



Universidad Autónoma
de Entre Ríos



Facultad de Ciencia
y Tecnología

Tesina de grado

Licenciatura en sistemas de información

“Propuesta de un algoritmo de *Deep Learning* para la predicción de
focos ígneos en los humedales del delta”

Tesistas

Alonso, Lucía del Carmen
Cabana, Alejo Matias

Director

Mg. Uhrig, Mariela Noelia

Codirector

Mg. Díaz, Santiago Raúl

Tribunal evaluatorio

Ing. Vera, Monica
Lic. Cabrera, Ignacio
Lic. Bonadeo Pamela

Lugar

Oro verde, Entre Ríos, Argentina

Fecha

9/12/2025

DATOS DE CONTACTO

Nombre y Apellido	Alonso Lucía del Carmen
DNI	40692514
Dirección de correo electrónico	alonso.luciadelc97@gmail.com
Teléfono	3456-406927

Nombre y Apellido	Cabana Alejo Matias
DNI	40405850
Dirección de correo electrónico	m97cabana@gmail.com
Teléfono	3436-458556

ÍNDICE GENERAL

ÍNDICE DE FIGURAS.....	3
ÍNDICE DE TABLAS.....	4
DEDICATORIAS.....	5
AGRADECIMIENTOS.....	6
RESUMEN.....	7
INTRODUCCIÓN.....	8
Objetivo general.....	9
CAPÍTULO 1 - MARCO TERRITORIAL Y AMBIENTAL DEL ÁREA DE ESTUDIO.....	10
1.1 Humedales: definición y características.....	10
1.2 Humedales del Delta de Paraná.....	11
1.3 Consecuencias derivadas de los incendios.....	14
CAPÍTULO 2 - INTELIGENCIA ARTIFICIAL.....	17
2.1. Inteligencia artificial.....	17
2.2. Machine Learning.....	18
2.3. Aprendizaje profundo.....	21
2.4 Métricas de desempeño y matriz de confusión.....	23
CAPÍTULO 3 - INVESTIGACIONES RELACIONADAS.....	25
3.1. Introducción de conceptos claves de predicción de incendios.....	25
3.2 Enfoques tradicionales en predicción de incendios.....	26
3.3 Modelos de predicción de focos ígneos utilizando IA.....	30
CAPÍTULO 4 - TELEDETECCIÓN.....	33
4.1. Teledetección.....	33
4.2. Principios físicos de la teledetección.....	35
4.3. Satélites y sensores.....	37
4.4. MODIS.....	39
4.5. LANDSAT.....	41
4.6 Teledetección y su aplicación en la predicción de incendios.....	43
CAPÍTULO 5. PROPUESTA METODOLÓGICA PARA LA DETECCIÓN TEMPRANA DE FOCOS ÍGNEOS EN HUMEDALES.....	45
5.1. Explicación de las variables y datos utilizados.....	45
5.2. Selección y descarte de características.....	46
5.3. Comparación de modelos de IA y evaluación de su rendimiento.....	48
CONCLUSIÓN.....	56
Posibles líneas de investigación.....	58
ANEXOS.....	59
A - Glosario de términos.....	59
BIBLIOGRAFÍA.....	60
Libros.....	60
Papers.....	60
Otros documentos (Tesis, informes técnicos y sitios web).....	63

ÍNDICE DE FIGURAS

Figura 1. Imagen de las principales diferencias entre los ecosistemas (terrestres, acuáticos y humedales) en relación con la variación del nivel de agua.....	10
Figura 2. Territorio PIECAS.....	12
Figura 3. Proceso de ML.....	18
Figura 4. Principio Máquinas de Vectores de soporte.....	20
Figura 5. Relación entre la IA y el aprendizaje automático y aprendizaje profundo.....	21
Figura 6. Ejemplo de una red neuronal convolucional.....	22
Figura 7. Proceso de la teledetección.....	34
Figura 8. Espectro electromagnético.....	36
Figura 9. Firma espectral comparativa de vegetación, agua y suelo desnudo.....	37
Figura 10. Mapa NDVI de vegetación.....	38
Figura 11. Comparación espacial entre mapas NDVI y EVI generados a partir de datos MODIS.....	40
Figura 12. Resoluciones del Landsat 8.....	42
Figura 13. FIRMS.....	47
Figura 14. Script utilizado para la exportación de imágenes satelitales de Landsat.....	48
Figura 15. Gráficos y resultados de Schroeder.....	49
Figura 16. Gráficos y resultados de Kumar-Roy.....	50
Figura 17. Gráficos de detección de fuego Schroeder.....	51
Figura 18. Gráficos de detección de fuego Kumar-Roy.....	52
Figura 19. Píxeles de fuego vs porcentaje Schroeder.....	53
Figura 20. Píxeles de fuego vs porcentaje Kumar-Roy.....	54

ÍNDICE DE TABLAS

Tabla 1 - Estructura de la matriz de confusión.....	24
Tabla 2 - Resumen comparativo de los principales sistemas internacionales de evaluación del peligro de incendios forestales.....	27
Tabla 3 - Resumen comparativo de métricas.....	55

DEDICATORIAS

Alonso Lucía

Dedico este trabajo con todo mi afecto a mis padres Beatríz y Sergio, que son mi mayor orgullo. Gracias por su amor y su esfuerzo incondicional. A mi hermana Rocío, por su compañía constante y su cariño. A mi pareja Iván, por su apoyo incondicional. Gracias por creer en mí y por acompañarme con amor, respeto y comprensión. A toda mi familia y amistades, por celebrar cada pequeño avance, por escuchar mis enojos, mis dudas, y también mis alegrías.

Muchísimas gracias a todos, este logro también es suyo.

Cabana Alejo

Quisiera dedicar esta tesina a mi mamá Maria de los Angeles Cabana, por ser mi mayor ejemplo de amor, esfuerzo y fortaleza. Por acompañarme en cada paso, incluso en los momentos de duda, y por enseñarme que la constancia y la fe en uno mismo pueden más que cualquier obstáculo. Gracias por todo. También quisiera dedicársela a mi familia, mi pareja y amigos, que me brindaron amor incondicional, apoyo constante y fe en mí incluso en los momentos más difíciles. Por último y no menos importante, agradecer a quienes me acompañaron en el camino, ya sea con una palabra de aliento, una charla o un simple gesto que hizo la diferencia.

AGRADECIMIENTOS

Alonso Lucía

En estas líneas quiero expresar mi más sincero agradecimiento a mis compañeros, docentes y personal no docente, tanto de la sede de la Facultad de Ciencia y Tecnología de Chajarí como de Oro Verde. Cada uno, desde su lugar, me ha guiado y acompañado con respeto y paciencia dejando una huella en mi formación académica y personal. Además, deseo hacer una mención especial a nuestra directora Mariela Uhrig y a nuestro codirector Santiago Díaz, quienes estuvieron siempre presentes para orientarnos, compartir sus conocimientos y brindarnos su apoyo en cada etapa de este proceso.

A mis colegas de trabajo que supieron brindarme los espacios necesarios para poder avanzar con este proyecto y a mi compañero y gran amigo, a quien tuve la fortuna de encontrar en el transcurso de esta carrera, Alejo Cabana. Gracias por tu complicidad, charlas, risas y esfuerzo compartido.

Cabana Alejo

Quiero expresar mi más sincero agradecimiento a todas las personas que formaron parte de este recorrido académico y personal. A mi amiga y compañera Lucía Alonso, por bancarme en todas. A mis docentes y tutores, por compartir sus conocimientos con paciencia, sobre todo agradecer a Mariela y Santiago que estuvieron desde un principio. A mis compañeros de carrera, por las horas compartidas y los desafíos superados.

Agradezco todas las experiencias —buenas y malas— que me moldearon en este camino y me impulsaron a crecer.

RESUMEN

Esta tesina propone un modelo de detección temprana de focos ígneos en los humedales del Delta del Paraná mediante el uso de técnicas de *Deep Learning*, con el objetivo de reducir el impacto económico y ambiental de los incendios forestales. A partir del análisis de trabajos previos y la experimentación con modelos de inteligencia artificial, se buscó identificar las arquitecturas más efectivas para la predicción de incendios en entornos con características geográficas y climáticas particulares como las del delta.

Se realizó una etapa de recopilación y preparación de datos, centrada en imágenes satelitales del Delta del Paraná, procesadas en formato *Tagged Image File Format* (TIFF) y divididas en fragmentos de tamaño uniforme adecuado para el entrenamiento. Para los ensayos se utilizaron modelos previamente entrenados y repositorios de código disponibles públicamente, con foco en la arquitectura U-Net, que se destaca por su capacidad para captar de manera precisa tanto la información contextual como la espacial. Las pruebas fueron ejecutadas sobre 100 imágenes de la región, evaluando el rendimiento mediante métricas de precisión.

Entre los modelos de detección de incendios, el propuesto por Schroeder, basado en la aplicación de un umbral dinámico sobre el Índice de Diferencia Normalizada de Quema (NDBI) para identificar áreas afectadas por fuego, mostró mejores resultados en relación al de Kumar-Roy, que utiliza una combinación de bandas de infrarrojo cercano y corto para clasificar píxeles con actividad ígnea, aplicando criterios de umbral fijos y relativos, permitiendo una mejor identificación de áreas de fuego en las imágenes.

El trabajo concluye con la propuesta de un modelo ajustado a las condiciones del ecosistema del delta, y destaca el potencial de estas tecnologías como herramienta para sistemas de alerta temprana y gestión ambiental. Finalmente, se establece un marco metodológico claro para futuras implementaciones prácticas.

Palabras claves: Deep Learning, Red neuronal convolucional, Teledetección, Incendios

INTRODUCCIÓN

En los últimos años, la creciente inquietud por preservar los ecosistemas ha impulsado un aumento en la investigación y desarrollo de tecnologías innovadoras para la detección temprana y la prevención de incendios forestales.

Debido a los incendios ocurridos en el Delta del Paraná en el año 2020, se ha evidenciado una degradación significativa del ecosistema y un impacto negativo en las comunidades aledañas (Ministerio de Ambiente y Desarrollo Sostenible, 2020). Esta situación ha resaltado la necesidad de contar con métodos precisos y eficientes para predecir los focos ígneos en los humedales.

Existen trabajos elaborados en diferentes regiones que permiten predecir con exactitud incendios bajo diferentes condiciones meteorológicas.

Se observa una tendencia en los estudios a utilizar herramientas de inteligencia artificial y teledetección. Entre estas investigaciones, se destaca la de Zhang G et al., (2019) para el “Modelado de la susceptibilidad a incendios forestales utilizando una red neuronal convolucional para la provincia de Yunnan, China”.

En Turquía, el estudio realizado por Çolak, E. y Sunar, F.(2020), evalúa los riesgos de los incendios a partir de datos geográficos, considerando topología, cobertura forestal y condiciones climáticas. Por otro lado, en Indonesia, Yang et al., (2021), llevaron a cabo una investigación orientada a la predicción de incendios forestales utilizando técnicas de aprendizaje supervisado y una red neuronal convolucional, empleando datos de sensores remotos. Además, evaluaron el rendimiento de su modelo en comparación con un enfoque de regresión logística¹.

Recientemente, Mansilla et al., (2021) presentaron una investigación centrada en herramientas de predicción de riesgos de incendios forestales basadas en técnicas de inteligencia artificial.

En conjunto, estos antecedentes destacan la importancia de la teledetección, el aprendizaje profundo y la evaluación de riesgos para la prevención y gestión de incendios forestales. Cada estudio aporta enfoques y metodologías distintas, lo que brinda una base sólida para la investigación propuesta en la tesina.

Esta investigación se enmarca en un enfoque transversal que abarca disciplinas diversas, desde la informática (*Deep Learning*) hasta la ecología².

¹ La regresión logística es un modelo estadístico utilizado para predecir la probabilidad de ocurrencia de un evento dicotómico (por ejemplo, éxito/fracaso, sí/no, 1/0) a partir de una o varias variables independientes.

² La ecología es la rama de la biología que estudia las relaciones de los organismos entre sí y con su entorno físico-químico.

Debido a que en la región del Delta del Paraná no existe un modelo planteado, se considera esencial investigar y comprender las soluciones propuestas, para poder identificar una técnica con el potencial de ser efectiva en la región.

A continuación se listan los objetivos específicos que dan curso a esta investigación, en pos de dejar sentadas las bases para luego arribar al objetivo general.

Objetivo general

Proponer un modelo de detección temprana de focos ígneos en los humedales, utilizando modelos de Deep Learning, para reducir el impacto económico y ambiental de los mismos.

Objetivos específicos

- Identificar, recolectar y preparar las fuentes de datos necesarias para el entrenamiento y evaluación de los modelos de *Deep Learning*.
- Evaluar modelos de *Deep Learning* utilizados en el ámbito de la predicción.
- Estudiar el proceso y los modelos de *Deep Learning* para la predicción, aplicado a la detección y prevención de incendios forestales.
- Identificar los patrones y tendencias en los datos históricos de incendios en los humedales para determinar las variables a tener en cuenta en un modelo de predicción de focos ígneos, en diferentes condiciones climáticas y geográficas.
- Realizar la comparación de diferentes modelos de *Deep Learning* y evaluar su performance con las métricas usuales.
- Proponer un modelo de detección temprana de focos ígneos en los humedales utilizando técnicas de *Deep Learning*.

CAPÍTULO 1 - MARCO TERRITORIAL Y AMBIENTAL DEL ÁREA DE ESTUDIO


Este capítulo tiene como propósito contextualizar la problemática, destacando la relevancia territorial y ambiental de los humedales del Delta del Paraná. Se analizan sus principales características ecológicas y socioeconómicas, así como las consecuencias de los incendios en la región y los antecedentes relacionados con su detección a través de técnicas de teledetección.

1.1 Humedales: definición y características

Un humedal es un ambiente donde el agua, ya sea de forma permanente o temporal, está presente en la superficie o debajo de ella. Como se observa en la Figura 1. Esta condición genera procesos naturales distintos a los que ocurren en ecosistemas terrestres o acuáticos. Se caracteriza por tener organismos adaptados a vivir en esas condiciones, especialmente plantas que crecen en el agua, y suelos con señales de haber estado saturados de humedad (Numerosky, 2022).

Figura 1

Principales diferencias entre los ecosistemas (en relación con el nivel de agua)



Nota. Adaptado de *Esquema que muestra las principales diferencias entre los ecosistemas terrestres, los acuáticos y los humedales en relación con la variación del nivel de agua.* Numerosky, 2022.


Estos humedales contienen una gran biodiversidad y constituyen entre el 12,8% y el 21,5% de la superficie del país (Kadus et al, s.f.)

Sin embargo, en la actualidad se estima que su extensión global disminuyó entre un 64% en el siglo XX. Debido al aumento de la población y desarrollo económico carente de criterios de sustentabilidad ambiental.

1.2 Humedales del Delta de Paraná

El Delta del Paraná, constituido por un extenso conjunto de humedales continentales de origen fluvial, se extiende a través de las provincias de Entre Ríos, Santa Fe y Buenos Aires (Giacosa et al., 2016, pág.2) con una superficie aproximada de 17.500 km² (kilómetros cuadrados). Tal como se observa en la Figura 2. Este vasto mosaico de humedales, asociados a la llanura de inundación del río Paraná, actúa como un corredor biogeográfico en el que conviven especies de regiones tropicales, subtropicales y templadas, destacándose entre ellas algunas especies de aves como el Capuchino castaño, el Capuchino pecho blanco y el Atajacaminos ala negra, que se encuentran en peligro de extinción (Giacosa et al., 2016).

Figura 2
Territorio PIECAS



Nota. Adaptado de *Territorio PIECAS-DP* de Ministerio de Ambiente y Desarrollo Sostenible, 2020.

Además de su importancia como hábitat para la biodiversidad, los humedales del Delta del Paraná desempeñan un papel esencial para el bienestar humano y el desarrollo

económico sostenible de la región, conforme a lo destacado por el Convenio Ramsar³ (2018, pág.2). Estos proporcionan numerosos servicios ecosistémicos, que incluyen la regulación de inundaciones, la formación de suelos y el suministro de agua para el consumo humano y la agricultura. Los mismos contribuyen de manera significativa a la calidad de vida y al desarrollo sostenible, beneficiando directamente a más de 15 millones de personas que residen en las áreas aledañas (Faros de conservación, 2022). Además, actúan como protectores naturales de las costas, contribuyen a la resiliencia de las ciudades y los asentamientos frente a los desafíos climáticos. Caracterizándose por ser depósitos naturales significativos de carbono (Convención de Ramsar 2018, pág. 2).

Aunque resulte relevante tanto para la biodiversidad y el bienestar humano, la perspectiva de los humedales, según el Convenio Ramsar revela una pérdida alarmante del 87% de estos ecosistemas desde el año 1700. Esta disminución se atribuye principalmente al avance constante de las actividades humanas, como señala Ali et al.(2018)

Una de las prácticas humanas recurrentes en las islas del Delta según el área de Ordenamiento Territorial del Ministerio de Ambiente y Desarrollo Sostenible de la Nación (2020), es el uso del fuego para despejar la vegetación que no es útil para el pastoreo. Esta práctica, común en tierras destinadas al uso ganadero y realizada principalmente al final del invierno, suele desarrollarse para promover el crecimiento de pastos frescos. No obstante, estas quemas no solo reflejan el proceso de "pampeanización"⁴ y los cambios en el uso del suelo, sino que también tienen repercusiones en los ecosistemas, como lo evidencian los focos ígneos observados entre enero y septiembre de 2020. Durante este período, se registraron 328.995 hectáreas afectadas por incendios, que corresponden a un 14% del territorio del Plan Integral Estratégico para la Conservación y Aprovechamiento Sostenible en el Delta del Paraná (PIECAS-DP), según datos del OAT⁵ (2020).

Estos incendios que, sumado a la fuerte sequía y una marcada disminución en el nivel del río Paraná (Montico et al., 2023), ambas prolongadas, desde fines del año 2019 hasta principios de 2023, han tenido un impacto significativo en la biodiversidad de la

³El Convenio de Ramsar, también conocido como la Convención sobre los Humedales, es un tratado internacional que se firmó en la ciudad de Ramsar, Irán, en 1971. Este convenio es un acuerdo intergubernamental que tiene como objetivo la conservación y el uso sostenible de los humedales a nivel mundial.

⁴ Proceso deampeanización: Proceso de expansión de la frontera agraria pampeana. Implica la transformación de tierras para fines agrícolas, como la siembra de cultivos y la cría de ganado.

⁵ El Ordenamiento Ambiental del Territorio es un instrumento del Estado para hacer efectiva la integración de las variables ambientales, sociales y económicas para el desarrollo sostenible.

región y han generado preocupación entre los ambientalistas y la comunidad local (FARN, 2021). A pesar de que en los años 2008 y 2012 incendios y sequías, subrayaron la necesidad de una regulación ambiental, que condujo a la creación y propuesta de una "Ley de Humedales" entre 2010 y 2013 periodo en el que senadores, ONGs y expertos colaboraron en dos proyectos de ley resaltando la importancia de los humedales, ambos orientados a establecer los presupuestos mínimos para la protección de los humedales en Argentina. Estos, no alcanzaron la aprobación final (Straccia et al. 2021).

A partir del año 2020, según lo que señala Capasso (2023), surgieron campañas exigiendo una ley de protección para los humedales. Esta demanda inspiró a grupos sociales a emprender acciones, usando estrategias como el *hashtag* #LeydeHumedalesYa en redes sociales y realizando acciones visuales para destacar la urgencia de preservar el medio ambiente. Un notable ejemplo fue el proyecto "Agitazo por los humedales" en Rosario (Argentina) que consistía en compartir imágenes con el objetivo de evidenciar la falta de interés y cuidado frente a la crisis ambiental.

En este sentido, la región se ve afectada por la actividad de industrias como la silvícola⁶ y ganadera, generando así una problemática socioambiental relacionada con el uso del territorio con fines económicos, provocando una movilización social que ha captado la atención mediática tanto a nivel regional como nacional. A pesar de esta realidad, existe una carencia significativa de información detallada sobre el impacto específico que estas actividades antrópicas tienen en estos territorios.

1.3 Consecuencias derivadas de los incendios

Como se explicó anteriormente, la preservación de los humedales del Delta de Paraná es esencial para la conservación de la biodiversidad y la sostenibilidad de la región. No obstante, es importante también abordar las consecuencias derivadas de los incendios, los cuales han emergido como una amenaza significativa para estos ecosistemas. Según el estudio y análisis de Finlay et al. (2012) los incendios producen daños colaterales como efectos provenientes del humo, principal contaminante del aire por las partículas y toxinas que genera, propiciando la aparición de problemas respiratorios; como así también contribuyen al surgimiento de problemas oftálmicos, como la irritación ocular, abrasión corneal y reducción de la visibilidad en aquellos conductores de carreteras cercanas a incendios forestales.

⁶ La práctica silvícola consiste en las intervenciones aplicadas a los bosques a fin de mantener o mejorar su utilidad con respecto a objetivos específicos, como la producción de madera.

Por otro lado, Castillo et al. (2021) destacan que los problemas de salud pública vinculados a los incendios forestales conllevan impactos socioeconómicos. La contaminación del suelo y del agua, según sus hallazgos, ha resultado en pérdidas económicas directas para los cultivos forestales y las cosechas agrícolas. También se puede mencionar que los incendios forestales acarrearán “efectos secundarios como el desgaste de la superficie terrestre, los deslizamientos de la tierra y el cambio en la calidad del agua, suelen ser más desastrosos que el fuego mismo” (U.S. Geological Survey, 2006).

Los incendios forestales representan una grave amenaza tanto para el medio ambiente como para la vida humana, por lo que resulta crucial desarrollar estrategias que permitan anticipar su ocurrencia y limitar sus daños. La creciente frecuencia de estos eventos ha impulsado la búsqueda de métodos eficientes para su detección y control. Entre estos, los modelos de riesgo de incendios se basan en el análisis de variables como las condiciones meteorológicas, el tipo de terreno y los patrones de comportamiento del fuego, para generar pronósticos precisos y en tiempo real.

De acuerdo con un informe del Programa de las Naciones Unidas para el Medio Ambiente (United Nations Environment Programme, 2022), se estima que la frecuencia de incendios forestales aumente un 30% hacia 2050 y un 50% hacia finales de 2100.

En este contexto, la implementación de sistemas informáticos está jugando un papel crucial. Tecnologías como la inteligencia artificial y el procesamiento de imágenes satelitales ya permiten el monitoreo y la predicción de incendios en tiempo real. Por ejemplo, en Argentina, plataformas como Global Forest Watch⁷ utilizan datos satelitales provistos por VIIRS para generar alertas tempranas. Estos sistemas, combinados con modelos predictivos, mejoran la capacidad de prevención y también optimizan la coordinación de los equipos de emergencia, brindándoles información precisa sobre la localización y la posible evolución del fuego.

Babu(2019) señala que el propósito de estos modelos es estimar y explicar el comportamiento del fuego y su propagación. Algunos ejemplos de estos modelos incluyen el Sistema Canadiense de Evaluación de Peligro de Incendios Forestales, el Sistema Métrico de Peligro de Incendios de McArthur, el Sistema de Evaluación de Peligro de Incendios de los Estados Unidos y el Sistema Europeo de Información sobre Incendios Forestales (EFFIS). Sin embargo, la efectividad de estos dependen en gran medida de la recopilación diaria y horaria de una extensa cantidad de datos sobre el terreno como también de estaciones meteorológicas, según lo que afirma Babu (2019, p. 34). Un

⁷ Acrónimo de GFW es una plataforma en línea que proporciona datos y herramientas para monitorear los bosques. gestionada por el Instituto de Recursos Mundiales (World Resources Institute)

ejemplo es el Sistema Canadiense de Evaluación de Peligro de Incendios Forestales, que hace uso de más de 750 estaciones meteorológicas, como indica Yang (2021, p. 1). Además, requiere una calibración constante para adaptarse a distintos entornos.

No obstante, en la actualidad estos métodos se basan en modelos matemáticos y en la experiencia de los expertos en el tema como indican Dentoni et al., (2012) y Babu (2019), lo que conlleva un coste operacional elevado.

La limitación de los mismos y la magnitud del problema subrayan la importancia de explorar enfoques alternativos. La capacidad de la inteligencia artificial para procesar grandes volúmenes de datos, reconocer patrones y adaptarse, la posiciona como una herramienta potencial en la lucha contra los incendios forestales. Por lo tanto, el Deep Learning, una subdisciplina dentro de la Inteligencia Artificial, podría ofrecer soluciones innovadoras en este ámbito. A diferencia de los sistemas tradicionales como los mencionados anteriormente, que dependen de instrumentos instalados en el terreno y requiere una infraestructura costosa, tanto en su instalación como en su mantenimiento, en países en desarrollo como Argentina. Científicos como Yang et al. 2021 propusieron modelos predictivos basados en redes neuronales que superan estos obstáculos como la complejidad y la cantidad de variables involucradas y la interacción entre ellas, estimada bajo aproximaciones .

En contraste, la flexibilidad y eficiencia hacen que los modelos basados en inteligencia artificial sean una opción cada vez más atractiva para abordar esta problemática a nivel global. Por lo tanto, en la presente tesina se buscará investigar, qué algoritmo de Deep Learning es óptimo para la región.

CAPÍTULO 2 - INTELIGENCIA ARTIFICIAL

Este capítulo se centra en los fundamentos teóricos de la inteligencia artificial y sus principales ramas. Se analiza la evolución del concepto de inteligencia artificial y el rol que desempeña el Machine Learning y el Deep Learning en la creación de sistemas capaces de aprender a partir de la información disponible. Por último, se profundiza en el estudio de las redes neuronales convolucionales (CNN), subrayando su importancia en el procesamiento y análisis de imágenes satelitales.

2.1. Inteligencia artificial

La inteligencia artificial (IA) busca modelar aspectos de la inteligencia humana que pueden ser simulados mediante máquinas, especialmente por sistemas informáticos (Copeland & B.J., 2025). El hardware cumple funciones de procesamiento, mientras que el software modela procesos cognitivos como el aprendizaje y la toma de decisiones. Estos procesos abarcan el aprendizaje (recolectar información y saber cómo utilizarla), el razonamiento (aplicar reglas para llegar a conclusiones) y la capacidad de autocorrección. De esta comparación con redes neuronales biológicas nacen las redes neuronales artificiales (RNA), que son sistemas de procesamiento inspirados en la neurona, la unidad básica del sistema nervioso. En una neurona, los estímulos activan sus entradas y, al superar un umbral, generan una señal.

Las RNA están compuestas por unidades de procesamiento que intercambian información y son útiles para tareas como clasificación y predicción, además de mejorar sus resultados a través del aprendizaje. Las RNA se entrenan ajustando pesos⁸ en sus conexiones mediante algoritmos de optimización, permitiendo que el modelo aprenda patrones a partir de los datos. Esta capacidad permite que la IA aborde problemas complejos, como predecir y gestionar incendios forestales, superando las limitaciones de enfoques tradicionales, especialmente ante los crecientes desafíos ambientales.

Dentro del campo de la informática, el primer trabajo que destaca para el avance de lo que posteriormente se conocería como inteligencia artificial fue realizado a mediados del siglo XX por el matemático de origen británico Alan Turing. McCarthy introdujo el término en 1956, dos años después de la muerte prematura de Alan Turing, definiendo la inteligencia artificial como la disciplina que se dedica a desarrollar máquinas con capacidades inteligentes (Copeland & B.J., 2025). La analogía entre las redes

⁸ Los pesos son parámetros numéricos que determinan la intensidad e importancia de la conexión entre dos neuronas. Durante el entrenamiento, estos valores se ajustan mediante algoritmos de optimización con el fin de minimizar el error del modelo.

neuronales biológicas y las redes neuronales artificiales surgió a partir de esta época, y estas estructuras se modelaron como conjuntos de unidades de procesamiento conectadas, que distribuyen los patrones de activación generados entre las unidades.

Estos modelos permiten a las máquinas analizar grandes volúmenes de datos, identificar patrones complejos y mejorar la toma de decisiones en diversos contextos.


2.2. Machine Learning

El *Machine Learning* es una rama de la IA que utiliza algoritmos para adquirir conocimiento a partir de datos. Su principal objetivo es desarrollar modelos que, a partir de datos de entrada, aprendan patrones y realicen predicciones sobre datos futuros. En esencia, el aprendizaje automático permite que las computadoras aprendan automáticamente a partir de datos históricos, utilizando algoritmos para construir modelos matemáticos o estadísticos que faciliten la predicción. (Balas et al., 2020)

Como se observa en la Figura 3, los modelos de *Machine Learning* analizan las entradas, encuentran patrones y realizan predicciones en base a estos.

Figura 3

Proceso de aprendizaje automático



Nota. Adaptado de Zendesk, 2025.

Los algoritmos de Machine Learning (ML) se clasifican en dos grandes categorías según su método de aprendizaje.

La primera corresponde al aprendizaje supervisado, en el cual el modelo se entrena a partir de ejemplos previamente etiquetados. Esta modalidad se asemeja al

proceso mediante el cual un estudiante adquiere conocimientos bajo la guía de un profesor.

Dentro del aprendizaje supervisado, se distinguen principalmente dos tipos de técnicas: clasificación y regresión.

En la clasificación, el modelo aprende a asignar categorías o clases a los datos de entrada. Por ejemplo, puede predecir si una imagen corresponde a un “gato” o a un “perro”, generando un resultado de tipo categórico o discreto.

Por su parte, la regresión tiene como objetivo predecir valores numéricos continuos, como estimar el precio de una vivienda en función de sus características (tamaño, ubicación, antigüedad) o predecir la temperatura del día siguiente.

La segunda categoría corresponde al aprendizaje no supervisado, en el cual el modelo identifica patrones o estructuras ocultas en conjuntos de datos sin etiquetas. Este tipo de aprendizaje se emplea principalmente en el análisis exploratorio de datos y abarca técnicas como el clustering y la asociación.

El clustering consiste en agrupar elementos de acuerdo con su grado de similitud, de modo que los objetos dentro de un mismo grupo sean más parecidos entre sí que con los pertenecientes a otros grupos. Se aplica, por ejemplo, en la segmentación de clientes o en la clasificación de imágenes sin etiquetas.

Por su parte, la asociación busca descubrir patrones, reglas o relaciones frecuentes entre variables en grandes volúmenes de datos. Un caso típico es el market basket analysis, donde se identifican productos que suelen comprarse juntos, lo que permite generar reglas del tipo “si un cliente adquiere X, es probable que también compre Y” (Deligiannidis et al., 2024).

Durante los últimos años, los algoritmos de *Machine Learning* se han desarrollado con éxito para la predicción, evaluación y seguimiento de incendios, por ejemplo Çolak, E. y Sunar, F.(2020) utilizaron máquinas de vectores de soporte (SVM) para la clasificación de imágenes satelitales en su área de estudio, puesto que, son precisos en la clasificación y pueden ser utilizados en donde se tenga una cantidad reducida de datos de entrenamiento.


El algoritmo SVM de aprendizaje supervisado se utiliza para encontrar el hiperplano⁹ que mejor separa los datos en dos o más clases.

⁹ Hiperplano: es la frontera de decisión entre las clases y se elige para maximizar la distancia entre los puntos de datos más cercanos.

En un espacio unidimensional (como una recta), un hiperplano es un punto: divide una línea en dos líneas. En un espacio bidimensional (como el plano xy), un hiperplano es una recta: divide el plano en dos mitades. En un espacio tridimensional, un hiperplano es un plano corriente: divide el espacio en dos mitades.

Figura 4

Principio Máquinas de Vectores de soporte



Nota. Adaptado de *Hands-on Machine Learning with Scikit-Learn, Keras, and TensorFlow* de Géron, 2019

A medida que aumenta la dimensionalidad de los datos, la interpretación geométrica del hiperplano de separación entre clases se vuelve más difícil, como se observa en la Figura 4. Esto puede dificultar la interpretación de los resultados y la comprensión de cómo las características individuales afectan la predicción.

Por lo cual se recurre a la teledetección, técnica que permite obtener información de la superficie terrestre mediante sensores satelitales o aéreos, debido a que la medición manual de áreas extensas resulta costosa, lenta e imprecisa para aplicaciones a gran escala. Yang et al. (2021) hicieron uso del aprendizaje supervisado donde entrenan una red neuronal convolucional en conjunto con datos de sensores remotos obtenidos del *Landsat 7* de *Google Earth Engine*¹⁰ (como entradas a la red neuronal) y *FIRMS* (para el conjunto de datos de etiquetas de verdad sobre el terreno, señalando, fuego y no fuego) para realizar la predicción de incendios forestales por mes.


Dentro de ML, el *Deep Learning* ha ganado relevancia por su capacidad de modelar relaciones complejas. Estos modelos permiten aprender representaciones jerárquicas y abstractas de los datos, lo que puede ser beneficioso para tareas complejas.

¹⁰ Google Earth Engine (GEE) es una plataforma en la nube desarrollada por Google que permite el acceso, visualización y análisis de grandes volúmenes de datos geoespaciales (Google Earth Engine, s.f.).

El aprendizaje profundo está surgiendo como una parte importante del campo del aprendizaje automático. En este enfoque, se emplea una amplia red neuronal que se entrena con grandes conjuntos de datos históricos para ejecutar una tarea particular.

Figura 5

Relación entre la IA y el aprendizaje automático y aprendizaje profundo



Nota. Adaptado de Machine learning vs. Deep learning, s/f

A modo de resumen se observa en la Figura 5 la relación de DL y ML mencionada en los capítulos 2.1 y 2.2

2.3. Aprendizaje profundo

Deep learning o aprendizaje profundo, se basa en redes neuronales profundas con múltiples capas¹¹ que permiten una mayor capacidad de abstracción y aprendizaje. Además, emplea transformaciones y tecnologías de gráficos simultáneamente para construir modelos de aprendizaje multicapa. Las técnicas desarrolladas recientemente han obtenido un rendimiento excelente en una variedad de aplicaciones, incluido el procesamiento de audio y voz, el procesamiento del lenguaje natural (NLP) y el procesamiento de datos visuales (Alzubaidi et al., 2021).

¹¹ Las capas son conjuntos de neuronas organizadas en niveles sucesivos. La capa de entrada recibe los datos originales, las capas ocultas procesan y transforman la información extrayendo patrones intermedios, y la capa de salida entrega el resultado final.

En el año 2006, Geoffrey Hinton adoptó el término *Deep Learning*, recuperando los trabajos iniciados con el perceptrón¹² realizados por Frank Rosenblat que habían permanecido latentes desde 1957, para explicar nuevas arquitecturas de Redes Neuronales profundas que son capaces de aprender mejor modelos más planos. El aprendizaje profundo es una subárea del aprendizaje automático que utiliza redes neuronales con muchas capas (de esta multiplicidad se deriva el término "profundo") para analizar diversos tipos de datos. A diferencia de los métodos tradicionales del ML, el aprendizaje profundo aprende por sí mismo las características importantes de los datos, sin intervención humana. Dentro del vasto campo del aprendizaje profundo, ciertas estructuras se han diseñado específicamente para tratar tipos particulares de datos y problemas. Para el análisis y reconocimiento de imágenes, una de las estructuras innovadoras y eficientes es la Red Neuronal Convolutiva.


2.3.1. Redes Neuronales Convolucionales (CNN)

Estas redes son un tipo de modelo de aprendizaje profundo diseñado para el procesamiento de imágenes, inspirado en el sistema visual biológico.

En una CNN, las primeras capas detectan patrones básicos (bordes, texturas), mientras que las capas más profundas identifican estructuras más complejas. Esto significa que las primeras capas detectan características más generales y abstractas, como formas y texturas, mientras que las capas más profundas se enfocan en características más específicas y detalladas.

Figura 6

Ejemplo de una red neuronal convolutiva



Nota. Adaptado de Londoño et al., 2016

¹² El perceptrón se compone de una neurona que combina las entradas mediante pesos, aplica una función de activación (generalmente un umbral) y produce una salida binaria. Constituye la base de las arquitecturas más complejas en el aprendizaje profundo.

En las CNN, existen tres tipos de capas intermedias que conforman su arquitectura: la capa convolucional, la capa de agrupación (*pooling*) y la capa completamente conectada (*fully connected*), cómo se puede observar en la Figura 6. La capa convolucional es el componente más importante, ya que se encarga de extraer automáticamente las características espaciales relevantes de las imágenes de entrada, generando mapas de características que destacan patrones como texturas, bordes y formas. La capa de agrupación reduce la dimensionalidad de los mapas generados, manteniendo las características más significativas y descartando detalles redundantes o ruido, lo que mejora la eficiencia computacional. Finalmente, la capa completamente conectada actúa como clasificador, asignando probabilidades a cada clase en función de los patrones detectados en las capas anteriores (Londoño et al., 2016).

Estas propiedades hacen que las CNN sean eficaces en la predicción de focos ígneos a partir de imágenes satelitales. Debido a su capacidad para detectar cambios sutiles en la cobertura del suelo, presencia de humo, diferencias térmicas o firmas espectrales relacionadas con incendios. En este contexto, U-Net se ha convertido en una de las arquitecturas más utilizadas, ya que está basada directamente en las CNN y aprovecha sus mecanismos de convolución para extraer características relevantes. Su estructura en forma de “U” combina una etapa de codificación, que captura patrones y señales profundas tal como lo haría una CNN tradicional, con una etapa de decodificación que permite recuperar la resolución espacial original, generando segmentaciones precisas a nivel de píxel. Esto la hace especialmente adecuada para identificar y delimitar zonas con posibles focos ígneos, humo o anomalías térmicas en imágenes satelitales complejas.

2.4 Métricas de desempeño y matriz de confusión

En base a la descripción del funcionamiento de las Redes Neuronales Convolucionales en el apartado 2.3, con el propósito de conocer el nivel de acierto de los modelos e identificar los errores que se producen, se recurre a diversas métricas de evaluación derivadas del aprendizaje automático, entre las cuales la matriz de confusión constituye una de las herramientas representativas para el estudio detallado de los resultados obtenidos.

En este sentido, la matriz de confusión es una herramienta que a partir de una representación tabular permite visualizar el desempeño de un algoritmo de clasificación

(Visa et al, 2011). Cuando se trata de un problema de clasificación binaria, la matriz de confusión tiene la siguiente estructura como se observa en la Tabla 1.

Tabla 1 - Estructura de la matriz de confusión.

	Predicho: Positivo	Predicho: Negativo
Predicho: Positivo	Verdadero Positivo (VP), casos en los que el modelo predice correctamente la clase positiva.	Falso Negativo (FN), casos en los que el modelo predice correctamente la clase negativa.
Predicho: Negativo	Falso Positivo (FP), casos en los que el modelo predice positivo, pero en realidad son negativos.	Verdadero Negativo (VN), casos en los que el modelo predice negativo, pero en realidad son positivos.

En problemas de clasificación multiclase, la matriz de confusión se amplía para incluir más filas y columnas, representando todas las clases posibles.

A partir de la matriz de confusión se pueden calcular métricas más específicas que cuantifican el rendimiento del modelo:

- Exactitud (Accuracy)

$$\text{Exactitud} = (VP + VN) / (VP + VN + FP + FN)$$

Mide la proporción de predicciones correctas sobre el total de casos.

- Precisión (Precision)

$$\text{Precisión} = VP / (VP + FP)$$

Indica cuántos de los casos predichos como positivos son realmente positivos.

- Exhaustividad o Sensibilidad (Recall)

$$\text{Sensibilidad} = VP / (VP + FN)$$

Mide la capacidad del modelo para detectar los casos positivos reales.

- Medida F1 (F1-score)

$$F1 = 2 \times (\text{Precisión} \times \text{Sensibilidad}) / (\text{Precisión} + \text{Sensibilidad})$$

Combina precisión y sensibilidad en una sola métrica balanceada, ofreciendo una visión más completa del rendimiento del modelo.

Estas métricas ofrecen una visión más detallada del rendimiento del modelo, fundamental en contextos donde los datos no están equilibrados.

CAPÍTULO 3 - INVESTIGACIONES RELACIONADAS

El presente capítulo reúne y analiza investigaciones previas relacionadas con la predicción de incendios forestales. En primer lugar, se presentan los conceptos básicos sobre el comportamiento del fuego y luego se revisan los principales enfoques y sistemas tradicionales utilizados para evaluar el riesgo de incendios, tanto en el ámbito nacional como internacional. Posteriormente, se analizan los modelos predictivos basados en inteligencia artificial y aprendizaje profundo, haciendo énfasis en aquellos que emplean redes neuronales convolucionales y técnicas de teledetección. Finalmente, se aborda la relevancia de la teledetección como herramienta para la obtención y el procesamiento de información espacial en los procesos de predicción y monitoreo de focos ígneos.

3.1. Introducción de conceptos claves de predicción de incendios

Los incendios forestales son fuegos activos que afectan áreas de vegetación, incluidas zonas de cultivo y áreas silvestres (Shivaprasad et al, 2025). Como peligros naturales, desempeñan un papel crucial en la dinámica de los ecosistemas, influyendo en la interacción entre la vegetación, el clima y las actividades humanas.

El triángulo de fuego, que representa gráficamente los tres elementos esenciales para que ocurra la combustión. Estos elementos son el combustible, presente en estado sólido, líquido o gaseoso; el comburente, principalmente el oxígeno, que posibilita la combustión; y la energía de activación, que es la fuente de calor necesaria para iniciar el fuego. Si alguno de estos componentes falta, la combustión no ocurre, lo que subraya la importancia de controlar estos elementos para la prevención y extinción de los mismos (Castillo Sarasty, 2021).

Una vez extinguido un incendio forestal, la zona afectada, visible en imágenes satelitales, se denomina cicatriz del incendio (Dentoni et al. 2013) y es un factor crítico para su análisis, los cuales se enfocan en la identificación de áreas propensas a la ignición y propagación del fuego.

Dentro de este orden de ideas, el estudio realizado por Cárdenas et al. (2013), destacó que otro factor crítico son las condiciones meteorológicas, como la temperatura y el viento, que desempeñan un papel crucial en la propagación de incendios forestales. Es por ello que uno de los índices más utilizados en Argentina es el Índice Canadiense de Incendios Forestales (*Canadian Forest Fire Weather Index - FWI*)¹³, que se basa en siete

¹³ Lawson B., Armitage O. "Weather Guide for the Canadian forest fire danger rating system". Natural Resources Canada, Canadian Forest Service, Northern Forestry Centre. Edmonton, Canadá. 2008.

indicadores derivados de cuatro observaciones meteorológicas: temperatura, humedad relativa, lluvia y viento.

Estos siete indicadores se dividen en dos grupos principales. El primero corresponde a los componentes de humedad del combustible (Fuel Moisture Codes), que representan la cantidad de humedad presente en diferentes capas del material combustible: el FPMC (Fine Fuel Moisture Code), que mide la humedad de los combustibles finos superficiales y refleja la facilidad de ignición; el DMC (Duff Moisture Code), que evalúa la humedad en la capa orgánica media del suelo e influye en la intensidad inicial del fuego; y el DC (Drought Code), que estima la sequedad acumulada en las capas profundas del suelo, indicando la persistencia del incendio (Dentoni y Muñoz, 2012).

El segundo grupo corresponde a los componentes del comportamiento del fuego (Fire Behavior Índices), que describen cómo podría desarrollarse un incendio una vez iniciado. Entre ellos se encuentran el ISI (Initial Spread Index), que indica la velocidad potencial de propagación inicial del fuego, dependiendo principalmente del viento y la sequedad del material fino; el BUI (Buildup Index), que representa la cantidad total de combustible disponible para arder, combinando la información del DMC y el DC; y finalmente el FWI (Fire Weather Index), que integra los anteriores para estimar la intensidad potencial del incendio y se utiliza como el valor principal para la emisión de alertas. Además, algunos estudios incluyen el DSR (Daily Severity Rating), un índice derivado del FWI que permite evaluar la severidad media de los incendios a lo largo de un período determinado (Dentoni y Muñoz, 2012).

3.2 Enfoques tradicionales en predicción de incendios

Como se mencionó en el apartado anterior, existen enfoques como el Índice Canadiense de Incendios Forestales que ayudan a la determinación de focos ígneos en la región. Debido al incremento de este fenómeno, Babu (2019) señala que, para estimar y explicar el comportamiento del fuego y su propagación, se utilizan modelos de peligro de incendios basados en las características del combustible forestal, el clima y la topografía.

Entre ellos se encuentran, Sistema Métrico de Peligro de Incendios de McArthur, Sistema de Evaluación de Peligro de Incendios de los Estados Unidos, el Sistema Europeo de Información sobre Incendios Forestales (EFFIS) y además el Sistema Canadiense de Evaluación de Peligro de Incendios Forestales.

A continuación se presenta la *Tabla 2* a modo de resumen de los sistemas antes mencionados:

Tabla 2 - Resumen comparativo de los principales sistemas internacionales de evaluación del peligro de incendios forestales

Sistema	Región	Variables	Propósito principal	Observaciones
Índice Meteorológico de Incendios (FWI)	Canadá y otros países	• Humedad del combustible • Temperatura • Viento • Precipitaciones • ISI (índice de propagación) • BUI (índice de acumulación)	Estimar diariamente el peligro de incendios	Es uno de los sistemas más difundidos a nivel internacional. Si bien requiere cálculos posteriores, ofrece buenos resultados en contextos templados.
Sistema de McArthur (FFDI)	Australia	• Temperatura • Humedad relativa • Viento • Número de días sin lluvia • Índice de sequía (KBDI)	Evaluar y anticipar el comportamiento del fuego	De carácter empírico, es utilizado desde hace décadas en Australia. Cuenta con versiones específicas para diferentes tipos de vegetación.
Sistema Nacional de los EE.UU. (NFDRS)	Estados Unidos	• Datos del combustible • Clima • Pendiente • Actividad eléctrica y humana • Entre otros	Clasificación operativa del peligro de incendio	Integra aspectos físicos y sociales. Su uso exige una red amplia de estaciones y personal capacitado en gestión del fuego.
EFFIS (Sistema Europeo)	Países de la Unión Europea	• Información meteorológica • Índices de vegetación (NDVI) • Tipo de cobertura del suelo • Imágenes satelitales	Monitoreo regional y apoyo a la toma de decisiones	Permite visualizar el peligro de incendios a escala continental. Su plataforma es pública y se actualiza con información satelital.
Sistema Canadiense Completo (CFFDRS)	Canadá	• Meteorología diaria • Humedad del suelo • Topografía • Comportamiento del fuego	Simulación y predicción detallada del fuego	Es una extensión del FWI. Utiliza una red extensa de más de 750 estaciones meteorológicas y permite estimaciones altamente localizadas.

El Sistema Canadiense como se observa en la *Tabla 1*, según Dentoni y Muñoz (2012), se divide en dos subsistemas principales; el primero es el Índice Meteorológico de Peligro de Incendios (FWI de sus siglas en inglés) que utiliza observaciones meteorológicas de la humedad, la velocidad del viento y de las lluvias producidas dentro de las 24 horas como así también, se debe tener en cuenta los efectos del viento y de la humedad del combustible, que puede variar en una región respecto a otra. También, Pertino (2008) remarca que este índice requiere de un conocimiento adecuado de las relaciones físicas implícitas. Adicionalmente, Dowdy et al. (2010) afirman que el FWI precisa de cálculos posteriores provenientes del índice de propagación inicial (ISI) y el índice de acumulación (BUI). Retomando las palabras de Dentoni y Muñoz (2012) el segundo subsistema principal es el de Predicción de Comportamiento del Fuego que evalúa parámetros relacionados a la conducta del fuego, como la velocidad de propagación de la cabeza del incendio, el consumo de combustibles, la tasa de crecimiento del perímetro y la intensidad del fuego, para un lugar e instante determinado. En contraste, Yang et al. (2021) señalan que el Sistema Canadiense utiliza más de 750 estaciones meteorológicas.

A su vez, el Sistema de Evaluación de Peligro de Incendios de los Estados Unidos integra las leyes de la física, como la combustión, lo cual permite desarrollar un sistema eficaz para clasificar el peligro de incendios.

Además, Dentoni y Muñoz (2012) sostienen que este sistema cuenta con variables de entrada como, número de estación, altura de la misma, modelo de combustible, estado de la vegetación herbácea y leñosa¹⁴, clase de pendiente, la fecha, el estado del tiempo, temperaturas de bulbo seco y húmedo, la velocidad y la dirección del viento, cantidad duración y tipo de precipitación, nivel de actividad eléctrica, temperatura y humedad máxima y mínima dentro de las 24 horas, humedad de los combustibles, riesgo de rayos y riesgo por causas humanas. En resumen, según el estudio realizado por Deeming et al. (1977) es una evaluación que se realiza en el área sobre los focos ígneos provocados por el hombre, en otras palabras, se basa en la estimación del personal a cargo de la gestión de incendios con respecto a la presencia de agentes causantes de los mismos. Además señala que esta estimación se realiza en base a una calificación (del 1 al 5) de las actividades que han sido fuentes de riesgo de los incendios provocados por el hombre en el área, donde, la calificación se ajusta en función del nivel de actividad normal para ese día de la semana, en términos más precisos, si una fuente de riesgo en particular, es menos activa de lo que es normalmente para ese día de la

¹⁴ Las plantas herbáceas tienen tallos blandos y fáciles de doblar, porque no forman madera. En cambio, las plantas leñosas tienen tallos duros y resistentes, ya que desarrollan madera y pueden vivir muchos años.

semana, se le asigna un nivel de actividad diario "Bajo"; pero si es más activa, se le asigna un nivel de actividad diario "Alto"; finalmente la importancia de una determinada fuente de riesgo se pondera en función de la proporción de incendios históricos provocados por el hombre que se producen en ese día de la semana, la cual se le atribuye a esa fuente de riesgo en específico.

Por otro lado, las variables de salida del Sistema de Evaluación de Peligro de Incendios de los Estados Unidos son: los indicadores de riesgo por rayos y por causas humanas, el índice de quema (que depende de los componentes de propagación y de liberación de energía) y el índice de carga de fuego.

Babu (2019) establece que estos sistemas de clasificación del peligro de incendios forestales mencionados hasta aquí, requieren de una gran cantidad de datos sobre el terreno y estaciones meteorológicas de manera diaria y horaria para el cálculo de sus índices.

A su vez, Pertino (2008) señala que el sistema métrico de peligro de incendios de McArthur es un modelo empírico que se fundamenta en la descripción estadística de incendios experimentales o históricos para predecir su comportamiento. Y además, asegura que a diferencia de los modelos físicos, no requiere un conocimiento adecuado de las relaciones físicas implícitas.

En cambio, Babu (2019) asevera que el Sistema Métrico de Peligro de Incendios de McArthur incluye cuatro submodelos, el primero es el "Factor Sequía", el cual representa la disponibilidad de combustible fino (hojas, pastos, u hojarasca) de otros combustibles en la superficie del suelo (Ramas, arbustos, o árboles) y que se mide a partir de parámetros meteorológicos como el número de días desde la última lluvia, la temperatura máxima diaria, la precipitación diaria y anual; el segundo submodelo es la "Humedad de combustible fino en la superficie", que se estima en función de los valores diarios de la temperatura y la humedad relativa; el tercero es la "Tasa de propagación", que es la combinación de los dos anteriores, donde el valor de la velocidad del viento se añade a la humedad del combustible fino; y el cuarto submodelo es la "Dificultad de Supresión" que depende de la relación entre la propagación del fuego derivado de la velocidad del viento y el "contenido de humedad del combustible fino en la superficie".

El Sistema Métrico de Peligro de Incendios de McArthur utiliza como una herramienta central para evaluar el riesgo de incendios en una determinada área, el índice de peligro de incendios forestales (FFDI) que, como indica Pazmiño (2019), fue formulado por Alan Grant McArthur (McArthur, 1966 , 1967) donde, inicialmente hacían uso de medidores mecánicos para su cálculo, luego fue formulado como una ecuación y actualmente es utilizado en Australia para la gestión del riesgo de incendios forestales.

Por otro lado, Babu (2019) expresa que existen tres subcomponentes en el índice de peligro de incendios modificado de McArthur, el sistema Mark 3 (Mk3), Mark 4 (Mk4) y Mark 5 (Mk5)¹⁵. Además, agrega que el Mk4 y Mk5 son versiones mejoradas de la Mk3 para incendios en pastizales y también existe el sistema Mk5F para incendios forestales. Este último representa disponibilidad de combustible, el cual para su cálculo necesita datos de la última precipitación, el número de días desde la última lluvia y el índice de sequía de Keetch-Byram (KBDI).

Según los estudios de Dowdy et al. (2010), no hay una diferencia significativa en la sensibilidad de las variables de entrada entre el FWI y el índice de peligro de incendios forestales de McArthur (FFDI), pero, como se mencionó anteriormente, el FWI requiere de cálculos posteriores provenientes de otros índices, lo cual limita poder expresar su fórmula en una forma simple a comparación del FFDI.

Ante la evaluación de las condiciones del riesgo de incendio se debe considerar una gama variada de aspectos. Suelen distinguirse dos factores en la valoración del riesgo: por un lado, el peligro o probabilidad de que ocurra un incendio en un lugar y momento determinados, y, por otro, la vulnerabilidad, que hace referencia al daño potencial que el fuego supondría para ese lugar. El peligro integrado de incendios se define como un producto de la ignición y la propagación. La ignición considera los aspectos físicos y humanos que explican el inicio del fuego, mientras en la propagación hace referencia a las condiciones promedio que explican la dispersión de un fuego una vez que se inicia.

La evaluación de las condiciones de riesgo de incendio combina múltiples variables que permiten comprender tanto la probabilidad de que ocurra un incendio como el impacto que este podría generar en un área específica. Este enfoque integral, que incluye el análisis del peligro y la vulnerabilidad, es clave para anticiparse a los eventos ígneos y minimizar sus consecuencias. A partir de esta base conceptual, se hace necesario profundizar en los modelos predictivos, herramientas fundamentales para la prevención y la gestión de incendios forestales.

3.3 Modelos de predicción de focos ígneos utilizando IA

Una vez descritos los conceptos fundamentales sobre incendios forestales y los factores que contribuyen a su propagación en el apartado 3.1, es importante abordar los

¹⁵ Los sistemas Mk3, Mk4, Mk5 y Mk5F son versiones sucesivas del McArthur Fire Danger Index, desarrolladas en Australia. Las versiones Mk4 y Mk5 mejoran la precisión del Mk3 para incendios en pastizales, mientras que el Mk5F se aplica a incendios forestales e incorpora variables como la precipitación reciente y el índice de sequía de Keetch-Byram (Babu, 2019).

modelos predictivos de focos ígneos, ya que estos representan una de las principales herramientas tecnológicas para la prevención y gestión de incendios forestales.

Los modelos de predicción integran múltiples variables como la disponibilidad de combustible, condiciones meteorológicas, topografía y comportamiento histórico de los incendios, para anticipar posibles brotes de fuego. Estos modelos emplean algoritmos y sistemas de información geográfica (SIG¹⁶) para simular escenarios donde los incendios forestales tienen más probabilidades de ocurrir o propagarse.

Estudios recientes, como el de Pereira et al (2021) , han desarrollado y perfeccionado modelos predictivos utilizando redes neuronales convolucionales (CNN), con arquitectura U-Net , mencionadas en el apartado 2.3.1, que ha demostrado gran capacidad para detectar patrones espaciales complejos en imágenes satelitales. En particular, utilizaron dos variantes del modelo U-Net una con 16 filtros¹⁷ iniciales y otra con 64 filtros iniciales ambas con 2 convoluciones por bloque. Cada convolución utiliza filtros de tamaño 3x3 y funciones de activación ReLU¹⁸. En el caso del modelo unet_64f_2conv_10c se utilizaron imágenes de 10 canales de entrada mientras que su variante unet_64f_2conv_762 procesa imágenes con 762 canales. En ambas versiones la arquitectura sigue el esquema clásico de U-Net con una fase contractiva¹⁹ donde se duplican los filtros en cada nivel (64 128 256 512) seguida de una fase expansiva simétrica que restaura la resolución original de la imagen. La capa de salida utiliza activación sigmoide²⁰ lo que confirma su uso para segmentación binaria (presencia o no de fuego en cada píxel).

La integración de datos históricos de incendios, junto con variables meteorológicas como temperatura, humedad y velocidad del viento, permitió no sólo anticipar la ocurrencia de incendios, sino también estimar su intensidad y dirección de propagación, brindando información valiosa para la toma de decisiones.

¹⁶ SIG o sistemas de información geográfica, permiten analizar y gestionar datos geoespaciales.

¹⁷ Los filtros (o kernels) son matrices utilizadas en las capas convolucionales para detectar características específicas de la imagen, como bordes, texturas o formas.

¹⁸ La función de activación ReLU (Rectified Linear Unit) es ampliamente utilizada en redes neuronales. Transforma los valores negativos de la entrada en cero y deja pasar los positivos sin cambios, lo que permite introducir no linealidad en el modelo y facilitar el aprendizaje eficiente.

¹⁹ Consiste en una serie de capas convolucionales y de pooling que reducen progresivamente la dimensión espacial de la imagen mientras extraen características relevantes, capturando contextos globales para la segmentación.

²⁰ La función de activación sigmoide transforma cualquier valor de entrada en un número entre 0 y 1, lo que permite interpretarlo como una probabilidad, siendo comúnmente utilizada en problemas de clasificación binaria y en la capa de salida de algunas redes neuronales.

Çolak, E. y Sunar, F.(2020) aplicaron SVM mencionado en el apartado 2.2 para clasificar imágenes satelitales de los bosques de Turquía, ya que según su investigación, el SVM es el más utilizado en el área de la teledetección, porque son precisos en la clasificación y pueden utilizarse con *datasets* en donde no se cuente con numerables cantidades de datos.

Yang y otros (2021) hicieron uso del aprendizaje supervisado donde entrenan una red neuronal convolucional en conjunto con datos de sensores remotos obtenidos del *Landsat 7* de *Google Earth Engine* (como entradas a la red neuronal) y *FIRMS* (para el conjunto de datos de etiquetas de verdad sobre el terreno, lo que significa fuego y no fuego) para realizar la predicción de incendios forestales por mes, en los bosques de indonesia, los resultados obtenidos con esta red superaron a los de un modelo de regresión logística, en otras palabras, tanto el error cuadrático medio como el área debajo de la curva de la característica operativa del receptor (ROC) dieron un valor mayor en diferentes escenarios de evaluación para el modelo construido con red neuronal en comparación del de regresión logística.

Sin embargo, el estudio no especifica detalles arquitectónicos críticos como la cantidad de capas convolucionales, el tamaño de los filtros, las funciones de activación utilizadas, ni la función de pérdida empleada, lo cual limita la reproducibilidad y evaluación de la metodología.

En contraste, estudios como el de Pereira et al. (2021) proporcionan especificaciones arquitectónicas detalladas: utilizan arquitecturas U-Net con 18 capas convolucionales (10 en el path contractivo y 8 en el expansivo), filtros de 3x3, activación ReLU en capas ocultas y sigmoid en la salida, para los modelos de Kumar-Roy y Schroeder. El modelo de Schroeder se basa en la aplicación de un umbral dinámico sobre el Índice de Diferencia Normalizada de Quema (NDBI) para detectar áreas afectadas por incendios, mientras que el modelo de Kumar-Roy emplea una combinación de bandas del infrarrojo cercano y de onda corta para clasificar los píxeles con actividad ígnea, aplicando criterios de umbral tanto fijos como relativos, lo que mejora la identificación de zonas con presencia de fuego en las imágenes satelitales.

Entre los modelos de detección de incendios, el propuesto por Schroeder, mostró mejores resultados en relación al de Kumar-Roy, permitiendo una mejor identificación de áreas de fuego en las imágenes.

Esta falta de transparencia metodológica en Yang et al. (2021) dificulta la evaluación de la aplicabilidad de su modelo a otros contextos, a pesar de que sus resultados superaron a los modelos de regresión logística en términos de error cuadrático medio y área bajo la curva ROC.

CAPÍTULO 4 - TELEDETECCIÓN

Este capítulo aborda los principios físicos que sustentan la teledetección, junto con los procesos de interacción entre la radiación electromagnética y los elementos de la superficie terrestre. Luego, se examinan los principales satélites y sensores utilizados en la obtención de imágenes, así como los productos derivados (entre ellos, los índices espectrales NDVI y EVI) que permiten evaluar el estado y la densidad de la vegetación. Y por último, se describen los sistemas satelitales MODIS y Landsat, resaltando sus aplicaciones en investigaciones recientes orientadas a la detección y predicción de focos ígneos.


4.1. Teledetección

La teledetección constituye una herramienta fundamental en el análisis del riesgo de incendios. Su aplicación se clasifica en dos grandes ámbitos, por un lado, en la generación de variables críticas que permiten estimar la probabilidad de ignición y la propagación del fuego, y por otro, en la evaluación de los recursos expuestos, en otras palabras, aquellos elementos del territorio susceptibles de resultar dañados.

En primer lugar, esta técnica se basa en la obtención de imágenes de la superficie terrestre mediante sensores instalados en plataformas espaciales, tal como lo explica Chuvieco (2008), el proceso se resume de la siguiente manera, el sol ilumina la superficie terrestre, y esta refleja parte de la energía en función del tipo de cubierta vegetal presente sobre ella. Luego, dicha energía es captada por los sensores satelitales y transmitida posteriormente a las estaciones receptoras en la Tierra, dicho proceso se observa en la Figura 7. Durante este proceso, la atmósfera desempeña un papel relevante, ya que puede dispersar o absorber parte de la señal original antes de que llegue al sensor.

Figura 7

Proceso de la teledetección.



Nota. Adaptado de Kain, 2024.

Todo ello, ha sido posible debido a los avances tecnológicos y el desarrollo que han experimentado, por un lado, las técnicas de tratamiento digital de imágenes, lo cual ha facilitado la obtención de datos significativos del territorio, y por otro, el acceso a la exhaustiva información digital proporcionada por sensores en su aspecto espacial, radiométrico, espectral y temporal (Chuvieco, 2008)

4.2. Principios físicos de la teledetección.


Como se ha mencionado en el apartado 4.1, la teledetección es una técnica que permite obtener información de objetos o fenómenos sin establecer ningún tipo de enlace físico directo con los mismos. Se centra en la adquisición, procesamiento y análisis de imágenes digitales, las cuales son capturadas principalmente por sensores que tienen instalados los satélites artificiales, los cuales, con el tiempo, la evolución de la teledetección ha sido notable, debido a la mejora continua en la calidad de los mismos (*Innovatione AgroFood Design*, 2024).

Los principios básicos de la teledetección satelital son compartidos por otros sistemas como la fotografía aérea, ya que todos dependen de la medición de la radiación electromagnética que emiten o reflejan los objetos en reacción a una fuente de energía, ya sea natural (la luz solar) o artificial (un radar) (*Innovatione AgroFood Design*, 2024). Existen dos tipos de teledetección, la pasiva, que capta la radiación natural proveniente del Sol y reflejada por los objetos de la superficie terrestre y, la teledetección activa que emplea su propia fuente de radiación artificial y mide la energía que los objetos devuelven.

La respuesta de cada objeto a esta radiación depende de variables externas (como las condiciones atmosféricas) y de sus características internas (composición y estructura fisicoquímica) (*Innovatione AgroFood Design*, 2024). La radiación electromagnética se transmite en forma de ondas, cuyas propiedades —longitud de onda y frecuencia— determinan su posición dentro del espectro electromagnético. Ambas variables están relacionadas de manera inversa, a mayor frecuencia, menor longitud de onda, y viceversa. El espectro electromagnético se muestra en la Figura 8, donde se aprecian las distintas longitudes de onda utilizadas en teledetección satelital.

Figura 8

Espectro electromagnético



Nota. Adaptado de Innovatione AgroFood Design, 2024

Cuando la radiación del Sol llega a la Tierra, puede comportarse de distintas maneras: una parte rebota (se refleja), otra parte la absorben los objetos y otra puede pasar a través de ellos.

Esto depende del material de cada objeto. Por ejemplo, un metal refleja mucha radiación, mientras que una tela oscura la absorbe más.

Gracias a estas diferencias, podemos distinguir unos materiales de otros.


Entonces, la mayoría de los sistemas de teledetección funcionan a partir de la energía reflejada o emitida por los objetos, en términos más precisos, la reflectancia que es el porcentaje de energía que un objeto refleja. Además de la reflectancia, otro de los valores que aportan a la identificación de un objeto, es la emisividad, que es la capacidad de un objeto para emitir energía en función de su temperatura.

La combinación de los valores de reflectancia y emisividad en distintas longitudes de onda conforma la firma espectral de un objeto, un patrón único que permite identificarlo mediante sensores remotos (*Innovatione AgroFood Design, 2024*).

Un ejemplo de firma espectral se observa en la Figura 9, donde se comparan las curvas típicas de vegetación, agua y suelo desnudo.

Figura 9

Firma espectral comparativa de vegetación, agua y suelo desnudo



Nota. Adaptado de Pham, B., 2018

4.3. Satélites y sensores.

Como se mencionó en el apartado 4.2, la teledetección es una medida dada en sí, por el mismo intercambio entre la radiación y los objetos de la superficie terrestre para estimar sus propiedades. Esta medida es captada por herramientas que se encuentran instaladas en los satélites artificiales, y llevan el nombre de sensores.


Los sensores son dispositivos capaces de registrar y almacenar información proveniente de la radiación electromagnética. Estos equipos miden electrónicamente la intensidad con la que los objetos de la superficie terrestre reflejan la radiación solar y, a partir de estos datos, generan imágenes que representan la zona observada. La calidad de dichas imágenes (tanto en términos espectrales como espaciales) está determinada por el nivel de resolución con el que opera el sensor (*Innovatione AgroFood Design*, 2024).

Por otro lado, en el marco de la teledetección, los productos satelitales son salidas de datos procesados a partir de las imágenes, derivados del procesamiento de la información captada por los sensores, los cuales permiten analizar fenómenos específicos como temperatura de la superficie, humedad del suelo o extensión de áreas afectadas por incendios. Entre estos productos se encuentran también los índices espectrales, que son combinaciones matemáticas de distintas bandas de una imagen satelital y que sintetizan información para el estudio de variables ambientales. Un ejemplo que puede observarse en la Figura 10 es el Índice de Vegetación de Diferencia

Normalizada (NDVI), que se obtiene a partir de la relación entre la reflectancia en el infrarrojo cercano y en el rojo. Este índice, con valores que oscilan entre -1 y 1, permite identificar la densidad y el vigor de la vegetación, ya que la biomasa verde refleja en gran medida la radiación en el infrarrojo cercano y absorbe la radiación en la región del espectro rojo. Esta propiedad hace de el NDVI una herramienta que sirve para monitorear la salud de los ecosistemas, detectar cambios espacio-temporales en la cobertura vegetal y evaluar la productividad agrícola, siendo ampliamente empleado en investigaciones ambientales y en la gestión de recursos naturales (Dirección de Educación Agraria et al., 2024; Numerosky, 2022).

Figura 10

Mapa NDVI de vegetación



Nota. Adaptado de Robinson et al. (2017)

Algunos de los satélites y sensores de teledetección que orbitan el planeta tierra son el VIIRS, MODIS, SMAP, Landsat, Sentinel y SAR, de las cuales sus imágenes satelitales brindadas por la NASA²¹ pueden ser visualizadas por medio de aplicaciones web, un ejemplo es la herramienta *Fire Information for Resource Management System* (FIRMS) o en español Sistema de información sobre incendios para la gestión de recursos, que distribuye datos de incendios activos a nivel mundial con una diferencia de 3 horas, 24 horas, 7 días, incluso datos de aquellos incendios ocurridos en un intervalo específico en el tiempo. Estos datos provienen del sensor MODIS (*Moderate Resolution Imaging Spectroradiometer* o en español espectrorradiómetro de imágenes de resolución moderada) a bordo de los satélites Aqua y Terra, y del sensor VIIRS (*Visible Infrared Imaging Radiometer Suite* o en español como el conjunto de radiómetros de imágenes infrarrojas visibles) a bordo del S-NPP y NOAA 20 (NASA, 2023). Una ventaja es que además de brindar datos de incendios pasados, FIRMS permite la descarga de los mismos y, también este permite la visualización de las áreas quemadas.

4.4. MODIS

En la apartado 4.2, se presentó el sensor VIIRS, que rota sobre la Tierra y se mencionó que el instrumento de observación remota de la NASA, que se encuentra a bordo de los satélites Terra y Aqua, es el sensor MODIS, el cual se encarga de capturar datos de cada 1-2 días, posee 36 bandas espectrales, lo que le permite capturar fenómenos como vegetación, nubosidad, incendios y cambios estacionales (*MODIS | Aqua Project Science*, s. f.).

De hecho, la herramienta FIRMS, la cual fue mencionada en la apartado 4.2, se desarrolló como una extensión del sistema MRR (*MODIS Rapid Response*) con el objetivo de satisfacer las necesidades de los usuarios interesados en la compatibilidad de los datos de las imágenes con Sistemas de Información Geográfica (SIG) o aquellos usuarios con poca o nula experiencia en teledetección que no podían manipular archivos de imágenes satelitales (Davies, 2009).


Dentro de lo que el MODIS produce hay varios productos especializados. Uno de ellos usado en estudios de vegetación es MYD13Q1 (*MODIS/Aqua Vegetation Indices 16-Day L3 Global 250m SIN Grid - LAADS DAAC*, s. f.). Este producto toma muchas imágenes cada 16 días y selecciona los píxeles de mejor calidad para representar cada lugar geográfico. Cada píxel representa unos 250 metros, lo cual permite cubrir extensiones grandes sin perder visibilidad de patrones importantes de vegetación.

²¹ NASA (*National Aeronautics and Space Administration*), organismo del gobierno de los Estados Unidos responsable del programa espacial civil y la investigación aeronáutica.

Además, este producto incluye dos índices clave de vegetación, el NDVI y el EVI. El NDVI como se mencionó en la apartado anterior, compara la reflectancia en el infrarrojo cercano con la del rojo, de modo que resalta cuánta vegetación verde hay y cuán saludable está, mientras que, el EVI se ajusta un poco mejor donde hay vegetación densa, y utiliza la banda azul para corregir efectos atmosféricos. Como se observa en la Figura 11 (*MODIS/Aqua Vegetation Indices 16-Day L3 Global 250m SIN Grid - LAADS DAAC*, s. f.).

Figura 11

Comparación espacial entre mapas NDVI y EVI generados a partir de datos MODIS



Nota. Adaptado de Xiong et al. (2023)

Estudios recientes han utilizado este producto, como es el ejemplo de Numerosky (2022) para estudiar las cubiertas vegetales en humedales del Delta del Paraná, ya que permite cubrir grandes regiones con una imagen, lo cual mejora la consistencia espacial de los análisis, además de brindar datos preprocesados (máscara de nubes, corrección atmosférica) que reducen la necesidad de hacer pasos extras de manera manual para su limpieza y corrección.

4.5. LANDSAT

Al igual que Aqua y Terra mencionados en la apartado 4.2, Landsat es una serie de satélites que observan la Tierra, gestionados por la NASA y el *United States Geological Survey (USGS)*²². Desde su primer lanzamiento en 1972 (*Landsat 1*), este programa ha proporcionado un archivo continuo de imágenes multispectrales que permiten estudiar cambios a lo largo del tiempo en la cubierta terrestre, los ecosistemas, uso del suelo, la atmósfera (*Landsat 1*, 2025), así como también para caracterizar inundaciones, drenaje, y cambios en las superficies de agua, como se señala en la investigación de Marchetti et al. (2020), donde para identificar los cursos de agua permanentes o superficies de agua existentes, tomaron una imagen de Landsat 5 de un momento donde el agua es baja, para revelar los cauces que siempre tienen agua y los cuerpos de agua de tamaño importante, como también, lo utilizaron para entender cómo se expande el agua cuando el nivel del río sube, capturando distintos momentos de inundaciones y clasificando cada imagen en dos categorías, “agua” o “no agua”, con el objetivo de observar cómo el agua progresa sobre el terreno.

Como se mencionó anteriormente, Landsat es una serie de satélites, el cual se ha desarrollado a lo largo de varias generaciones, cada una mejorando ciertos aspectos técnicos como la nitidez de las imágenes, la precisión espectral, la calidad radiométrica y la fiabilidad geométrica. Por ejemplo, Landsat 8, cuenta con los instrumentos OLI (*Operational Land Imager*) y TIRS (*Thermal Infrared Sensor*), que proporcionan imágenes de 30 metros de resolución espacial en la mayoría de sus bandas multispectrales, una banda pancromática más fina (15 metros) que permite extraer más detalles, y bandas térmicas (calor) que ayudan a detectar variaciones de temperatura de la superficie (Landsat NASA, 2023).

Además, la resolución espectral de Landsat permite trabajar con distintas bandas que capturan porciones específicas del espectro electromagnético, cada una con una función particular para el análisis ambiental. Entre ellas se destacan: B2 (Azul), útil para detectar cuerpos de agua y zonas despejadas; B3 (Verde) y B4 (Rojo), fundamentales para observar el vigor y la salud de la vegetación; B5 (Infrarrojo cercano – NIR), altamente sensible a la biomasa y al estrés vegetal; y B6 y B7 (Infrarrojo de onda corta – SWIR 1 y SWIR 2), claves para detectar humedad del suelo y de la vegetación, así como cambios producidos por incendios. Estas bandas permiten identificar características


²² Agencia científica del gobierno estadounidense dedicada al estudio del paisaje, los recursos naturales y los riesgos naturales.

esenciales del entorno terrestre, como la presencia de vegetación, la humedad del suelo, los cuerpos de agua y las alteraciones generadas por eventos térmicos.

Lo anteriormente mencionado puede observarse en la Figura 12.

Figura 12

Resoluciones del Landsat 8



Nota. Adaptado de *Landsat NASA*, 2023

Otra ventaja de Landsat es su escala temporal, tiene un período de revisita de aproximadamente 16 días, lo que significa que cada punto de la Tierra es captado con frecuencia, siempre que no haya nubes o bloqueos atmosféricos (Landsat NASA, 2023). Esa frecuencia permite construir series temporales de observaciones, comparar cómo cambian los espacios de un año al otro, detectar crecientes, sequías o efectos de uso del suelo.

Además, los productos de Landsat tienen varios niveles de procesamiento (Level-1, Level-2, etc.) que incluyen correcciones geométricas, corrección radiométrica, corrección topográfica, y el uso de modelos digitales de elevación para eliminar distorsiones debidas al relieve del terreno. Esto permite que las imágenes sean precisas y útiles para superponer mapas, hacer mediciones de distancia o área.

Es por ello que, Landsat juega un papel fundamental en estudios ambientales regionales, ofreciendo una combinación equilibrada de resolución espacial, ya que, al tener una resolución de 30 metros, es factible en un punto intermedio para estudios regionales sin tener que usar imágenes de alta resolución, que suelen ser costosas y voluminosas (Marchetti et al., 2020). Además ofrece cobertura temporal y continuidad

histórica, lo que lo hace adecuado para monitorear fenómenos que cambian con el tiempo, como inundaciones, alteraciones en la vegetación y usos del suelo.

4.6 Teledetección y su aplicación en la predicción de incendios

La teledetección se ha consolidado en las últimas décadas como una herramienta clave en el estudio y monitoreo de los incendios forestales. Su capacidad para recopilar datos en tiempo casi real, de manera sistemática y en grandes extensiones de terreno, ha revolucionado la forma en que se comprende y gestiona este fenómeno. A través del uso de sensores montados en satélites, es posible detectar variaciones en la vegetación, cambios térmicos, niveles de humedad y otros factores asociados tanto a la ocurrencia como a la propagación del fuego.

Una de las principales ventajas de la teledetección radica en su capacidad de identificar zonas con alto riesgo de ignición antes de que se produzca el incendio. Esto es posible mediante el análisis de indicadores como el Índice de Vegetación de Diferencia Normalizada (NDVI), que permite estimar la cantidad y el estado del combustible vegetal disponible (Dirección de Educación Agraria et al., 2024; Numerosky, 2022). Asimismo, la información térmica proveniente de sensores infrarrojos permite detectar anomalías de temperatura que pueden anticipar la presencia de focos calientes o combustión latente. Aun así, aunque es muy útil para anticipar riesgos y monitorear áreas extensas, no siempre garantiza detecciones inmediatas ni de alta precisión en todos los escenarios.

En esta línea, es importante destacar el estudio de Yang et al. (2021), quienes aplicaron imágenes satelitales como insumo para el desarrollo de un modelo de predicción de incendios forestales. En su investigación, emplearon datos del satélite Landsat 7, procesados a través de la plataforma Google Earth Engine, como entradas para una red neuronal. Estas imágenes aportaron la información espacial y multiespectral necesaria para caracterizar las condiciones de la superficie terrestre. Al mismo tiempo, incorporaron los datos del sistema FIRMS, que se basa en el sensor MODIS y específicamente en su producto MYD13Q1, para obtener las etiquetas de validación en terreno, clasificando las áreas como “fuego” o “no fuego”. De esta manera, combinaron distintas fuentes de teledetección con el objetivo de generar predicciones mensuales precisas sobre la ocurrencia de incendios.

Este enfoque resalta cómo la integración de diferentes sensores y satélites (como Landsat y MODIS) permite no solo disponer de información continua y detallada del territorio, sino también utilizar los datos que nos brindan sus imágenes para entrenar modelos de inteligencia artificial que pueden anticipar fenómenos complejos. En particular, Yang et al. (2021) remarcan que el uso de la teledetección constituye una

ventaja frente a los sistemas tradicionales de monitoreo, que dependen de redes meteorológicas en tierra. Por ejemplo, el Sistema Canadiense utiliza más de 750 estaciones meteorológicas distribuidas a lo largo de su territorio; sin embargo, este método requiere una calibración constante para adaptarse a distintos entornos y no logra cubrir de manera homogénea grandes extensiones.

Por otro lado, en el estudio de Çolak, E. y Sunar, F.(2020) que utilizaron máquinas de vectores de soporte (SVM) para la clasificación de imágenes satelitales en su área de estudio, puesto que, el coste de medir convencionalmente un área es costoso, requiere de mucho tiempo y esas mediciones son imprecisas para la implementación a gran escala; todo ello para una aplicación que evalúa el riesgo de incendios forestales.

Frente a ello, la teledetección ofrece una cobertura más amplia, uniforme y consistente, lo que la convierte en una herramienta más eficiente para abordar problemáticas ambientales de gran alcance.

CAPÍTULO 5. PROPUESTA METODOLÓGICA PARA LA DETECCIÓN TEMPRANA DE FOCOS ÍGNEOS EN HUMEDALES

En este capítulo se describe la metodología empleada para la predicción de focos ígneos en el Delta del Paraná mediante técnicas de aprendizaje automático. Se detallan las variables y los datos utilizados, con énfasis en las imágenes satelitales multiespectrales de Landsat 8 presentado en el apartado 4.5. Además, se explica el proceso de selección de características relevantes, el filtrado y la preparación de los datos, así como la comparación y evaluación de diferentes modelos de inteligencia artificial. También, se analizan las métricas de desempeño presentadas en el apartado 2.4 y se discuten las limitaciones y consideraciones metodológicas que condicionan los resultados obtenidos. Finalmente se propone el modelo Schroeder para la detección temprana de focos ígneos en los humedales del Delta de Paraná.

5.1. Explicación de las variables y datos utilizados.

La predicción de focos ígneos mediante técnicas de aprendizaje automático requiere una base de datos sólida, consistente y representativa del fenómeno a estudiar. En este contexto, uno de los insumos más relevantes son las imágenes satelitales, especialmente aquellas que permiten observar cambios en la superficie terrestre con suficiente nivel de detalle tanto espacial como espectral. Para este tipo de aplicaciones, una de las fuentes utilizadas es la misión Landsat 8 como se presentó en la apartado 4.5, debido a su equilibrio entre resolución, cobertura temporal y accesibilidad.

Esta misión, operada en conjunto por la NASA (apartado 4.3) y el USGS (apartado 4.5), proporciona imágenes multiespectrales de alta calidad a través de sus sensores OLI (*Operational Land Imager*) y TIRS (*Thermal Infrared Sensor*). Una de sus principales ventajas radica en su resolución espacial de 30 metros en la mayoría de sus bandas. Esto significa que cada píxel de la imagen representa un área de 30x30 metros en el terreno, lo cual permite distinguir con mayor precisión detalles dentro del paisaje, como pequeños cuerpos de agua, sectores parcialmente quemados, o incluso diferencias sutiles en el tipo de cobertura vegetal. (NASA, s.f.)

Esta resolución es significativamente superior a la de otros sensores como MODIS (que como se explica en el apartado 4.4 trabaja con resoluciones de 250 metros), por lo que Landsat resulta más adecuado para estudios localizados como los del Delta del Paraná, donde la dinámica del fuego puede depender de microambientes muy específicos como se menciona en el capítulo 1.2. Además, su resolución espectral

permite trabajar con bandas que capturan distintas porciones del espectro electromagnético, como se indica en el capítulo 4.5.

El período temporal sugerido abarca desde principios de 2020 hasta fines de 2022 como se mencionó en el apartado 1.3, de modo de cubrir al menos tres ciclos anuales completos, incluyendo épocas de mayor riesgo estacional. Las imágenes seleccionadas son recortadas a una región que abarca el Delta del Paraná, como se observó en el capítulo 1, asegurando la concentración del análisis en la zona de interés.

Además, se contempla la posibilidad de aplicar un preprocesamiento que incluya el enmascaramiento de nubes, la normalización de valores de reflectancia y la conversión a un formato uniforme que facilite su uso posterior en modelos de aprendizaje automático. Cada imagen puede ser exportada con su fecha de adquisición en el nombre del archivo (formato YYYY/MM/DD), y con dimensiones ajustadas (por ejemplo, 256x256 píxeles), lo cual facilita su incorporación en arquitecturas de *Deep Learning* como se señala en el capítulo 2.3.

Este conjunto de imágenes multiespectrales, combinado con información temporal, constituye una base sólida para entrenar modelos capaces de detectar patrones vinculados a la ocurrencia de incendios forestales en la región.

5.2. Selección y descarte de características

En el proceso de análisis mediante imágenes satelitales, una etapa crítica es la selección adecuada de características (bandas espectrales, índices y metadatos) que serán utilizadas en el modelado, visualización o entrenamiento de algoritmos predictivos. Esta elección influye directamente en la precisión del análisis y la eficiencia computacional, especialmente al trabajar con grandes volúmenes de datos provenientes de sensores como Landsat-8.

Para este estudio, se utilizó la plataforma *Google Earth Engine* (GEE) definida en el capítulo 2.2, la cual proporciona imágenes multiespectrales de dicho satélite, con una resolución espacial de 30 metros y una frecuencia de adquisición de 16 días que permite un monitoreo constante del área de interés. Se filtraron las imágenes correspondientes al período comprendido entre el 1 de enero de 2020 y el 12 de diciembre de 2022, asegurando además que cubrieran la región definida por un rectángulo geográfico delimitado por las coordenadas [-61.5, -32.7, -60.3, -32.2].

Las bandas espectrales seleccionadas para el análisis fueron:

- B2 (Azul, 0.45-0.51 μm)
- B3 (Verde, 0.53-0.59 μm)
- B4 (Rojo, 0.64-0.67 μm)

- B5 (Infrarrojo Cercano, 0.85-0.88 μm)
- B6 (Infrarrojo de Onda Corta 1, 1.57-1.65 μm) y B7 (Infrarrojo de Onda

Corta 2, 2.11-2.29 μm)

Se aplicó un preprocesamiento consistente en la reproyección de las bandas para homogeneizar la resolución espacial (utilizando la banda B2 como referencia), y el recorte de las imágenes a la región de interés, limitando así el procesamiento a la zona geográfica relevante.

Todas estas operaciones fueron realizadas mediante scripts en Google Earth Engine, empleando su capacidad para procesar grandes volúmenes de datos satelitales de forma remota y eficiente, sin requerir hardware local de alta potencia. El análisis se llevó a cabo en computadoras equipadas con procesadores *Intel Core i3* y *Amd Ryzen 3*, bajo sistemas operativos *Windows* y *Linux*, lo cual demuestra la accesibilidad y viabilidad de estos métodos.

Luego de exportar las imágenes satelitales a Drive se compararon las mismas con la plataforma FIRMS para determinar su fidelidad. Como se observa en la Figura 13.

Figura 13

FIRMS.





Figura 14

Script utilizado para la exportación de imágenes satelitales de Landsat.



5.3. Comparación de modelos de IA y evaluación de su rendimiento

En este capítulo se presentan estudios en los cuales se realiza un análisis comparativo entre diversos algoritmos de aprendizaje de máquina en diversas aplicaciones de la analítica de datos, para determinar cuál red ofrece un mayor desempeño en la identificación de focos ígneos.


Se descartaron aquellos modelos cuya área geográfica discierne de nuestro objeto de estudio, también aquellos donde la documentación era escasa y finalmente se optó por la elección del modelo de Almeida Pereira et al. (2021) que utiliza imágenes satelitales del *Landsat* 8 mencionado en el apartado 4.5 y métodos de aprendizaje profundo presentados en la apartado 2.3. Este trabaja con un conjunto de datos de imágenes procesadas en parches de 256x256 al disponer de 11 regiones corresponden a los distintos continentes/subcontinentes se entrenó con la información a disposición.

Posteriormente se evaluó diferentes arquitecturas de U-Net entre las cuales se destacó aquella que contiene 64 filtros, 2 convoluciones por bloque y 10 canales de entrada, de los modelos de Kumar-Roy y Schroeder presentados en la apartado 3.3,

aunque ambas arquitecturas muestran un rendimiento bajo en términos absolutos, el modelo de Schroeder supera al de Kumar-Roy en precisión media (0.048 vs. 0.020), lo que indica que fue más efectivo en identificar correctamente los píxeles correspondientes a focos ígneos. Además, Schroeder presenta una menor dispersión en sus resultados (std de 0.125 frente a 0.141), lo que sugiere una mayor estabilidad y consistencia en las predicciones. A continuación se observan los resultados obtenidos.

Figura 15


Gráficos y resultados del modelo de Schroeder



Nota. Las gráficas muestran cómo se comportan las métricas del modelo presentado, donde el azul representa la Precisión, el verde indica Recall, el rojo F1-Score y naranja Jaccard Score. El eje X indica el valor de cada métrica y el eje Y la frecuencia de esos valores. Se observa que Precisión, Recall y F1-Score son bajos, mientras que el Jaccard Score es estable, lo que sugiere que el modelo acierta en parte pero aún tiene margen de mejora.

Figura 16


Gráficos y resultados de Kumar-Roy



Nota. En comparación con la primera imagen, esta muestra un comportamiento aún más concentrado en valores muy bajos para Precisión, Recall y F1-Score, lo que indica menor capacidad del modelo de Kumar-Roy para identificar correctamente los casos positivos. Sin embargo, el Jaccard Score sigue siendo estable entre las métricas, mostrando coherencia general en las predicciones.

Figura 17


Gráficos de detección de fuego Schroeder



Nota. La gráfica muestra el porcentaje de detección de fuego por imagen. El eje X corresponde al número de imagen y el eje Y al porcentaje de fuego detectado. Presenta picos aislados donde el modelo responde ante la presencia de fuego, demostrando el potencial para reconocer patrones reales.

Figura 18


Gráficos de detección de fuego Kumar-Roy



Nota. En comparación con la gráfica anterior, se observan valores más bajos, identificando fuego con menor intensidad.

Figura 19


Píxeles de fuego vs porcentaje Schroeder.



Nota. La gráfica muestra la relación entre el número de píxeles de fuego (eje X) y el porcentaje de fuego detectado (eje Y). Se observa una correlación positiva: a medida que aumenta el número de píxeles detectados, también crece el porcentaje de fuego.

Figura 20

Píxeles de fuego vs porcentaje Kumar–Roy



Nota. En comparación con la imagen anterior se ven menor concentración de puntos lo que indica que el modelo de Schroeder responde de manera eficiente.

Como se observa desde la figura 16 hasta la 20, ambos modelos implementan y utilizan métricas incluyendo precisión (P), *recall* (R) , *F-Score* y para su evaluación se ejecutaron los scripts en *Google Colab*, donde se probaron 100 imágenes de la región del Delta de Paraná, que corresponden a eventos de incendios forestales confirmados, con datos disponibles que abarcan el período comprendido entre el 1 de enero de 2020 y el 12 de diciembre de 2022. Este rango temporal incluye diferentes estaciones climáticas, lo que asegura la representatividad de las condiciones ambientales variables a lo largo del año. Cabe destacar que durante agosto de 2020 se registró una alta incidencia de incendios, lo que permitió al modelo aprender patrones asociados a períodos de mayor

riesgo y propagación del fuego. La elección de estas imágenes responde a un balance entre la disponibilidad de datos y la capacidad computacional para realizar una evaluación representativa, considerándose suficientemente robusta para validar la performance de los modelos.

El script de evaluación (`evaluate_v1.py`) calcula las métricas utilizando una matriz de confusión ambas presentadas en el apartado 2.4 con verdaderos positivos (tp), falsos positivos (fp), falsos negativos (fn) y verdaderos negativos (tn):

- Precisión (P): $tp/(tp + fp)$ - mide la proporción de píxeles correctamente identificados como fuego.
- Recall (R): $tp/(tp + fn)$ - mide la proporción de píxeles de fuego detectados correctamente.
- IoU: $tp/(tp+fp+fn)$ - Índice de Jaccard que mide la similitud entre predicción y verdad de campo.
- F-score: $(2 * P * R)/(P + R)$ - media armónica entre precisión y recall.

. A continuación, en la *Tabla 3* se presentan los valores promedio obtenidos por los modelos:

Tabla 3 - Resumen comparativo de métricas

	Precisión (P)	Recall (R)	IoU	F-score
Modelo <i>Schroeder</i>	0.048	<0.001	0.450	<0.001
Modelo <i>Kumar-Roy</i>	0.020	0.000	0.450	0.000

Cabe señalar que los valores de *recall* y *F-score*, explicados en la apartado 2.4, fueron cercanos o iguales a cero debido a un desbalance de clases en las imágenes evaluadas (por ejemplo, muy baja presencia de píxeles etiquetados como incendios). No obstante, el valor del índice de *Jaccard* ($IoU \approx 0.45$) sugiere cierta capacidad de localización espacial en las predicciones, lo que indica potencial para mejoras mediante ajustes finos y re-entrenamiento.

Al analizar en detalle las métricas de rendimiento en la *Tabla 3*, se observa que los valores de Recall y F-score para la detección de focos ígneos son significativamente bajos (cercanos a cero en ambos modelos), a pesar de que la métrica IoU (superposición

espacial) mostró un resultado razonable. Esta limitación se atribuye directamente al severo desbalance de clases presente en los datos satelitales, donde la clase 'Fuego' constituye un porcentaje ínfimo de los píxeles totales.

Para mitigar este problema, la práctica recomendada en el campo del Deep Learning aplicado a la segmentación de datos desbalanceados es implementar modificaciones a la función de pérdida del modelo. Específicamente, se sugiere el uso de una Función de Pérdida Ponderada (Weighted Binary Cross-Entropy) o Focal Loss, que penalizan de forma desproporcionada los incendios no detectados, obligando al modelo a ser menos conservador en su clasificación.

Si bien esta implementación y el re-entrenamiento del modelo son la acción técnica correcta para validar la propuesta algorítmica, el alcance de esta tesina se centra en la propuesta teórica, la adaptación metodológica y el análisis crítico de resultados presentados en este capítulo.

Los modelos Kumar-Roy y Schroeder, utilizaron las librerías *TensorFlow*, *Keras*, *Numpy*, *OpenCV* (cv2), *scikit-learn*, *pandas*, *geopandas*, *rasterio* (ver anexo A) y las imágenes fueron almacenadas en formato TIFF. Por otro lado, los pesos fueron descargados desde el repositorio utilizando los scripts brindados por el mismo y previamente entrenados, siendo estos esenciales para la inferencia y el aprendizaje.

La arquitectura U-Net presentada en el apartado 3.3 utilizada en estos modelos de codificador con conexiones de salto, permiten capturar información contextual como también información precisa. Cada bloque codificador de la arquitectura consta de dos capas convolucionales normalización por bloque después de cada convolución, función de activación ReLu y agrupación máxima (2x2) para las dimensiones espaciales y la estructura del bloque decodificador consta de una convolución transpuesta concatenación de las características, dos capas convolucionales consecutivas, normalización por lotes después de cada convolución y función de activación de ReLU.

Una vez obtenidas las métricas correspondientes, se evaluaron las salidas de las imágenes satelitales con el FIRMS a modo de comparar la fidelidad del mismo.

CONCLUSIÓN

En esta tesina se abordó el análisis de modelos basados en *Deep Learning* para la detección temprana de focos ígneos en los humedales del Delta de Paraná, una región de vital importancia ecológica y social del país como se mencionó en el capítulo 1.1

A partir del estudio de antecedentes, el análisis de datos satelitales y la aplicación de redes neuronales convolucionales capítulo 2.3.1 , se comprobó el potencial de la inteligencia artificial como herramienta efectiva para anticipar eventos de fuego en entornos complejos.

En este sentido, los modelos basados en la arquitectura U-Net han demostrado mejor desempeño frente a otras alternativas evaluadas, evidenciando su capacidad para identificar áreas afectadas con precisión y coherencia espacial. Para la región se optó por proponer el modelo de Schroeder debido a la eficacia en sus resultados.

Este estudio aspira a contribuir a la sociedad remarcando la necesidad de continuar explorando enfoques basados en inteligencia artificial, dada su flexibilidad, escalabilidad y adaptabilidad a distintas condiciones geográficas. Asimismo, es importante contar con bases de datos abiertas, entornos de desarrollo colaborativos y herramientas de cómputo accesibles, para posibilitar investigaciones incluso con recursos limitados.

En un contexto donde la frecuencia de incendios aumenta, resulta fundamental que los organismos ambientales, posean tecnologías que les permitan actuar de manera preventiva. Si bien, esta investigación se enmarca en un estudio teórico, proporciona una ruta clara para el desarrollo de soluciones prácticas, haciendo uso de las tecnologías emergentes.

Posibles líneas de investigación

En base a los hallazgos de este trabajo, se identifican las siguientes líneas de investigación:

1. Se propone comparar imágenes multiespectrales con la información proveniente de FIRMS con el objetivo de entrenar y validar los sistemas de detección de incendios, sentando las bases para una futura implementación de mecanismos de alerta temprana.
2. Se sugiere explorar modelos más complejos, tales como Vision Transformers (ViT) o arquitecturas híbridas CNN+LSTM, que podrían ofrecer mejoras en la precisión y la capacidad de generalización al emplear un conjunto más amplio y diverso de imágenes.
3. Se propone diseñar una interfaz web o una aplicación móvil que permita visualizar y analizar los resultados obtenidos, facilitando la toma de decisiones y la gestión territorial participativa basada en la evidencia.

ANEXOS

A - Glosario de términos

- Formato TIFF (Tagged Image File Format): es un tipo de archivo de imagen que permite almacenar información en alta calidad y múltiples bandas espectrales. Es utilizado en aplicaciones de teledetección y sistemas de información geográfica (SIG) debido a su capacidad para conservar metadatos y datos geoespaciales.
- GeoPandas: extiende las funcionalidades de Pandas al ámbito geoespacial. Permite trabajar con datos geográficos en formatos como shapefiles y GeoJSON, ofreciendo métodos para la representación y análisis en geometrías.
- Keras: interfaz de alto nivel para el desarrollo de redes neuronales, que funciona sobre TensorFlow. Su principal característica es la facilidad para construir, entrenar y evaluar modelos de manera estructurada y eficiente.
- NumPy: librería para el cálculo numérico en Python. Permite trabajar con arreglos y matrices multidimensionales, además de ofrecer un conjunto de funciones matemáticas avanzadas para el manejo de grandes volúmenes de datos.
- OpenCV (cv2): es una biblioteca especializada en procesamiento de imágenes. Ofrece múltiples funciones para la lectura, transformación y análisis de imágenes y videos, incluyendo operaciones como filtrado, segmentación y detección de bordes.
- Pandas: es una herramienta destinada al análisis y manipulación de datos estructurados. Permite gestionar información en formato tabular, lo que facilita la limpieza, el filtrado y la organización de los datos.
- Rasterio es una librería diseñada para el manejo de datos raster, comúnmente utilizados en el análisis geoespacial y de teledetección. Facilita la lectura, escritura y manipulación de imágenes satelitales y mapas, conservando su información georreferenciada.
- Scikit-learn: es una biblioteca enfocada en el aprendizaje automático. Proporciona herramientas para realizar tareas de clasificación, regresión, agrupamiento y reducción de dimensionalidad, además de funciones para la evaluación del rendimiento de los modelos.
- Tensor Flow: es una biblioteca de código abierto desarrollada por Google, orientada al desarrollo y entrenamiento de modelos de aprendizaje automático y redes neuronales profundas.

BIBLIOGRAFÍA

Libros

Babu, K. S. (2019). *Developing Forest Fire Danger index using geo spatial techniques*. International Institute of Information Technology, Hyderabad.

Chuvieco Salinero, E. (2008). *Teledetección ambiental*. Grupo Planeta.

Deligiannidis, L., Dimitoglou, G., & Arabnia, H. (2024). *Artificial intelligence: Machine Learning, Convolutional Neural Networks and Large Language Models*. Walter de Gruyter GmbH & Co KG.

Géron, A. (2019). *Hands-on Machine Learning with Scikit-Learn, Keras, and TensorFlow*. Ed. O'Reilly Media, Inc.

Lawson B., Armitage O. "Weather Guide for the Canadian forest fire danger rating system". Natural Resources Canada, Canadian Forest Service, Northern Forestry Centre. Edmonton, Canadá. 2008.

McArthur, A. G. (1966). *Weather and grassland fire behaviour*. Forestry and Timber Bureau, Department of national Development, Commonwealth of Australia.

McArthur, A. G. (1967). *Fire behaviour in eucalypt forests*. Leaflet N° 107. Forest Research Institute, Forestry and Timber Bureau, Canberra.

Papers

Almeida Pereira, G. H., Fusioka, A. M., Nassu, B. T., & Minetto, R. (2021). Active fire detection in Landsat-8 imagery: A large-scale dataset and a deep-learning study. *ISPRS Journal of Photogrammetry and Remote Sensing: Official Publication of the International Society for Photogrammetry and Remote Sensing (ISPRS)*, 178, 171–186. <https://doi.org/10.1016/j.isprsjprs.2021.06.002>

Alzubaidi, L., Zhang, J., Humaidi, A. J., Al-Dujaili, A., Duan, Y., Al-Shamma, O., Santamaría, J., Fadhel, M. A., Al-Amidie, M., & Farhan, L. (2021). Review of deep learning: concepts, CNN architectures, challenges, applications, future directions. *Journal of Big Data*, 8(1). <https://doi.org/10.1186/s40537-021-00444-8>

- Balas, V. E., Kumar, R., & Srivastava, R. (Eds.). (2020). *Recent trends and advances in artificial intelligence and Internet of Things*. Springer International Publishing. <https://doi.org/10.1007/978-3-030-32644-9>
- Capasso, V. (2023). Demandas socioambientales y visualidad en América Latina el caso de Agitazo por los humedales (Argentina). *Humanidades revista de la Universidad de Montevideo*, 13. <https://doi.org/10.25185/13.6>
- Çolak, E. y Sunar, F. (2020). Evaluation of forest fire risk in the Mediterranean Turkish forests: A case study of Menderes región, Izmir. *Revista Internacional de Dis*, 101479. <https://doi.org/10.1016/j.ijdr.2020.101479>
- Davies, D., Ilavajhala, S., Min Minnie Wong & Justice, C. (2009). *Fire Information for Resource Management System: Archiving and Distributing MODIS Active Fire Data*. *IEEE Transactions on Geoscience and Remote Sensing*, 47(1), 72-79. <https://doi.org/10.1109/tgrs.2008.2002076>
- Dowdy, A. J., Mills, G. A., Finkele, K. & de Groot, W. (2010). *Index sensitivity analysis applied to the Canadian Forest Fire Weather Index and the McArthur Forest Fire Danger Index*. *Meteorological Applications*, 17(3), 298-312. <https://doi.org/10.1002/met.170>
- Finlay, S. E., Moffat, A., Gazzard, R., Baker, D. & Murray, V. (2012). *Health Impacts of Wildfires*. *PLoS Currents*. <https://api.semanticscholar.org/CorpusID:13266139>
- Londoño, A. S. S., López, A. F. J., Franco, M. C., & Roa, A. A. C. (2017). Clasificación y mapeo automático de coberturas del suelo en imágenes satelitales utilizando Redes Neuronales Convolucionales. *Orinoquia*, 21(1 Sup), 64-75. <https://doi.org/10.22579/20112629.432>
- Marchetti, Z., Ramonell, C., Brumnich, F., Alberdi, R., & Kandus, P. (2020). Vegetation and hydrogeomorphic features of a large lowland river: NDVI patterns summarizing fluvial dynamics and supporting interpretations of ecological patterns. *Earth Surface Processes And Landforms*, 45(3), 694-706. <https://doi.org/10.1002/esp.4766>

- Montico , S., Di Leo, N. C., & Berardi, J. A. (2023). Sequía, bajante y efectos de los incendios en suelos del delta del Paraná, Argentina. *Cuadernos Del CURIHAM*, e199. <https://doi.org/10.35305/curiham.vi.199>
- Pazmiño, D. (2019). *Peligro de incendios forestales asociado a factores climáticos en Ecuador*. FIGEMPA: Investigación y Desarrollo, 1(1), 10-18. <https://doi.org/10.29166/revfig.v1i1.1800>
- Pereira, A. H. de A., Fusioka, A. M., Nassu, B. T., & Minetto, R. (2021). Active fire detection in Landsat-8 imagery: A large-scale dataset and a deep-learning study. *ISPRS Journal of Photogrammetry and Remote Sensing*, 178, 171-186. <https://doi.org/10.1016/j.isprsjprs.2021.06.002>
- Robinson, N., Allred, B., Jones, M., Moreno, A., Kimball, J., Naugle, D., Erickson, T., & Richardson, A. (2017). A Dynamic Landsat Derived Normalized Difference Vegetation Index (NDVI) Product for the Conterminous United States. *Remote Sensing*, 9(8), 863. <https://doi.org/10.3390/rs9080863>
- Shivaprasad, K., Sowmya, Danakumara, T., Gowda, M. M., Kumar, R., Kumar, S. D., & Kumar, B. S. (2025). Forest fire and its impact on forest biodiversity. En *Elsevier eBooks* (pp. 37-53). <https://doi.org/10.1016/b978-0-443-31406-3.00004-7>
- Straccia, P. H., Monkes, J. I., & Isla Raffaele, M. L. (2021). Las políticas de escala en las disputas ambientales: el caso de los humedales en Argentina. *Huellas*, 25, 1; 5. <https://ri.conicet.gov.ar/handle/11336/147915>
- Zhang, G., Wang, M. & Liu, K. (2019). *Forest Fire Susceptibility Modeling Using a Convolutional Neural Network for Yunnan Province of China*. International Journal of Disaster Risk Science, 10(3), 386-403. <https://doi.org/10.1007/s13753-019-00233-1>
- Xiong, C., Ma, H., Liang, S., He, T., Zhang, Y., Zhang, G., & Xu, J. (2023). Improved global 250 m 8-day NDVI and EVI products from 2000–2021 using the LSTM model. *Scientific Data*, 10(1). <https://doi.org/10.1038/s41597-023-02695-x>
- Yang, S., Lupascu, M. & Meel, K. S. (2021). *Predicting Forest Fire Using Remote Sensing Data And Machine Learning*. Proceedings of the AAAI Conference on Artificial Intelligence, 35(17), 14983-14990. <https://doi.org/10.1609/aaai.v35i17.17758>

Otros documentos (Tesis, informes técnicos y sitios web)

- Ali, M. K., Salathé, T., & Küpper, C. (2018). *Ramsar y patrimonio mundial: medio siglo de colaboración para la conservación de los humedales*. Revista del Patrimonio Mundial, (89), 6–17. https://unesdoc.unesco.org/ark:/48223/pf0000366362_spa
- Cardenas, M. E., Vázquez, J. C., Castillo, J. J., & Villena Ruiz, S. (2013, June). Sistema de predicción de incendios forestales basado en el índice FWI para la provincia de Córdoba. *XV Workshop de Investigadores en Ciencias de la Computación*.
- Castillo Sarasty, J. E. (2021). *Prototipo web para predicción y detección de incendios forestales en los Cerros Orientales de Bogotá, mediante una red de sensores e inteligencia artificial* [Tesis de pregrado, Universidad Piloto de Colombia].
- Convención de Ramsar sobre los humedales. (2018, Julio). *Ampliar la conservación, el uso racional y la restauración de los humedales para lograr los Objetivos de Desarrollo Sostenible*. Extraído de https://www.ramsar.org/sites/default/files/documents/library/wetlands_sdgs_s.pdf
- Copeland, & B.J. (2025, July 30). *History of artificial intelligence | Dates, Advances, Alan Turing, ELIZA, & Facts*. Encyclopedia Britannica. <https://www.britannica.com/science/historyof-artificial-intelligence>
- Deeming, J. E., Burgan, R. E. & Cohen, J. D. (1977). *The National Fire-Danger Rating System - 1978* (INT-GTR-39). United States Department of Agriculture, Forest Service, Intermountain Forest and Range Experiment Station. https://www.fs.usda.gov/rm/pubs_series/int/gtr/int_gtr039.pdf
- Dentoni, M. del C., & Muñoz, M. M. (2012). *Informe Técnico No 1. Sistemas de Evaluación de Peligro de Incendios*. https://www.argentina.gob.ar/sites/default/files/ambiente-itn1_pnmf.pdf
- Dentoni, M. del C., & Muñoz, M. M. (2013). *Glosario de términos relacionados con el manejo del fuego* (Informe Técnico N° 8). Secretaría de Ambiente y Desarrollo Sustentable, Plan Nacional de Manejo del Fuego. https://www.argentina.gob.ar/sites/default/files/ambiente-itn8_glosario-1.pdf

Dirección de Educación Agraria, Dirección Provincial de Educación Técnico Profesional, & Subsecretaría de Educación, DGCyE. (2024, 18 junio). *Explorando la vegetación desde el espacio. Continuemos Estudiando.* <https://continuemosestudiando.abc.gob.ar/contenido/explorando-la-vegetacion-desde-el-espacio/>

Faros de conservación. (2022, 5 abril). Argentina.gob.ar. https://www.argentina.gob.ar/sites/default/files/faros_de_conservacion-descripcion_e_informacion_general.pdf

Fundación Ambiente y Recursos Naturales (FARN). (2021). *Informe sobre incendios en el Delta del Paraná 2021.* [Informe]. https://farn.org.ar/wp-content/uploads/2021/08/INFORME-DELTA-INCENDIOS-2021_compressed.pdf

Giacosa B. R., Rodríguez J. M., Elberg G., Biasatti R., Algarañaz N., Britos M. H. & Guardaparques del PN Predelta. (2016) *Ficha Informativa de los Humedales de Ramsar (FIR).*

Google Earth Engine. (s.f.). *Google Earth Engine: A planetary-scale platform for Earth science data & analysis.* Recuperado de <https://earthengine.google.com/>

Innovatione AgroFood Design. (2024, 15 marzo). *Fundamentos y principios de teledetección - Innovatione. Innovatione.* <https://innovatione.eu/2019/06/24/fundamentos-de-teledeteccion/#:~:text=Los%20fundamentos%20f%C3%ADsicos%20b%C3%A1sicos%20de%20la%20teledetecci%C3%B3n%20espacial,de%20radiaci%C3%B3n%20natural%20%28luz%20solar%29%20o%20artificial%20%28radar%29.>

Kain, T. (2024, 22 septiembre). *Conceptos básicos de teledetección y SIG.* Sigma Earth. <https://sigmaearth.com/es/basics-of-remote-sensing-and-gis/>

Kandus, P., Quintana, R. D., Minotti, P. G., Oddi, J. del P., Baigún, C., González Trilla, G., & Ceballos, D. (s.f.). Ecosistemas de humedal y una perspectiva hidrogeomórfica como marco para la valoración ecológica de sus bienes y servicios. En Libro de servicios ecosistémicos (Capítulo 11). *Universidad de Buenos Aires.*

https://ubatic.agro.uba.ar/sites/default/files/files/libro_serv_ecosist/pdf/Capitulo_11.pdf

Landsat 1. (2025, 11 julio). USGS. <https://www.usgs.gov/landsat-missions/landsat-1>

Landsat NASA. (2023, 12 enero). Landsat 8 | Landsat Science. Landsat Science | A Joint NASA/USGS Earth Observation Program.

<https://landsat.gsfc.nasa.gov/satellites/landsat-8>

Machine learning vs. Deep learning. (s/f). Cognitive.la. Recuperado el 23 de junio de 2025, de <https://cognitive.la/blog/machine-learning-vs-deep-learning>

Mansilla, A. L. S., Mateo Pla, M. Á., & Lemus Zúñiga, L. G. (2022). *Evaluación de un sistema para la previsión de Riesgos de Incendios Forestales Catastróficos basado en Inteligencia Artificial*. Universitat Politècnica de València. Recuperado de <https://hdl.handle.net/10251/188666>

Ministerio de Ambiente y Desarrollo Sostenible. (2020, Noviembre). *Informe de superficies afectadas por incendios en el Delta e islas del Río Paraná*. https://www.argentina.gob.ar/sites/default/files/informe_superficies_afectadas_por_incendios_2020_piecas-dp_final.pdf

MODIS | Aqua Project Science. (s. f.). <https://aqua.nasa.gov/modis>

MODIS/Aqua Vegetation Indices 16-Day L3 Global 250m SIN Grid - LAADS DAAC. (s. f.). <https://ladsweb.modaps.eosdis.nasa.gov/missions-and-measurements/products/MYD13Q1>

NASA. (s.f.). *Landsat 8 mission details*. NASA. <https://landsat.gsfc.nasa.gov/satellites/landsat-8/landsat-8-mission-details/>

National Aeronautics and Space Administration. (2023, 26 de octubre). *Spectral Indices for Land and Aquatic Applications: Part 1: Overview of Spectral Indices [Informe PDF]*. https://appliedsciences.nasa.gov/sites/default/files/2023-10/Spectral_Indices_Part1.pdf

Numerosky, J. M. (2022). *Análisis de patrones temporales en humedales del Delta del Paraná mediante el estudio de series de tiempo* [Tesis de licenciatura, Universidad

de Buenos Aires, Facultad de Ciencias Exactas y Naturales, Departamento de Matemática]. Universidad de Buenos Aires.

https://web.dm.uba.ar/files/tesis_lic/2022/numerosky.pdf

Ordenamiento ambiental del territorio. (2020, abril 11). Argentina.gob.ar.
<https://www.argentina.gob.ar/ambiente/ordenamiento-territorial/oat>

Pertino, G. (2008). *Un modelo de objetos para la predicción del comportamiento del fuego en incendios sobre distintas superficies* [Tesis de grado]. Universidad Nacional de La Plata.

Pham, B. (2018). Satellite remote sensing of the variability of the continental hydrology cycle in the lower Mekong basin over the last two decades.

10.13140/RG.2.2.27136.07686.

U.S. Geological Survey. (2006, February). Wildfire impacts: USGS science priorities (Fact Sheet 2006–3015). *U.S. Department of the Interior*.

<https://pubs.usgs.gov/fs/2006/3015/2006-3015.pdf>

United Nations Environment Programme. (2022, February 23). *Number of wildfires to rise by 50 per cent by 2100 and governments are not prepared, experts warn*. UNEP.

<https://www.unep.org/news-and-stories/press-release/number-wildfires-rise-50-cent-2100-and-governments-are-not-prepared>

Visa, S., Ramsay, B., Ralescu, A., & van der Knaap, E. (2011, April 16-17). *Confusion matrix-based feature selection* [Conference paper]. Proceedings of The 22nd Midwest Artificial Intelligence and Cognitive Science Conference, Cincinnati, OH, USA.

Zendesk. (2025, August 7). *Deep learning vs. machine learning: A complete guide*.

<https://www.zendesk.com/blog/machine-learning-and-deep-learning/>

Aval del director de tesis – FCyT 2025

Estudiante/s: Alonso Lucía del Carmen, Cabana Alejo Matías

Título del trabajo de investigación: “Propuesta de un algoritmo de Deep Learning para la predicción de focos ígneos en los humedales del delta”

Programa de estudios: **Licenciatura en Sistemas de Información**

Fecha de entrega: 9/12/2025

Por medio de la presente, me dirijo a ustedes en calidad de Director de Tesis a fin de dar consentimiento respecto al cumplimiento de los requisitos de escritura y calidad académica del trabajo final del cual presido, en conformidad con lo establecido en la “Resolución CD FCyT Nro. 503/23”.

Además, quiero dejar en claro que tanto los objetivos propuestos en el pre-proyecto aprobado en el año lectivo 2025 fueron respetados y llevados a cabo en todo el trabajo de investigación desarrollado.-



Mg. Uhrig, Mariela Noelia
uhrig.mariela@uader.edu.ar