196>
- Franzpc. (2019, octubre 30). *Lista de índices espectrales en Sentinel 2 y Landsat*. El blog de franz. <https://acolita.com/lista-de-indices-espectrales-en-sentinel-2-y-landsat/>
- García Echeverri, L. (2021). *Estudio multitemporal de los incendios de 2019 en roraima (brasil) a partir de imágenes satelitales* [Universidad de loa Andes]. <http://hdl.handle.net/1992/55561>
- Ghorbanzadeh, O., Blaschke, T., Gholamnia, K., & Aryal, J. (2019). Forest Fire Susceptibility and Risk Mapping Using Social/Infrastructural Vulnerability and Environmental Variables. *Fire*, 2(3), 50. <https://doi.org/10.3390/fire2030050>
- Giraldo Colonia, R. A. (2021). Análisis de aplicaciones espectrales derivados de imágenes satelitales PerúSAT-1. *Revista del Instituto de investigación de la Facultad de minas, metalurgia y ciencias geográficas*, 24(47), 75-81. <https://doi.org/10.15381/iigeo.v24i47.20653>
- Goetz, S. J., Fiske, G. J., & Bunn, A. G. (2006). Using satellite time-series data sets to analyze fire disturbance and forest recovery across Canada. *Remote Sensing of Environment*, 101(3), 352-365. <https://doi.org/10.1016/j.rse.2006.01.011>
- Goldammer, J., Mutch, R., & Pugliese, P. (2001). *Global Forest Fire Assessment 1990-2000*. FAO Forest Resources Assessment Programme. <https://www.fao.org/4/ad653e/ad653e00.htm#TopOfPage>
- González Gutiérrez, I., Farfán Gutiérrez, M., Morales Manilla, L. M., Pérez Salicrup, D. R., Garza Saldaña, J. J., Medina Puente, A., González Gutiérrez, I., Farfán Gutiérrez, M., Morales Manilla, L. M., Pérez Salicrup, D. R., Garza Saldaña, J. J., & 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*, 71, 193-220. <https://doi.org/10.15359/rgac.71-2.7>
- Guo, F., Zhang, L., Jin, S., Tigabu, M., Su, Z., & Wang, W. (2016). Modeling Anthropogenic Fire Occurrence in the Boreal Forest of China Using Logistic Regression and Random Forests. *Forests*, 7(11), Article 11. <https://doi.org/10.3390/f7110250>

- Haberl, H., Erb, K. H., Krausmann, F., Gaube, V., Bondeau, A., Plutzar, C., Gingrich, S., Lucht, W., & Fischer-Kowalski, M. (2007). Quantifying and mapping the human appropriation of net primary production in earth's terrestrial ecosystems. *Proceedings of the National Academy of Sciences*, *104*(31), 12942-12947. <https://doi.org/10.1073/pnas.0704243104>
- Harrell, F. (2012). *Regression Modeling Strategies*.
- Hernandez, O. (2024). *Mano del hombre, es el principal causante de los incendios forestales en Rivas | TN8.tv*. <https://www.tn8.tv/sucesos/mano-del-hombre-es-el-principal-causante-de-los-incendios-forestales-en-rivas/>
- Hernández Sampieri, R., Fernández Collado, C., & Baptista Lucio, P. (2014). *Metodología de la investigación* (6a ed). McGraw-Hill.
- Hong, H., Naghibi, S. A., Moradi Dashtpajardi, M., Pourghasemi, H. R., & Chen, W. (2017). A comparative assessment between linear and quadratic discriminant analyses (LDA-QDA) with frequency ratio and weights-of-evidence models for forest fire susceptibility mapping in China. *Arabian Journal of Geosciences*, *10*(7), 167. <https://doi.org/10.1007/s12517-017-2905-4>
- Hu, X., Ban, Y., & Nascetti, A. (2021). Sentinel-2 MSI data for active fire detection in major fire-prone biomes: A multi-criteria approach. *International Journal of Applied Earth Observation and Geoinformation*, *101*, 102347. <https://doi.org/10.1016/j.jag.2021.102347>
- Ibarra-Montoya, J. L., & Huerta-Martínez, F. M. (2016). Modelado espacial de incendios: Una herramienta predictiva para el Bosque La Primavera, Jalisco México. *Revista Ambiente & Agua*, *11*, 35-49. <https://doi.org/10.4136/ambi-agua.1536>
- IBM. (2022, noviembre 28). *IBM Documentation*. <https://www.ibm.com/docs/es/db2/11.1?topic=visualizer-confusion-matrix-view>
- INETER. (2015). *Portal de Mapas Interactivos de Cobertura y Usos de la Tierra de la República de Nicaragua*. <https://www.ineter.gob.ni/>
- Instituto Geográfico Nacional. (2018). *Programa marco Copernicus: Componente espacio Copernicus*. Instituto Geográfico Nacional. [https://www.ign.es/web/resources/docs/IGNCnig/actividades/OBS/Programa\\_Marco\\_Copernicus\\_User\\_Uptake/3\\_componente\\_espacio\\_Copernicus.pdf](https://www.ign.es/web/resources/docs/IGNCnig/actividades/OBS/Programa_Marco_Copernicus_User_Uptake/3_componente_espacio_Copernicus.pdf)

- Instituto Nacional de Información de Desarrollo (INIDE). (2022). *Anuario Estadístico*. [https://www.inide.gob.ni/docs/Anuarios/Anuario2022/ANUARIO\\_ESTADISTICO2022.pdf](https://www.inide.gob.ni/docs/Anuarios/Anuario2022/ANUARIO_ESTADISTICO2022.pdf)
- Intriago Giler, E. B. (2022). *Estudio comparativo de dos métodos de detección de cultivos de cacao, banano y palma en la zona oeste de la provincia de los Ríos, a partir de las imágenes satelitales landsat-8 y sentinel 2* [Proyecto de investigación, Universidad técnica estatal de Quevedo]. <https://repositorio.uteq.edu.ec/handle/43000/6830>
- Lira, J. (2018). *Tratamiento Digital de Imágenes Multiespectrales* (Tercera edición).
- Liu, Y., Wang, Y., & Zhang, J. (2012). New Machine Learning Algorithm: Random Forest. En B. Liu, M. Ma, & J. Chang (Eds.), *Information Computing and Applications* (Vol. 7473, pp. 246-252). Springer Berlin Heidelberg. [https://doi.org/10.1007/978-3-642-34062-8\\_32](https://doi.org/10.1007/978-3-642-34062-8_32)
- MARENA. (2020). *Plan de Manejo Reserva Natural Volcán Mombacho – Marena*. <https://www.marena.gob.ni/planes-de-manejo/plan-de-manejo-reserva-natural-volcan-mombacho/>
- Maxar Technologies. (2024). *Benefits of short-wave infrared (SWIR) for fire detection and monitoring*. Maxar Technologies. [resources.maxar.com](https://resources.maxar.com)
- Milanović, S., Kaczmarowski, J., Ciesielski, M., Trailović, Z., Mielcarek, M., Szczygieł, R., Kwiatkowski, M., Bałazy, R., Zasada, M., & Milanović, S. D. (2023). Modeling and Mapping of Forest Fire Occurrence in the Lower Silesian Voivodeship of Poland Based on Machine Learning Methods. *Forests*, 14(1), Article 1. <https://doi.org/10.3390/f14010046>
- Milanović, S., Marković, N., Pamučar, D., Gigović, L., Kostić, P., & Milanović, S. D. (2021). Forest Fire Probability Mapping in Eastern Serbia: Logistic Regression versus Random Forest Method. *Forests*, 12(1), Article 1. <https://doi.org/10.3390/f12010005>
- Ministerio del Ambiente y los Recursos Naturales. (2018). *Plan de Manejo Complejo Volcánico San Cristobal*. <https://www.marena.gob.ni/planes-de-manejo/plan-de-manejo-complejo-volcanico-san-cristobal/>
- Moreno Rubio, I. (2021). *Detección de incendios en áreas forestales usando algoritmos de deep learning* [Trabajo final de Grado, Universidad de Jaén]. <http://crea.ujaen.es/jspui/handle/10953.1/20283>

- Morrison, P. (2007). *Roads and Wildfires*. Pacific Biodiversity Institute. [https://www.pacificbio.org/publications/wildfire\\_studies/Roads\\_And\\_Wildfires\\_2007.pdf](https://www.pacificbio.org/publications/wildfire_studies/Roads_And_Wildfires_2007.pdf)
- NASA. (2024). *Layer Information: MODIS (Aqua & Terra) Fire and Thermal Anomalies*. FIRMS MODIS Fire Hotspot. <https://firms.modaps.eosdis.nasa.gov/map/>
- Nieto Gonzalez, J. L. (2018). *Detección de incendios mediante identificación de humo con visión artificial en condiciones de iluminación variable* [Universidad Autónoma del Estado de México]. <http://ri.uaemex.mx/handle/20.500.11799/95189>
- Nuñez Acosta, Y. A. & Peña Ojeda, J. N. (2023). *Evaluación de áreas afectadas por incendios forestales utilizando imágenes satelitales Sentinel-2. Caso de estudio "Pinares de Mayarí"*. *Opuntia Brava*. 15(Especial)(301-313).
- Oficina de las Naciones Unidas para la Reducción del Riesgo de Desastres. (2023). *Wildfires in Latin America: Preliminary analysis, messages, and resources*. <http://www.undrr.org/quick/72203>
- Olaya, V. (2014). *Sistemas de Información Geográfica*. [https://www.icog.es/TyT/files/Libro\\_SIG.pdf](https://www.icog.es/TyT/files/Libro_SIG.pdf)
- Oliveira, S., Oehler, F., San-Miguel-Ayanz, J., Camia, A., & Pereira, J. M. (2012). Modeling spatial patterns of fire occurrence in Mediterranean Europe using Multiple Regression and Random Forest. *Forest Ecology and Management*, 275, 117-129.
- Onda Local. (2024, abril 15). *Nicaragua: Bosques arden en diferentes puntos del territorio nacional*. Onda Local. [https://ondalocalni.com/noticias/2681-incendios-forestales-nicaragua-quema-bosques-biodiversidad-medio-ambiente/get\\_absolute\\_url](https://ondalocalni.com/noticias/2681-incendios-forestales-nicaragua-quema-bosques-biodiversidad-medio-ambiente/get_absolute_url)
- Pacheco, C. E., Aguado, I., & Nieto, H. (2009). Análisis de ocurrencia de incendios forestales causados por rayo en la España peninsular. *GeoFocus. International Review of Geographical Information Science and Technology*, 9, 232-249.
- Parajuli, A., Gautam, A. P., Sharma, S. P., Bhujel, K. B., Sharma, G., Thapa, P. B., Bist, B. S., & Poudel, S. (2020). Forest fire risk mapping using GIS and remote sensing in two major landscapes of Nepal. *Geomatics, Natural Hazards and Risk*, 11(1), 2569-2586. <https://doi.org/10.1080/19475705.2020.1853251>
- Peralta, J. C. M. (2010). Evaluación del riesgo ante incendios forestales en la cuenca del Río Tempisque, Costa Rica. *Revista Geográfica de América Central*, 2(45), 33-64.
- Perez, C., & Muñoz, A. (2006). *Teledeteccion: Nociones y Aplicaciones*.

- Pérez, D. (2007). *Introducción a los Sensores Remotos—Aplicaciones en Geología*.
- Pla, C., Valdes-Abellan, J., Pardo, M., Jódar-Abellán, A., Benavente, D., & Fernandez-Cortes, A. (2018). *Geoestadística con software libre: Material para prácticas docentes*.
- Pompa-García, M., Vázquez-Vázquez, L., Zapata-Molina, M., & Solís-Moreno, R. (2012). Modelo conceptual del potencial de incendios forestales en Durango: Avances preliminares. *Revista Mexicana de Ciencias Forestales*, 3(13), 95-102. <https://doi.org/10.29298/rmcf.v3i13.492>
- Portillo-Quintero, C. A., & Sánchez-Azofeifa, G. A. (2010). Extent and conservation of tropical dry forests in the Americas. *Biological Conservation*, 143(1), 144-155. <https://doi.org/10.1016/j.biocon.2009.09.020>
- Pucha-Cofrep, F., Fries, A., Cánovas-García, F., Oñate-Valdivieso, F., González-Jaramillo, V., & Pucha-Cofrep, D. (2017). *Fundamentos de SIG: Aplicaciones con ArcGIS* (Segunda edición). Ediciones Rialp.
- QGIS.org. (2023). *QGIS Web Site*. <https://qgis.org/resources/hub/>
- R Core Team. (2023). *R: A language and environment for statistical computing*. [Software]. <https://www.R-project.org/>.
- Requelme Vigo, J. C. (2019). *Análisis de la pérdida de cobertura boscosa y cambio de uso del suelo, mediante el análisis de imágenes satelitales, período 2000 al 2018; en el distrito de Chadín, Chota* [Universidad Nacional de Cajamarca]. <http://repositorio.unc.edu.pe/handle/20.500.14074/3538>
- Reyes-Bueno, F., & Balcazar-Gallegos, C. (2021). Factores que inciden en la probabilidad de ocurrencia de incendios forestales en Ecuador. *FIGEMPA: Investigación y Desarrollo*, 11(1), 50-60. <https://doi.org/10.29166/revfig.v11i1.2634>
- Rodríguez Chávez, Ó. E., & Arredonda Bautista, H. A. (2005). *Manual para el manejo y procesamiento de imágenes satelitales obtenidas del sensor remoto Modis de la Nasa, aplicado en estudios de Ingeniería Civil* [Trabajo de Grado, Pontificia Universidad Javeriana]. <http://repositorio.javeriana.edu.co/handle/10554/7050>
- Rothermel, R. C. (1991). *Predicting Behavior and Size of Crown Fires in the Northern Rocky Mountains*. U.S. Department of Agriculture, Forest Service, Intermountain Forest and Range Experiment Station.

- Rouse, J. W., Haas, R. H., Schell, J. A., & Deering, D. W. (1974, enero 1). *Monitoring vegetation systems in the Great Plains with ERTS*. <https://ntrs.nasa.gov/citations/19740022614>
- Sakellariou, S., Cabral, P., Caetano, M., Pla, F., Painho, M., Christopoulou, O., Sfougaris, A., Dalezios, N., & Vasilakos, C. (2020). Remotely Sensed Data Fusion for Spatiotemporal Geostatistical Analysis of Forest Fire Hazard. *Sensors*, 20(17), 5014. <https://doi.org/10.3390/s20175014>
- Sakellariou, S., Tampekis, S., Samara, F., Flannigan, M., Jaeger, D., Christopoulou, O., & Sfougaris, A. (2019). Determination of fire risk to assist fire management for insular areas: The case of a small Greek island. *Journal of Forestry Research*, 30(2), 589-601. <https://doi.org/10.1007/s11676-018-0666-x>
- Sánchez Villena, A. (2019). Uso de programas estadísticos libres para el análisis de datos: Jamovi, Jasp y R. *Revista Perspectiva*, 20(1), 112-114. <https://doi.org/10.33198/rp.v20i1.00026>
- Santos, J. M. (2020). *Sistemas de información geográfica*. Editorial UNED.
- Saucedo, A. M., & Inchausti, P. E. (2023). *Predicción de incendios forestales mediante modelos de Machine Learning*. XXVIII Congreso Argentino de Ciencias de la Computación (CACIC).
- Segura Herrera, M. (2021). *Correlación entre la humedad del suelo y los índices NDVI y NDWI como indicativo del estrés híbrido en el cultivo de caña de azúcar (Saccharum officinarum) en la variedad BC 001220, Ingenio Taboga 2019*. <https://agris.fao.org/search/en/providers/124218/records/65fb055e85e84924f70b6c28>
- SICA. (2021, junio 19). *SICA: Más del 50% de probabilidades de fenómeno de La Niña para América Central, según perspectivas*. Portal del SICA. [https://www.sica.int/noticias/sica-mas-del-50-de-probabilidades-de-fenomeno-de-la-nina-para-america-central-segun-perspectivas\\_1\\_127848.html](https://www.sica.int/noticias/sica-mas-del-50-de-probabilidades-de-fenomeno-de-la-nina-para-america-central-segun-perspectivas_1_127848.html)
- Su, Z., Zheng, L., Luo, S., Tigabu, M., & Guo, F. (2021). Modeling wildfire drivers in Chinese tropical forest ecosystems using global logistic regression and geographically weighted logistic regression. *Natural Hazards*, 108(1), 1317-1345. <https://doi.org/10.1007/s11069-021-04733-6>
- Szpakowski, D. M., Jensen, J. L. R., Chow, T. E., & Butler, D. R. (2023). Assessing the Use of Burn Ratios and Red-Edge Spectral Indices for Detecting Fire Effects in the

Greater Yellowstone Ecosystem. *Forests*, 14(7), 1508.  
<https://doi.org/10.3390/f14071508>

Taylor, A. H., & Skinner, C. N. (1998). Fire history and landscape dynamics in a late-successional reserve, Klamath Mountains, California, USA. *Forest Ecology and Management*, 111(2-3), 285-301. [https://doi.org/10.1016/S0378-1127\(98\)00342-9](https://doi.org/10.1016/S0378-1127(98)00342-9)

Tedim, F., & Leone, V. (2020). The Dilemma of Wildfire Definition: What It Reveals and What It Implies. *Frontiers in Forests and Global Change*, 3, 553116. <https://doi.org/10.3389/ffgc.2020.553116>

Tehrany, M. S., Jones, S., Shabani, F., Martínez-Álvarez, F., & Tien Bui, D. (2019). A novel ensemble modeling approach for the spatial prediction of tropical forest fire susceptibility using LogitBoost machine learning classifier and multi-source geospatial data. *Theoretical and Applied Climatology*, 137(1-2), 637-653. <https://doi.org/10.1007/s00704-018-2628-9>

Tehrany, M. S., Lee, M.-J., Pradhan, B., Jebur, M. N., & Lee, S. (2014). Flood susceptibility mapping using integrated bivariate and multivariate statistical models. *Environmental Earth Sciences*, 72(10), 4001-4015. <https://doi.org/10.1007/s12665-014-3289-3>

Tien Bui, D., Le, K.-T., Nguyen, V., Le, H., & Revhaug, I. (2016). Tropical Forest Fire Susceptibility Mapping at the Cat Ba National Park Area, Hai Phong City, Vietnam, Using GIS-Based Kernel Logistic Regression. *Remote Sensing*, 8(4), 347. <https://doi.org/10.3390/rs8040347>

Velásquez, L. M. V., & Benavides, K. L. (2014). Efectos post-incendio en bosques de pino del trópico seco de Nicaragua. *Revista Científica de FAREM-Estelí*, 11, Article 11.

Wilder, B. T., Jarnevich, C. S., Baldwin, E., Black, J. S., Franklin, K. A., Grissom, P., Hovanes, K. A., Olsson, A., Malusa, J., Kibria, A. S. M. G., Li, Y. M., Lien, A. M., Ponce, A., Rowe, J. A., Soto, J. R., Stahl, M. R., Young, N. E., & Betancourt, J. L. (2021). Grassification and Fast-Evolving Fire Connectivity and Risk in the Sonoran Desert, United States. *Frontiers in Ecology and Evolution*, 9, 655561. <https://doi.org/10.3389/fevo.2021.655561>

Xu, Z., Li, J., & Xu, L. (2024, julio 19). *Wildfire Risk Prediction: A Review*. <http://arxiv.org/abs/2405.01607>

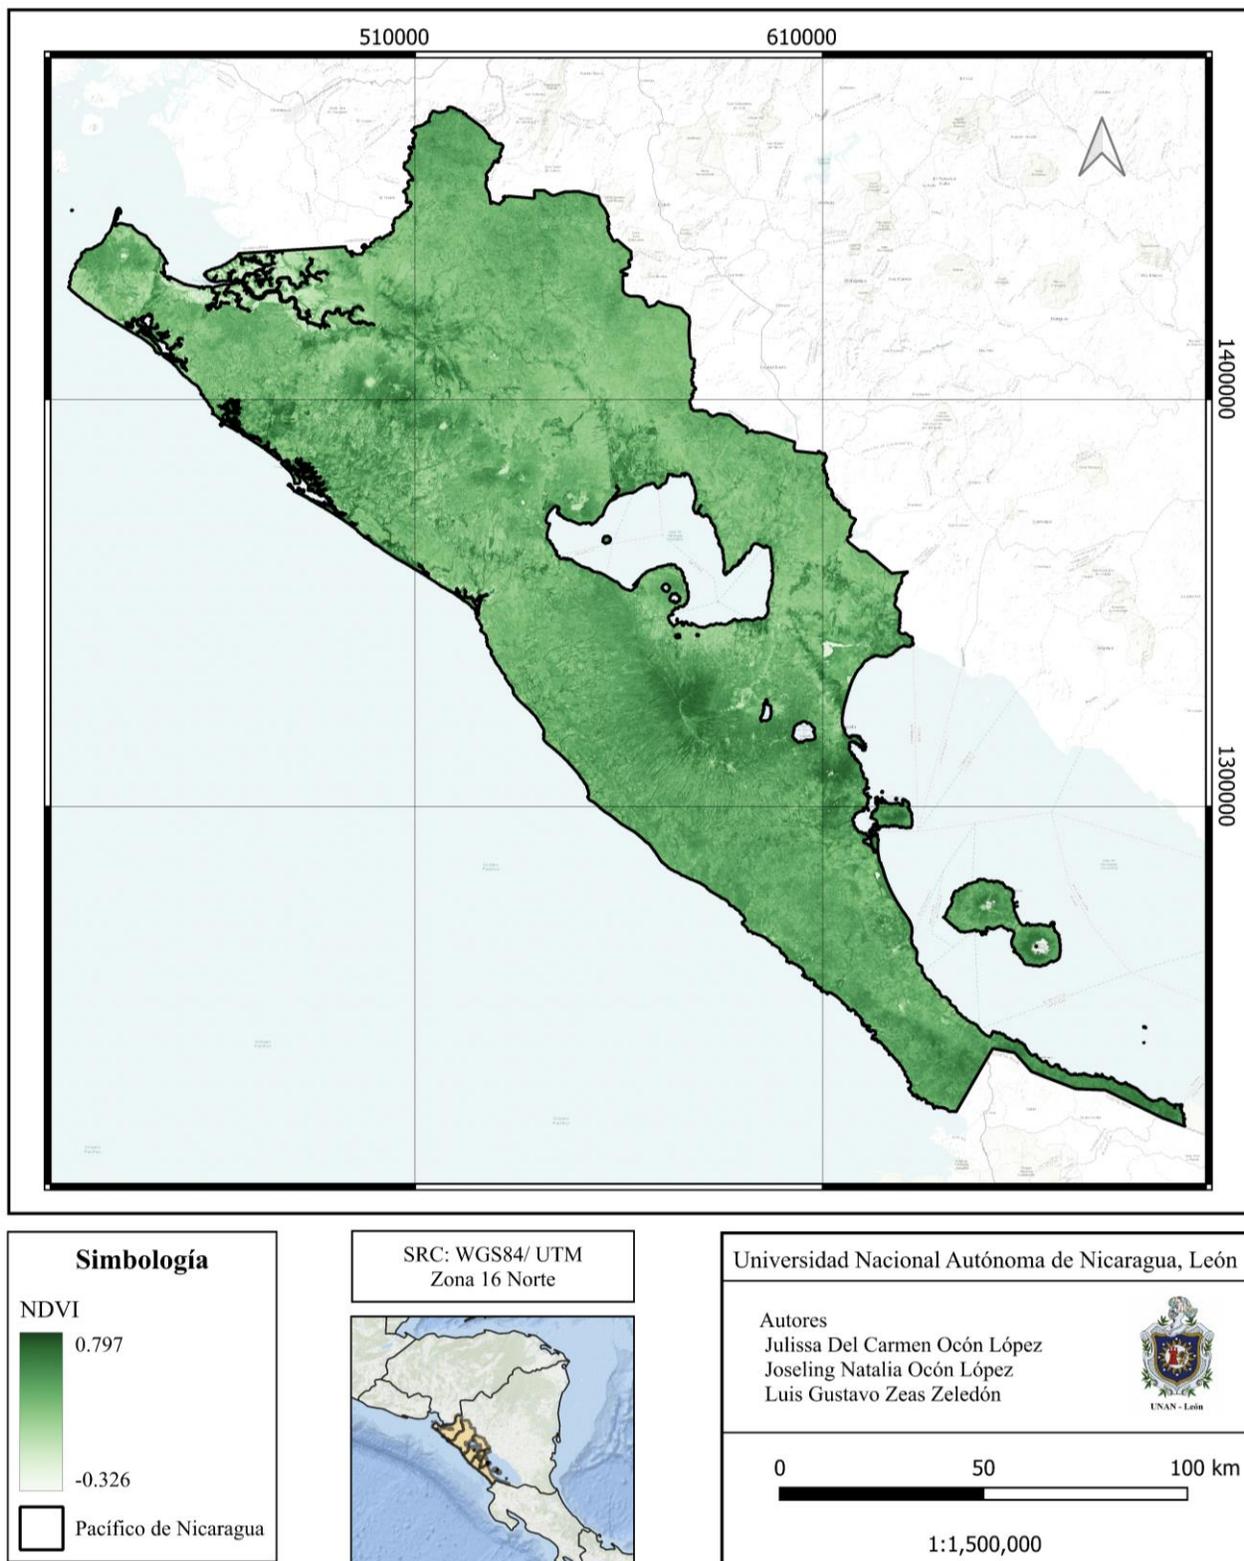
Xue, J., & Su, B. (2017). Significant Remote Sensing Vegetation Indices: A Review of Developments and Applications. *Journal of Sensors*, 2017, e1353691. <https://doi.org/10.1155/2017/1353691>

Yakubu, I., Mireku Gyimah, D., & Duker, A. (2015). Review of methods for modelling forest fire risk and hazard. *African Journal of Environmental Science and Technology*, 9(3), 155-165. <https://doi.org/10.5897/AJEST2014.1820>

## IX. ANEXOS

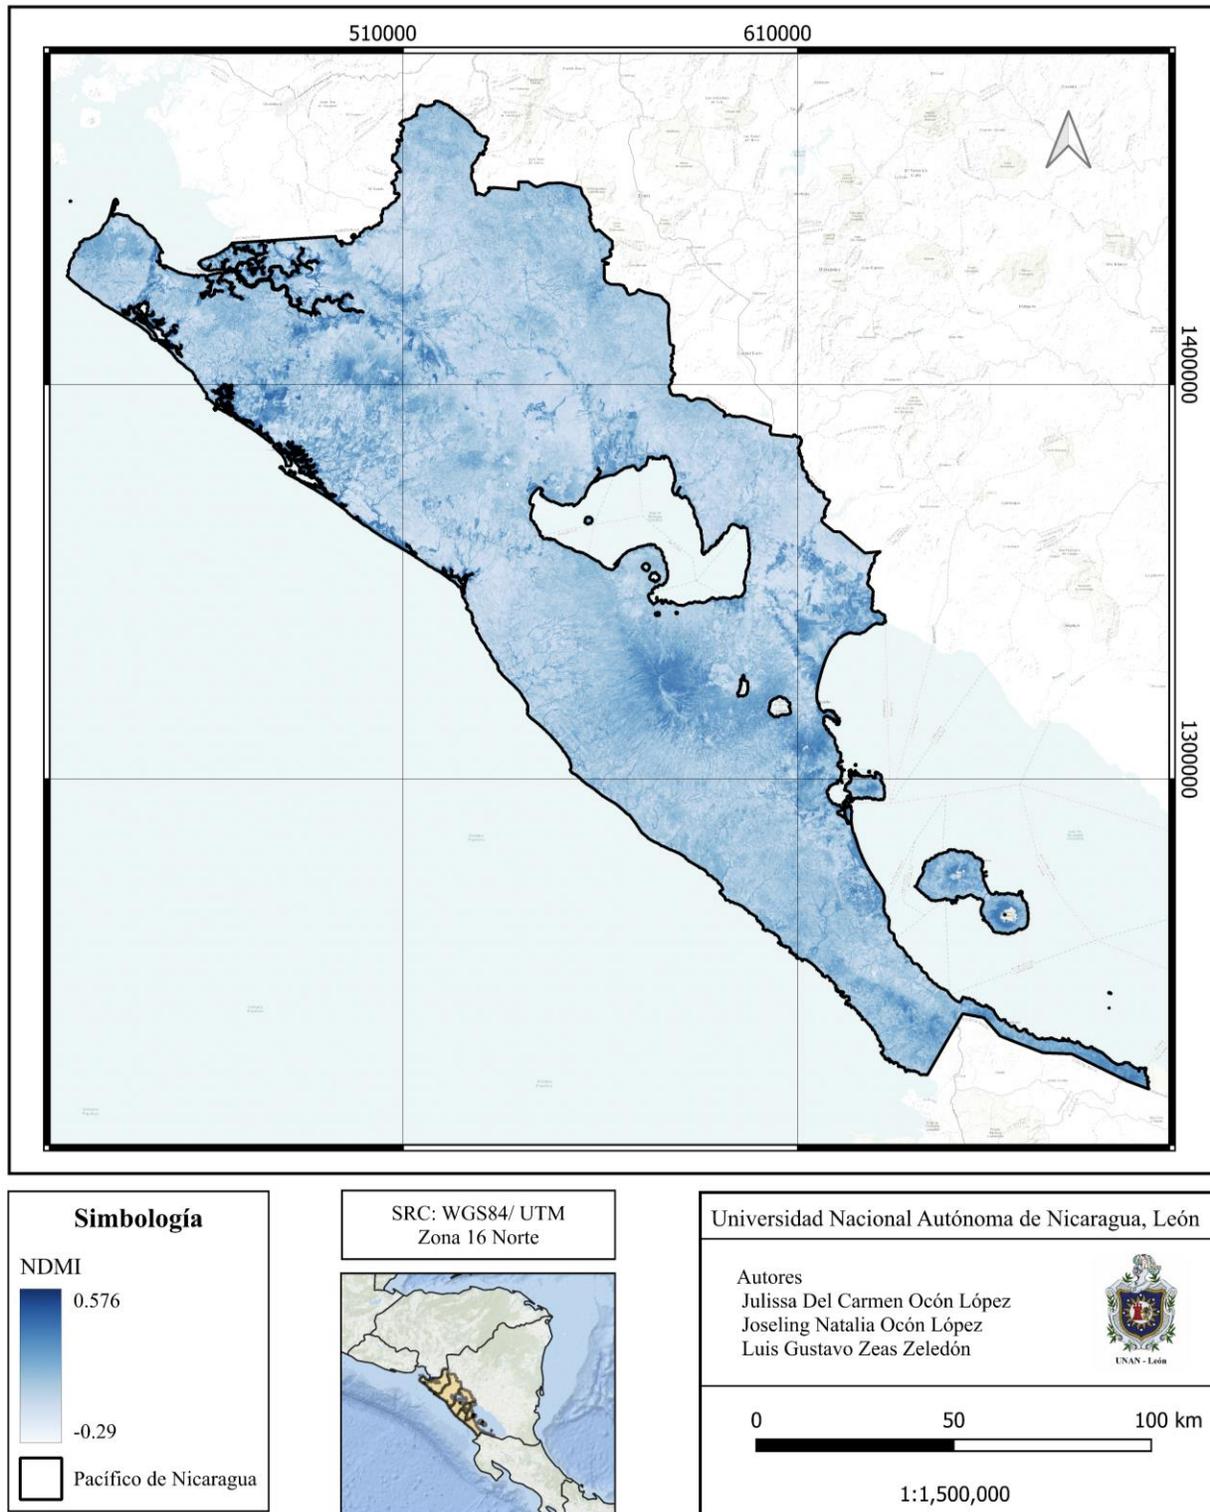
Figura 12

Índice de vegetación de diferencia normalizada (NDVI) del Pacífico de Nicaragua.



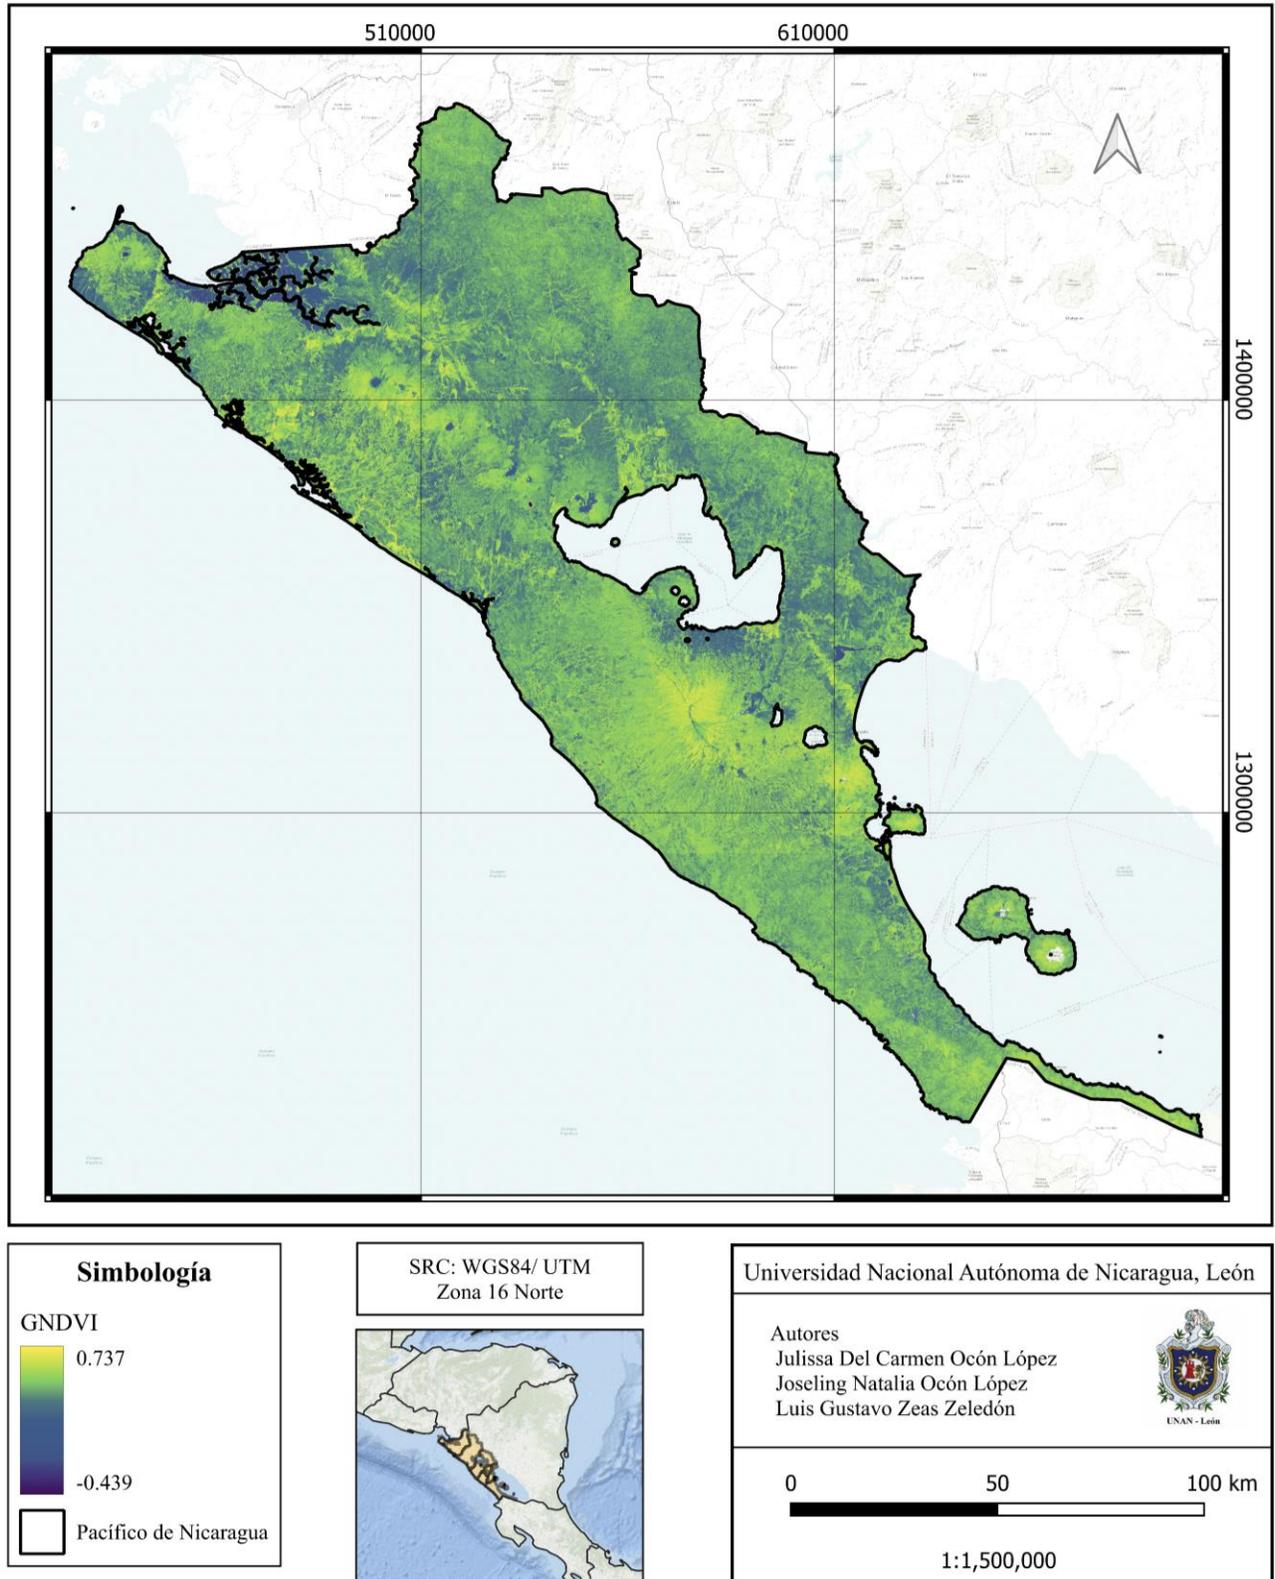
**Figura 13**

*Índice de humedad de diferencia normalizada (NDMI) del Pacífico de Nicaragua.*



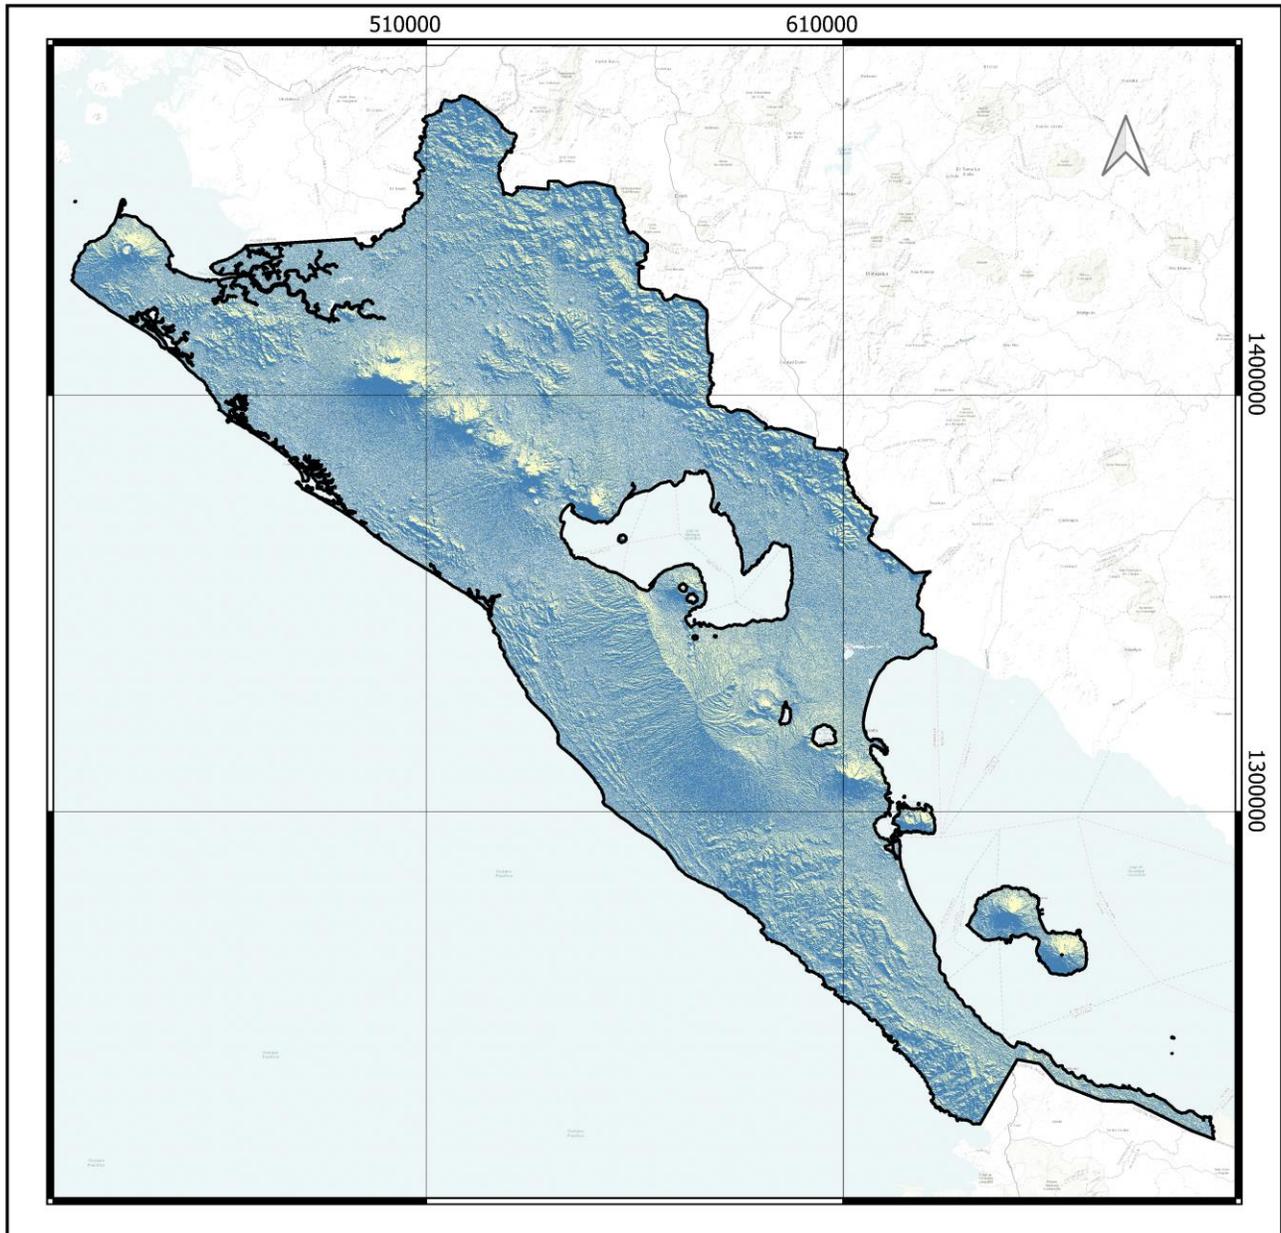
**Figura 14**

*Índice de vegetación de diferencia normalizada verde (GNDVI) del Pacífico de Nicaragua.*



**Figura 15**

*Orientación del Pacífico de Nicaragua.*



**Simbología**

Orientación

- Umbría
- Solana
- Pacífico de Nicaragua

SRC: WGS84/ UTM  
Zona 16 Norte

Universidad Nacional Autónoma de Nicaragua, León

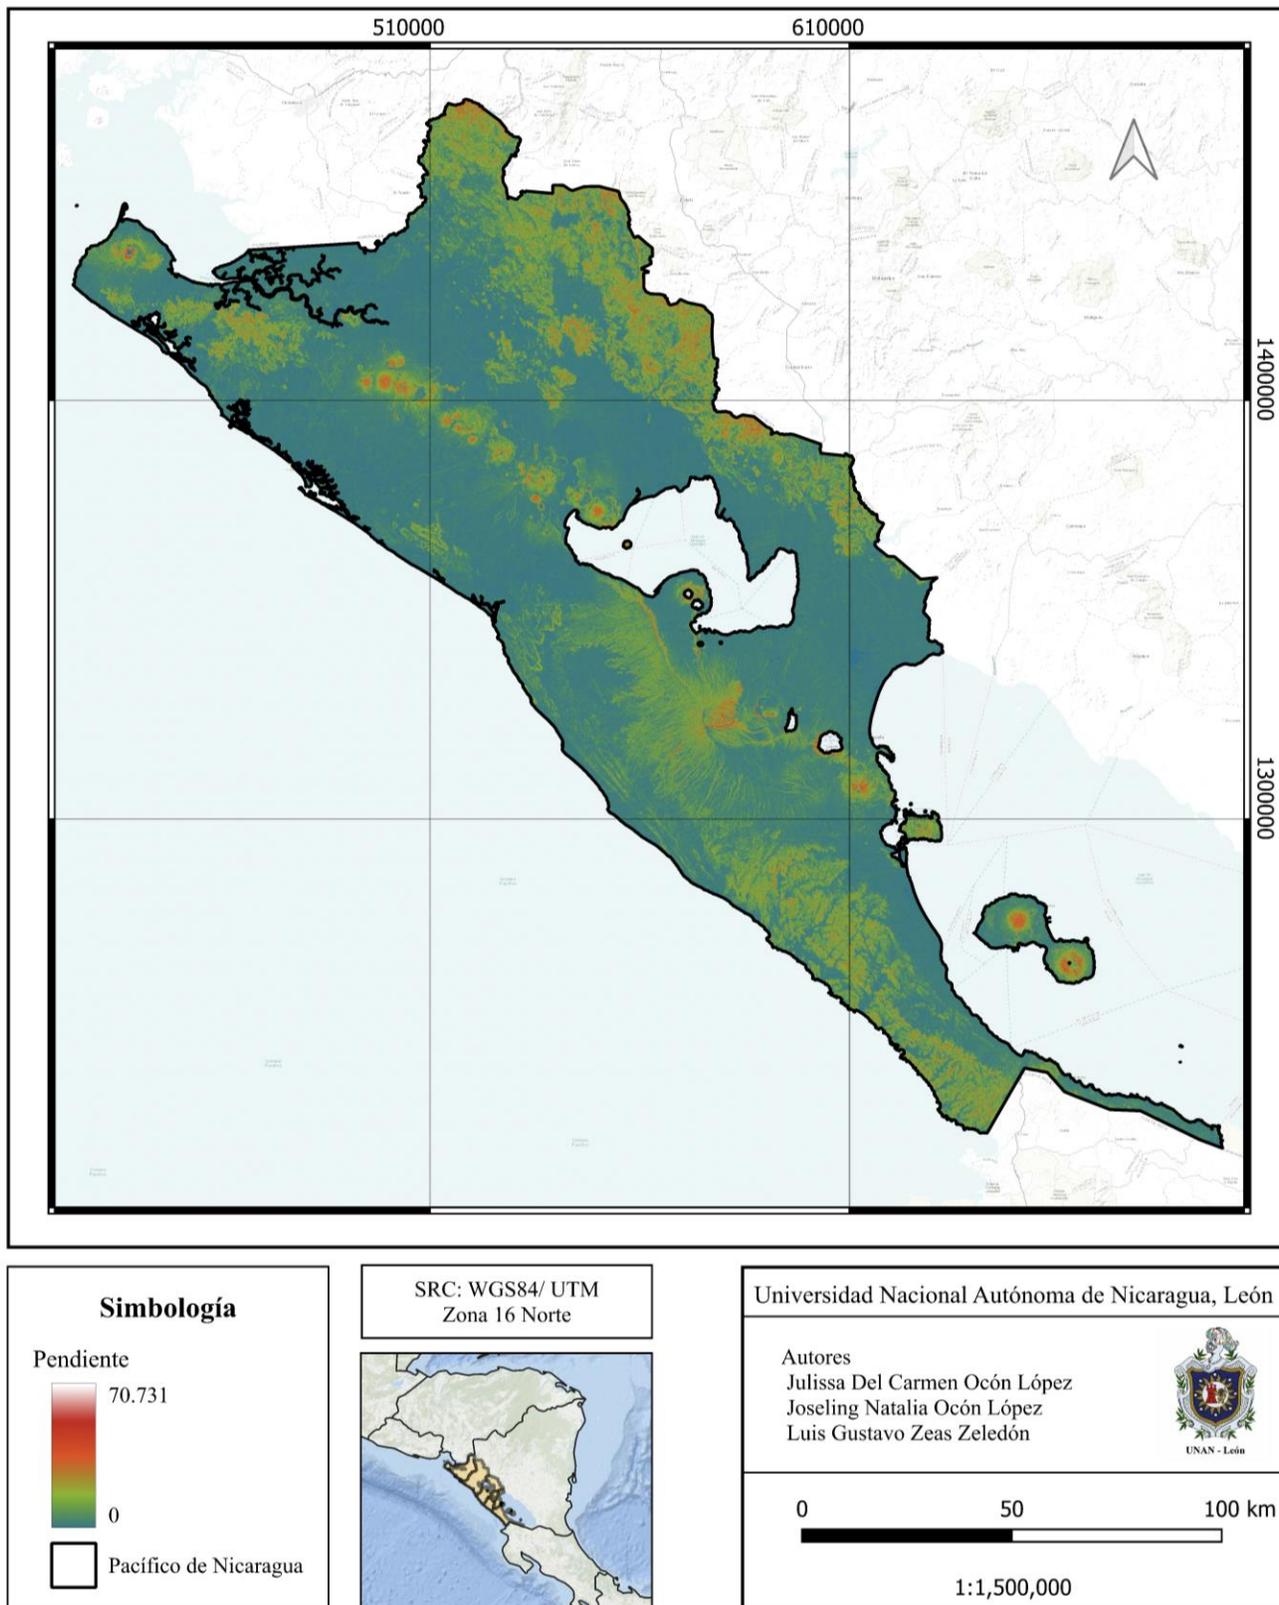
Autores  
Julissa Del Carmen Ocón López  
Joseling Natalia Ocón López  
Luis Gustavo Zeas Zeledón

0 50 100 km

1:1,500,000

Figura 16

*Pendiente del Pacífico de Nicaragua.*



**Figura 17**

*Altitud del Pacífico de Nicaragua.*

