



UNIVERSIDAD NACIONAL DEL ALTIPLANO
ESCUELA DE POSGRADO
DOCTORADO EN CIENCIA, TECNOLOGÍA Y MEDIO
AMBIENTE



TESIS

**EVALUACIÓN DEL EFECTO DE LAS ESTRUCTURAS DE REDES
NEURONALES CONVOLUCIONALES EN LA DISCRIMINACIÓN DE
ÁRBOLES PLUS DE ALGARROBO EN LA ZONA NORTE DEL PERÚ COMO
ESTRATEGIA PARA ENFRENTAR LA DEFORESTACIÓN Y LA
DESERTIFICACIÓN**

PRESENTADA POR:

SAIRE ROENFI GUERRA LIMA

PARA OPTAR EL GRADO ACADÉMICO DE:

DOCTOR EN CIENCIA, TECNOLOGÍA Y MEDIO AMBIENTE

PUNO, PERÚ

2024

Reporte de similitud

NOMBRE DEL TRABAJO

EVALUACIÓN DEL EFECTO DE LAS ESTRUCTURAS DE REDES NEURONALES CON VOLUCIONALES EN LA DISCRIMINACIÓN DE

AUTOR

SAIRE ROENFI GUERRA LIMA

RECuento DE PALABRAS

20468 Words

RECuento DE CARACTERES

118959 Characters

RECuento DE PÁGINAS

96 Pages

TAMAÑO DEL ARCHIVO

6.0MB

FECHA DE ENTREGA

Jul 11, 2024 1:02 PM GMT-5

FECHA DEL INFORME

Jul 11, 2024 1:04 PM GMT-5

● **9% de similitud general**

El total combinado de todas las coincidencias, incluidas las fuentes superpuestas, para cada base de datos.

- 7% Base de datos de Internet
- Base de datos de Crossref
- 6% Base de datos de trabajos entregados
- 2% Base de datos de publicaciones
- Base de datos de contenido publicado de Crossref

● **Excluir del Reporte de Similitud**

- Material bibliográfico
- Material citado
- Material citado
- Coincidencia baja (menos de 8 palabras)


CÉSAR T. MEDINA ESPINOZA
Industria Alimentaria Reg. CIP. 39643
Investigador en Ciencias de la Ingeniería



Resumen



UNIVERSIDAD NACIONAL DEL ALTIPLANO
ESCUELA DE POSGRADO
DOCTORADO EN CIENCIA, TECNOLOGÍA Y MEDIO
AMBIENTE

TESIS

**EVALUACIÓN DEL EFECTO DE LAS ESTRUCTURAS DE REDES
NEURONALES CONVOLUCIONALES EN LA DISCRIMINACIÓN DE ÁRBOLES
PLUS DE ALGARROBO EN LA ZONA NORTE DEL PERÚ COMO ESTRATEGIA
PARA ENFRENTAR LA DEFORESTACIÓN Y LA DESERTIFICACIÓN**



PRESENTADA POR:

SAIRE ROENFI GUERRA LIMA

PARA OPTAR EL GRADO ACADÉMICO DE:

DOCTOR EN CIENCIA, TECNOLOGÍA Y MEDIO AMBIENTE

APROBADA POR EL JURADO SIGUIENTE:

PRESIDENTE


.....
Ph.D. SABINO ATENCIO LIMACHI

PRIMER MIEMBRO


.....
D.Sc. TEOFILO DONAIRES FLORES

SEGUNDO MIEMBRO


.....
D.Sc. GERMAN BELIZARIO QUISPE

ASESOR DE TESIS


.....
Dr. WENCESLAO TEDDY MEDINA ESPINOZA

Puno, 29 de enero de 2024.

ÁREA: Ciencias de la ingeniería.

TEMA: Evaluación del efecto de las estructuras de redes neuronales convolucionales en la discriminación de árboles plus de algarrobo en la zona norte del Perú como estrategia para enfrentar la deforestación y la desertificación.

LÍNEA: Ingeniería de procesos.



DEDICATORIA

Dedico este trabajo a mis hijos Luana y Sebastián, por ser el principal motivo de superación constante.

Saire Roenfi Guerra Lima.



AGRADECIMIENTOS

Este trabajo fue financiado por el Consejo Nacional de Ciencia, Tecnología e Innovación Tecnológica (CONCYTEC) y el Programa Nacional de Investigación Científica y Estudios Avanzados (PROCIENCIA), con Número de contrato PE501078266-2022-PROCIENCIA, con título “Redes convolucionales y combinaciones de bandas espectrales e índices vegetativos para identificación de árboles plus de algarrobo (*Prosopis pallida*) aplicando técnicas Deep learning e imágenes multiespectrales”, dirigido por el doctor Wilson Manuel Castro Silupu de la Universidad Nacional de Frontera, a quién agradezco especialmente por todo el apoyo brindado para la ejecución de esta tesis y al pleno de integrantes de este proyecto.

También agradezco a mi director el doctor Wenceslao Medina Espinoza por su tiempo y apoyo permanente.

Agradezco a mi familia, a mi esposa, a mis hijos y a mis padres por su apoyo incondicional que perdura en el tiempo.

Saire Roenfi Guerra Lima.



ÍNDICE GENERAL

	Pág.
DEDICATORIA	i
AGRADECIMIENTOS	ii
ÍNDICE GENERAL	iii
ÍNDICE DE TABLAS	v
ÍNDICE DE FIGURAS	vi
ÍNDICE DE ANEXOS	vii
ACRÓNIMOS	viii
RESUMEN	1
ABSTRACT	2
INTRODUCCIÓN	3

CAPÍTULO I

REVISIÓN DE LITERATURA

1.1	Marco teórico	5
1.1.1	Tipos de bosques	6
1.1.2	Especies en bosques secos tropicales	8
1.1.3	Degradación de bosques	9
1.1.4	El algarrobo como especie forestal	12
1.1.5	Árboles plus – arboles semilleros	18
1.1.6	Sistemas de monitorización de bosques	19
1.1.7	Análisis de imágenes	24
1.2	Antecedentes	32
1.2.1	Internacionales	32
1.2.2	Nacionales	32
1.2.3	Locales	35

CAPÍTULO II

PLANTEAMIENTO DEL PROBLEMA

2.1	Identificación del problema	38
2.2	Enunciados del problema	39
2.2.1	Problema general	39
2.2.2	Problemas específicos	39
2.3	Justificación	40



2.4	Objetivos	40
2.4.1	Objetivo general	40
2.4.2	Objetivos específicos	40
2.5	Hipótesis	41
2.5.1	Hipótesis general	41
2.5.2	Hipótesis específicas	41

CAPÍTULO III

MATERIALES Y MÉTODOS

3.1	Lugar de estudio	42
3.2	Población	43
3.3	Muestra	43
3.4	Método de investigación	44
3.5	Descripción detallada de métodos por objetivos específicos	44
3.5.1	Diseño de muestreo	44
3.5.2	Descripción detallada del uso de materiales, equipos, insumos, entre otros	44
3.5.3	Descripción de variables a ser analizados en el objetivo específico	47
3.5.4	Aplicación de prueba estadística	48

CAPÍTULO IV

RESULTADOS Y DISCUSIÓN

4.1	Resultados	49
4.1.1	Imágenes RGB de árboles de algarrobo de la zona norte del Perú	49
4.1.2	Diseño e implementación de las redes neuronales convolucionales	53
4.1.3	Precisión de las redes neuronales convolucionales para clasificar los árboles de algarrobo	56
4.2	Discusión	61
4.2.1	Imágenes RGB de árboles de algarrobo.	61
4.2.2	Diseño e implementación de redes neuronales convolucionales	62
4.2.3	precisión de las redes neuronales convolucionales para clasificar los árboles de algarrobo	62

CONCLUSIONES	64
--------------	----

RECOMENDACIONES	65
-----------------	----

BIBLIOGRAFÍA	66
--------------	----

ANEXOS	78
--------	----



ÍNDICE DE TABLAS

	Pág.
1. Distritos de la costa norte con alta probabilidad de registro de árboles plus	42
2. Resultados del ROI y segmentación de imágenes RGB de árboles de algarrobo	49
3. Imágenes segmentadas de árboles no plus (sección superior) y plus (sección inferior)	50
4. Comparación entre las características morfológicas de los árboles de algarrobo plus y no plus	51

ÍNDICE DE FIGURAS

	Pág.
1. Bosques tropicales (a), subtropicales (b), templados (c) y boreales (d)	7
2. Proporción de causas de degradación forestal por continente	10
3. Áreas acumuladas deforestadas del Perú desde el 2001 al 2019	11
4. Concentración de alertas de deforestación en el Perú	11
5. Concentración de alertas de deforestación en el Perú	12
6. Ocurrencia de algarrobo según Global Biodiversity Information Facility (GBIF) (puntos azules) y CABI Invasive Species Compendium (puntos rojos)	16
7. Deterioro del algarrobo	17
8. Ejemplo ilustrativo de árboles plus (más robustos) y no plus	19
9. Monitoreo convencional de bosques	20
10. UAVs con ala fija (a), híbrido (b), multirrotor (c), dirigible (d) con ala batiente (e), con ala de parafoil (f)	23
11. Ejemplo de sensor RGB usado por UAV	24
12. Ilustración de un sistema común de aprendizaje automático	25
13. Componentes (capas) de una CNN	27
14. Efecto de diferentes matrices de convolución (filtros)	29
15. Georreferencia de la zona de estudio	43
16. Despegue del dron para la captura de imágenes de los árboles de algarrobo	45
17. Geolocalización de los árboles de algarrobo evaluados	45
18. Representación gráfica de las características morfológicas de los árboles de algarrobo plus y no plus	52
19. Arquitectura de la red propuesta AlgarroboNet	55
20. Características de las capas de la red convolucional propuesta AlgarroboNet	55
21. Comparación del rendimiento de los modelos CNN para la discriminación de árboles de algarrobo plus y no plus	57
22. Matriz de confusión de los modelos CNN para la discriminación de árboles de algarrobo plus y no plus	58
23. Precisión (a) y F- measure (b) de los modelos CNN para la discriminación de árboles de algarrobo plus y no plus	59



ÍNDICE DE ANEXOS

	Pág.
1. Matriz de consistencia	78
2. Programación de Algarrobo NET	79
3. Representación gráfica de las características morfológicas de los árboles plus y no plus ampliado por parámetro	81
4. Características de las capas de la red convolucional propuesta AlgarroboNet	85



ACRÓNIMOS

ALS	Datos de escaneo láser aerotransportado
CNN	Redes neuronales convolucionales
CONCYTEC	Consejo Nacional de Ciencia, Tecnología e Innovación Tecnológica
EE.UU	Estados Unidos de Norte América
EPG	: Escuela de Posgrado
FAO	Organización para la Alimentación y la Agricultura
GBIF	Global Biodiversity Information Facilit
GPU	Unidades de Procesamiento Gráfico
GUI	Interfaz gráfica de usuario
JPEG	Joint Photographic Experts Group
LiDAR	Detección y alcance de luz
NAS	Sistemas de almacenamiento en nube
NIR	Infrarroja cercana
PIB	Producto Interno Bruto
PROCIENCIA	Programa Nacional de Investigación Científica y Estudios Avanzados
K-NN	k-vecino más cercano
RADAR	Detección y alcance por radio
RF	Bosques aleatorios
RGB	Rojo, verde y azul
ROI	Región de interés
SENASA	Servicio Nacional de Sanidad Agraria
SERFOR	Servicio Nacional de Sanidad Agraria
SVM	Máquinas de vectores de soporte
SWIR	Infrarroja de onda corta
TIR	Bandas infrarrojas térmica
UAV	Vehículo aéreo no tripulado
UNA	: Universidad Nacional del Altiplano
USD	Dólares americanos
UTM	Universal transversal Mercator

RESUMEN

Los bosques secos del norte peruano tienden a deforestarse, por lo que se requiere implementar estrategias para la gestión de especies protegidas como el algarrobo, basados en la identificación y selección de productores de semillas de calidad que lo proporcionan los algarrobos plus. El objetivo de esta investigación fue evaluar el efecto de las estructuras de redes neuronales convolucionales para discriminar árboles plus de algarrobo en la zona norte del Perú como estrategia para enfrentar la deforestación y la desertificación. Se evaluaron 624 algarrobos ubicados en localidades de Tumbes, Piura y Lambayeque; mediante análisis de imágenes obtenidas con dron y comparadas con sus características morfológicas que fueron proporcionadas por el Servicio Forestal Nacional del Perú (SERFOR) que aseguraron sus caracteres plus y no plus para este estudio, luego de la corrección y segmentación de las imágenes, los datos se alimentaron al Matlab 2019a para ser analizados con redes convolucionales conocidas como AlexNet, DenseNet, MobileNet y GoogleNet, así como una arquitectura nueva, denominada AlgarroboNet. Las redes convolucionales lograron una clasificación exitosa de los árboles, destacándose AlexNet como el modelo más preciso y estable, con una precisión F-measure de 0,96, seguido de DenseNet y MobileNet (0,95 para ambos), GoogleNet (0,94) y finalmente AlgarroboNet (0,87). A pesar del menor rendimiento de AlgarroboNet, se puede concluir que esta propuesta al incrementar su entrenamiento, por contener menor número de capas y cantidad de parámetros, es eficiente para la selección masiva y caracterización de árboles de algarrobo plus para implementarlo en programas de reforestación.

Palabras clave: Algarrobo, aprendizaje profundo, deforestación, desertificación, redes neuronales convolucionales.

ABSTRACT

Nowadays, Northern Peru dry forests tends to be deforested. Based on identification and selection of quality seeds provided by plus-algarrobo trees producers, are necessary to implement strategies to protected species management of native algarrobo tree. As strategy to confront deforestation and desertification, the aim of this work was to evaluate convolutional neural network structures effect to discriminate algarrobo-plus trees at Tumbes, Piura and Lambayeque northern Peru areas. Image analysis of morphological characteristics of 624 algarrobo trees, acquired by dron, were compared with morphological characteristics provided by Peruvian National Forest Service (SERFOR) to ensure the plus and non-plus characters of these species. Corrected and segmented images were analyzed with convolutional networks such as AlexNet, DenseNet, MobileNet, GoogleNet and AlgarroboNet.fed through Matlab 2019a software. Convolutional networks achieved a successful algarrobo trees classification. Accuracy and stability of convolutional networks were estimated by the F-measure precision values. AlexNet obtained 0.96, DenseNet and MobileNet 0.95 and Algarrobo.net 0.87. However, due to smaller both layers and parameter numbers, Algarrobo.net is efficient to mass selection and characterization of algarrobo-plus trees, being a promising alternative in reforestation programs managements.

Keywords: Algarrobo, convolutional neural networks, deep learning, deforestation, desertification



WENCESLAO T. MEDINA ESPINOZA
Ing. Industrias Alimentarias Reg. OP 39843
Doctor en Ciencias de la Ingeniería

INTRODUCCIÓN

Los bosques estacionalmente secos del noroeste peruano albergan una riqueza natural representada principalmente por los árboles de algarrobo (*Prosopis pallida*), que no solo dominan el paisaje, sino que también proveen recursos esenciales como madera y frutos. Esta especie se posiciona entre las más relevantes en la Ecozona Costa, según el Inventario Nacional Forestal y de Fauna Silvestre. Sin embargo, la persistente amenaza de degradación y deforestación ha reducido su distribución y densidad, con un descenso notorio en la cantidad de individuos, lo cual genera impactos negativos en la ecología y economía locales.

Esta problemática ha despertado iniciativas como la formación de un Grupo de Trabajo Multisectorial, evidenciando la urgencia de estrategias para la gestión sostenible de bosques de algarrobos. Esta necesidad se alinea con la Agenda Nacional de Investigación Forestal y de Fauna Silvestre 2020 – 2025, que destaca la importancia de tecnologías innovadoras en el manejo sostenible de especies, como las relacionadas con la identificación de árboles élites o "plus".

En este contexto, la presente investigación se sitúa en la línea de Recursos Naturales y Medio Ambiente del área de Ciencias de la Ingeniería, abordando el tema crucial de la Evaluación del efecto de las estructuras de redes neuronales convolucionales en la discriminación de árboles plus de algarrobo en la zona norte del Perú.

El propósito de esta investigación es identificar y seleccionar árboles élites con el fin de contribuir al manejo sostenible de los bosques de algarrobo, mitigando los impactos negativos sobre la biodiversidad y la economía local. Para esto, se integrarán métodos novedosos como la teledetección y el aprendizaje profundo, los cuales, a su vez, son eficientes y fácilmente escalables a versiones miniaturizadas o para su uso masivo, estando al alcance de toda la población interesada.

Este trabajo se divide en siete capítulos. El primero incluye la revisión de literatura, la cual aborda el marco teórico con tópicos como los bosques o ecosistema forestal, el algarrobo, sistemas de monitorización de bosques, drones y análisis de imágenes; así como los antecedentes. El II capítulo plasma el planteamiento del problema, la justificación, objetivos e hipótesis correspondientes. El III capítulo incluye los materiales y métodos, detallando el lugar de estudio, población y muestra, al igual que



los métodos de investigación desde la adquisición de imágenes RGB por dron hasta su procesamiento y análisis mediante redes neuronales convolucionales conocidas y una propuesta, cuya precisión se evaluó según distintas métricas. El VI capítulo muestra los resultados y discusiones correspondientes, mientras que los capítulos V, VI y VII tratan las conclusiones, recomendaciones y bibliografía, respectivamente.

CAPÍTULO I

REVISIÓN DE LITERATURA

1.1 Marco teórico

Los bosques abarcan el 31% de la superficie terrestre global, con más de 4 millones de hectáreas, equivalente a aproximadamente 0,5 hectáreas por persona FAO y PNUMA (2020). De este porcentaje, casi la mitad de la cobertura forestal se mantiene en un estado relativamente intacto, y más del 33% consiste en bosques primarios. La concentración de la mayoría de los bosques a nivel mundial se observa en cinco países principales: Brasil, Canadá, China, Estados Unidos de América y la Federación de Rusia FAO y PNUMA (2020).

En términos de biodiversidad, los bosques son fundamentales, ya que albergan el 80% de las especies de anfibios, el 75% de las especies de aves y el 68% de las especies de mamíferos en la Tierra (FAO y PNUMA, 2020). Además, desempeñan funciones cruciales, como la modulación del clima, la captura y almacenamiento de, la purificación del aire, la regulación del ciclo del agua, la prevención de la erosión del suelo y la provisión de hábitats para seres humanos y animales, así como recursos maderables y no maderables (CEPLAN, 2023).

Más de 700 millones de hectáreas de bosques, equivalentes al 18% de la superficie forestal total, se encuentran en áreas protegidas legalmente establecidas (FAO, 2022). Los bosques y los árboles se destacan como medios efectivos para combatir el cambio climático, ya que contienen 662,000 millones de toneladas de carbono, constituyendo más de la mitad de las reservas de carbono globales de los suelos y la vegetación. A pesar de la reducción constante de su superficie, entre 2011 y 2020, los bosques lograron absorber más carbono del que emitieron, gracias a iniciativas como la reforestación y la mejora en la gestión forestal (FAO, 2022).

En términos económicos, más del 50% del Producto Interno Bruto (PIB) mundial, que ascendió a 84,4 billones de USD en 2020, depende moderada (31 billones de USD al año) o fuertemente (13 billones de USD al año) de los servicios ecosistémicos, especialmente aquellos proporcionados por los bosques (FAO, 2022). La estimación de la riqueza derivada de servicios ecosistémicos forestales, como recreación, caza, hábitat, suministro de productos forestales no maderables y servicios hídricos, alcanza los 7,5

billones de USD, representando el 21% de la riqueza total de los activos de la tierra y aproximadamente el 9% del PIB global. Aunque no se consideran en el cálculo de la riqueza nacional, los activos naturales, incluidos los bosques, son esenciales, y su disminución podría afectar a otros activos a largo plazo. Actualmente, se trabaja en mejorar las estimaciones del valor de la naturaleza, especialmente en el contexto de los bosques (FAO, 2022).

En cuanto al empleo, alrededor de 33 millones de personas, equivalente al 1% del empleo mundial, trabajan directa o indirectamente en el sector forestal, ya sea de manera formal o informal. En 2015, este sector contribuyó con más de 1,52 billones de USD al PIB mundial de manera directa, indirecta e inducida (FAO, 2022).

1.1.1 Tipos de bosques

Los bosques se categorizan principalmente en bosques regenerados de forma natural y bosques plantados. A nivel mundial, los bosques regenerados de forma natural abarcan aproximadamente el 93% de la superficie forestal total, mientras que el restante 7% está compuesto por bosques plantados (FAO y PNUMA, 2020).

Específicamente, más del 34% de los bosques globales son clasificados como bosques primarios, caracterizados por la regeneración natural de especies arbóreas autóctonas, sin evidencia aparente de actividad humana y con procesos ecológicos sin perturbaciones significativas (FAO y PNUMA, 2020).

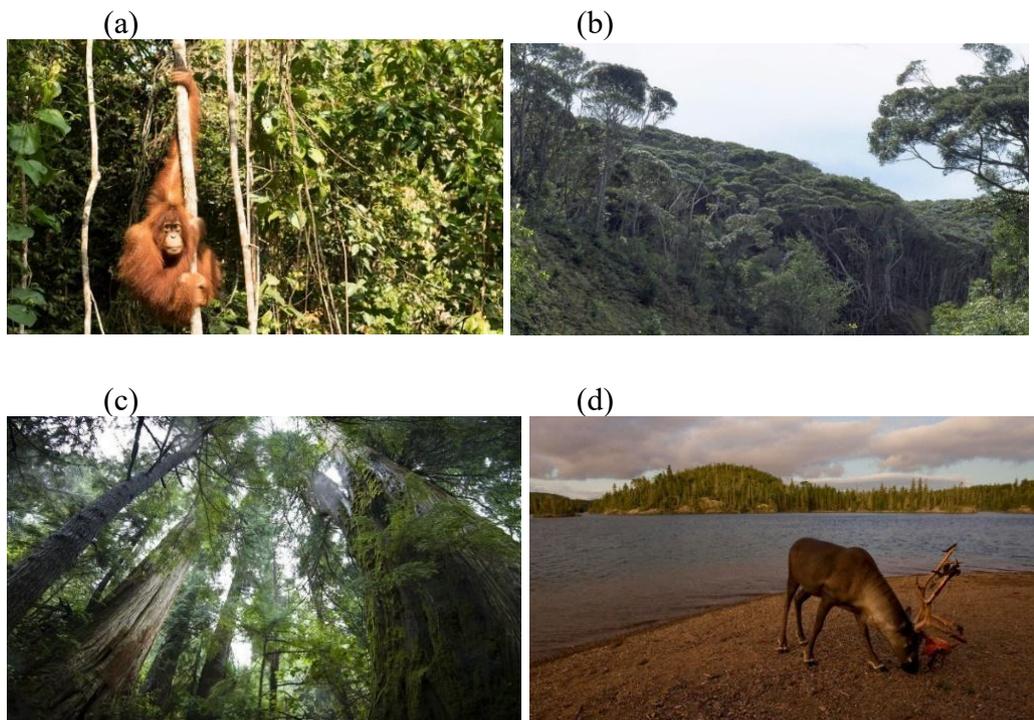
En el caso de los bosques plantados, su extensión ha aumentado en 123 millones de hectáreas desde 1990, abarcando actualmente 294 millones de hectáreas (FAO y PNUMA, 2020). Alrededor del 45% de estos bosques plantados son plantaciones forestales, que se caracterizan por una gestión intensiva con dos o tres especies arbóreas, nativas o exóticas, de la misma edad y con un espaciado regular, principalmente con fines productivos (FAO y PNUMA, 2020). El 55% restante, conocido como "otros bosques plantados", se establece para la restauración de ecosistemas y la protección del suelo y el agua. A nivel mundial, el 44% de las plantaciones forestales incorpora especies introducidas, con notables variaciones regionales. Por ejemplo, América del Sur destaca con el 97% de sus plantaciones forestales compuestas por especies introducidas, mientras que, en

América del Norte y Central, este porcentaje es tan solo del 4% (FAO y PNUMA, 2020).

Existen clasificaciones en base al clima, pudiendo ser tropicales, subtropicales, templados y boreales (Fondo Mundial Para la Naturaleza, 2019) (Figura 1).

Figura 1

Bosques tropicales (a), subtropicales (b), templados (c) y boreales (d)



Nota. Tomado de Fondo Mundial Para la Naturaleza (2019).

- a) Bosques tropicales: Caracterizados por temperaturas superiores a los 18°C durante todo el año y una abundancia de agua. Aquí, se encuentran más plantas y animales distintos que en cualquier otro lugar de la Tierra.
- b) Bosques subtropicales: Similar a los tropicales, aunque menos biodiversos. Aunque cuentan con una temporada de frío significativa, su diversidad de plantas y animales no se ve afectada por temperaturas más frescas.
- c) Bosques templados: Sujetos a las cuatro estaciones del año, presentan variedades como bosques de coníferas perennes, bosques caducifolios con árboles que pierden sus hojas anualmente, y combinaciones de ambos.

- d) Bosques boreales: Ubicados en regiones extremadamente frías, estos bosques albergan vida adaptada a temperaturas gélidas durante todo el año, como el reno de bosque o caribú.

En el ámbito de los bosques tropicales secos, definidos por Schröder et al. (2021) como aquellos ubicados en regiones tropicales con marcada estacionalidad en la distribución de las precipitaciones, resultando en meses de sequía, se estima que alrededor del 25% de la población mundial depende de estos bosques secos para cubrir sus necesidades diarias (Schröder et al., 2021). Sin embargo, estos bosques enfrentan desafíos significativos, como altas tasas de deforestación y degradación, siendo objeto de un estudio insuficiente en comparación con los bosques húmedos (Jiménez-Rodríguez et al., 2022).

1.1.2 Especies en bosques secos tropicales

Los bosques secos tropicales poseen altos niveles de biodiversidad, con 12 grupos florísticos distintos en América Central y del Sur (Stan y Sanchez-Azofeifa, 2019). Estos bosques también presentan una variedad única de especies de árboles, que varía desde aproximadamente 100 en latitudes altas hasta más de 1000 cerca del ecuador (Stan y Sanchez-Azofeifa, 2019). Además, en los bosques secos tropicales crecen unas 6958 especies de plantas leñosas, de las cuales el 40% no se encuentran en ninguna parte del mundo (Hasnat y Hossain, 2019).

Los bosques tropicales son muy ricos en flora y fauna; las especies vegetales autóctonas más importantes son los agaves, las acacias, los cactus, etc. y es el hábitat de distintos tipos de mamíferos, mariposas, polillas, abejas, avispa, hormigas, aves, reptiles, anfibios, etc. (Hasnat y Hossain, 2019). Además, los bosques secos tropicales son el hogar de diversos animales salvajes como grandes felinos, monos, loros, roedores, aves silvestres, perezosos, aulladores negros, monos, zorros, mapaches, tejones, lince, pumas, etc. (Hasnat y Hossain, 2019). Los bosques secos tropicales son también el refugio de diferentes tipos de reptiles.

La diversidad de especies en los bosques secos tropicales muestra tendencias latitudinales, siendo mayor cerca del ecuador. Por ejemplo, las parcelas en México y Brasil suelen tener entre 90 y 100 especies de flora por variables climáticas como la precipitación/evapotranspiración y la irradiancia (Stan y

Sanchez-Azofeifa, 2019). Por otro lado, en las latitudes ecuatoriales, factores como el suelo y la edad del rodal son dominantes en una mayor variación de especies (Stan y Sanchez-Azofeifa, 2019). En Costa Rica, las parcelas tienen más de 135 especies de árboles, y en sitios panameños se estima que hay más de 1000 especies de flora. La mayoría de las especies son exclusivas de una sola parcela o etapa sucesional, y hay una mayor presencia de especies comunes cerca del ecuador (Stan y Sanchez-Azofeifa, 2019).

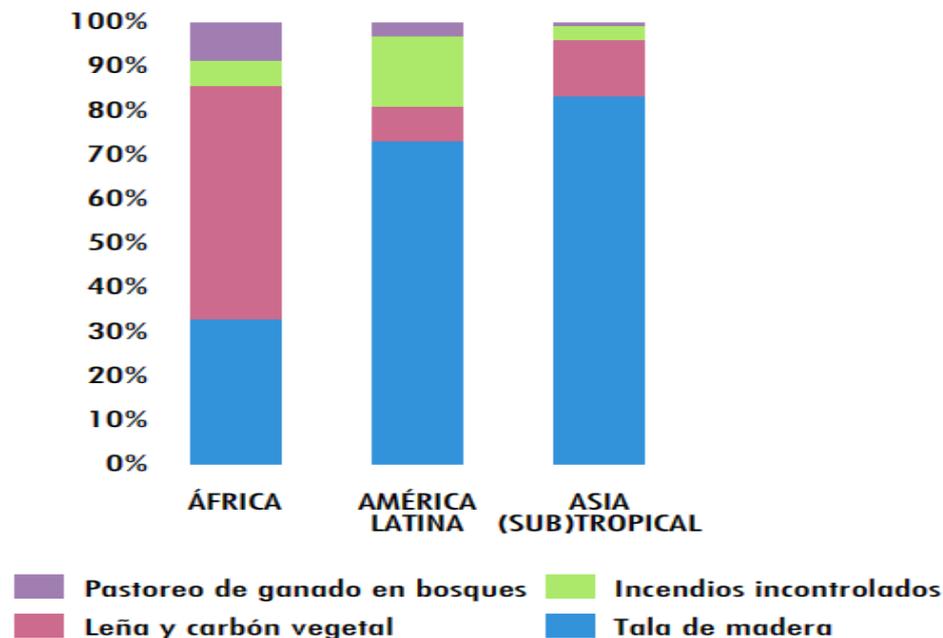
1.1.3 Degradación de bosques

La superficie forestal mundial se presenta diversificada, con alrededor del 49% que se mantiene en un estado relativamente inalterado, mientras que el 9% se encuentra fragmentado, careciendo de conectividad significativa (FAO y PNUMA, 2020). Esta fragmentación es más pronunciada en bosques secos subtropicales y bosques templados oceánicos, a diferencia de los bosques tropicales húmedos y los bosques boreales de coníferas, que son menos propensos a la fragmentación (FAO y PNUMA, 2020). Cerca del 80% de la superficie forestal global se distribuye en fragmentos que superan el millón de hectáreas, mientras que el restante 20% se divide en más de 34 millones de fragmentos, siendo la mayoría de estos fragmentos de menos de 1,000 hectáreas (FAO y PNUMA, 2020).

La degradación de los bosques implica una reducción o pérdida de la productividad biológica o económica, dando lugar a una disminución a largo plazo en el suministro de beneficios derivados de los bosques, como madera, biodiversidad y otros productos o servicios (FAO y PNUMA, 2020). Entre las causas de degradación forestal a nivel mundial (según datos de África, Latinoamérica y Asia sub tropical), prevalece la tala de madera, seguido de leña y carbón vegetal, incendios incontrolados y, por último, pastoreo de ganado en bosques, como revela la Figura 2 (FAO y PNUMA, 2020).

Figura 2

Proporción de causas de degradación forestal por continente

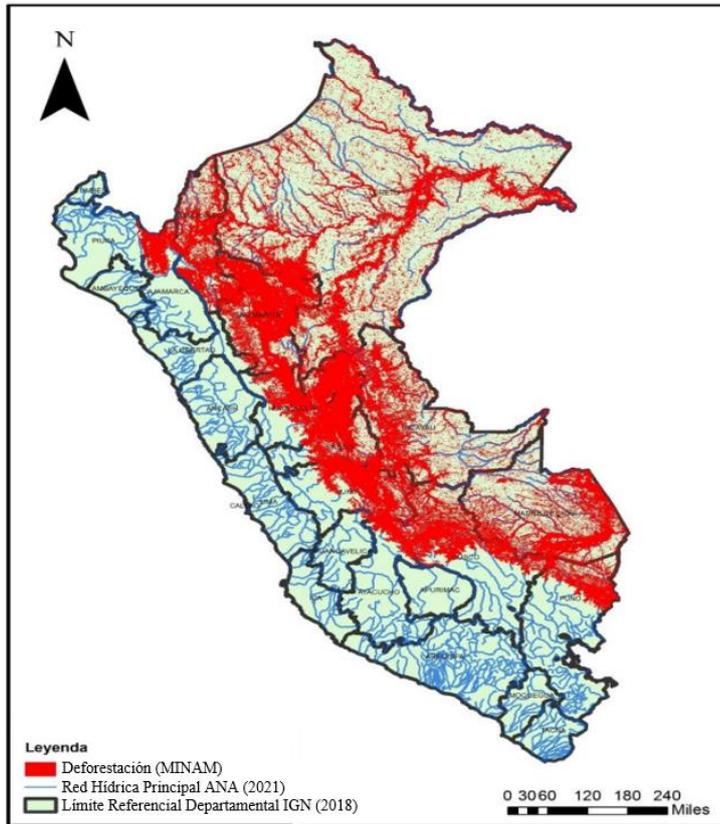


Nota. Tomado de FAO y PNUMA (2020).

La degradación va exacerbada por la deforestación, que ha resultado en la pérdida de aproximadamente 420 millones de hectáreas de bosque desde 1990 (FAO y PNUMA, 2020). Aunque la tasa de deforestación ha disminuido en las últimas décadas, entre 2015 y 2020 se estimó una pérdida anual de 10 millones de hectáreas, en comparación con los 16 millones de hectáreas por año en la década de 1990. Además, más de 100 millones de hectáreas de bosques están siendo afectadas por diversos factores como incendios forestales, plagas, enfermedades, especies invasivas, sequías y fenómenos meteorológicos adversos (FAO y PNUMA, 2020). Particularmente, en el Perú en las últimas dos décadas se observa una gran proporción de áreas deforestadas o sin vegetación con mayor énfasis en la región amazónica como se nota en las Figura 3 y 4, respectivamente.

Figura 3

Áreas acumuladas deforestadas del Perú desde el 2001 al 2019



Nota. Tomado de CEPLAN (2023).

Figura 4

Concentración de alertas de deforestación en el Perú



Nota. Tomado de CEPLAN (2023).

En el contexto peruano, la escala de deforestación es baja, ya que la tala y quema del bosque suelen realizarse para la creación de pequeñas parcelas, generando sistemas fragmentados (CEPLAN, 2023). Sin embargo, esta deforestación no es uniforme, afectando más a ecosistemas como el bosque seco y especies específicas como el algarrobo.

1.1.4 El algarrobo como especie forestal

El algarrobo (*Prosopis pallida*) (Figura 5) es un árbol caducifolio facultativo que florece en ecosistemas secos, destacándose por su resistencia a condiciones adversas como salinidad, sequía y altas temperaturas (Salazar Zarzosa et al., 2021). El algarrobo es originario zonas áridas y semiáridas de América del Sur, principalmente a lo largo de la costa de Perú, Ecuador y Colombia (Salazar Zarzosa et al., 2021), pero también se ha documentado su presencia en otras partes del mundo. Los análisis moleculares han demostrado que el algarrobo se originó evolutivamente a partir del mezclado, que incluye *P. pallida*, *P. chilenses* y *P. ruscifoliae* debido a su similitud morfológica y distribución geográfica superpuesta en la costa de América del Sur (Salazar Zarzosa et al., 2021).

Figura 5

Concentración de alertas de deforestación en el Perú



El término "pallida", que significa pálido o de tono claro, hace referencia al follaje grisáceo del algarrobo, especialmente cuando está seco, como se aprecia en las muestras de herbario (Salazar Zarzosa et al., 2021).

A. Importancia económica

La capacidad del algarrobo para sobresalir en condiciones difíciles conlleva ventajas sustanciales tanto desde una perspectiva medioambiental como económica para la comunidad local, destacándose por encima de otras especies en su entorno natural (Salazar Zarzosa et al., 2021). Algunas de las aplicaciones más relevantes de los algarrobos incluyen:

- **Alimento para el ser humano.** Desde tiempos precolombinos, los frutos del algarrobo han sido esenciales en la alimentación humana, con la Algarrobina siendo una tradición cultural arraigada en la Costa norte del Perú (Kometter y Reynel, 2020). Los estudios nutricionales respaldan su valor, destacando su alto contenido proteico y beneficios en la alimentación humana (Kometter y Reynel, 2020). Los frutos de las especies de *Prosopis*, ricos en azúcares, hidratos de carbono y proteínas, ofrecen una versatilidad única. Las vainas, constituyendo el 90% del fruto, son utilizadas tanto para consumo humano como para forraje animal, gracias a su contenido de fibra y nutrientes (Pasiiecznik, Felker, et al., 2001). La harina derivada de las vainas, con su alto contenido proteico, se propone como insumo para la producción de alimentos como el pan. Además, las semillas de las vainas poseen agentes espesantes no tóxicos con aplicaciones potenciales en las industrias farmacéutica y alimentaria (Salazar Zarzosa et al., 2021).
- **Alimento para los animales.** El algarrobo no solo beneficia a los humanos, sino que también desempeña un papel vital como alimento para animales. Las hojas y vainas son consumidas por ganado caprino, porcino y vacuno, contribuyendo a su nutrición (Pasiiecznik, Felker, et al., 2001). El uso de las hojas varía mucho entre las especies de *Prosopis* y entre los distintos animales que pueden consumirlas. Se sabe que una minoría de especies tienen hojas que son apetecibles para el ganado y que son muy apreciadas como fuente de forraje o forraje (Pasiiecznik, Felker, et al., 2001).

- Madera para construcción y carpintería. La madera del algarrobo destaca por su dureza y durabilidad, siendo apreciada en construcciones desde tiempos antiguos (Pasicznik, Felker, et al., 2001). Utilizada en forma natural para portales y travesaños, así como en carpintería rústica, la madera también se destaca como un recurso valioso para combustible, ya sea quemada directamente o convertida en carbón vegetal. Su alto valor calorífico y la capacidad de arder incluso cuando está verde la convierten en una elección preferida para las comunidades locales (Pasicznik, Felker, et al., 2001).
- Leña y carbón. La leña del algarrobo es ampliamente utilizada en zonas rurales para cocinar. Aunque la madera es un producto comercializado, su aplicación histórica como leña y carbón destaca por su eficacia (Pasicznik, Felker, et al., 2001). Este carbón, con alto poder calorífico, se distingue por dar un sabor especial a los alimentos asados y horneados (Pasicznik, Felker, et al., 2001).
- Miel y cera. El algarrobo contribuye significativamente al ámbito apícola, siendo una planta melífera crucial para la producción de miel y cera (Pasicznik, Felker, et al., 2001). Las flores de *Prosopis* proveen néctar y polen en abundancia, favoreciendo la apicultura. La miel resultante es de calidad, con un color claro y un agradable sabor, mientras que la cera se utiliza en la producción de velas y preparados farmacéuticos (Pasicznik, Felker, et al., 2001).
- Goma exudada: Las gomas exudadas de *Prosopis*, solubles en agua, líquidas y de color amarillo fresco, se han utilizado históricamente, masticadas por algunas tribus o en la fabricación de confiterías (Pasicznik, Felker, et al., 2001). Además, la corteza recubierta de goma se ha utilizado para producir pinturas y tintes en Norteamérica (Pasicznik, Felker, et al., 2001).
- Bosques y comunidades naturales en zonas áridas. En las regiones secas y desérticas, los bosques secos dominados por algarrobo son fundamentales, ofreciendo comunidades de baja diversidad, pero

significativas por su endemismo (Kometter y Reynel, 2020). Los bosques de Prosopis proveen sombra, refugio y hábitat valioso para animales salvajes, contribuyendo a la subsistencia de las poblaciones humanas (Pasiiecznik, Felker, et al., 2001).

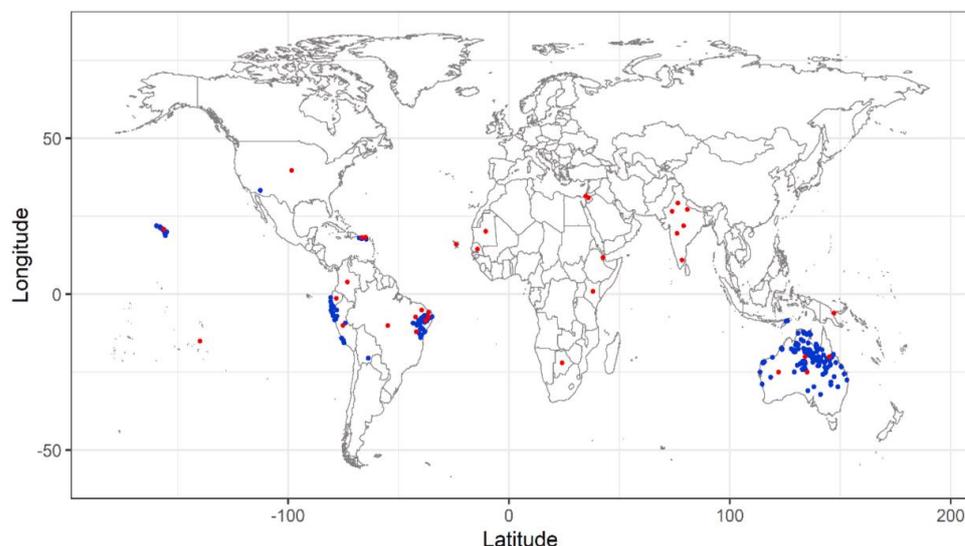
- Cubierta vegetal adaptable a zonas áridas. Los árboles de Prosopis son altamente adaptables, siendo su raíz clave para la supervivencia al aprovechar el agua en el subsuelo (Kometter y Reynel, 2020). Actúan como delimitadores, protegiendo contra el viento y reduciendo la erosión del suelo, contribuyendo a la mejora de las condiciones ambientales (Pasiiecznik, Felker, et al., 2001).
- Mejora del suelo. Las especies de Prosopis aportan significativamente al suelo con follaje y fijación de nitrógeno desde sus raíces, mejorando las propiedades físicas, mecánicas y biológicas (Pasiiecznik, Felker, et al., 2001). Contribuyen a la reducción de la salinidad y alcalinidad del suelo, creando un efecto de "isla de fertilidad" bajo su dosel (Salazar Zarzosa et al., 2021).
- Mejora a nivel microclimático y en la disponibilidad de agua. La presencia del algarrobo atenúa las condiciones extremas de climas cálidos y áridos, ofreciendo sombra apreciada por humanos y ganado (Pasiiecznik, Felker, et al., 2001). Además, su contribución a la mejora ambiental general se destaca en la mitigación del movimiento de tierra y arena, protegiendo contra la erosión y reduciendo la salinidad y alcalinidad del suelo (Pasiiecznik, Felker, et al., 2001).
- Medicina natural. Extractos de partes de plantas de Prosopis se utilizan en numerosas aplicaciones medicinales, tratando afecciones como infecciones de boca y garganta, enfermedades internas y trastornos de la piel (Pasiiecznik, Felker, et al., 2001). Las especies de Prosopis han sido empleadas en diversas culturas por sus propiedades medicinales, desde el tratamiento de enfermedades hasta usos dermatológicos y oftalmológicos (Pasiiecznik, Felker, et al., 2001).

B. Situación actual

De acuerdo con la Figura 6, se documentó la presencia de algarrobo en distintas partes del mundo. A pesar de su presencia global, con excepciones en lugares como Botswana, Djibouti, India, Puerto Rico, EE.UU., Hawaii, Australia y Brasil donde crece de forma natural, la situación actual del algarrobo revela una preocupante disminución de sus poblaciones, especialmente en América del Sur, donde se considera el recurso genético arbóreo más vulnerable (Salazar Zarzosa et al., 2021). La deforestación ha impactado fuertemente las regiones que alguna vez albergaron los mayores bosques de *Prosopis* en América, en particular en México, Perú/Chile y Argentina (Pasiecznik, Felker, et al., 2001). La degradación resulta de la conversión de tierras para la agricultura y la ganadería, así como de la tala para diversos usos madereros (Pasiecznik, Felker, et al., 2001)

Figura 6

Ocurrencia de algarrobo según Global Biodiversity Information Facility (GBIF) (puntos azules) y CABI Invasive Species Compendium (puntos rojos)



Nota. Tomado de Salazar Zarzosa et al. (2021).

Aunque algunos bosques han experimentado talas selectivas y agotamiento genético, la sobreexplotación y la transformación del hábitat han conducido a una marcada reducción de la cobertura natural (Figura 7),

especialmente en Argentina. Además, en África, la expansión desde el norte y la presión desde el sur debido a las actividades agrícolas y ganaderas han contribuido a la invasión de ecosistemas de sabana (Pasiiecznik, Felker, et al., 2001).

Figura 7

Deterioro del algarrobo



Nota. Tomado de Kometter y Reynel (2020).

La distribución del algarrobo a ambos lados de la costa del Pacífico Sur está influenciada por eventos climáticos como El Niño, que provocan fluctuaciones entre períodos secos y húmedos (Salazar Zarzosa et al., 2021). Esta variabilidad climática ha llevado a adaptaciones fisiológicas y morfológicas en el algarrobo para sobrevivir en años de sequía y aprovechar el crecimiento posterior a las inundaciones (Salazar Zarzosa et al., 2021). Sin embargo, a pesar de su adaptabilidad, la distribución en su hábitat nativo, como en Perú, enfrenta amenazas por la presión antrópica y la conversión del hábitat, lo que destaca la importancia de los esfuerzos de conservación (Salazar Zarzosa et al., 2021). Esto resulta en un grave problema social porque las comunidades están perdiendo los ingresos que obtenían del follaje, frutos y madera, en diversos productos, afectando su calidad de vida (Kometter y Reynel, 2020).

Al analizar el Inventario Forestal Nacional, se encontró que el 40% de los algarrobos en pie están muertos y, de los vivos, el 27% tienen una afectación fitosanitaria en tránsito hacia la muerte, donde los más afectados son los algarrobos jóvenes (Kometter y Reynel, 2020). Las causas son múltiples, como las fluctuaciones y transformaciones en el clima, que resultan en períodos prolongados de sequía, inducen un estrés hídrico que debilita a los árboles, facilitando así la actividad biológica de insectos, hongos, bacterias y virus (Kometter y Reynel, 2020). Este escenario se ve agravado por la intervención humana, que incluye la sobreexplotación sin prácticas de manejo forestal, el sobrepastoreo y la tala ilegal (Kometter y Reynel, 2020).

1.1.5 Árboles plus – arboles semilleros

Los árboles plus, también conocidos como árboles semilleros, árboles marco o árboles de élite son aquellos con buenas características para la producción de semillas (Pommerening et al., 2021). Una representación gráfica se muestra en la Figura 8.

La selección se realiza en base a características como una copa grande y densa, fustes saludables; así como otros factores culturales, ambientales, económicos, valor estético, espiritual, etc.(Pommerening et al., 2021). Estos criterios son flexibles y pueden modificarse según los cambios en los objetivos de gestión forestal, el clima, las expectativas sociales y la adaptabilidad a las condiciones biofísicas de la zona (Dieng et al., 2023).

En el caso específico de especies como *Prosopis*, donde solo algunas tienen importancia económica, la selección se basa en la variabilidad significativa en productividad y uso, destacándose especies como *P. pallida* (Pasiiecznik, Felker, et al., 2001). En la gestión de bosques de algarrobos, la identificación de árboles sobresalientes se realiza considerando características como la velocidad de crecimiento, productividad en frutos, volumen foliar, entre otros, con el objetivo de reducir la mortalidad de estos bosques.

Figura 8

Ejemplo ilustrativo de árboles plus (más robustos) y no plus



Nota. Tomado de Pommerening et al. (2021).

1.1.6 Sistemas de monitorización de bosques

A. Metodología tradicional

Inventario de campo como se muestra en la (Figura 9)

Muestreo de parcelas: Implica la selección cuidadosa y medición de parcelas representativas en una región boscosa, recolectando datos detallados sobre la composición de especies, densidad, diámetro del tronco, altura y otros parámetros, utilizándolos de manera integral para estimar con precisión las características del bosque en su conjunto (Aguirre et al., 2023).

Encuestas tipo Inventario Forestal: Evalúan todos los recursos, abordando diferentes formaciones en grandes parcelas distribuidas sistemáticamente (Schnell et al., 2015). Cada conglomerado consta de cuatro subparcelas rectangulares y mide todos los árboles por encima de un umbral de diámetro, registrando variables como diámetro, altura, especie, productos y servicios (Schnell et al., 2015). Ofrecen una evaluación detallada de recursos a nivel nacional, regional o local, facilitando una gestión sostenible y bien informada de estos ecosistemas (Crespo Lera, 2023).

Unidades de Muestreo: Enfocadas en áreas específicas de interés, emplean muestreo aleatorio y técnicas específicas para incluir elementos poblacionales en la unidad de muestreo (Schnell et al., 2015). Pueden variar en formas geométricas y tamaños, con subparcelas y patrones

espaciales. Se aplican también unidades especializadas, como líneas de muestreo, destinadas a estimar características lineales de la población (Schnell et al., 2015).

Figura 9

Monitoreo convencional de bosques



Nota. Tomado de Cortés (2023).

En cuanto a la Teledetección se utilizan sensores Pasivos: Distinción entre datos ópticos de resolución media y alta. Los primeros se centran en áreas agrícolas y asentamientos urbanos para cartografiar la cubierta arbórea, utilizando imágenes de satélites Landsat y SPOT (Schnell et al., 2015). Los segundos emplean datos de imágenes aéreas o de satélites con resolución espacial submétrica, como IKONOS y QuickBird, diferenciando entre interpretación manual de imágenes y clasificación basada en objetos (Schnell et al., 2015).

Sensores Activos: Incluyen técnicas como la detección y alcance de luz (LiDAR) mediante datos de escaneo láser aerotransportado (ALS) y detección y alcance por radio (RADAR) (Schnell et al., 2015).

B. Teledetección

La teledetección es el proceso de obtener información sobre la superficie terrestre sin contacto físico directo; se lleva a cabo mediante el

uso de dispositivos y sensores remotos, como satélites, aviones, drones o sensores terrestres (Weiss et al., 2020). Estos instrumentos miden la radiación electromagnética reflejada o emitida por el objetivo, y la información recopilada depende de las propiedades específicas del instrumento y del dispositivo (Weiss et al., 2020).

En el ámbito de la agricultura, la teledetección desempeña un papel crucial, siendo considerada una de las tecnologías más importantes para la agricultura de precisión y la agricultura inteligente (Tsouros et al., 2019).

Esta tecnología proporciona información espacial y temporal sobre el estado del cultivo de manera no destructiva, facilitando así un manejo sostenible de los cultivos (Tsouros et al., 2019; Weiss et al., 2020).

C. Sistemas de teledetección

Los sistemas de teledetección pueden dividirse de forma general en sistemas pasivos y activos. Los sistemas pasivos de teledetección capturan la energía electromagnética reflejada en las bandas visible, infrarroja cercana (NIR) e infrarroja de onda corta (SWIR), así como la energía electromagnética emitida en las bandas infrarroja térmica (TIR) y microondas (Amani et al., 2020). Por otro lado, los sistemas activos de teledetección se centran principalmente en medir la radiación de retrodispersión proveniente de diversos objetos en la tierra, abarcando diferentes partes del espectro electromagnético (Amani et al., 2020).

D. Drones – Vehículos aéreos no tripulados

Los UAV son plataformas de teledetección portables, flexibles, rápidas, controlables y ofrecen resultados con alta resolución temporal y espacial (González-Jaramillo et al., 2019). Los UAV suelen incluir los siguientes elementos clave: a) uno o más UAV; b) sistema de control del UAV; c) estación de control terrestre como una computadora para comunicarse con el sistema de control del UAV o para controlar y monitorear directamente el UAV; d) sensores o cámaras para la adquisición de datos (Tsouros et al., 2019).

D.1 Tipos de drones (ala fija, ala móvil)

Los UAV multirrotor, caracterizados por múltiples hélices giratorias, abarca UAV de ala giratoria con cuatro o más rotores, como cuadricópteros, hexacópteros u octocópteros (Tsouros et al., 2019). Su eficiencia energética no destaca y su duración de vuelo es limitada, pero su capacidad para ajustar independientemente la velocidad de rotación de cada rotor permite una rápida recuperación de la altitud y actitud en caso de perturbaciones (Z. Zhang y Zhu, 2023).

Los UAV de ala fija, similares en estructura a los aviones convencionales, generan fuerza de sustentación a través de alas fijas durante el movimiento hacia adelante (Z. Zhang y Zhu, 2023). Aunque requieren pista para despegue y aterrizaje, y su aterrizaje es más complicado de controlar que el de los UAV multirrotor, ofrecen ventajas como mayor velocidad y duración de vuelo. Son más costosos que otros tipos (Tsouros et al., 2019).

Los UAV híbridos, también conocidos como despegue y aterrizaje vertical, combinan las características de los UAV multirrotor y de ala fija. Estos despegan y aterrizan en modo multirrotor y vuelan en modo de ala fija, ofreciendo un fácil control durante el despegue y el aterrizaje, así como ahorro de energía (Z. Zhang y Zhu, 2023). No vuelan a altas velocidades ni por largos períodos, pero son menos costosos y adecuados para áreas no muy extensas (Tsouros et al., 2019).

Los dirigibles, seguros y más ligeros que el aire, vuelan a bajas velocidades y son de mayor tamaño en comparación con otros UAV. Su diseño les permite permanecer en el aire incluso sin potencia (Tsouros et al., 2019).

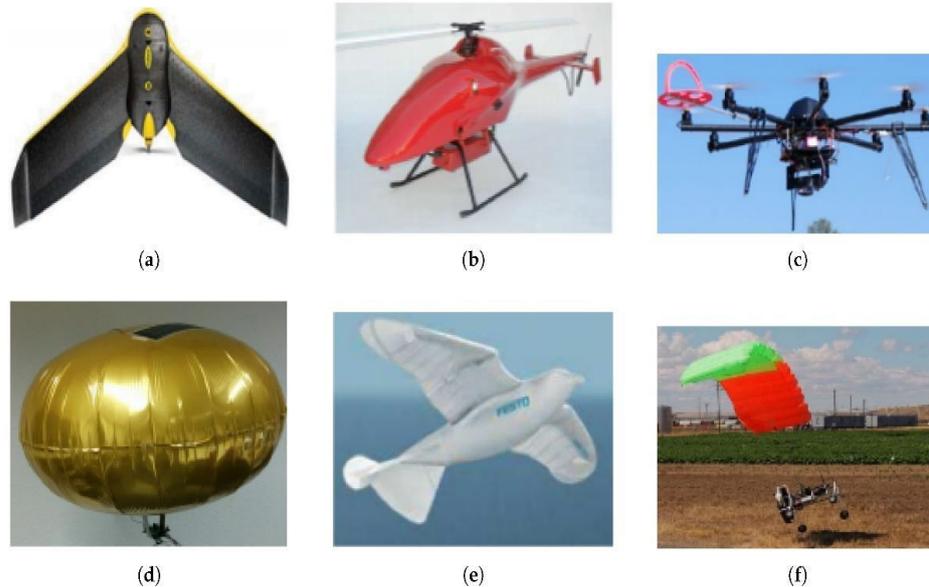
Los UAV de ala batiente, pequeños y con alas flexibles inspiradas en pájaros e insectos, se caracterizan por su alto consumo energético (Tsouros et al., 2019).

Los UAV con ala de parafoil, que cuentan con hélices traseras para controlar el rumbo y aprovechar la fuerza del aire, son capaces de

transportar una carga útil mayor y con alta eficiencia energética (Tsouros et al., 2019).

Figura 10

UAVs con ala fija (a), híbrido (b), multirrotor (c), dirigible (d) con ala batiente (e), con ala de parafoil (f)



Nota. Tomado de Tsouros et al. (2019).

D.2 Sistemas RGB

Los sensores RGB (Figura 11), que capturan información en las bandas roja, verde y azul del espectro visible, son ampliamente empleados en sistemas UAV para aplicaciones de agricultura de precisión (Tsouros et al., 2019). Las cámaras RGB presentan dos tipos comunes en estas plataformas. Primero, están las cámaras integradas en el UAV, montadas mediante cardanes y con resoluciones superiores a 20 megapíxeles (Z. Zhang y Zhu, 2023). Estas cámaras ofrecen imágenes de alta resolución a altas velocidades de cuadro, pero muestran imposibilidad de cambiar la lente original, lo que restringe su versatilidad para entornos remotos y de gran angular. En segundo lugar, las cámaras réflex de lente única ofrecen flexibilidad en la sustitución de lentes con diferentes distancias focales (Z. Zhang y Zhu, 2023). Aunque son aptas para la detección remota o la observación de gran angular, son más pesadas y requieren cardanes para

su instalación, lo que implica que el UAV deba ser lo suficientemente grande y tener capacidad de carga adecuada para (Z. Zhang y Zhu, 2023).

Figura 11

Ejemplo de sensor RGB usado por UAV



Nota. Tomado de Tsouros et al. (2019).

A pesar de su asequibilidad, capacidad para obtener imágenes de alta resolución y facilidad de operación y procesamiento, los sistemas RGB no son idóneos para analizar parámetros de la vegetación que requieren información del espectro no visible (Tsouros et al., 2019). Por ello, suelen combinarse con otros tipos de sensores para obtener información más completa (Tsouros et al., 2019).

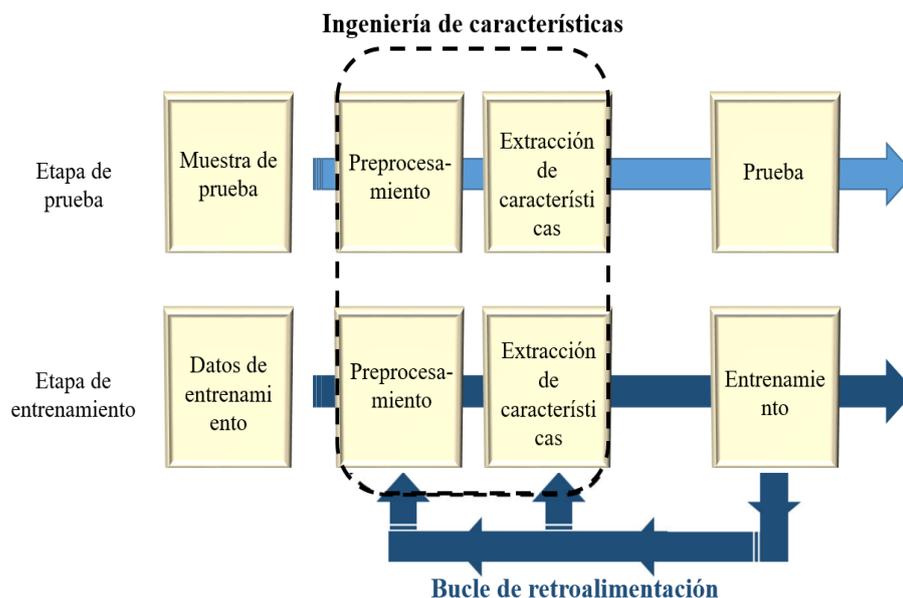
1.1.7 Análisis de imágenes

A. Aprendizaje máquina – Sistemas expertos

Los sistemas de teledetección generan un gran volumen de datos espectrales, por lo que se requieren técnicas de procesamiento de datos para extraer información útil y ayudar a la toma de decisiones (Sishodia et al., 2020). El aprendizaje automático (ML) es una herramienta poderosa cada vez más empleada para mapear y comprender los recursos forestales (Chehreh et al., 2023). La Figura 12 muestra un flujograma común de aplicación de aprendizaje automático.

Figura 12

Ilustración de un sistema común de aprendizaje automático



Nota. Tomado de Benos et al. (2021).

El ML se ha consolidado como una herramienta esencial en diversos sectores, incluyendo sistemas médicos, marketing y biología, con aplicaciones significativas que transforman la forma en que se procesan los datos y se realizan predicciones (Tsouros et al., 2019). En el contexto de la agricultura de precisión, el ML desempeña un papel crucial al analizar la información recopilada por UAVs. Su capacidad para estimar parámetros de crecimiento, identificar enfermedades y discriminar objetos en imágenes ha revolucionado la gestión agrícola, permitiendo una toma de decisiones más informada y eficiente (Tsouros et al., 2019).

Los algoritmos de ML están diseñados para optimizar el rendimiento a través de la exploración de ejemplos y experiencias previas (Benos et al., 2021). El proceso de ML implica una fase de aprendizaje y otra de prueba, donde el modelo desarrollado se enfrenta a datos no vistos anteriormente, destacando la importancia de su adaptabilidad y aplicación a situaciones diversas (Benos et al., 2021).

El preprocesamiento de datos adquiere un papel crítico en el resultado final. Comprende acciones como limpieza, integración y

transformación de datos, esenciales para garantizar la calidad y utilidad de la información que alimenta el modelo de ML (Benos et al., 2021).

Los algoritmos de ML se clasifican en aprendizaje supervisado y no supervisado (Chehreh et al., 2023). El aprendizaje no supervisado se destaca por su capacidad para identificar patrones en conjuntos de datos no clasificados ni etiquetados. En contraste, el aprendizaje supervisado utiliza conjuntos de datos etiquetados para entrenar algoritmos, lo que resulta en la capacidad de clasificar datos o predecir resultados con mayor precisión (Chehreh et al., 2023).

B. Deep Learning - Redes convolucionales

El aprendizaje profundo es un subcampo del aprendizaje automático que emplea arquitecturas (redes) más complejas y avanzadas para desplazar el proceso de extracción de características de interés y enfocarse en el sistema de aprendizaje (Benos et al., 2021). Otras características del aprendizaje profundo que lo diferencian del aprendizaje automático es que a) la arquitectura es muy similar a la de un cerebro al contar con múltiples capas y neuronas interconectadas, b) puede por sí solo extraer características (durante el proceso de entrenamiento) ocultas de datos y patrones distintivos e importantes, c) al no producir muchos parámetros, no hay riesgo de sobreajuste, y d) no se necesita un preprocesamiento ni conocimiento previo (Debus et al., 2021).

Las redes neuronales convolucionales (CNN) son una categoría destacada de algoritmos de aprendizaje profundo ampliamente utilizada en el análisis de imágenes, especialmente en el sector forestal, donde han demostrado ser altamente efectivas en la identificación y segmentación de árboles a partir de imágenes de UAVs (Chehreh et al., 2023). La denominación "convolucional" implica deslizar un pequeño núcleo o filtro sobre los datos de entrada, multiplicando elementos y sumando resultados en diferentes posiciones, generando así un mapa de características que codifica la presencia y fuerza de ciertas características en los datos originales (Chehreh et al., 2023). En este proceso, la primera capa tiende a aprender características de bajo nivel, como bordes y esquinas, mientras

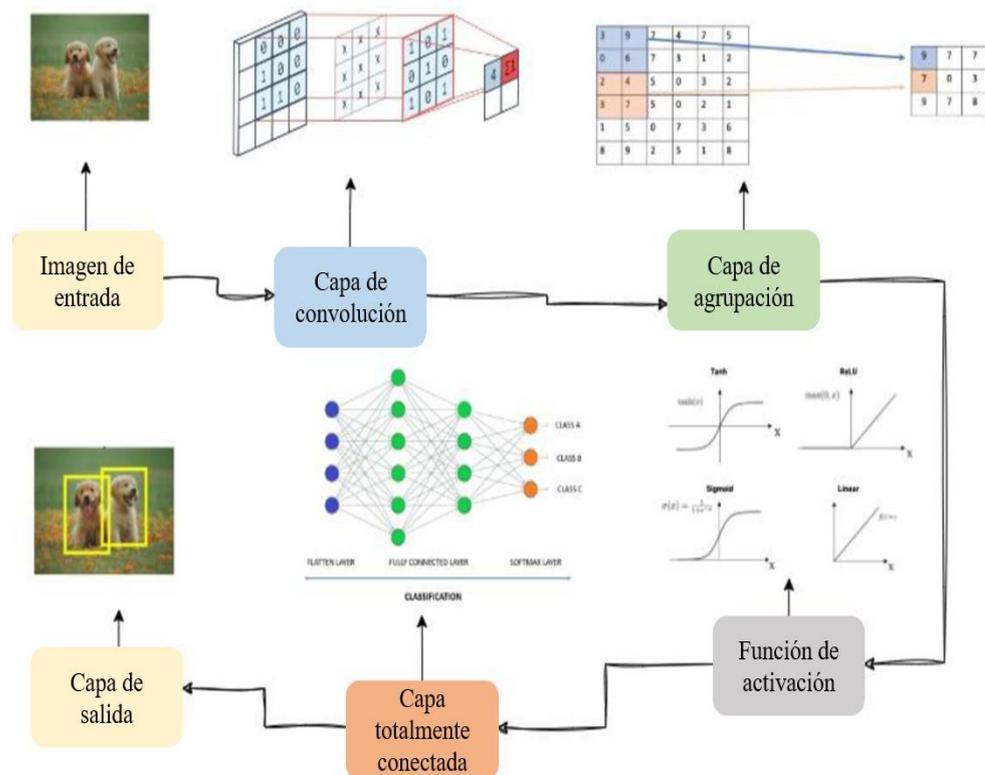
que las capas más profundas capturan características de nivel superior, como formas y objetos. entrada (Chehreh et al., 2023).

En cuanto a los tipos de capas, se tienen como:

Una CNN normalmente se compone de cuatro tipos de capas: Convolutiva, Pooling, Función de Activación y Totalmente conectada (Taye, 2023) (Figura 13).

Figura 13

Componentes (capas) de una CNN



Nota. Tomado de Taye (2023).

Convolutiva: Constituye un conjunto de filtros o núcleos aplicados a los datos previos a su utilización; cada núcleo, caracterizado por su ancho, alto y peso, desencadena la extracción de características fundamentales de los datos de entrada (Taye, 2023). Inicialmente, los pesos en el núcleo se asignan de manera aleatoria, pero a lo largo del proceso de entrenamiento, se actualizan gradualmente con base en los datos proporcionados (Taye, 2023).

Pooling: La capa de agrupación busca reducir la dimensionalidad de los mapas de características a la vez que preserva la información crucial (Taye, 2023). A través de un filtro que aplica operaciones de agrupación, deslizándose sobre los datos en la capa correspondiente (ya sea máximo, mínimo o promedio) (Taye, 2023).

Función de activación: Sucede a la etapa de convolución en una CNN. Su propósito reside en introducir no linealidades que permitan ajustar o finalizar la salida generada, actuando como un elemento clave para limitar o saturar la salida (Taye, 2023).

Entre las funciones de activación más populares en CNN, se incluyen: a) Sigmoide, que restringe los valores de salida entre 0 y 1 y acepta números reales como entrada; b) Tanh, también acepta números reales como entrada, pero con un rango de salida limitado entre -1 y 1; c) ReLU, convierte todos los valores de entrada al rango positivo. La ventaja principal de ReLU sobre otros algoritmos radica en el ahorro significativo de tiempo y recursos cuando se implementa (Taye, 2023).

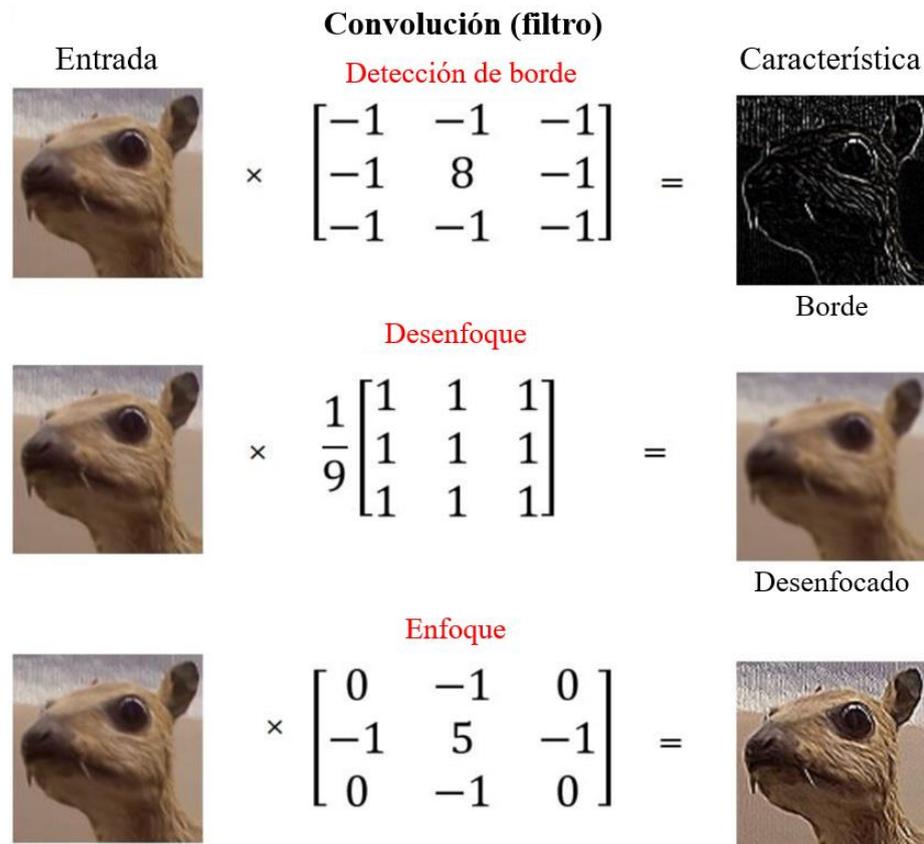
Totalmente conectada: En esta capa, las neuronas se estructuran en conjuntos que evocan la disposición observada en las redes neuronales convencionales (Taye, 2023). Cada nodo que está completamente vinculado, establece una conexión directa con todos los nodos tanto en la capa superior como en la inferior. Cada nodo presente en los últimos marcos de la capa de agrupación se conecta como un vector que se extiende

En cuanto a los tipos de filtros o kernel son una técnica muy popular en el procesamiento de imágenes para realizar operaciones de convolución en los datos de entrada y así extraer características relevantes (Shorten y Khoshgoftaar, 2019) Estos filtros funcionan deslizando una matriz $n \times n$ por una imagen con un filtro de desenfoque gaussiano, que dará como resultado una imagen más borrosa; un filtro de suavizado para suavizar las imágenes o reducir el ruido; un filtro de detección de características para detectar líneas, curvas, esquinas o patrones específicos; o un filtro de bordes verticales u horizontales de alto contraste, que dará como resultado una imagen más nítida a lo largo de los bordes

(Shorten y Khoshgoftaar, 2019). En la Figura 14 se nota el efecto de distintos filtros en una imagen.

Figura 14

Efecto de diferentes matrices de convolución (filtros)



Nota. Tomado de Taye (2023).

Una desventaja de esta técnica es que es muy similar a los mecanismos internos de las CNN; las CNN tienen núcleos paramétricos que aprenden la forma óptima de representar las imágenes capa por capa (Shorten y Khoshgoftaar, 2019).

El entrenamiento desde cero se refiere a la práctica de iniciar y entrenar una red neuronal sin utilizar pesos preentrenados (o información) de modelos existentes. En lugar de aprovechar los pesos aprendidos de un modelo preexistente, se inician todos los pesos de la red desde cero y se ajustan durante el proceso de entrenamiento utilizando el nuevo conjunto de datos.

Este enfoque requiere de suficientes datos de entrenamiento, contrastando con el uso de transferencia de aprendizaje, donde se aprovechan los pesos ya entrenados de una red preexistente (ver en la sección posterior).

La transferencia de aprendizaje automático convencional se destaca por utilizar datos de entrenamiento y datos de prueba que comparten el mismo espacio de características de entrada y distribución de datos (Weiss et al., 2020). No obstante, cuando existe una disparidad en la distribución de datos entre estos dos conjuntos, los resultados predictivos del modelo pueden sufrir degradación. Esta discrepancia puede surgir cuando resulta complicado y costoso obtener datos de entrenamiento que coincidan tanto en el espacio de características como en la distribución de datos prevista para el conjunto de prueba. Para abordar este desafío, surge la motivación detrás del aprendizaje por transferencia (Weiss et al., 2020).

El aprendizaje por transferencia se emplea para potenciar el rendimiento de un modelo en un dominio de destino al transferir información desde un dominio relacionado (Weiss et al., 2020). Para comprender esta práctica, se puede recurrir a analogías del mundo real como, por ejemplo, dos personas que desean aprender a tocar el piano: una sin experiencia musical previa y la otra con un conocimiento extenso de tocar la guitarra. La persona con experiencia musical previa puede aprender a tocar el piano de manera más eficiente transfiriendo los conocimientos adquiridos al aprender a tocar la guitarra (Weiss et al., 2020). En esencia, el aprendizaje por transferencia permite utilizar experiencias previas en tareas relacionadas para mejorar el desempeño en una nueva tarea (Weiss et al., 2020).

C. Redes comúnmente utilizadas- estructura

Las CNN han desempeñado un papel significativo en diversas áreas, incluyendo la clasificación y la identificación de imágenes, estableciéndose como normas de amplio reconocimiento (Dhillon y Verma, 2020). Los principales modelos de CNN son LeNet, AlexNet, ZFNet, GoogleNet, VGGNet, ResNet, Modelo Inception, ResNeXt,

SENet, MobileNet V1/V2, DenseNet, Modelo Xception, NASNet/PNASNet/ENASNet y EfcientNet (Dhillon y Verma, 2020). Algunos de los modelos más empleados se detallan a continuación.

C.1 AlexNet

Es el modelo pionero que inició con la investigación en visión por computadora (Chou et al., 2023). Este modelo implementa capas de abandono específicamente diseñadas para abordar el problema de la sobrecarga de datos de entrenamiento. Su entrenamiento se realiza mediante descenso de gradiente estocástico por lotes, utilizando valores particulares para el decaimiento del peso y el impulso, durante un período de 5-6 días en dos GPUs GTX 580 (Dhillon y Verma, 2020).

C.2 DenseNet

Es la abreviatura de Densely Connected Convolutional Networks que se destaca por su enfoque en la densa conectividad entre capas (Huang et al., 2017). Presenta una estructura única en la que cada capa está acoplada de forma retroalimentada (feed forward), generando $L(L+1)/2$ conexiones directas entre las capas (Dhillon y Verma, 2020). Esta peculiaridad permite la concatenación de mapas de características de salida y entrada, posibilitando que cada capa adquiera conocimiento colectivo de todas las capas anteriores. (Dhillon y Verma, 2020).

C.3 MobileNet

Fue diseñada específicamente para la implementación eficiente en dispositivos móviles con recursos computacionales (Zang et al., 2022).

Presenta las versiones 1 (V1) y 2 (V2), la V1 utiliza una arquitectura con 30 capas, incorporando capas convolucionales con stride 2, capas depthwise y capas pointwise (Dhillon y Verma, 2020). La V2 introduce cuellos de botella lineales y conexiones de acceso directo entre los mismos, utilizando convoluciones separables en profundidad y ofreciendo una mayor eficiencia (Dhillon y Verma, 2020).

C.4 GoogleNet

Es la factorización de las capas convolucionales; en lugar de aplicar una convolución directa, GoogleNet utiliza convoluciones 1x1 (conocidas como convoluciones de punto) seguidas de convoluciones 3x3 o 5x5 para reducir el número de parámetros, al tiempo que mantiene la capacidad de aprendizaje de características complejas (Szegedy et al., 2016).

Su innovación radica en el "módulo de inicio", un bloque de construcción que optimiza los recursos computacionales al considerar mayor profundidad y anchura del modelo, rompiendo con la estructura secuencial convencional al evitar simplemente apilar capas de convolución y agrupación (Dhillon y Verma, 2020).

1.2 Antecedentes

1.2.1 Internacionales

A nivel mundial se han empleado imágenes satelitales para el mapeo y posterior gestión de los recursos forestales. Para la discriminación o predicción de atributos en específico, mayoritariamente se han empleado algoritmos de aprendizaje automático. Por ejemplo, Adam et al. (2017) mapearon la distribución de *P. glandulosa* en ambientes semiáridos en Sudáfrica mediante datos satelitales de WorldView-2 acoplados a modelos de máquinas de vectores de soporte (SVM) y bosques aleatorios (RF) con una precisión general del 86%. (Sesnie et al., 2023) utilizaron datos de Sentinel-2 y RapidEye satelitales acoplados a RF, SVM, redes neuronales de regresión cuantil, aumento de gradiente y lineal potenciado de gradiente extremo para mapear tres especies de árboles ecuatorianos, obteniendo valores R^2 de hasta 54%.

1.2.2 Nacionales

En el Perú se han realizado estudios similares. (Barboza et al., 2022) determinaron los cambios en el uso y cobertura del suelo en el bosque seco de Tumbes utilizando imágenes de Sentinel 2 y modelos de RF con precisiones superiores al 89%. Fremout et al. (2022) usaron datos de Sentinel-1 y Sentinel-2

con modelos de RF para estimar la biomasa área y la cubierta leñosa del bosque seco tropical en Lambayeque que incluía especies como *P. pallida*. Se lograron predicciones con R^2 de 81% para la cubierta leñosa y 27% para la biomasa aérea.

Aunque las imágenes satelitales han proporcionado buenos resultados, muestran ciertas desventajas como, por ejemplo, imágenes con baja resolución, corta disponibilidad para capturar las imágenes necesarias y largo periodo de tiempo para obtenerlas después de su adquisición (Sishodia et al., 2020; Tsouros et al., 2019). Una mejor alternativa es el uso de UAV al ser más seguros, portables, flexibles, versátiles y permiten la incorporación de cámaras con distintas bandas espectrales, lo que proporciona información de mejor calidad (González-Jaramillo et al., 2019). Otro punto importante es si se emplean cámaras RGB que capturan imágenes en el espectro visible o cámaras multiespectrales/hiperespectrales que capturan imágenes en múltiples bandas espectrales para identificar características específicas como especies de vegetación, calidad del agua y distribución de minerales (Z. Zhang y Zhu, 2023).

Effiom et al., (2019) combinaron imágenes RGB adquiridas por UAV y UAV multiespectrales con modelos de SVM, RF y máxima verosimilitud (ML) para identificar especies de árboles en Países Bajos. Se obtuvo mayor precisión (84%) al emplear imágenes multiespectrales con SVM y RT. (González-Jaramillo et al., 2019) estimaron la biomasa de un bosque tropical en Ecuador mediante imágenes RGB y multiespectrales de UAV y el algoritmo Iso Cluster. Se lograron estimaciones con un R^2 de 85% con las imágenes RGB, mientras que, al usar las imágenes multiespectrales, la precisión fue menor por la saturación producto de la densidad del bosque. Pu et al. (2023) usaron UAV con un sensor de 903 nm junto a distintas técnicas de aprendizaje automático para detectar árboles de *Populus deltoides* en China, obteniendo la mejor precisión general con el método de semilla y k-vecino más cercano (k-NN).

En Perú, (Messinger et al. (2016) evaluaron la biomasa y estructura del bosque amazónico en Madre de Dios utilizando imágenes RGB de UAV con modelos de estructura a partir del movimiento, y detección y alcance de luz aerotransportada, obteniendo resultados similares (R^2 desde 54% hasta 89%). Casapia et al. (2020) identificaron palmeras en el bosque húmedo en Loreto con

imágenes RGB de UAV y algoritmos de RF, k-NN, SVM y particionamiento recursivo (RP) con una precisión general del 85% con RF. McNicol et al. (2021) determinaron la estructura forestal del bosque tropical en Madre de Dios mediante imágenes RGB y NIR de UAV junto a un algoritmo multi estéreo, obteniendo valores elevados de sesgo (40-50%). Baena et al. (2018) emplearon con éxito imágenes multiespectrales de UAV y modelos tridimensionales para evaluar la composición y dinámica de las poblaciones de *P. pallida* en el norte peruano, así como identificar y cuantificar árboles antiguos y evaluar su salud en el sur. Baena et al. (2017) identificaron y cuantificaron especies de *P. pallida*, *Colicodendron scabridum* y *Cordia lutea* vivos y especies de *P. pallida* muertos, además de evaluar su salud en el bosque seco de Lambayeque. Se emplearon imágenes multiespectrales de UAV y un algoritmo de clasificación en Arcgis, donde se obtuvo una precisión general de 94,10%.

De acuerdo con Chehreh et al. (2023), para mejorar la precisión en el análisis de imágenes forestales obtenidas por UAV la tendencia es usar arquitecturas de aprendizaje profundo como las CNN.

Marin et al. (2022) identificaron palmas de *Mauritia flexuosa* en bosques de Colombia con una precisión del 98% usando imágenes RGB de UAV y la arquitectura Mask R-CNN. Csillik et al. (2018) combinaron imágenes multiespectrales capturadas por UAV y CNN para identificar árboles de cítricos en Estados Unidos, alcanzando una precisión de 96,24%. Ampatzidis y Partel, (2019) emplearon las mismas técnicas, algoritmos y unidades de estudio, pero para la detección y conteo con una precisión del 99,9%. dos Santos et al., (2019) detectaron árboles cumbaru en Brasil a partir de imágenes RGB de UAV y modelos Faster R-CNN, RetinaNet y YOLOv3. Se obtuvo la mayor precisión (92,64%) con RetinaNet. Ferreira et al. (2020) detectaron palmeras amazónicas en Brasil con imágenes RGB de UAV y CNN con precisiones de 78,6% a 98,6%. Osco et al. (2020) usaron imágenes multiespectrales de UAV y CNN para geolocalizar y contar árboles de cítricos en huertos en Brasil. La precisión (95%) fue mayor al comparar con los enfoques convencionales Faster R-CNN (86%) y RetinaNet (62%). Aeberli et al., (2021) emplearon imágenes multiespectrales de UAV para detectar plantas de *Musa spp.* en Australia. Se obtuvo una precisión del 93% al usar CNN y 86% al emplear coincidencia de plantillas y filtro máximo

local. Olariu et al., (2022) evaluaron la capacidad de las imágenes RGB de UAV para mapear especies de plantas leñosas en Estados Unidos, entre las que se encontraba *P. Glandulosa*. Se emplearon modelos ML, SVM, RF y CNN, y este último proporcionó la precisión general más alta (96,9%).

1.2.3 Locales

En Perú solo existen dos estudios que evaluaron el uso de CNN y UAV, pero sin sensores multiespectrales, además de no enfocarse en el algarrobo, ni otras especies del género *Prosopis*. Salazar Zarzosa et al. (2021) identificaron árboles de aguacate con imágenes RGB de UAV y CNN con una precisión de 98%. (Morales et al., 2018) emplearon imágenes RGB de UAV y CNN para detectar palmeras de *Mauritia flexuosa* jóvenes y adultas, aisladas y parcialmente cubiertas por distintas vegetaciones en Iquitos, logrando una precisión del 98,14%.

Independientemente de si se emplean técnicas de teledetección como UAV, el uso de modelos de CNN con enfoque de aprendizaje de transferencia ha mostrado resultados prometedores en la solución de distintos problemas de clasificación. En India, (Nag et al., 2023) modificaron estructuras de CNN convencionales mediante estrategias de transferencias de aprendizaje, logrando una precisión superior al 95% en todos los modelos, con DenseNet-121 al frente (99,85%). Similarmente, Miraei Ashtiani et al. (2021) probaron el rendimiento de modelos de CNN modificados para detectar etapas de madurez de moras blancas y negras en Irán, obteniendo la precisión más elevada con AlexNet (98,32%) y ResNet-18 (98,65%).

Además de modificar la estructura de los modelos de CNN preentrenados para mejorar el rendimiento, la transferencia de aprendizaje puede implementarse para usar dichas redes como base y desarrollar nuevas arquitecturas. En China, Chou et al. (2023) identificaron enfermedades de hojas del manzano usando CNN convencionales y un modelo propuesto basado en el enfoque de aprendizaje por transferencia, donde este último obtuvo la precisión más elevada con 98,82%. (Zang et al., 2022) desarrollaron nuevas arquitecturas de CNN con base al modelo MobileNet-V2 con fines de reconocimiento de enfermedades de cultivos e identificación de enfermedades de plantas de arroz, respectivamente, en China.

Además, se mejoraron algunas características de la red, logrando alcanzar una precisión superior al 99% en ambos estudios. (Oppong et al., 2022) propusieron una arquitectura de red basada en la extracción de características de diez modelos de CNN previamente entrenadas para identificar plantas medicinales en Ghana. DenseNet201 mostró la precisión más elevada con 87%, mientras que el modelo propuesto, probado con distintos conjuntos de datos, alcanzó una precisión superior, de hasta 98% al 100%. (Alex et al., 2022) propusieron un novedoso modelo multitarea basado en CNN para detectar especies y enfermedades de plantas, alcanzando una precisión del 97% a 98% y de 91% a 99%, respectivamente, para distintos conjuntos de datos.

En consonancia con lo anterior, el propósito del desarrollo de nuevas arquitecturas de CNN no solo debe centrarse en obtener un alto rendimiento, ni su generabilidad en aplicaciones destinadas, sino también en su optimización en términos de tiempo y requerimientos informáticos. Por ejemplo, en el estudio de (X. Zhang et al., (2021) implementaron métodos de identificación de enfermedades vegetales basados en CNN convencionales y una nueva arquitectura utilizando el enfoque de aprendizaje por transferencia. El modelo propuesto alcanzó una precisión del 97,24% y con un tiempo menor de procesamiento de imagen frente a los otros modelos.

Respecto a estudios donde se mejoraron las redes CNN preentrenadas, Wu et al. (2022) entrenaron arquitecturas de CNN para identificar especies de plantas leñosas en Taiwán. El modelo Xception logró la precisión más alta (99,39%), pero la red MobileNet V2 requirió menos tiempo de prueba. En Japón, Suh et al. (2018) evaluaron un procedimiento de transferencia de aprendizaje con tres implementaciones diferentes de la red AlexNet y luego su rendimiento frente a otras arquitecturas de CNN en la clasificación de remolacha azucarera y papa voluntaria. El mejor modelo AlexNet modificado mostró una precisión de 98%, incluso el rendimiento fue ligeramente mayor al modelo AlexNet convencional (97,9%). En general, VGG-19 mostró mejores resultados (98,4%) que todos los modelos, pero su entrenamiento requirió más del 400%. Schröder et al., (2021) evaluaron el potencial de distintas CNN con transferencia de aprendizaje para identificar cuerpos extraños en muestras de quinua en Perú. Se alcanzaron



precisiones que oscilaron entre el 98% y 99%, donde DenseNet-201 mostró los mejores resultados, pero consumía más tiempo de entrenamiento.

CAPÍTULO II

PLANTEAMIENTO DEL PROBLEMA

2.1 Identificación del problema

Los bosques son un componente crítico de la biodiversidad mundial al conformar la mayoría de la biodiversidad terrestre (FAO y PNUMA, 2020). En Perú, los bosques representan el 56% del territorio (CEPLAN, 2023). Los bosques desempeñan diversas funciones ecológicas y económicas importantes, además de brindar múltiples productos para la subsistencia y para las demandas internacionales (Stan y Sanchez-Azofeifa, 2019). Sin embargo, actualmente la biodiversidad está comprometida significativamente por el avance de la deforestación y la degradación forestal (FAO y PNUMA, 2020).

La deforestación y la degradación forestal reducen la densidad de biomasa y son contribuyentes clave de las emisiones de gases de efecto invernadero (Jiménez-Rodríguez et al., 2022). De 2010 a 2020, la superficie forestal se redujo en 4,7 millones de hectáreas anualmente en todo el mundo (FAO y PNUMA, 2020). Después de África, en América del Sur se registró la mayor pérdida neta de superficie forestal (2,6 millones de hectáreas al año) en el mismo periodo (FAO y PNUMA, 2020). Específicamente en Perú, la tasa de deforestación más alta en los últimos 20 años se registró el 2020 con una pérdida de 200 mil hectáreas de bosque, lo cual es crítico considerando que alrededor de 300 mil personas dependen de los recursos y servicios ecosistémicos que brindan los bosques (CEPLAN, 2023).

Los bosques secos (BS) son uno de los ecosistemas forestales de mayor importancia biológica más amenazados; a pesar de ello, son poco estudiados (Stan y Sanchez-Azofeifa, 2019). Los BS abarcan aproximadamente el 42% de los bosques tropicales y contienen altos niveles de biodiversidad, pero solo el 8% están protegidos legalmente y el 2% están intactos (Stan y Sanchez-Azofeifa, 2019). América del Sur es uno de los puntos de mayor concentración de BS; sin embargo, gran parte de ellos están desprotegidos, fragmentados y con riesgo de extinción (Stan y Sanchez-Azofeifa, 2019).

La costa norte del Perú cuenta con más de 3 millones de hectáreas de BS, siendo el sustento de más de 150 comunidades campesinas (Kometter y Reynel, 2020). El algarrobo (*Prosopis pallida*) es un árbol emblemático de estos bosques y tiene una gran importancia económica al brindar recursos valiosos como madera, vainas, hojas, miel y

cera (Pasiecznik, Felker, et al., 2001). Esto lo posiciona como una de las 10 especies forestales con mayor importancia ecológica en el estrato arbóreo y fustal identificadas en la Ecozona Costa del Panel uno del Inventario Nacional Forestal y de Fauna Silvestre (Calderón et al., s/f). Sin embargo, su existencia está siendo amenazada por factores como el cambio climático que ocasiona sequía prolongada y estrés hídrico, por acción de insectos y microorganismos, además de la acción antrópica (Kometter y Reynel, 2020).

Se están aunando esfuerzos para generar estrategias que contribuyan a la gestión y reducción poblacional (mortalidad) de los bosques de algarrobo, destacándose el estudio de “Caracterización de árboles plus de algarrobo género *Prosopis* (Fabaceae) en localidades de la región Piura” por parte de SERFOR en alianza con la Red de Energía del Perú (ISA REP) y el Servicio Nacional de Sanidad Agraria (SENASA) (Calderón et al., s/f). Para abordar este problema, es necesaria la adopción de nuevas tecnologías que permitan optimizar el manejo sostenible de los bosques de algarrobo, así como estudiar su estructura, composición y diversidad, en consonancia con las líneas de investigación prioritarias establecidas en la Agenda Nacional de Investigación Forestal y de Fauna Silvestre 2020 – 2025 (Cortés, 2023). En esta línea, la teledetección combinada con técnicas de inteligencia artificial se muestra como una herramienta eficaz para el monitoreo y gestión de los bosques.

2.2 Enunciados del problema

2.2.1 Problema general

¿La estructura de las redes neuronales convolucionales influye en la discriminación de árboles plus de algarrobo en la zona norte del Perú como estrategia para enfrentar la deforestación y la desertificación?

2.2.2 Problemas específicos

- información espectral de árboles de algarrobo plus y no plus de la zona norte del Perú?
- ¿Qué estructuras de redes convolucionales se pueden diseñar para procesos de clasificación de árboles plus de algarrobo?
- ¿Qué efecto tiene la estructura de redes convolucionales en la clasificación de árboles de algarrobo plus?

2.3 Justificación

Los bosques de algarrobo cumplen un papel esencial en los ecosistemas de bosques secos, además de proporcionar recursos económicos y alimenticios a la población. Sin embargo, su supervivencia se encuentra comprometida por el cambio climático y la deforestación; por lo que se requieren técnicas de monitoreo y evaluación que permitan una adecuada gestión de estas especies. Una estrategia puede ser la identificación y selección de árboles plus para implementar programas de reforestación. Para llevar a cabo esto, la información suele adquirirse mediante estudios terrestres que demandan mucho tiempo y recursos o mediante imágenes satelitales con baja resolución espacial, limitada disponibilidad y poca flexibilidad. La teledetección por vehículos aéreos no tripulados (UAV) es una opción más apropiada, pero comúnmente se les incorpora cámaras RGB y para el análisis se emplean algoritmos de aprendizaje automático que podrían no aprovechar al máximo los datos obtenidos. Recientemente se está haciendo hincapié en el uso de cámaras multispectrales y algoritmos de aprendizaje profundo más robustos, particularmente redes neuronales profundas (CNN). En este sentido, la combinación de CNN e imágenes multispectrales de UAV se muestran como una alternativa prometedora para el monitoreo de especies de algarrobo y así proporcionar información importante para las actividades de restauración y reforestación. Desde el factor económico este estudio brinda metodologías de uso práctico para reconocer a los árboles de algarrobo para que con poca inversión se pueda reforestar los bosque secos del norte peruano con especímenes resistentes al medio ambiente y los inminente veneficios que este genera a los pobladores como la sombra para su ganado, el fruto para alimentar y la madera para cocinar entre otro muchos más.

2.4 Objetivos

2.4.1 Objetivo general

Evaluar el efecto de las estructuras de redes neuronales convolucionales para discriminar árboles plus de algarrobo en la zona norte del Perú como estrategia para enfrentar la deforestación y la desertificación.

2.4.2 Objetivos específicos

- Adquirir imágenes RGB de árboles plus y no plus de algarrobo de la zona norte del Perú

- Diseñar e implementar redes neuronales convolucionales con diferentes estructuras para clasificar árboles plus de algarrobo.
- Evaluar la precisión de las redes neuronales convolucionales diseñadas frente a arquitecturas conocidas para clasificar los árboles de algarrobo.

2.5 Hipótesis

2.5.1 Hipótesis general

La estructura de las redes neuronales convolucionales sí influye en la discriminación de árboles plus de algarrobo en la zona norte del Perú como estrategia para enfrentar la deforestación y la desertificación.

2.5.2 Hipótesis específicas

- La adquisición de imágenes RGB brinda información sobre características específicas y de interés de los árboles de algarrobo plus y no plus de la zona norte del Perú.
- Se pueden diseñar redes convolucionales para procesos de clasificación de árboles plus de algarrobo
- Las redes neuronales convolucionales diseñadas tendrán mejor precisión que las arquitecturas conocidas para clasificar los árboles plus de algarrobo al estar desarrolladas para este fin

CAPÍTULO III

MATERIALES Y MÉTODOS

3.1 Lugar de estudio

Se evaluaron los bosques de algarrobo ubicados en localidades de Tumbes, Piura y Lambayeque para identificar árboles plus o árboles fenotípicamente sobresalientes respecto a los individuos de una población, con una o varias características de interés económico según la propuesta de (I. Roberto et al., 1998) La zona de estudio fue escogida en base a estudios desarrollados por el SERFOR en 2021 y 2022, información relacionada a los ecosistemas de bosques estacionalmente secos asociados a *Prosopis* (K. Roberto y Carlos Reynel, 2022) e imágenes satelitales de libre acceso (Google Earth), donde se determinó que en la costa norte del Perú existe mayor probabilidad de encontrar árboles plus y, por consiguiente, se podrían obtener más muestras y rápidamente. Las localidades específicas se detallan en la Tabla 1 y su georreferencia se muestra en la Figura 15.

Tabla 1

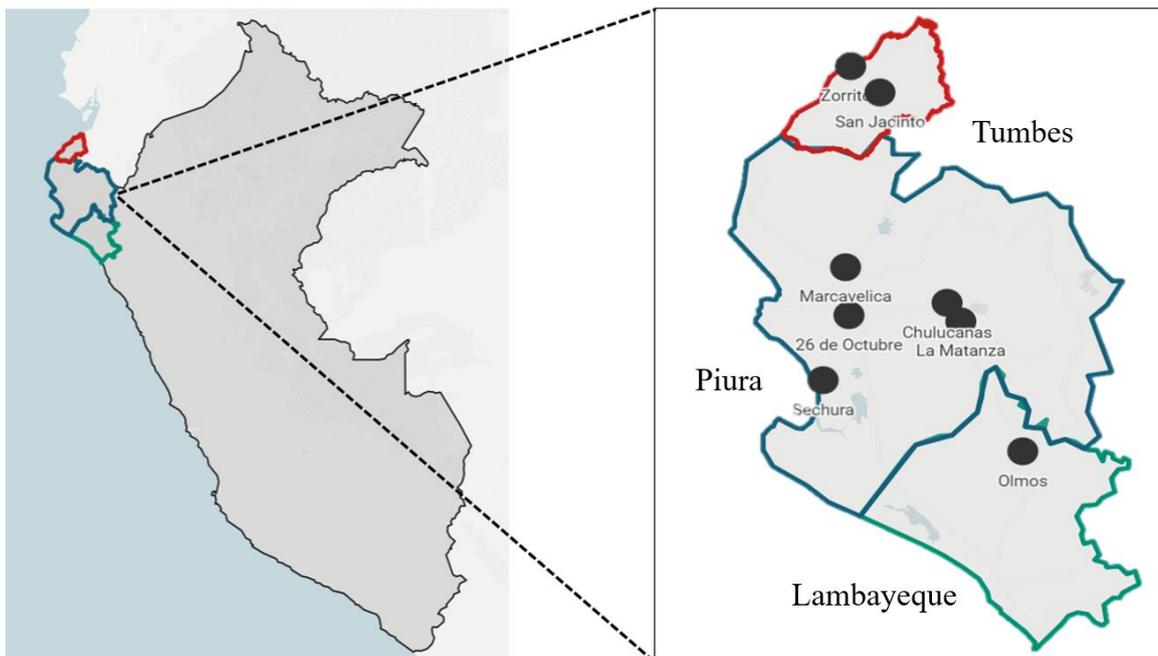
Distritos de la costa norte con alta probabilidad de registro de árboles plus

Departamento	Provincia	Distrito
Tumbes	Contralmirante Villar	Zorritos
	Tumbes	San Jacinto
Piura	Morropón	Chulucanas
		La Matanza
	Piura	Veintiséis de Octubre
	Sechura	Sechura
	Sullana	Marcavelica
Lambayeque	Lambayeque	Olmos

En esta zona el algarrobo tiene un alto valor económico para las comunidades debido al forraje y la producción de frutos; sin embargo, anualmente miles de hectáreas son deforestadas, lo que contribuye progresivamente con la desertificación, cuyo impacto es notable. Por ejemplo, se reportó que en el año 2000 se comercializaban 30 mil toneladas de algarroba, pero a partir del 2014 la cantidad se redujo hasta a menos de 5 mil toneladas (PERÚ, 2014).

Figura 15

Georreferencia de la zona de estudio



3.2 Población

La población está constituida por los árboles de algarrobo (*Prosopis pallida*) ubicados en todo el norte del Perú; los que están constituidos por: 338 árboles no plus y 286 árboles plus, sumando un total de 624 muestras.

3.3 Muestra

Árboles de algarrobos ubicados en Tumbes, Piura y Lambayeque, clasificados y/o identificados como árboles plus o no plus en base a caracteres biológicos y dasométricos según la base de datos proporcionada por la Dirección de Estudios e Investigación – DEI del SERFOR.

3.4 Método de investigación

El estudio es del tipo experimental, ya que implica la evaluación de diferentes estructuras de redes neuronales convolucionales para evaluar su impacto en la discriminación de árboles plus de algarrobo. También es aplicado porque el estudio se realiza con el propósito de encontrar soluciones prácticas y estrategias para la conservación ambiental. A su vez, puede clasificarse como investigación exploratoria por la novedad de las tecnologías aplicadas y por la falta de resultados o antecedentes relacionados previos.

3.5 Descripción detallada de métodos por objetivos específicos

3.5.1 Diseño de muestreo

Se utilizó el plan de gestión de bosques y los mapas de gestión de bosques de SEFOR para ubicar los árboles plus de algarrobo, tomando muestras por conveniencia.

3.5.2 Descripción detallada del uso de materiales, equipos, insumos, entre otros

A. Adquisición de imágenes

Se capturaron 624 imágenes de árboles de algarrobo plus y no plus en las localidades de los distritos propuestos. La identificación de árboles plus y no plus se llevó a cabo según información de los caracteres biológicos y dasométricos.

La toma de imágenes RGB se realizó con un dron cuadricóptero (Figura 16) entre las 9:00 y las 15:00 horas con una altura de vuelo de 50 a 75 metros sobre el nivel del suelo. Cuando las condiciones climáticas impidieron tanto el vuelo de la aeronave o la adquisición de imágenes por parte de esta se aplazó la toma hasta que el clima sea favorable.

El formato de almacenamiento de las fotos fue *.JPEG, obteniéndose al menos dos fotografías por cada árbol seleccionado, codificando las imágenes por zona, fecha y clase. El tamaño de las imágenes fue de 227 x 227 pixeles cada una. La información de latitud y

longitud en grados se determinó mediante sistema GPS (Figura 17) lo cual permitió recortar la imagen y contar con la ubicación real de cada punto en coordenadas en UTM (Universal Transversal de Mercator).

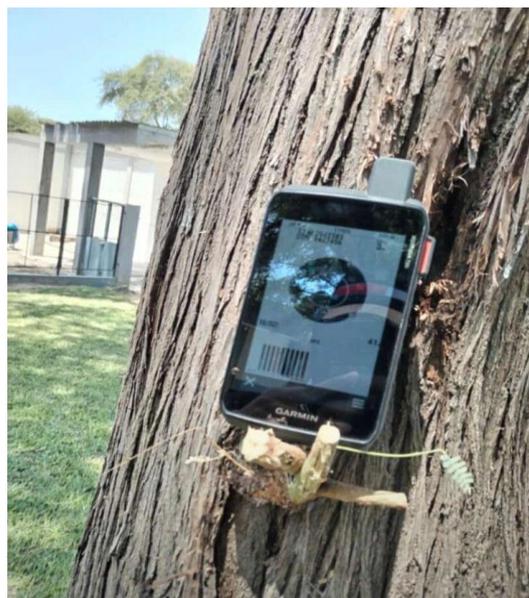
Figura 16

Despegue del dron para la captura de imágenes de los árboles de algarrobo



Figura 17

Geolocalización de los árboles de algarrobo evaluados



Las imágenes se almacenaron en campo en dispositivos de almacenamiento portátil y al acabar el día se transfirieron a sistemas de almacenamiento en nube (NAS) para acceso online desde los laboratorios de la Universidad Nacional de Frontera.

B. Extracción de ROI

Siguiendo la metodología de (Castro et al., 2018; Schröder et al., 2021), para extraer información de las muestras de algarrobo, se delimitaron las Regiones de Interés (ROIs) para

asociar el valor de las combinaciones RGB de cada píxel a la clasificación de los algarrobos plus y no plus.

C. Fenotipado de los árboles de algarrobo

Aprovechando la información morfológica de los árboles adquirida por el UAV se calcularon distintas características de forma, incluyendo el área, eje mayor, eje menor, excentricidad, redondez, solidez, diámetro equivalente y perímetro. El eje mayor se refiere a la dimensión más larga o extensión horizontal de la copa, mientras que el eje menor es la dimensión más corta o extensión vertical de la copa. La excentricidad es la relación entre los ejes mayor y menor. La redondez expresa la circularidad y se basa en la relación entre el producto del área y 4π , con el perímetro. La solidez expresa la convexidad y se define por la relación entre el área de biomasa y el área convexa. El diámetro equivalente se mide como la raíz cuadrada del producto del área de biomasa del árbol y $4/\pi$ (Concepcion II et al., 2020).

D. Segmentación de imágenes

La segmentación de las imágenes es necesaria para eliminar los píxeles no ROI y resaltar los píxeles del árbol, originando imágenes particionadas o segmentos más pequeños y homogéneos. Para segmentar las imágenes de semillas se utilizó el umbral de color en el espacio de color RGB según lo descrito en (Concepcion II et al., 2020) (Fig. 3). El espacio de color tiene tres canales, a saber, rojo, verde y azul, en los que se puede

derivar un histograma sin propiedades de invariancia de la iluminación determinando el número de píxeles que tienen colores en un rango fijo que dependen del número de intervalos.

E. Clasificación de árboles de algarrobo plus y no plus

Se desarrolló e implementó en script de Matlab 2019a un protocolo de procesamiento de imágenes en batch con el cual extraer las bandas RGB (imágenes de intensidad por capa) y, para mejorar la funcionalidad, se desarrolló una interfaz gráfica de usuario (GUI). Se implementaron clasificadores basados en estructuras de redes de convolución como AlexNet, DenseNet, MobileNet y GoogleNet. Su elección se basó en que son sencillas, han sido usadas con éxito ampliamente en problemas de clasificación de imágenes y porque sus arquitecturas se encuentran disponibles en el Deep Learning Toolbox de Matlab.

También se desarrolló e implementó una nueva red a partir de las redes conocidas usando la estrategia de transferencia de datos. Se modificó la respuesta de las últimas capas totalmente conectadas para que respondan a la clasificación de las clases identificadas: Clase a) Árbol normal y Clase b) Árbol Plus y se denominó AlgarroboNet.

3.5.3 Descripción de variables a ser analizados en el objetivo específico

En el primer objetivo “Adquirir imágenes RGB de árboles plus y no plus de algarrobo de la zona norte del Perú” se tuvo en cuenta únicamente el tipo de árbol (plus o no plus). Aunque también se recabó información sobre la ubicación geográfica, esta variable no se tuvo en cuenta en el análisis.

En el segundo objetivo “Diseñar e implementar redes neuronales convolucionales con diferentes estructuras” se evaluaron las distintas redes convolucionales conocidas y una propuesta. No se evaluó la influencia de ninguna característica de la arquitectura como hiperparámetros, función de activación, etc.

En el tercer objetivo “Evaluar la precisión de las redes neuronales convolucionales diseñadas frente a arquitecturas conocidas para clasificar los

árboles de algarrobo” se midió la precisión de las redes convolucionales mediante matrices de confusión y distintas métricas detalladas en la siguiente subsección.

3.5.4 Aplicación de prueba estadística

Considerando la naturaleza del estudio, la “significancia estadística” de la información extraída con estrategias de inteligencia artificial se mide con distintas métricas como se detalla a continuación.

A partir de los resultados obtenidos en la clasificación de imágenes se construyeron matrices de confusión (clases reales y predichas). Se realizaron análisis de clasificación específica de clase para la clase (C_i): las muestras positivas corresponden a la clase $i^{\text{ésima}}$, y las muestras negativas corresponden a todas las demás clases. Al mismo tiempo, los términos verdadero y falso se refieren a muestras clasificadas correcta o incorrectamente. Para evaluar el rendimiento de los modelos se calcularon los siguientes estadísticos:

- Accuracy (o tasa de aciertos) de un clasificador multiclase se calculó como la proporción del número total de predicciones correctas.
- Precisión (o precisión positiva) es el número de muestras de la clase C_i que se clasificaron correctamente con respecto a las muestras que se predijeron como pertenecientes a la clase C_i ya sea correcta o incorrectamente.
- Recall o tasa de verdaderos positivos es una medida de la capacidad del clasificador para seleccionar correctamente instancias de la clase objetivo de aquellas que pertenecen a la misma clase objetivo.
- F-measure o {f-score} es la media armónica de la precisión y el recuerdo y está definida por la ecuación 1.

$$F - measure = 2 \times \frac{Precision \times Recall}{Precision + Recall} \dots \text{Ecuación 1}$$

Debido a la demanda de capacidades de cómputo para el análisis de las estructuras de redes de convolución se usó estrategias de cómputo de alto rendimiento; computación paralela y/o computación en Unidades de Procesamiento Gráfico (GPU). La estadística de comparación se basó en una estrategia de validación cruzada K-fold cross - validation ($k=5$); esta operación se realizó cincuenta veces, aleatorizando los valores de entrada y almacenando las métricas por modelo.

CAPÍTULO IV

RESULTADOS Y DISCUSIÓN

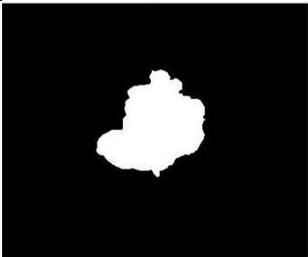
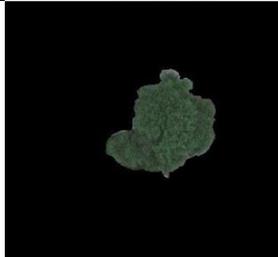
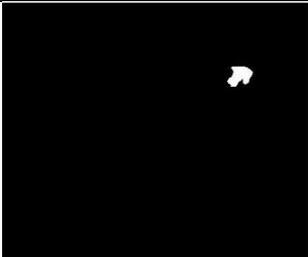
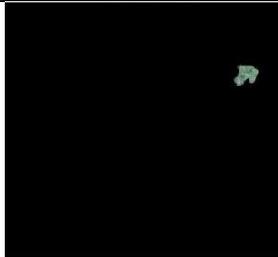
4.1 Resultados

4.1.1 Imágenes RGB de árboles de algarrobo de la zona norte del Perú

La Tabla 2 muestra la representación visual del proceso de captura de imágenes y segmentación. En el primer panel se muestra la imagen RGB capturada por el dron, donde se observan los elementos circundantes del terreno. El segundo panel resalta la Región de Interés (ROI) identificada mediante el procesamiento de la imagen. En el tercer panel se presenta la imagen segmentada, lo que facilitará el análisis posterior.

Tabla 2

Resultados del ROI y segmentación de imágenes RGB de árboles de algarrobo

Tipo de algarrobo	Imagen		
	RGB	ROI	Segmentada
<i>Árbol plus</i>			
<i>Árbol no plus</i>			

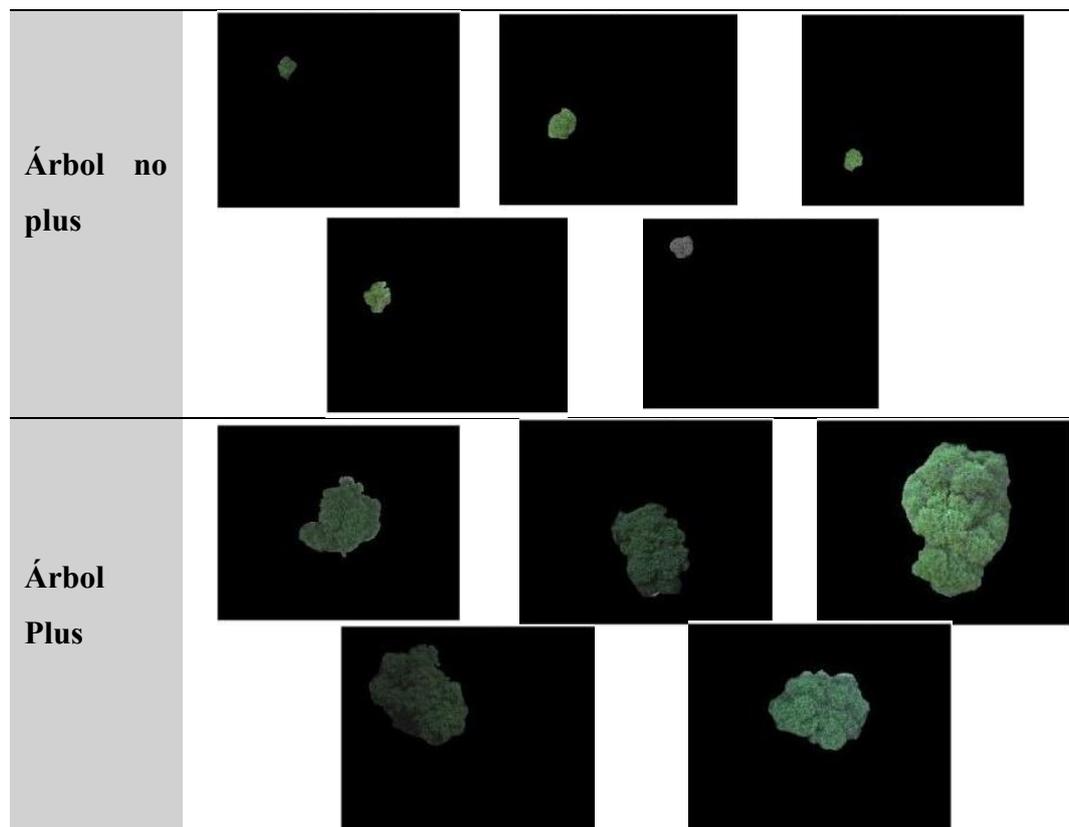
La ROI es prácticamente el componente o superficie donde se ubica el objeto de interés (los árboles de algarrobo, en estos casos), mientras que el fondo es la región restante (Xiao et al., 2024). Como valores de entrada para las redes neuronales pueden emplearse las imágenes ROI, pero los algoritmos pueden

clasificar erróneamente algunas partes del fondo como el objeto de interés; por lo que para abordar esta problemática y separar el objetivo del fondo se hace uso de la segmentación (X. Zhang et al., 2021).

A pesar de las diferencias en la forma y color de los árboles de algarrobo, así como en las disparidades del entorno, el potencial de identificación de la ROI deseada es alto, lo que se transmite en una correcta segmentación. El procesamiento de las imágenes fue capaz de eliminar la iluminación y distinguir las oclusiones que son obligatorias para el análisis de imágenes en esta etapa, lo cual se muestra en la Tabla 3, donde se revelan otras imágenes segmentadas de árboles plus y no plus. La detección precisa de los árboles de algarrobo es vital para la clasificación de sus clases y también resulta útil para evaluar sus características morfogeométricas y otros parámetros de interés.

Tabla 3

Imágenes segmentadas de árboles no plus (sección superior) y plus (sección inferior)



Como resultado adicional, las diferencias en las características morfológicas de los algarrobos plus y no plus se detallan en la Tabla 4 y se muestran gráficamente en la Figura 18, pero con más detalle se muestra en el Anexo 3

Tabla 4

Comparación entre las características morfológicas de los árboles de algarrobo plus y no plus

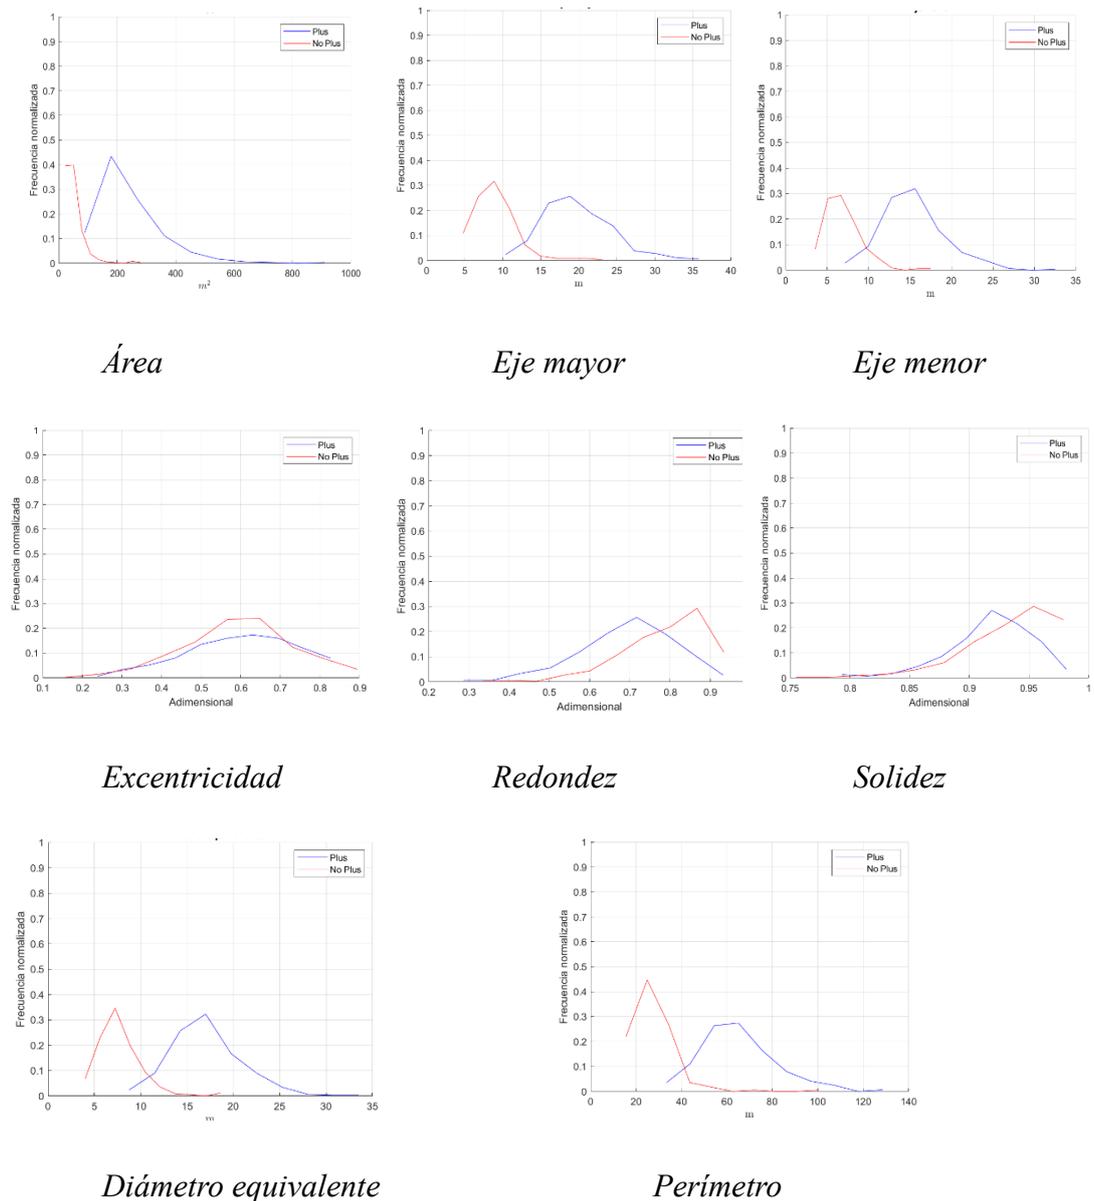
Parámetros	Algarrobo plus		Algarrobo no plus	
	Promedio	Desv. estándar	Promedio	Desv. estándar
Área (m ²)	238,5	115,0	50,6	36,6
Eje mayor (m)	19,7	4,6	8,9	2,9
Eje menor (m)	15,3	3,8	6,9	2,3
Excentricidad	0,599	0,140	0,597	0,143
Circularidad	0,695	0,120	0,788	0,111
Solidez	0,918	0,036	0,935	0,039
Diámetro equivalente (m)	17,0	3,9	7,7	2,4
Perímetro (m)	64,8	16,6	27,5	10,5

En otros estudios también se ha usado UAV para el fenotipado de diversas especies herbáceas en campo (Guo et al., 2020). La evaluación de estas propiedades se ha usado con éxito junto a redes neuronales convolucionales para la clasificación de elementos microestructurales del tejido vegetal de la calabaza (Oblitas et al., 2021) y para el estudio de la relación microestructura-propiedad-proceso de fritura de papa (OBLITAS-CRUZ et al., 2023). Junto a otros algoritmos de aprendizaje automático y profundo también se reportaron estudios sobre la detección y clasificación de frutas (Bhargava y Bansal, 2020),

clasificación de variedades de frijol seco (Mendigoria et al., 2021), detección de insectos en cultivos extensivos (Kasinathan et al., 2021), y clasificación de semillas de maíz (Javanmardi et al., 2021).

Figura 18

Representación gráfica de las características morfológicas de los árboles de algarrobo plus y no plus



Por otro lado, otros autores han usado las características morfológicas evaluadas mediante UAV con sensor RGB como valores de entrada para modelos de identificación de coronas de piña (Wan Nurazwin Syazwani et al., 2022),

detección de cabezas de sorgo (Gonzalo-Martín et al., 2021), y recuento de masas de algodón (Feng et al., 2019).

De acuerdo con la Figura 18, en su mayoría, los algarrobos plus presentaron mayor área que los algarrobo no plus, ambos con sesgo positivo a la derecha. El eje mayor y el eje menor de los algarrobos plus tienen un comportamiento similar a la distribución normal, siendo mayor a los valores de los algarrobos no plus, los cuales presentaron sesgo positivo a la derecha. Sin embargo, los ejemplares plus con las mejores características muestran frecuencias sumamente bajas ($< 0,1$).

Por otro lado, ambas clases de algarrobos presentan solapamiento y distribuciones similares respecto a la excentricidad con ligero sesgo negativo a la izquierda; así como en la redondez y solidez, ambos con mayor sesgo negativo a la izquierda. Los algarrobos plus presentaron mayor excentricidad que los algarrobos no plus, pero menor redondez y solidez con distribuciones similares y vasto solapamiento. En general, ninguna característica en específico puede permitir la diferenciación cualitativa de las clases de algarrobo y no podrían usarse como valores de entrada para los modelos de clasificación. Por lo tanto, para este fin se planteó el uso de los valores RGB y técnicas multivariantes de aprendizaje profundo.

4.1.2 Diseño e implementación de las redes neuronales convolucionales

Se hizo uso de la Caja de herramientas de Matlab Deep Network Designer, la cual permite crear, visualizar, editar y entrenar redes de aprendizaje automático. En este caso se usaron AlexNet, DenseNet, MobileNet y GoogleNet, redes neuronales de clasificación de imágenes preentrenadas que ya hayan aprendido a extraer características potentes e informativas a partir de imágenes naturales y utilizarlas para la clasificación de árboles de algarrobo plus y no plus. Este tipo de redes preentrenadas son muy útiles en casos en los que faltan muestras de datos (Alzubaidi et al., 2021). Además, considerando que se pretende que las técnicas propuestas en este estudio sean escaladas para su uso masivo, estas redes facilitan el proceso (Alzubaidi et al., 2021).

El alto rendimiento de estas redes se garantiza por su entrenamiento con más de un millón de imágenes distribuidas en más de mil categorías, cuyo conjunto de datos se utilizaron en el desafío de reconocimiento visual a gran escala de ImageNet (ImageNet Large-Scale Visual Recognition Challenge [ILSVRC]) (Russakovsky et al., 2015).

Otra ventaja de utilizar Deep Network Designer es el poder editar la red para transferencia de aprendizaje para crear una red nueva, más generalizable y con mayor rendimiento sin necesidad de entrenarla desde cero. (Chao et al., 2020) obtuvieron 1,35% más de precisión y mayor estabilidad durante el entrenamiento de redes convolucionales al utilizar la transferencia de aprendizaje para identificar enfermedades en hojas del manzano. En el estudio de (Lee et al., 2020), los modelos de CNN usados para caracterizar enfermedades vegetales mostraron una mejor generalización en la adaptación a nuevos datos al implementarse enfoques de aprendizaje por transferencia. En este trabajo también se concluyó que usar modelos con entrenamiento previo reduce el impacto del sobreajuste. Resultados similares obtuvieron (Trang et al., 2019), quienes emplearon CNN con transferencia de aprendizaje para identificar enfermedades del mango, cuya precisión (88,46%) fue similar durante el proceso de entrenamiento y validación, en comparación con otros modelos. En este escenario, se transfirieron las características aprendidas del modelo a la tarea de clasificación de clases de árboles de algarrobo con menos imágenes de entrenamiento. Debido al objeto de estudio, a este nuevo modelo se le denominó AlgarroboNet, cuya arquitectura se muestra en la Figura 19.

El detalle de las capas que conforma AlgarroboNet se muestra en la Figura 20 y con más precisión en el Anexo 4, donde a) Imagen Input, es la capa de entrada de la red donde se introducen las imágenes de algarrobo plus y no plus que se van a procesar; b) 2-D Convolution, realiza la convolución de la imagen de entrada con filtros para extraer características; c) Batch Normalization, normaliza las activaciones para acelerar el entrenamiento y mejorar la estabilidad; d) ReLU (unidades lineales rectificadas), aplica la función de activación ReLU para introducir no linealidades en la red; e) Fully Connected, conecta todas las activaciones de la capa anterior a cada neurona de esta capa, introduciendo la capacidad de aprender combinaciones lineales de características; f) Softmax,

aplica la función softmax para convertir las activaciones en probabilidades; g) Classification Output, representa la capa de salida de la red que produce las probabilidades finales para cada clase. Las activaciones son las salidas de las unidades o neuronas y representan la información aprendida y procesada por la red a medida que se alimenta con datos.

Figura 19

Arquitectura de la red propuesta AlgarroboNet

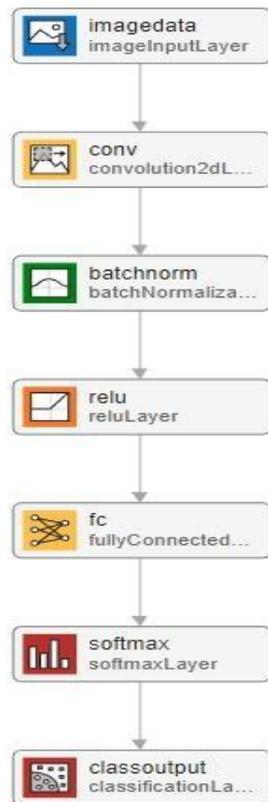


Figura 20

Características de las capas de la red convolucional propuesta AlgarroboNet

Analysis for training in Deep Network Designer
 Name: Network from Deep Network Designer
 Analysis date: 15-Dec-2023 05:16:49 10.9M
total trainable

Name	Type	Activations	Learnable Properties	States
1 imagedata 227x227x3 images with 'zerocenter' nor...	Image Input	227(5) × 227(5) × 3(C) × 1(B)	-	-
2 conv 110 5x5 convolutions with stride [1] an...	2-D Convolution	223(5) × 223(5) × 110(C) × 1(B)	Heights 5 × 5 × 3 × 110 Bias 1 × 1 × 110	-
3 batchnorm Batch normalization	Batch Normalization	223(5) × 223(5) × 110(C) × 1(B)	Offset 1 × 1 × 110 Scale 1 × 1 × 110	Trained/lean 0 % TrainedVarL 0 %
4 relu ReLU	ReLU	223(5) × 223(5) × 110(C) × 1(B)	-	-
5 fc 2 fully connected layer	Fully Connected	1(5) × 1(5) × 2(C) × 1(B)	Heights 2 × 5470190 Bias 2 × 1	-
6 softmax softmax	Softmax	1(5) × 1(5) × 2(C) × 1(B)	-	-
7 classoutput classificationOutput	Classification Output	1(5) × 1(5) × 2(C) × 1(B)	-	-

Por último, Learnable Properties se refieren a los parámetros de la red (p. ej., pesos y sesgos) que se ajustan durante el proceso de entrenamiento mediante el descenso de gradiente. Estos parámetros se modifican durante el entrenamiento para que la red aprenda a realizar tareas específicas.

4.1.3 Precisión de las redes neuronales convolucionales para clasificar los árboles de algarrobo

Para seguir el progreso del entrenamiento de los modelos, en la Figura 21 se trazó la precisión durante el proceso. La precisión alcanzada para todos los modelos durante el entrenamiento fue cercana al 100%, similar al discriminar la madurez de la morera (Ashtiani et al., 2021), identificar enfermedades de las hojas del manzano (Chao et al., 2020), clasificar enfermedades de plantas (Saleem et al., 2020), identificar especies de plantas leñosas (Wu et al., 2022a).

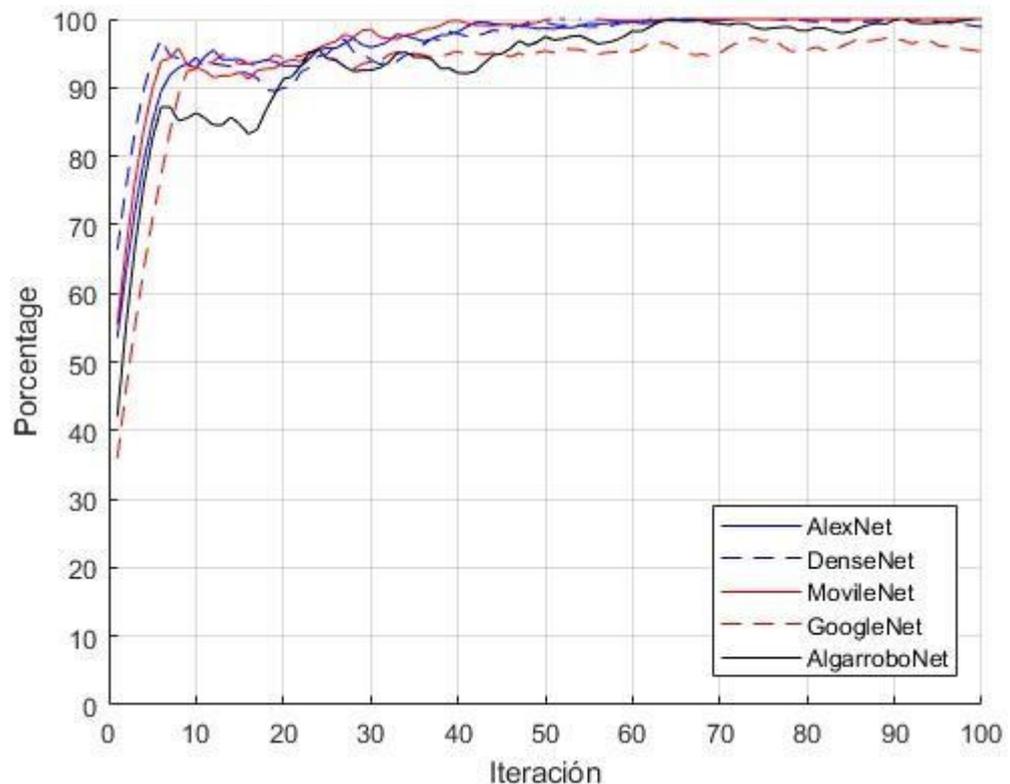
Por otro lado, la precisión de los modelos AlexNet, MobileNet y DenseNet mostraron los mejores resultados con ligeras diferencias al alcanzar la estabilidad a alrededor de 40, 45 y

50 iteraciones, respectivamente. Resultados similares encontraron (Avila-George et al., 2023) al discriminar cuerpos extraños en granos de quinua. GoogleNet mostró el resultado más bajo al alcanzar una precisión de alrededor del 95% a aproximadamente 40 iteraciones.

En general, la precisión suele aumentar con un mayor número de iteraciones. No obstante, después de cierto número de épocas, la precisión del reconocimiento de la red puede estancarse o incluso disminuir (Miraei Ashtiani et al., 2021), lo cual ocurrió al inicio del entrenamiento de AlgarroboNet. Por lo tanto, para lograr la máxima precisión de detección/discriminación se debe monitorear y seleccionar cuidadosamente el número óptimo de iteraciones para entrenar las redes neuronales convolucionales. AlgarroboNet fue más preciso que GoogleNet, pero mostró una alta y evidente inestabilidad durante todo el entrenamiento, llegando a rozar el 100% de precisión a alrededor de 65 iteraciones, disminuyendo progresivamente y volviendo a subir a su máximo a alrededor de 90 iteraciones.

Figura 21

Comparación del rendimiento de los modelos CNN para la discriminación de árboles de algarrobo plus y no plus

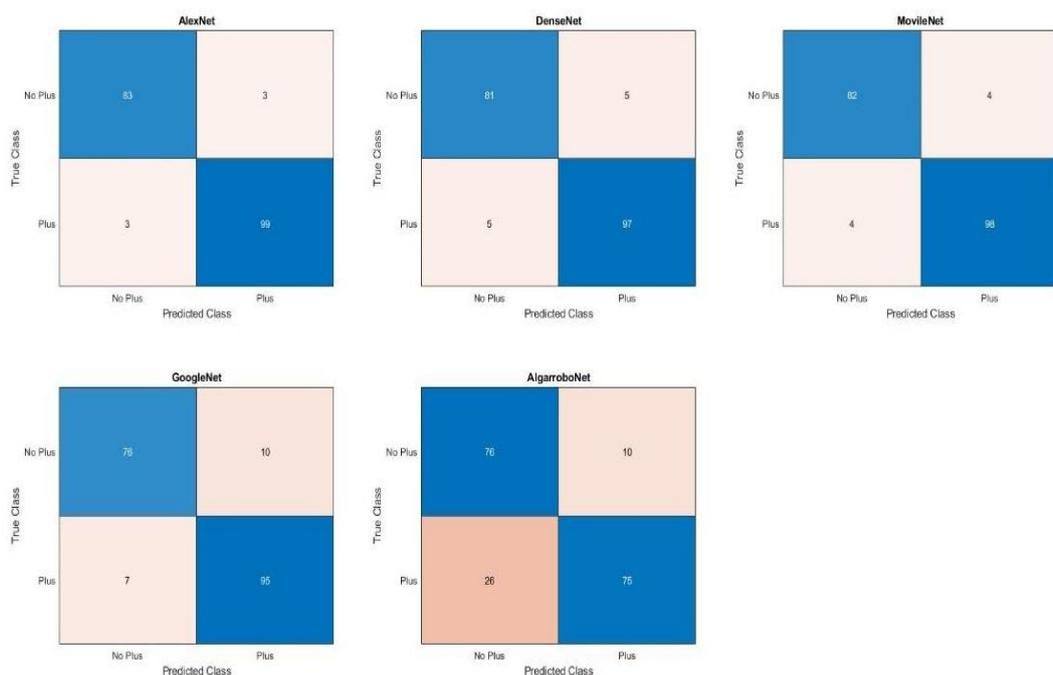


La “ralentización” y “aceleración” en el proceso de aprendizaje de arquitecturas propuestas como AlgarroboNet también fue reportado en un modelo autodiseñado en (Chellapandi et al., 2021). Sin embargo, (Suh et al., 2018) reportaron que, el número de épocas para el entrenamiento depende de la arquitectura de la red, siendo directamente proporcional a su profundidad. Considerando que AlgarroboNet es una red simple, para alcanzar la mayor precisión deseada requirió entrenarse con más iteraciones probablemente por otros factores como el ajuste de los hiperparámetros, los cuales también tienen relación con la estabilidad (Suh et al., 2018). En este sentido, al igual que en (Castro et al., 2024) al evaluar modelos LSTM para discriminar filetes de caballa sometidos a ciclos de congelación-descongelación, para alcanzar modelos AlgarroboNet estables se necesitó un número significativo de iteraciones, haciendo que la capacidad de adaptación a las imágenes utilizadas sea menos eficiente que en los otros modelos usados.

La Figura 22 muestra la matriz de confusión con los resultados de la clasificación de los árboles de algarrobo con los distintos algoritmos, donde las filas representan las categorías originales y las columnas representan las categorías previstas. Con AlexNet se obtuvo los mejores resultados al clasificar correctamente el 96,5% de árboles plus (83 de 86) y el 97,0% de árboles no plus (99 de 102). La clasificación correcta de árboles plus y no plus usando MobileNet fue de 95,3% y 96,1%, mientras que con DenseNet fue de 94,2% y 95,1% y con GoogleNet fue de 91,6% y 90,5%, respectivamente. El algoritmo propuesto, AlgarroboNet, presentó el rendimiento de clasificación más bajo, siendo de 74,5% para clasificar árboles de algarrobo plus y 88,2% para árboles de algarrobo no plus.

Figura 22

Matriz de confusión de los modelos CNN para la discriminación de árboles de algarrobo plus y no plus

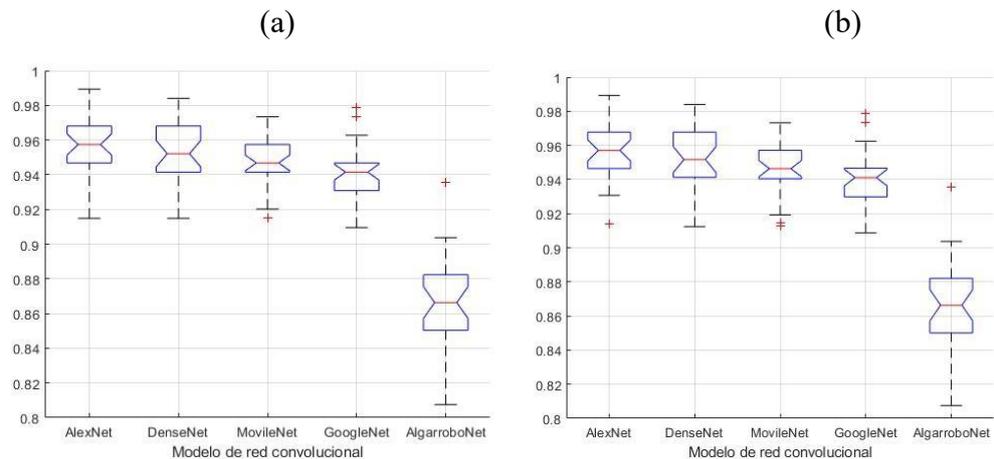


A partir de los resultados mostrados en la matriz de confusión, se calculó la precisión y F-measure (Figura 23) de los modelos. AlexNet mostró los mejores resultados con una precisión y F-measure de 0,96, seguido de DenseNet y MobileNet con un valor medio de 0,95 para ambos parámetros. Por último, GoogleNet arrojó un valor 0,94 para ambas métricas y 0,87 usando AlgarroboNet. Resultados similares se encontraron en investigaciones previas al usar distintas

redes convolucionales en tareas identificación y/o clasificación de especies vegetales mediante imágenes RGB de UAV (Ampatzidis y Partel, 2019; dos Santos et al., 2019; Ferreira et al., 2020; Marin et al., 2022; Morales et al., 2018; Olariu et al., 2022; Salazar Zarzosa et al., 2021).

Figura 23

Precisión (a) y F- measure (b) de los modelos CNN para la discriminación de árboles de algarrobo plus y no plus



A pesar del rendimiento mostrado por los modelos, se evidencia alta variabilidad en los resultados (Figura 23) e incluso valores atípicos, lo que podría deberse a factores como el tamaño insuficiente del conjunto de datos, sensibilidad a los hiperparámetros y problemas de convergencia durante el entrenamiento (Alzubaidi et al., 2021). Teniendo en cuenta que AlexNet contiene muchas menos capas (8) que otras redes, su precisión suele ser sorprendentemente buena (Suh et al., 2018). Sin embargo, a pesar de ello, AlexNet incluye mayor cantidad de parámetros (61 millones), a comparación de DenseNet y MobileNet con 201 capas y 53 capas y 20 millones y 3,5 millones de parámetros, respectivamente. Por lo tanto, al igual que los hallazgos encontrados en (Saleem et al., 2020) al clasificar enfermedades de plantas con redes convolucionales, MobileNet es un modelo comparativamente más preferible debido a su menor número de parámetros, lo que se traduce en una reducción significativa del tiempo de cálculo. Además, este modelo requirió una menor cantidad de iteraciones durante el entrenamiento (Figura 21) para lograr su estabilidad. Resultados contradictorios se encontraron al usar redes convolucionales para identificar plantas medicinales (Oppong et al., 2022), identificar enfermedades del tomate (Nag et al., 2023), discriminar la

madurez de la morera (Miraei Ashtiani et al., 2021), clasificar remolacha azucarera y papa voluntaria (Suh et al., 2018) al definir como mejor modelo a DenseNet201, DenseNet121, ResNet y VGG-19, respectivamente.

La menor precisión de AlgarroboNet también puede deberse al no estar preentrenada con una cantidad masiva de imágenes al igual que los otros modelos. Sin embargo, adquirir y usar una cantidad excesiva de datos representa un problema, por lo que existen técnicas que mejoran el tamaño y los atributos de los conjuntos de datos de entrenamiento como la rotación, traslación, recorte, inyección de ruido y espacio de color (Alzubaidi et al., 2021). En (Chao et al., 2020), la tecnología de aumento de datos hizo que el proceso de entrenamiento de las redes convolucionales sea más estable, con menos sobreajuste y mayor generabilidad, lo que aumentó la precisión para identificar enfermedades en hojas del manzano. En este mismo escenario, Yosinski et al. (2014) reportaron que, la eficacia del aprendizaje por transferencia disminuye si hay menos similitud entre la tarea original de la red y la nueva tarea en cuestión. Al igual que Suh et al. (2018), quienes clasificaron remolacha azucarera y papa voluntaria, todas las redes de este estudio fueron preentrenadas originalmente con ImageNet Dataset, que contenía imágenes de objetos que se encuentran comúnmente en la vida cotidiana, como escritorios, computadoras, animales, etc., bastante diferentes de los árboles de algarrobo.

Asimismo, las características morfogeométricas de los árboles de algarrobo plus y no plus son muy similares (Figura 18), lo que dificultaría su distinción por el modelo (Chao et al., 2020). Sin embargo, el rendimiento de AlgarroboNet sigue siendo prometedor y con potencial de mejora si la red se preentrena con un conjunto de datos de imágenes relacionadas. Por último, el entrenamiento de una red profunda depende de la configuración de otros parámetros, como la tasa de aprendizaje, el impulso y el tamaño del lote (Suh et al., 2018); por lo tanto, debe investigarse su influencia en el rendimiento de AlgarroboNet.

La simplicidad del modelo AlgarroboNet propuesto significó una reducción de la precisión, pero su uso puede trasladarse a dispositivos móviles con memoria y potencia computacional limitadas y en entornos sin disponibilidad de

Internet 4G según lo documentado por (Wu et al., 2022b). En esta línea, el enfoque propuesto está en consonancia con trabajos como (Chen et al., 2021), quienes desarrollaron un modelo CNN simple para identificar enfermedades de cultivos. La diferencia con los resultados obtenidos en este trabajo es que el modelo de Chen et al., (2021) mostró mayor precisión que los modelos convencionales probados, debido a las mejoras realizadas en la capacidad de aprendizaje de la red.

El modelo propuesto por Zhao et al. (2022) desarrollado con un enfoque de transferencia de aprendizaje, para identificar enfermedades vegetales mostró mayor precisión (97,24%) que las arquitecturas CNN convencionales (89,21% a 94,58%), así como menor tiempo de procesamiento por imagen (0,13 s frente a 0,18-1,03 s). Similarmente en CNN preentrenadas, (Wu et al., 2022b) utilizaron distintas CNN para identificar especies de plantas leñosas, obteniendo mayor precisión con Xception (99,39%), pero la red MobileNet V2 (98,73%) requirió menos tiempo de prueba por imagen (53 ms frente a 17.1 ms). Suh et al., (2018) clasificaron remolacha azucarera y papa voluntaria con arquitecturas de CNN, obteniendo la mayor precisión con VGG-19 (98,7%), pero con un tiempo de entrenamiento de 71,4 min. Por otra parte, AlexNet requirió 15,6 min para entrenar y alcanzó una precisión de 97,7%.

Teniendo en cuenta todos los resultados mencionados, el modelo AlgarroboNet sería una solución adecuada para aplicaciones en tiempo real, aunque la precisión esté por debajo de los demás modelos estudiados. No obstante, el rendimiento de AlgarroboNet podría mejorarse sin necesidad de aumentar el número de capas y parámetros, así como XDNet, la red diseñada por (Chou et al., 2023) para identificar enfermedades en hojas del manzano, el cual mostró mayor precisión que siete modelos conocidos.

4.2 **Discusión**

4.2.1 **Imágenes RGB de árboles de algarrobo.**

En otros estudios también se ha usado UAV para el fenotipado de diversas especies herbáceas en campo (Guo et al., 2020). La evaluación de estas propiedades se ha usado con éxito junto a redes neuronales convolucionales para la clasificación de elementos microestructurales del tejido vegetal de la calabaza

(Oblitas et al., 2021) y para el estudio de la relación microestructura-propiedad-proceso de fritura de papa (OBLITAS-CRUZ et al., 2023). Junto a otros algoritmos de aprendizaje automático y profundo también se reportaron estudios sobre la detección y clasificación de frutas (Bhargava y Bansal, 2020), clasificación de variedades de frijol seco (Mendigoria et al., 2021), detección de insectos en cultivos extensivos (Kasinathan et al., 2021), y clasificación de semillas de maíz (Javanmardi et al., 2021), utilizando imágenes RGB para su estudio que fueron funcionales como en la presente investigación.

4.2.2 Diseño e implementación de redes neuronales convolucionales

Otra ventaja de utilizar Deep Network Designer es el poder editar la red para transferencia de aprendizaje para crear una red nueva, más generalizable y con mayor rendimiento sin necesidad de entrenarla desde cero. (Chao et al., 2020) obtuvieron 1,35% más de precisión y mayor estabilidad durante el entrenamiento de redes convolucionales al utilizar la transferencia de aprendizaje para identificar enfermedades en hojas del manzano. En el estudio de Lee et al. (2020), los modelos de CNN usados para caracterizar enfermedades vegetales mostraron una mejor generalización en la adaptación a nuevos datos al implementarse enfoques de aprendizaje por transferencia. En este trabajo también se concluyó que usar modelos con entrenamiento previo reduce el impacto del sobreajuste. Resultados similares obtuvieron Trang et al. (2019) quienes emplearon CNN con transferencia de aprendizaje para identificar enfermedades del mango, cuya precisión (88,46%) fue similar durante el proceso de entrenamiento y validación, en comparación con otros modelos.

4.2.3 precisión de las redes neuronales convolucionales para clasificar los árboles de algarrobo

La “ralentización” y “aceleración” en el proceso de aprendizaje de arquitecturas propuestas como AlgarroboNet también fue reportado en un modelo autodiseñado en (Chellapandi et al., 2021). Sin embargo, (Suh et al., 2018) reportaron que, el número de épocas para el entrenamiento depende de la arquitectura de la red, siendo directamente proporcional a su profundidad. Considerando que AlgarroboNet es una red simple, para alcanzar la mayor precisión deseada requirió entrenarse con más iteraciones probablemente por otros



factores como el ajuste de los hiperparámetros, los cuales también tienen relación con la estabilidad (Suh et al., 2018). En este sentido, al igual que en (Castro et al., 2024) al evaluar modelos LSTM para discriminar filetes de caballa sometidos a ciclos de congelación-descongelación, para alcanzar modelos AlgarroboNet estables se necesitó un número significativo de iteraciones, haciendo que la capacidad de adaptación a las imágenes utilizadas sea menos eficiente que en los otros modelos usados.

CONCLUSIONES

- Las redes neuronales convolucionales logan discriminar con alta confiabilidad los Árboles de algarrobo plus y no plus para reforestar los bosques secos del norte peruano
- Se capturaron imágenes RGB de árboles de algarrobo "plus" y "no plus" en localidades de Tumbes, Lambayeque y Piura. La información adquirida permitió calcular las características morfogeométricas, como área, ejes mayor y menor, solidez, redondez, excentricidad, perímetro y diámetro equivalente.
- La clasificación de los árboles de algarrobo "plus" y "no plus" se llevó a cabo mediante la implementación redes convolucionales reconocidas como AlexNet, DenseNet, MobileNet y GoogleNet y una nueva arquitectura, denominada AlgarroboNet, utilizando el enfoque de transferencia de aprendizaje.
- AlexNet exhibió el mejor desempeño y estabilidad durante la clasificación, alcanzando una precisión y F-measure de 0,96. Le siguieron ligeramente MobileNet y DenseNet, mientras que GoogleNet mostró el rendimiento más bajo. La propuesta, AlgarroboNet, presentó resultados inferiores (0,87 para ambas métricas), pero fue prometedora considerando su falta de entrenamiento y simplicidad, ideal en entornos prácticos.



RECOMENDACIONES

- Robustecer la data con imágenes de otras regiones geográficas, donde se cultiva los algarrobos para validar los modelos y redes convolucionales.
- Explorar el uso de cámaras multiespectrales e hiperspectrales para obtener información adicional y más detallada para mejorar el rendimiento de los modelos.
- Diseñar, implementar y evaluar el rendimiento de nuevas estructuras de redes neuronales convolucionales frente a otras arquitecturas pre entrenadas.
- Explorar la creación de herramientas interactivas y prácticas (uso en celular móvil, computación en la nube y desarrollo de prototipos portátiles, por ejemplo) basadas en los modelos para facilitar la identificación y monitoreo de árboles, beneficiando a gestores forestales y comunidades locales.

BIBLIOGRAFÍA

- Adam, E., Mureriwa, N., y Newete, S. (2017). Mapping *Prosopis glandulosa* (mesquite) in the semi-arid environment of South Africa using high-resolution WorldView-2 imagery and machine learning classifiers. *Journal of Arid Environments*, 145, 43–51. <https://doi.org/10.1016/j.jaridenv.2017.05.001>
- Aeberli, A., Johansen, K., Robson, A., Lamb, D. W., y Phinn, S. (2021). Detection of banana plants using multi-temporal multispectral uav imagery. *Remote Sensing*, 13(11). <https://doi.org/10.3390/rs13112123>
- Aguirre, Z., González, L., Muñoz, J., y Muñoz, L. (2023). *Procesos sucesionales de la vegetación bajo plantaciones forestales y bosque andino en la hoya de Loja, Ecuador*. <https://doi.org/10.37885/220809828>
- Alex, W., Sánchez, C., César, U., y Trujillo, V. (2022). Redes neuronales artificiales: una medición de aprendizajes de pronósticos como demanda potencial. *Ciencia y Tecnología*, 27, 51–60. <https://doi.org/10.47460/uct.v27i118.686>
- Alzubaidi, L., Zhang, J., Humaidi, A. J., Al-Dujaili, A., Duan, Y., Al-Shamma, O., Santamaría, J., Fadhel, M. A., Al-Amidie, M., y Farhan, L. (2021). Review of deep learning: concepts, CNN architectures, challenges, applications, future directions. *Journal of Big Data 2021 8:1*, 8(1), 1–74. <https://doi.org/10.1186/S40537-021-00444-8>
- Amani, M., Ghorbanian, A., Ahmadi, S. A., Kakooei, M., Moghimi, A., Mirmazloumi, S. M., Moghaddam, S. H. A., Mahdavi, S., Ghahremanloo, M., Parsian, S., Wu, Q., y Brisco, B. (2020). Google Earth Engine Cloud Computing Platform for Remote Sensing Big Data Applications: A Comprehensive Review. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 13, 5326–5350. <https://doi.org/10.1109/JSTARS.2020.3021052>
- Ampatzidis, Y., y Partel, V. (2019). UAV-based high throughput phenotyping in citrus utilizing multispectral imaging and artificial intelligence. *Remote Sensing*, 11(4). <https://doi.org/10.3390/rs11040410>
- Avila-George, H., De-La-Torre, M., Sánchez-Garcés, J., Quispe, J. J. C., Prieto, J. M., y Castro, W. (2023). Discrimination of foreign bodies in quinoa (*Chenopodium quinoa*

- Willd.) grains using convolutional neural networks with a transfer learning approach. *PeerJ*, 11, e14808. <https://doi.org/10.7717/PEERJ.14808/TABLE-4>
- Baena, S., Boyd, D. S., y Moat, J. (2018). UAVs in pursuit of plant conservation - Real world experiences. *Ecological Informatics*, 47, 2–9. <https://doi.org/10.1016/j.ecoinf.2017.11.001>
- Baena, S., Moat, J., Whaley, O., y Boyd, D. S. (2017). Identifying species from the air: UAVs and the very high resolution challenge for plant conservation. *PLoS ONE*, 12(11). <https://doi.org/10.1371/journal.pone.0188714>
- Barboza, E., Salazar, W., Gálvez-Paucar, D., Valqui-Valqui, L., Saravia, D., Gonzales, J., Aldana, W., Vásquez, H. V., y Arbizu, C. I. (2022). *Cover and Land Use Changes in the Dry Forest of Tumbes (Peru) Using Sentinel-2 and Google Earth Engine Data*. 2. <https://doi.org/10.3390/iecf2022-13095>
- Benos, L., Tagarakis, A. C., Dolias, G., Berruto, R., Kateris, D., y Bochtis, D. (2021). Machine learning in agriculture: A comprehensive updated review. En *Sensors* (Vol. 21, Número 11). MDPI AG. <https://doi.org/10.3390/s21113758>
- Bhargava, A., y Bansal, A. (2020). Automatic Detection and Grading of Multiple Fruits by Machine Learning. *Food Analytical Methods*, 13(3), 751–761. <https://doi.org/10.1007/S12161-019-01690-6/METRICS>
- Calderón, F. T., Alberto, J., Ventura, M., Alonso, M., Hoyos, E., Adela, F., Villar, C., Roy, D., Gomero, A., Lenin, G., Alcántara, B., Andrés, D., Hidalgo, N., Delgado, A. C., Helbert, R., y Herrera, A. A. (s/f). 2 *Agenda Nacional de Investigación Forestal y de Fauna Silvestre* AGENDA NACIONAL DE INVESTIGACIÓN FORESTAL Y DE FAUNA SILVESTRE.
- Casapia, X. T., Falen, L., Bartholomeus, H., Cárdenas, R., Flores, G., Herold, M., Coronado, E. N. H., y Baker, T. R. (2020). Identifying and quantifying the abundance of economically important palms in tropical moist forest using UAV imagery. *Remote Sensing*, 12(1). <https://doi.org/10.3390/RS12010009>
- Castro, W., Oblitas, J., Maicelo, J., y Avila-George, H. (2018). Evaluation of Expert Systems Techniques for Classifying Different Stages of Coffee Rust Infection in

- Hyperspectral Images. *International Journal of Computational Intelligence Systems*, 11(1), 86–100. <https://doi.org/10.2991/IJCIS.11.1.8>
- Castro, W., Saavedra, M., Castro, J., Tech, A. R. B., Chuquizuta, T., y Avila-George, H. (2024). Using recurrent neural networks to identify broken-cold-chain fish fillet from spectral profiles. *Neural Computing and Applications*, 36(8), 4377–4386. <https://doi.org/10.1007/S00521-023-09311-4/METRICS>
- CEPLAN. (2023). *Análisis de la deforestación y pérdida de vegetación a nivel nacional y el impacto a nivel regionales* (Centro Nacional de Planeamiento Estratégico, Ed.).
- Chao, X., Sun, G., Zhao, H., Li, M., y He, D. (2020). Identification of Apple Tree Leaf Diseases Based on Deep Learning Models. *Symmetry 2020, Vol. 12, Page 1065*, 12(7), 1065. <https://doi.org/10.3390/SYM12071065>
- Chehreh, B., Moutinho, A., y Viegas, C. (2023). Latest Trends on Tree Classification and Segmentation Using UAV Data—A Review of Agroforestry Applications. En *Remote Sensing* (Vol. 15, Número 9). MDPI. <https://doi.org/10.3390/rs15092263>
- Chellapandi, B., Vijayalakshmi, M., y Chopra, S. (2021). Comparison of pre-trained models using transfer learning for detecting plant disease. *Proceedings - IEEE 2021 International Conference on Computing, Communication, and Intelligent Systems, ICCIS 2021*, 383–387. <https://doi.org/10.1109/ICCCIS51004.2021.9397098>
- Chen, J., Zhang, D., Suzauddola, M., y Zeb, A. (2021). Identifying crop diseases using attention embedded MobileNet-V2 model. *Applied Soft Computing*, 113, 107901. <https://doi.org/10.1016/J.ASOC.2021.107901>
- Chou, C. H., Shen, T. W., Tung, H., Hsieh, P. F., Kuo, C. E., Chen, T. M., y Yang, C. W. (2023). Convolutional neural network-based fast seizure detection from video electroencephalograms. *Biomedical Signal Processing and Control*, 80. <https://doi.org/10.1016/J.BSPC.2022.104380>
- Concepcion II, R., Lauguico, S. C., Alejandrino, J., y Dadios, E. P. (2020). (PDF) *Variety Classification of Lactuca Sativa Seeds Using Single-Kernel RGB Images and Spectro- Textural-Morphological Feature-Based Machine Learning*. https://www.researchgate.net/publication/348701794_Variety_Classification_of_La

ctuca_Sativa_Seeds_Using_Single-Kernel_RGB_Images_and_Spectro- _Textural-
Morphological_Feature-Based_Machine_Learning

- Cortés, V. (2023, octubre 20). *Instituto Forestal ya es parte de la Red de Inventarios Nacionales de América Latina y el Caribe - Diario Sostenible*. <https://www.diariosostenible.cl/noticia/actualidad/2023/11/instituto-forestal-ya-es-parte-de-la-red-de-inventarios-nacionales-de-america-latina-y-el-caribe>
- Crespo Lera, N. (2023). *Asignación automática de parcelas del Inventario forestal nacional a municipios usando Datos abierto enlazados*. Universidad de Valladolid. Escuela Técnica Superior de Ingenierías Agrarias.
- Csillik, O., Cherbini, J., Johnson, R., Lyons, A., y Kelly, M. (2018). Identification of citrus trees from unmanned aerial vehicle imagery using convolutional neural networks. *Drones*, 2(4), 1–16. <https://doi.org/10.3390/drones2040039>
- Debus, B., Parastar, H., Harrington, P., y Kirsanov, D. (2021). Deep learning in analytical chemistry. En *TrAC - Trends in Analytical Chemistry* (Vol. 145). Elsevier B.V. <https://doi.org/10.1016/j.trac.2021.116459>
- Dhillon, A., y Verma, G. K. (2020). Convolutional neural network: a review of models, methodologies and applications to object detection. *Progress in Artificial Intelligence*, 9(2), 85–112. <https://doi.org/10.1007/S13748-019-00203-0/METRICS>
- Dieng, M., Mbow, C., Skole, D. L., y Ba, B. (2023). Sustainable land management policy to address land degradation: linking old forest management practices in Senegal with new REDD+ requirements. En *Frontiers in Environmental Science* (Vol. 11). Frontiers Media SA. <https://doi.org/10.3389/fenvs.2023.1088726>
- dos Santos, A. A., Marcato Junior, J., Araújo, M. S., Di Martini, D. R., Tetila, E. C., Siqueira, H. L., Aoki, C., Eltner, A., Matsubara, E. T., Pistori, H., Feitosa, R. Q., Liesenberg, V., y Gonçalves, W. N. (2019). Assessment of CNN-based methods for individual tree detection on images captured by RGB cameras attached to UAVS. *Sensors (Switzerland)*, 19(16). <https://doi.org/10.3390/s19163595>
- Effiom, A. E., van Leeuwen, L. M., Nyktas, P., Okojie, J. A., y Erdbrügger, J. (2019). Combining unmanned aerial vehicle and multispectral Pleiades data for tree species

- identification, a prerequisite for accurate carbon estimation. *Journal of Applied Remote Sensing*, 13(03), 1. <https://doi.org/10.1117/1.jrs.13.034530>
- FAO. (2022). *Versión resumida de El estado de los bosques del mundo*. https://www.google.com.pe/books/edition/Versi%C3%B3n_resumida_de_El_estado_de_los_bosques_del_mundo/V%3ADas+forestales+hacia+la+recuperaci%C3%B3n+verde+y+la+creaci%C3%B3n+de+econm%C3%ADas+inclusivas,+resilientes+y+sosteniblsyprintsec=frontcover
- FAO y PNUMA. (2020). *EL ESTADO DE LOS BOSQUES DEL MUNDO 2020 : los bosques, la biodiversidad y las personas*.
- Feng, A., Sudduth, K., Vories, E., y Zhou, J. (2019). Evaluation of cotton stand count using UAV-based hyperspectral imagery. *2019 ASABE Annual International Meeting*. <https://doi.org/10.13031/AIM.201900807>
- Ferreira, M. P., Almeida, D. R. A. de, Papa, D. de A., Minervino, J. B. S., Veras, H. F. P., Formighieri, A., Santos, C. A. N., Ferreira, M. A. D., Figueiredo, E. O., y Ferreira, E. J. L. (2020). Individual tree detection and species classification of Amazonian palms using UAV images and deep learning. *Forest Ecology and Management*, 475. <https://doi.org/10.1016/j.foreco.2020.118397>
- Fondo Mundial Para la Naturaleza. (2019). *Cuatro tipos de bosques*. <https://www.worldwildlife.org/descubre-wwf/historias/cuatro-tipos-de-bosques-conoce-las-diferencias>
- Fremout, T., Cobián-De Vinatea, J., Thomas, E., Huaman-Zambrano, W., Salazar-Villegas, M., Limache-de la Fuente, D., Bernardino, P. N., Atkinson, R., Csaplovics, E., y Muys, B. (2022). Site-specific scaling of remote sensing-based estimates of woody cover and aboveground biomass for mapping long-term tropical dry forest degradation status. *Remote Sensing of Environment*, 276. <https://doi.org/10.1016/j.rse.2022.113040>
- González-Jaramillo, V., Fries, A., y Bendix, J. (2019). AGB Estimation in a Tropical Mountain Forest (TMF) by Means of RGB and Multispectral Images Using an

- Unmanned Aerial Vehicle (UAV). *Remote Sensing 2019, Vol. 11, Page 1413, 11(12)*, 1413. <https://doi.org/10.3390/RS11121413>
- Gonzalo-Martín, C., García-Pedrero, A., y Lillo-Saavedra, M. (2021). Improving deep learning sorghum head detection through test time augmentation. *Computers and Electronics in Agriculture*, 186, 106179. <https://doi.org/10.1016/J.COMPAG.2021.106179>
- Guo, W., Fukano, Y., Noshita, K., y Ninomiya, S. (2020). Field-based individual plant phenotyping of herbaceous species by unmanned aerial vehicle. *Ecology and Evolution*, 10(21), 12318–12326. <https://doi.org/10.1002/ECE3.6861>
- Hasnat, G. N. T., y Hossain, M. K. (2019). *Global Overview of Tropical Dry Forests*. 1–23. <https://doi.org/10.4018/978-1-7998-0014-9.CH001>
- Javanmardi, S., Miraei Ashtiani, S. H., Verbeek, F. J., y Martynenko, A. (2021). Computer-vision classification of corn seed varieties using deep convolutional neural network. *Journal of Stored Products Research*, 92, 101800. <https://doi.org/10.1016/J.JSPR.2021.101800>
- Jiménez-Rodríguez, D. L., Gao, Y., Solórzano, J. V., Skutsch, M., Pérez-Salicrup, D. R., Salinas-Melgoza, M. A., y Farfán, M. (2022). Mapping Forest Degradation and Contributing Factors in a Tropical Dry Forest. *Frontiers in Environmental Science*, 10. <https://doi.org/10.3389/fenvs.2022.912873>
- Kasinathan, T., Singaraju, D., y Uyyala, S. R. (2021). Insect classification and detection in field crops using modern machine learning techniques. *Information Processing in Agriculture*, 8(3), 446–457. <https://doi.org/10.1016/J.INPA.2020.09.006>
- Kometter, R., y Reynel, C. (2020). *Bio Modus Tropical www.biomodus.net Los Bosques de “Algarrobo” (Prosopis spp) Están Muriendo en la Costa Norte del Perú ¿Qué Hacer?* <https://orcid.org/0000-0002-3545-6484><https://orcid.org/0000-0002-6173-9023>
- Lee, S. H., Goëau, H., Bonnet, P., y Joly, A. (2020). New perspectives on plant disease characterization based on deep learning. *Computers and Electronics in Agriculture*, 170(February), 105220. <https://doi.org/10.1016/j.compag.2020.105220>

- Marin, W., Mondragon, I. F., y Colorado, J. D. (2022). Aerial Identification of Amazonian Palms in High-Density Forest Using Deep Learning. *Forests*, 13(5). <https://doi.org/10.3390/f13050655>
- McNicol, I. M., Mitchard, E. T. A., Aquino, C., Burt, A., Carstairs, H., Dassi, C., Modinga Dikongo, A., y Disney, M. I. (2021). To What Extent Can UAV Photogrammetry Replicate UAV LiDAR to Determine Forest Structure? A Test in Two Contrasting Tropical Forests. *Journal of Geophysical Research: Biogeosciences*, 126(12). <https://doi.org/10.1029/2021JG006586>
- Mendigoria, C. H., Concepcion, R., Dadios, E., Aquino, H., Alaias, O. J., Sybingco, E., Bandala, A., Vicerra, R. R., y Cuello, J. (2021). Seed Architectural Phenotypes Prediction and Variety Classification of Dry Beans (*Phaseolus vulgaris*) Using Machine Learning Algorithms. *IEEE Region 10 Humanitarian Technology Conference, R10-HTC, 2021-September*. <https://doi.org/10.1109/R10-HTC53172.2021.9641554>
- Messinger, M., Asner, G. P., y Silman, M. (2016). Rapid assessments of amazon forest structure and biomass using small unmanned aerial systems. *Remote Sensing*, 8(8). <https://doi.org/10.3390/rs8080615>
- Miraei Ashtiani, S. H., Javanmardi, S., Jahanbanifard, M., Martynenko, A., y Verbeek, F. J. (2021). Detection of mulberry ripeness stages using deep learning models. *IEEE Access*, 9, 100380–100394. <https://doi.org/10.1109/ACCESS.2021.3096550>
- Morales, G., Kemper, G., Sevillano, G., Arteaga, D., Ortega, I., y Telles, J. (2018). Automatic segmentation of *Mauritia flexuosa* in unmanned aerial vehicle (UAV) imagery using deep learning. *Forests*, 9(12). <https://doi.org/10.3390/f9120736>
- Nag, A., Chanda, P. R., y Nandi, S. (2023). Mobile app-based tomato disease identification with fine-tuned convolutional neural networks. *Computers and Electrical Engineering*, 112, 108995. <https://doi.org/10.1016/J.COMPELECENG.2023.108995>
- Oblitas, J., Mejia, J., De-La-torre, M., Avila-George, H., Gil, L. S., López, L. M., Ibarz, A., y Castro, W. (2021). Classification of the Microstructural Elements of the Vegetal Tissue of the Pumpkin (*Cucurbita pepo* L.) Using Convolutional Neural Networks.

- Applied Sciences* 2021, Vol. 11, Page 1581, 11(4), 1581.
<https://doi.org/10.3390/APP11041581>
- OBLITAS-CRUZ, J., CASTRO-SILUPU, W., Torres-Carranza, E., y Ibarz-Ribas, A. (2023). Study of the microstructure-property-processing relationship in five potato (*Solanum tuberosum*) varieties during the frying process based on an automatic classification system using convolutional neural networks. *Food Science and Technology*, 43, 2023. <https://doi.org/10.5327/FST.00155>
- Olariu, H. G., Malambo, L., Popescu, S. C., Virgil, C., y Wilcox, B. P. (2022). Woody Plant Encroachment: Evaluating Methodologies for Semiarid Woody Species Classification from Drone Images. *Remote Sensing*, 14(7). <https://doi.org/10.3390/rs14071665>
- Opong, S. O., Twum, F., Hayfron-Acquah, J. Ben, y Missah, Y. M. (2022). A Novel Computer Vision Model for Medicinal Plant Identification Using Log-Gabor Filters and Deep Learning Algorithms. *Computational Intelligence and Neuroscience*, 2022. <https://doi.org/10.1155/2022/1189509>
- Oscó, L. P., de Arruda, M. dos S., Marcato Junior, J., da Silva, N. B., Ramos, A. P. M., Moryia, É. A. S., Imai, N. N., Pereira, D. R., Creste, J. E., Matsubara, E. T., Li, J., y Gonçalves, W. N. (2020). A convolutional neural network approach for counting and geolocating citrus-trees in UAV multispectral imagery. *ISPRS Journal of Photogrammetry and Remote Sensing*, 160, 97–106. <https://doi.org/10.1016/j.isprsjprs.2019.12.010>
- Pasiecznik, N. M., Felker, P., Harris, P., Harsh, L., y Cruz, G. (2001). *The Prosopis juliflora-Prosopis pallida complex : a monograph*. HDRA.
- PERÚ, N. E. C. (2014). *Bosques de algarrobo se ven afectados por aparición de hongos* | PERU | EL COMERCIO PERÚ. <https://elcomercio.pe/peru/piura/bosques-algarrobo-ven-afectados-aparicion-hongos-312307-noticia/>
- Pommerening, A., Maleki, K., y Haufe, J. (2021). Tamm Review: Individual-based forest management or Seeing the trees for the forest. En *Forest Ecology and Management* (Vol. 501). Elsevier B.V. <https://doi.org/10.1016/j.foreco.2021.119677>

- Pu, Y., Xu, D., Wang, H., Li, X., y Xu, X. (2023). A New Strategy for Individual Tree Detection and Segmentation from Leaf-on and Leaf-off UAV-LiDAR Point Clouds Based on Automatic Detection of Seed Points. *Remote Sensing*, 15(6), 1619. <https://doi.org/10.3390/RS15061619/S1>
- Roberto, I., Braulio, G., y Veronica, E. (1998). (PDF) *Métodos de Selección de Arboles Plus*. https://www.researchgate.net/publication/255949339_Metodos_de_Seleccion_de_Arboles_Plus
- Roberto, K., y Carlos Reynel, R. (2022). (PDF) *Los Bosques de “Algarrobo” (Prosopis spp) Están Muriendo en la Costa Norte del Perú ¿Qué Hacer?* https://www.researchgate.net/publication/366204932_Los_Bosques_de_Algarrobo_Prosopis_spp_Estan_Muriendo_en_la_Costa_Norte_del_Peru_Que_Hacer
- Russakovsky, O., Deng, J., Su, H., Krause, J., Satheesh, S., Ma, S., Huang, Z., Karpathy, A., Khosla, A., Bernstein, M., Berg, A. C., y Fei-Fei, L. (2015). ImageNet Large Scale Visual Recognition Challenge. *International Journal of Computer Vision*, 115(3), 211–252. <https://doi.org/10.1007/S11263-015-0816-Y/FIGURES/16>
- Salazar Zarzosa, P., Mendieta-Leiva, G., Navarro-Cerrillo, R. M., Cruz, G., Grados, N., y Villar, R. (2021). An ecological overview of *Prosopis pallida*, one of the most adapted dryland species to extreme climate events. *Journal of Arid Environments*, 193. <https://doi.org/10.1016/j.jaridenv.2021.104576>
- Saleem, M. H., Potgieter, J., y Arif, K. M. (2020). Plant Disease Classification: A Comparative Evaluation of Convolutional Neural Networks and Deep Learning Optimizers. *Plants* 2020, Vol. 9, Page 1319, 9(10), 1319. <https://doi.org/10.3390/PLANTS9101319>
- Schnell, S., Kleinn, C., y Ståhl, G. (2015). Monitoring trees outside forests: a review. *Environmental Monitoring and Assessment*, 187(9), 1–17. <https://doi.org/10.1007/S10661-015-4817-7/METRICS>
- Schröder, J. M., Ávila Rodríguez, L. P., y Günter, S. (2021). Research trends: Tropical dry forests: The neglected research agenda? *Forest Policy and Economics*, 122. <https://doi.org/10.1016/j.forpol.2020.102333>

- Sesnie, S. E., Espinosa, C. I., Jara-Guerrero, A. K., y Tapia-Armijos, M. F. (2023). Ensemble Machine Learning for Mapping Tree Species Alpha-Diversity Using Multi-Source Satellite Data in an Ecuadorian Seasonally Dry Forest. *Remote Sensing*, 15(3). <https://doi.org/10.3390/rs15030583>
- Shorten, C., y Khoshgoftaar, T. M. (2019). A survey on Image Data Augmentation for Deep Learning. *Journal of Big Data*, 6(1), 1–48. <https://doi.org/10.1186/S40537-019-0197-0/FIGURES/33>
- Sishodia, R. P., Ray, R. L., y Singh, S. K. (2020). Applications of remote sensing in precision agriculture: A review. *Remote Sensing*, 12(19), 1–31. <https://doi.org/10.3390/rs12193136>
- Stan, K., y Sanchez-Azofeifa, A. (2019). Tropical dry forest diversity, climatic response, and resilience in a changing climate. En *Forests* (Vol. 10, Número 5). MDPI AG. <https://doi.org/10.3390/f10050443>
- Suh, H. K., IJsselmuiden, J., Hofstee, J. W., y van Henten, E. J. (2018). Transfer learning for the classification of sugar beet and volunteer potato under field conditions. *Biosystems Engineering*, 174, 50–65. <https://doi.org/10.1016/J.BIOSYSTEMSENG.2018.06.017>
- Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J., y Wojna, Z. (2016). Rethinking the Inception Architecture for Computer Vision. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 2016-December*, 2818–2826. <https://doi.org/10.1109/CVPR.2016.308>
- Taye, M. M. (2023). Theoretical Understanding of Convolutional Neural Network: Concepts, Architectures, Applications, Future Directions. *Computation 2023, Vol. 11, Page 52, 11(3)*, 52. <https://doi.org/10.3390/COMPUTATION11030052>
- Trang, K., Tonthat, L., Gia Minh Thao, N., y Tran Ta Thi, N. (2019). Mango Diseases Identification by a Deep Residual Network with Contrast Enhancement and Transfer Learning. *2019 IEEE Conference on Sustainable Utilization and Development in Engineering and Technologies, CSUDET 2019*, 138–142. <https://doi.org/10.1109/CSUDET47057.2019.9214620>

- Tsouros, D. C., Bibi, S., y Sarigiannidis, P. G. (2019). A review on UAV-based applications for precision agriculture. En *Information (Switzerland)* (Vol. 10, Número 11). MDPI AG. <https://doi.org/10.3390/info10110349>
- Wan Nurazwin Syazwani, R., Muhammad Asraf, H., Megat Syahirul Amin, M. A., y Nur Dalila, K. A. (2022). Automated image identification, detection and fruit counting of top-view pineapple crown using machine learning. *Alexandria Engineering Journal*, 61(2), 1265–1276. <https://doi.org/10.1016/J.AEJ.2021.06.053>
- Weiss, M., Jacob, F., y Duveiller, G. (2020). Remote sensing for agricultural applications: A meta-review. *Remote Sensing of Environment*, 236. <https://doi.org/10.1016/j.rse.2019.111402>
- Wu, T. Y., Yeh, K. T., Hsu, H. C., Yang, C. K., Tsai, M. J., y Kuo, Y. F. (2022a). Identifying Fagaceae and Lauraceae species using leaf images and convolutional neural networks. *Ecological Informatics*, 68, 101513. <https://doi.org/10.1016/J.ECOINF.2021.101513>
- Wu, T. Y., Yeh, K. T., Hsu, H. C., Yang, C. K., Tsai, M. J., y Kuo, Y. F. (2022b). Identifying Fagaceae and Lauraceae species using leaf images and convolutional neural networks. *Ecological Informatics*, 68, 101513. <https://doi.org/10.1016/J.ECOINF.2021.101513>
- Xiao, J. L., Fan, J. S., Liu, Y. F., Li, B. L., y Nie, J. G. (2024). Region of interest (ROI) extraction and crack detection for UAV-based bridge inspection using point cloud segmentation and 3D-to-2D projection. *Automation in Construction*, 158(May 2023), 105226. <https://doi.org/10.1016/j.autcon.2023.105226>
- Yosinski, J., Clune, J., Bengio, Y., y Lipson, H. (2014). How transferable are features in deep neural networks? *Advances in Neural Information Processing Systems*, 4(January), 3320–3328. <https://arxiv.org/abs/1411.1792v1>
- Zang, H. X., Su, H., Qi, Y., Feng, L., Hou, R., He, M., Liu, P., Xu, P., Yu, Y., y Chen, P. (2022). Ages of giant panda can be accurately predicted using facial images and machine learning. *Ecological Informatics*, 72. <https://doi.org/10.1016/J.ECOINF.2022.101892>



- Zhang, X., Yang, J., Lin, T., y Ying, Y. (2021). Food and agro-product quality evaluation based on spectroscopy and deep learning: A review. En *Trends in Food Science and Technology* (Vol. 112, pp. 431–441). Elsevier Ltd. <https://doi.org/10.1016/j.tifs.2021.04.008>
- Zhang, Z., y Zhu, L. (2023). A Review on Unmanned Aerial Vehicle Remote Sensing: Platforms, Sensors, Data Processing Methods, and Applications. En *Drones* (Vol. 7, Número 6). MDPI. <https://doi.org/10.3390/drones7060398>
- Zhao, X., Li, K., Li, Y., Ma, J., y Zhang, L. (2022). Identification method of vegetable diseases based on transfer learning and attention mechanism. *Computers and Electronics in Agriculture*, 193(17), 106703. <https://doi.org/10.1016/j.compag.2022.106703>

ANEXOS

Anexo 1. Matriz de consistencia

PROBLEMA	OBJETIVO	HIPÓTESIS	VARIABLES INDICADORES	E
PROBLEMA GENERAL	OBJETIVO GENERAL	HIPÓTESIS GENERAL	VARIABLES	
¿Diferentes ¿Cuál es el efecto de las estructuras de redes neuronales convolucionales para discriminar árboles plus de algarrobo en la zona norte del Perú como estrategia de reforestación?	Estudiar las estructuras neuronales Evaluar el efecto de las estructuras de redes neuronales convolucionales para discriminar árboles plus de algarrobo en la zona norte del Perú como estrategia para enfrentar la deforestación y la desertificación.	La estructura de las redes neuronales convolucionales si influyen en la discriminación de árboles plus de algarrobo en la zona norte del Perú como estrategia para enfrentar la deforestación y la desertificación	<ul style="list-style-type: none"> • Variables independientes: Parámetros morfogeométricos <ul style="list-style-type: none"> ▪ Área de la copa (m²) ▪ Eje menor (m) ▪ Eje mayor (m) ▪ Redondez (adimensional) ▪ Compactness (adimensional) • Variable dependiente: Accuracy (porcentaje) 	
PROBLEMAS ESPECÍFICOS	OBJETIVOS ESPECÍFICOS	HIÓTESIS ESPECÍFICA	INDICADORES	
<p>información espectral de árboles de algarrobo plus y no plus de la zona norte del Perú?</p> <p>¿Qué estructuras de redes convolucionales se pueden diseñar para procesos de clasificación de árboles plus de algarrobo?</p> <p>¿Qué efecto tiene la estructura de redes convolucionales en la clasificación de árboles de algarrobo plus?</p>	<ul style="list-style-type: none"> • Adquirir imágenes RGB de árboles plus y no plus de algarrobo de la zona norte del Perú • Diseñar e implementar redes neuronales convolucionales con diferentes estructuras para clasificar árboles plus de algarrobo. • Evaluar la precisión de las redes neuronales convolucionales diseñadas frente a arquitecturas conocidas para clasificar los árboles de algarrobo. 	<ul style="list-style-type: none"> • La adquisición de imágenes RGB brinda información sobre características específicas y de interés de los árboles de algarrobo plus y no plus de la zona norte del Perú. • Se pueden diseñar redes convolucionales para procesos de clasificación de árboles plus de algarrobo. • Las redes neuronales convolucionales diseñadas tendrán mejor precisión que las arquitecturas conocidas para clasificar los árboles plus de algarrobo al estar desarrolladas para este fin. 	Discriminación de árboles plus y no plus	

Anexo 2. Programación de Algarrobo NET

```
function ArbolAlgarroboNet(pos)
% nombre de la carpeta
comb = combnk(1:24,3); % combinaciones
load labels.mat % cargar labels
Tipo= strcat(labels(comb(pos,1)),'-',...
             labels(comb(pos,2)),'-',labels(comb(pos,3)));
carpeta =strcat(cd,'\DataStore227UNP\'',Tipo);

% cargado de datosclc
imds = imageDatastore(carpeta, ...
    'IncludeSubfolders',true, ...
    'LabelSource','foldernames');

%% Mostrar imagenes por cada subcarpeta
subcarpetas=unique(imds.Labels);
figure

for i=1:length(subcarpetas)
    listing=dir(strcat(carpeta,'\ ',string(subcarpetas(i))));
    subplot(1,2,i)
    posicion = round(1 + (length(listing)-1).*rand);

    im=imread(strcat(listing(posicion).folder,'\ ',listing(posicion).name));
    imshow(im)
    title(string(subcarpetas(i)))
end

%% Preparar la red neuronal

% cargar la red
load layer_algarrobo3.mat;
layers = layer_algarrobo3;

% entrenamiento y calculo de estadisticos
NumTrainings= 30; %numero de entrenamientos
StatsCM=zeros(NumTrainings,4);

f = waitbar(0, 'Calculando');

for i=1:NumTrainings

    % recorte de carpetas
    [imdsTrain,imdsValidation] =
    splitEachLabel(imds,0.7,'randomized');

    % opciones de la red
    options = trainingOptions('sgdm', ...
        'MiniBatchSize',80, ...
        'MaxEpochs',20, ...
        'InitialLearnRate',0.0005, ...
        'Shuffle','every-epoch', ...
        'ValidationData',imdsValidation, ...
        'ValidationFrequency',5, ...
        'ExecutionEnvironment', 'gpu',...
        'Verbose',false, ...
        'Plots','training-progress');
```



```
% entrenar a la red
[netTransfer, info] = trainNetwork(imdsTrain, layers, options);
save netTransfer netTransfer

% validar la red
[YPred, scores] = classify(netTransfer, imdsValidation);

% obtencion de la matriz de confusion
CM = confusionmat(imdsValidation.Labels, YPred);

% calculo de los estadisticos
StatsCM(i,:) = CalcStats(CM);

% mostrar avance en la barra de progreso
waitbar(i/NumTrainings, f, sprintf('Progress: %d %%',
floor(i/NumTrainings*100)));

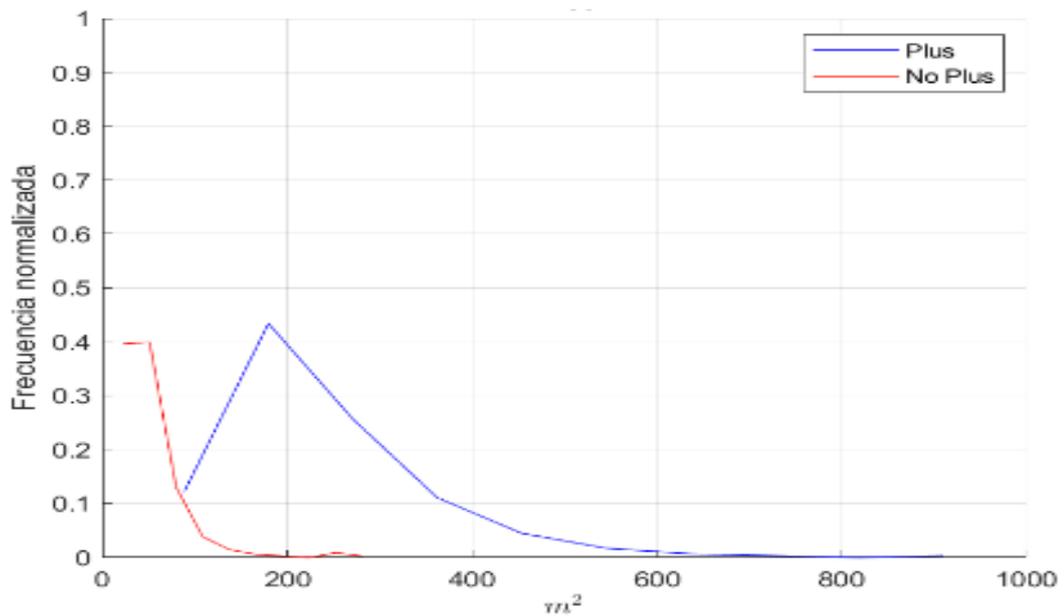
end
close(f)

%% Graficar curva de entrenamiento
resultado.NetworkIteration = info.OutputNetworkIteration;
resultado.NetworkTrainingAccuracy = info.TrainingAccuracy;
resultado.CM = CM;
resultado.StatsCM = StatsCM;
resultado.YPred = YPred;
resultado.YReal = imdsValidation.Labels;

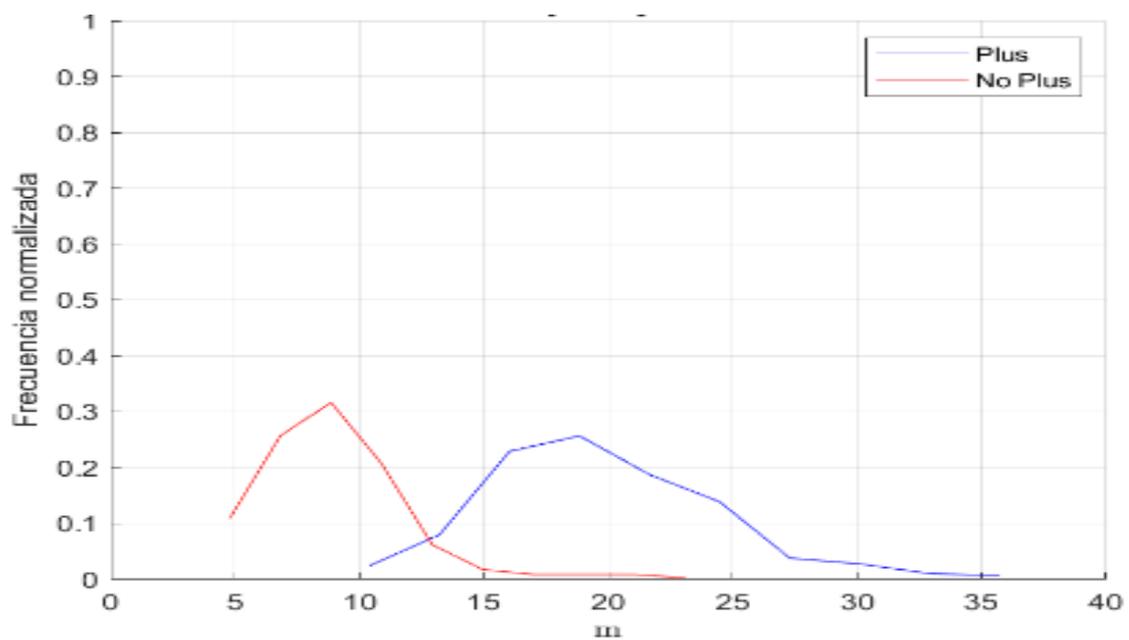
archivo = string((fullfile(cd, 'DataStore227UNP', Tipo, ['resultado'
'.mat']))));
save(archivo, 'resultado')

display(strcat('Culminado-', num2str(pos), '-', Tipo))
```

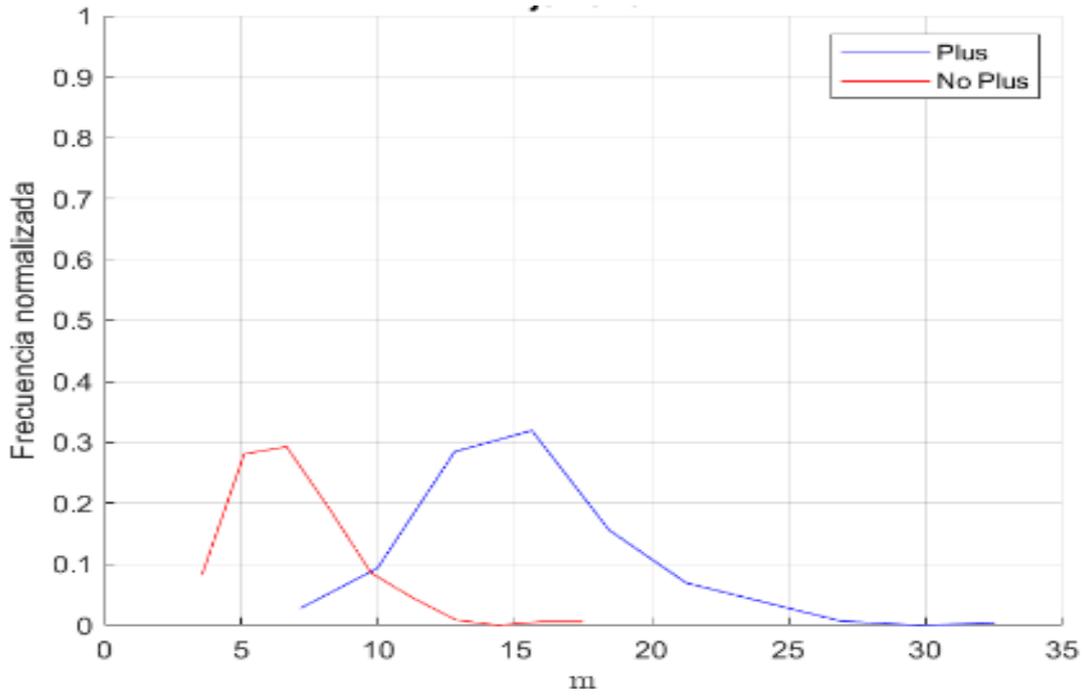
Anexo 3 Representación gráfica de las características morfológicas de los árboles plus y no plus ampliado por parámetro



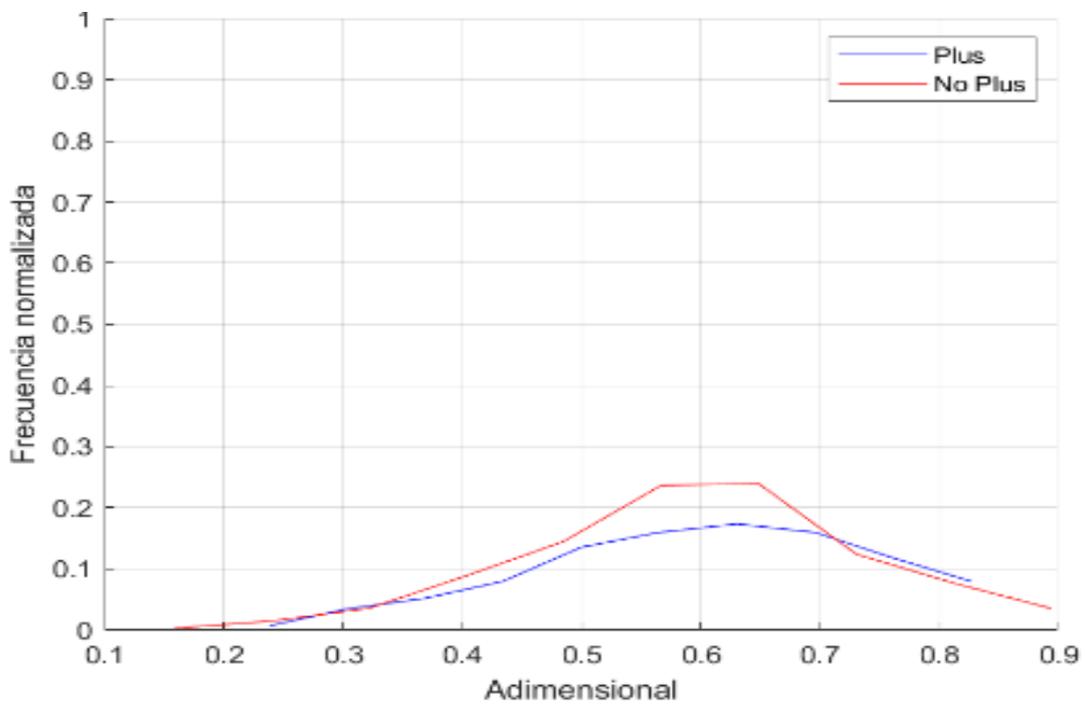
ÁREA



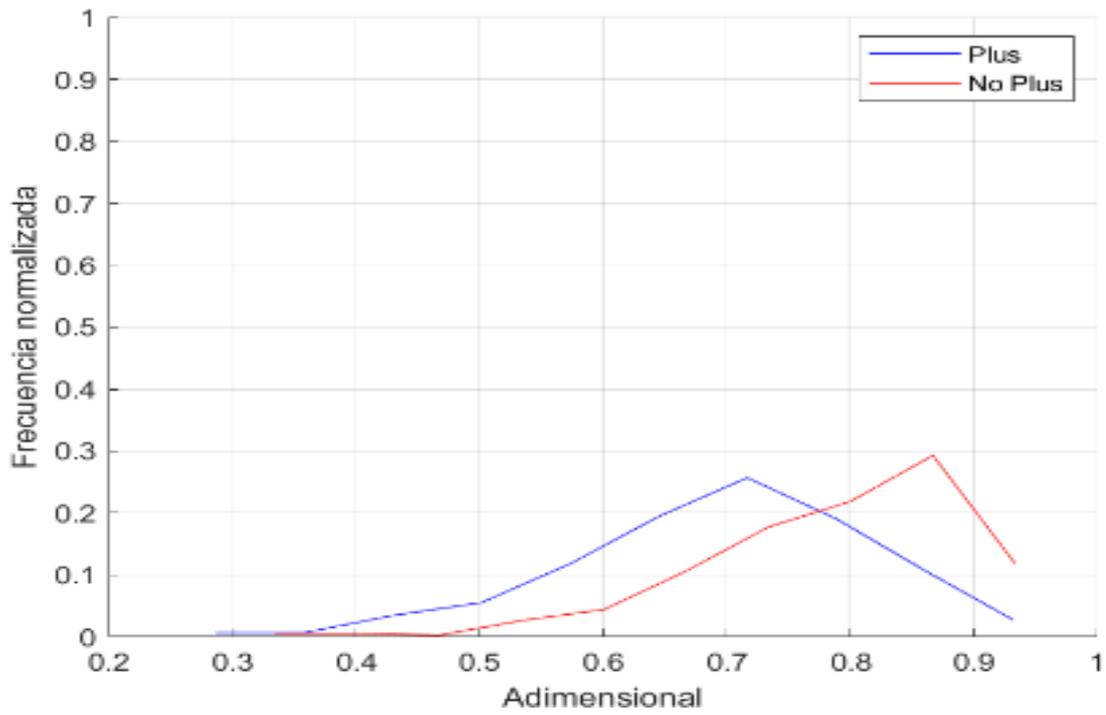
EJE MAYOR



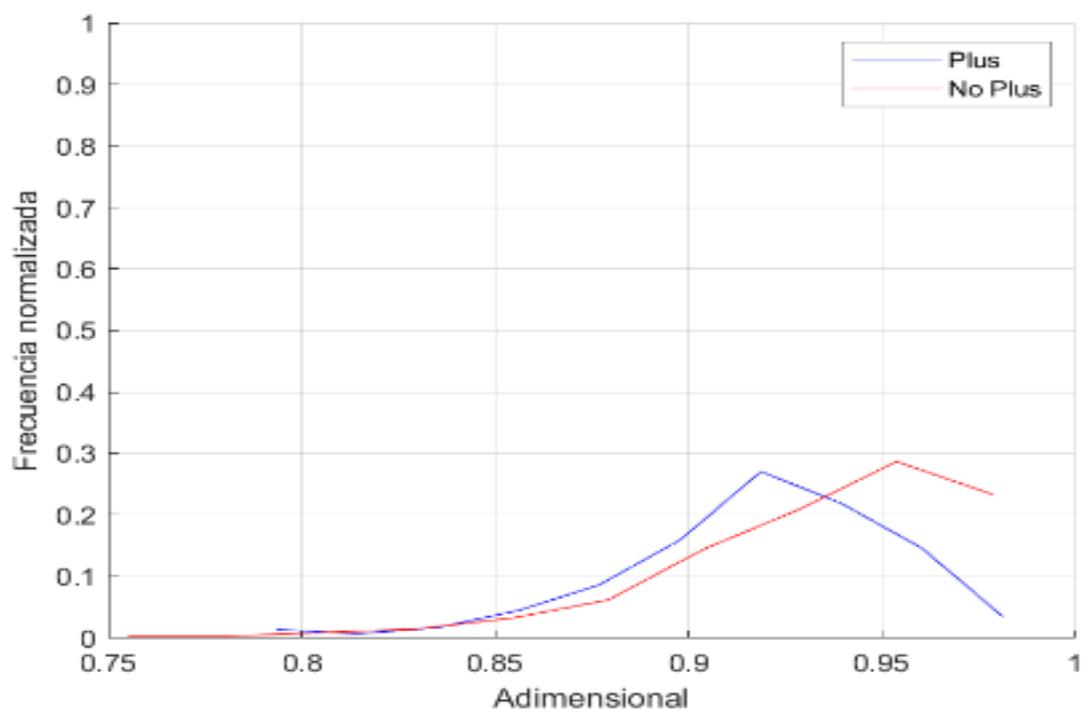
EJE MENOR



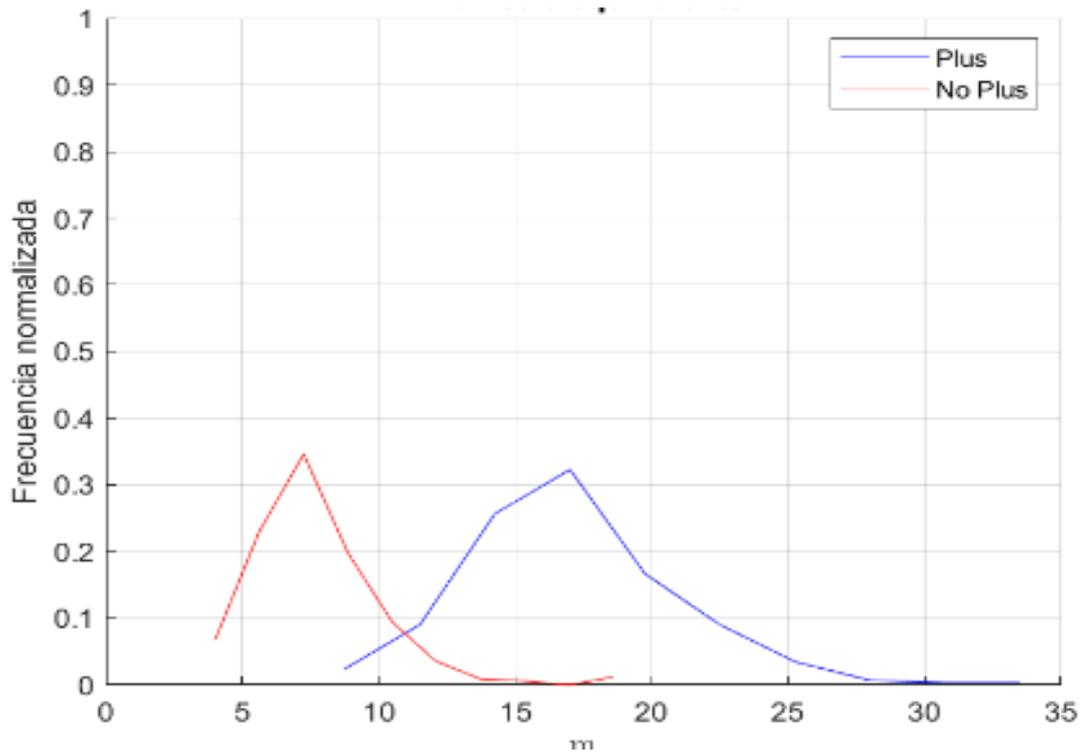
EXCENTRICIDAD



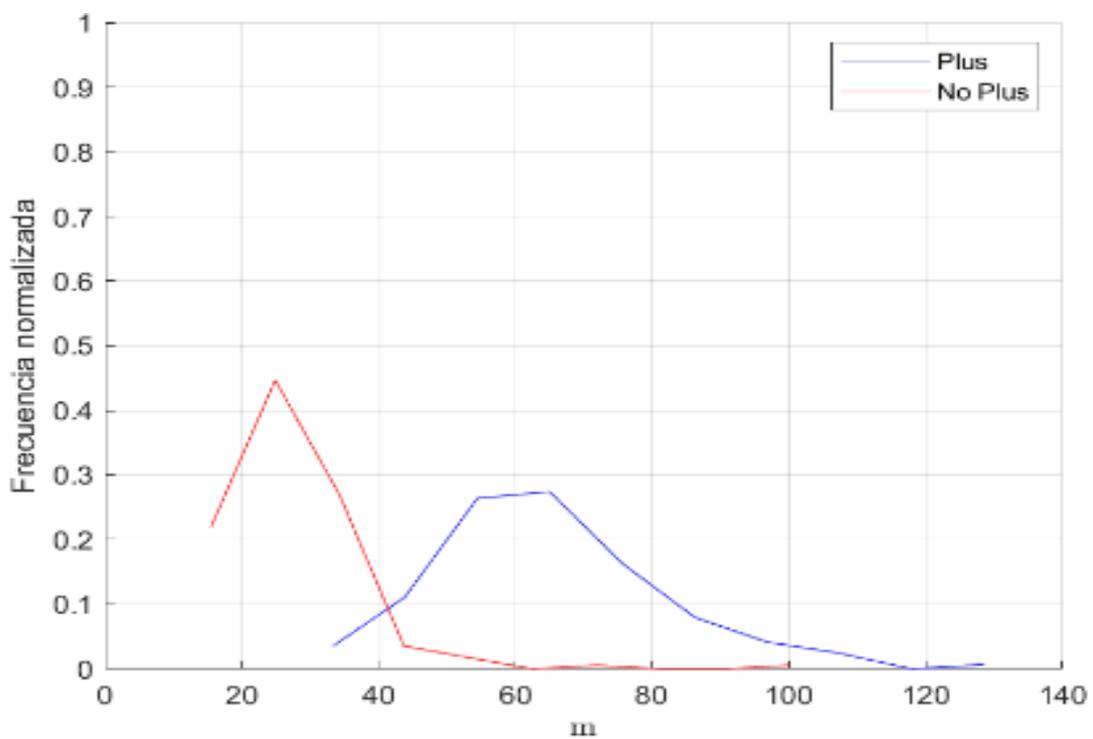
REDONDEZ



SOLIDEZ



DIÁMETRO EQUIVALENTE



PERÍMETRO

Anexo 4 Características de las capas de la red convolucional propuesta

AlgarroboNet

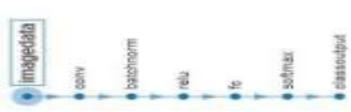
Analysis for training in Deep Network Designer

Name: Network from Deep Network Designer

Analysis date: 19-Dec-2023 05:16:49

10.9M

Total learnables



ANALYSIS RESULT

Name	Type	Activations	Learnable Properties	States
1 imagedata 227 x 227 x 3 images with 'zerocenter' nor...	Image Input	227(S) x 227(S) x 3(C) x 1(B)	-	-
2 conv 110 5x5 convolutions with stride [1 1] an...	2-D Convolution	223(S) x 223(S) x 110(C) x 1(B)	Weights 5 x 5 x 3 x 110 Bias 1 x 1 x 110	-
3 batchnorm Batch normalization	Batch Normalization	223(S) x 223(S) x 110(C) x 1(B)	Offset 1 x 1 x 110 Scale 1 x 1 x 110	Trained/learn Trained/VerL... 0 x... 0 x...
4 relu ReLU	ReLU	223(S) x 223(S) x 110(C) x 1(B)	-	-
5 fc 2 fully connected layer	Fully Connected	1(S) x 1(S) x 2(C) x 1(B)	Weights 2 x 5470190 Bias 2 x 1	-
6 softmax softmax	Softmax	1(S) x 1(S) x 2(C) x 1(B)	-	-
7 classoutput crossentropy	Classification Output	1(S) x 1(S) x 2(C) x 1(B)	-	-



Universidad Nacional
del Altiplano Puno



VRI
Vicerrectorado
de Investigación



Repositorio
Institucional

DECLARACIÓN JURADA DE AUTENTICIDAD DE TESIS

Por el presente documento, Yo Saire Roenfi Guerra Lima.
identificado con DNI 01333218 en mi condición de egresado de:

Escuela Profesional, Programa de Segunda Especialidad, Programa de Maestría o Doctorado

Doctorado en Ciencia, Tecnología y Medio Ambiente

informo que he elaborado el/la Tesis o Trabajo de Investigación denominada:

"Evaluación del efecto de las estructuras de redes neuronales convolucionales en la discriminación de árboles plus de algarrrojo en la zona norte del Perú como estrategia para enfrentar la deforestación y la desertificación."

Es un tema original.

Declaro que el presente trabajo de tesis es elaborado por mi persona y no existe plagio/copia de ninguna naturaleza, en especial de otro documento de investigación (tesis, revista, texto, congreso, o similar) presentado por persona natural o jurídica alguna ante instituciones académicas, profesionales, de investigación o similares, en el país o en el extranjero.

Dejo constancia que las citas de otros autores han sido debidamente identificadas en el trabajo de investigación, por lo que no asumiré como tuyas las opiniones vertidas por terceros, ya sea de fuentes encontradas en medios escritos, digitales o Internet.

Asimismo, ratifico que soy plenamente consciente de todo el contenido de la tesis y asumo la responsabilidad de cualquier error u omisión en el documento, así como de las connotaciones éticas y legales involucradas.

En caso de incumplimiento de esta declaración, me someto a las disposiciones legales vigentes y a las sanciones correspondientes de igual forma me someto a las sanciones establecidas en las Directivas y otras normas internas, así como las que me alcancen del Código Civil y Normas Legales conexas por el incumplimiento del presente compromiso

Puno 15 de Julio del 2024

FIRMA (obligatoria)



Huella



Universidad Nacional
del Altiplano Puno



Vicerrectorado
de Investigación



Repositorio
Institucional

AUTORIZACIÓN PARA EL DEPÓSITO DE TESIS O TRABAJO DE INVESTIGACIÓN EN EL REPOSITORIO INSTITUCIONAL

Por el presente documento, Yo Saire Roenfi Guerra Lima,
identificado con DNI 01333218 en mi condición de egresado de:

Escuela Profesional, Programa de Segunda Especialidad, Programa de Maestría o Doctorado

Doctorado en Ciencia, Tecnología y Medio Ambiente

informo que he elaborado el/la Tesis o Trabajo de Investigación denominada:

"Evaluación del efecto de las estructuras de redes neuronales convolucionales en la discriminación de árboles plus de algarrobo en la zona norte del Perú como estrategia para enfrentar la deforestación y desertificación"

para la obtención de Grado, Título Profesional o Segunda Especialidad.

Por medio del presente documento, afirmo y garantizo ser el legítimo, único y exclusivo titular de todos los derechos de propiedad intelectual sobre los documentos arriba mencionados, las obras, los contenidos, los productos y/o las creaciones en general (en adelante, los "Contenidos") que serán incluidos en el repositorio institucional de la Universidad Nacional del Altiplano de Puno.

También, doy seguridad de que los contenidos entregados se encuentran libres de toda contraseña, restricción o medida tecnológica de protección, con la finalidad de permitir que se puedan leer, descargar, reproducir, distribuir, imprimir, buscar y enlazar los textos completos, sin limitación alguna.

Autorizo a la Universidad Nacional del Altiplano de Puno a publicar los Contenidos en el Repositorio Institucional y, en consecuencia, en el Repositorio Nacional Digital de Ciencia, Tecnología e Innovación de Acceso Abierto, sobre la base de lo establecido en la Ley N° 30035, sus normas reglamentarias, modificatorias, sustitutorias y conexas, y de acuerdo con las políticas de acceso abierto que la Universidad aplique en relación con sus Repositorios Institucionales. Autorizo expresamente toda consulta y uso de los Contenidos, por parte de cualquier persona, por el tiempo de duración de los derechos patrimoniales de autor y derechos conexos, a título gratuito y a nivel mundial.

En consecuencia, la Universidad tendrá la posibilidad de divulgar y difundir los Contenidos, de manera total o parcial, sin limitación alguna y sin derecho a pago de contraprestación, remuneración ni regalía alguna a favor mío; en los medios, canales y plataformas que la Universidad y/o el Estado de la República del Perú determinen, a nivel mundial, sin restricción geográfica alguna y de manera indefinida, pudiendo crear y/o extraer los metadatos sobre los Contenidos, e incluir los Contenidos en los índices y buscadores que estimen necesarios para promover su difusión.

Autorizo que los Contenidos sean puestos a disposición del público a través de la siguiente licencia:

Creative Commons Reconocimiento-NoComercial-CompartirIgual 4.0 Internacional. Para ver una copia de esta licencia, visita: <https://creativecommons.org/licenses/by-nc-sa/4.0/>

En señal de conformidad, suscribo el presente documento.

Puno 15 de Julio del 2024


FIRMA (obligatoria)



Huella