



UNIVERSIDAD REGIONAL AMAZÓNICA IKIAM

FACULTAD DE CIENCIAS DE LA VIDA

CARRERA INGENIERÍA EN ECOSISTEMAS

**MACHINE LEARNING COMO UNA HERRAMIENTA PARA LA
IDENTIFICACIÓN DE FITOLITOS DE PALMAS DE LA
PROVINCIA DE NAPO**

Proyecto de investigación previo a la obtención de Título de:

INGENIERO EN ECOSISTEMAS

AUTOR: KARLA ESTEFANÍA VERA GUERRERO

TUTOR: PhD. BRYAN GUIDO VALENCIA CASTILLO

CO-TUTOR: PhD. MARÍA CRISTINA PEÑUELA MORA

NAPO-ECUADOR


2023

DECLARACIÓN DE DERECHO DE AUTOR, AUTENTICIDAD Y RESPONSABILIDAD

Yo, Karla Estefanía Vera Guerrero, con documento de identidad N° 1726429341, declaro que los resultados obtenidos en la investigación que presento en este documento final, previo a la obtención del título de Ingeniería en ecosistemas, son absolutamente inéditos, originales, auténticos y personales.

En virtud de lo cual, el contenido, criterios, opiniones, resultados, análisis, interpretaciones, conclusiones, recomendaciones y todos los demás aspectos vertidos en la presente investigación son de mi autoría y de mi absoluta responsabilidad.

Tena, 2 de febrero de 2023



Karla Estefanía Vera Guerrero

1726429341

AUTORIZACIÓN DE PUBLICACIÓN EN EL REPOSITORIO INSTITUCIONAL

Yo, Karla Estefanía Vera Guerrero, con documento de identidad N° 1726429341, en calidad de autora y titular de los derechos morales y patrimoniales del trabajo de titulación: MACHINE LEARNING COMO UNA HERRAMIENTA PARA LA IDENTIFICACIÓN DE FITOLITOS DE PALMAS DE LA PROVINCIA DE NAPO de conformidad con el Art. 114 del CÓDIGO ORGÁNICO DE LA ECONOMÍA SOCIAL DE LOS CONOCIMIENTOS, CREATIVIDAD E INNOVACIÓN, reconozco a favor de la Universidad Regional Amazónica Ikiam una licencia gratuita, intransferible y no exclusiva para el uso no comercial de la obra, con fines estrictamente académicos.

Así mismo autorizo a la Universidad Regional Amazónica Ikiam para que realice la publicación de este trabajo de titulación en el Repositorio Institucional de conformidad a lo dispuesto en el Art. 114 de la Ley Orgánica de Educación Superior.

Tena, 2 de febrero del 2023



Karla Estefanía Vera Guerrero

1726429341

CERTIFICADO DE DIRECCIÓN DE TRABAJO DE INTEGRACIÓN CURRICULAR

Certifico que el Trabajo de Integración Curricular Titulado: MACHINE LEARNING COMO UNA HERRAMIENTA PARA LA IDENTIFICACIÓN DE FITOLITOS DE PALMAS DE LA PROVINCIA DE NAPO, en la modalidad: (tesis), fue realizado por: Karla Estefanía Vera Guerrero, bajo nuestra dirección.

El mismo ha sido revisado en su totalidad y analizado por la herramienta de verificación de similitud de contenido; por lo tanto, cumple con los requisitos teóricos, científicos, técnicos, metodológicos y legales establecidos por la Universidad Regional Amazónica Ikiam, para su entrega y defensa.

Tena, 2 de febrero de 2023



PhD. Bryan Guido Valencia Castillo
C.I: 1760101632



PhD. María Cristina Peñuela Mora
C.I: 1756861496

AGRADECIMIENTOS

A través de estas líneas expreso mi profundo agradecimiento a mi madre el pilar de mi vida, por enseñarme los valores más importantes el respeto, honestidad, responsabilidad, empatía y sobre todo la solidaridad. Por nunca cortarme las alas y enseñarme a soñar en grande. Gracias por tener un corazón tan grande.

A mi abuelita el motor de mi vida, mi segunda madre. Su crianza fue fundamental para ser lo que soy ahora, gracias por su paciencia y dedicación durante estos 25 años.

A mi tíos y familiares por sus palabras de aliento y apoyo incondicional.

A mis tutores, Bryan Valencia y María Cristina Peñuela, por confiar en mis habilidades, por el tiempo invertido en la enseñanza, la paciencia y el cariño que me han brindado.

A la vida y a la Universidad Regional Amazónica Ikiam por darme la oportunidad de cumplir unas de mis metas y por permitirme encontrar a personas increíbles mis profesores, amigos y compañeros de carrera, que han compartido su vida y experiencias inolvidables.

Tengo a tantas personas que agradecer, Por ello:

“Gracias, infinitas gracias a todos y cada una de las personas que son y fueron parte de mi vida”

DEDICATORIA

Pocas palabras, grandes sentimientos, dedico
este trabajo a mi madre, abuelita, familiares,
tutores, amigos y compañeros.

“Empecé este trabajo por curiosidad y lo
terminé por el amor a la selva, los fitolitos y la
programación”

TABLA DE CONTENIDO

CARÁTULA	
DECLARACIÓN DE DERECHO DE AUTOR.....	ii
AUTORIZACIÓN DE PUBLICACIÓN EN EL REPOSITORIO INSTITUCIONAL.....	iii
CERTIFICADO DE DIRECCIÓN DE TRABAJO DE INTEGRACIÓN	
CURRICULAR.....	iv
AGRADECIMIENTOS.....	v
DEDICATORIA.....	vi
TABLA DE CONTENIDO.....	vii
ÍNDICE DE TABLAS.....	ix
ÍNDICE DE FIGURAS.....	x
ÍNDICE DE ACRÓNIMOS.....	xi
RESUMEN.....	xii
ABSTRACT.....	xiii
 CAPÍTULO I	
1. PLANTEAMIENTO DEL PROBELMA DE INVESTIGACIÓN.....	1
1.1 Antecedentes.....	1
1.1.1 Función y formación de los fitolitos.....	1
1.1.2 Extracción e identificación de fitolitos.....	2
1.1.3 Machine learning.....	2
1.1.4 Utilidad de los fitolitos.....	5
1.2 Planteamiento del problema.....	6
1.3 Justificación de la investigación.....	10
1.4 Preguntas de investigación.....	11
1.5 Objetivos de investigación	11
1.5.1 Objetivo general.....	11
1.5.2 Objetivos específicos.....	11
 CAPÍTULO II:	
2. MARCO METODOLÓGICO.....	12
2.1 Área de estudio.....	12
2.2 Fase de campo.....	12
2.2.1 Recolección y preparación de muestras.....	12
2.3 Fase de laboratorio.....	13

2.3.1 Incineración seca.....	13
2.3.2 Incineración húmeda.....	14
2.3.3 Preparación láminas de fitolitos.....	14
2.4 Procesamiento y análisis de datos.....	15
2.4.1 Descripción e identificación morfológica de fitolitos.....	15
2.4.2 Conjunto de datos.....	15
2.4.3 Creación de modelo.....	15
2.4.4 Métricas de rendimiento del modelo.....	16
CAPÍTULO III	
3. REPRESENTACIÓN DE DATOS Y RESULTADOS.....	17
3.1 Extracción e identificación de fitolitos.....	17
3.2 Identificación de fitolitos con machine learning.....	21
3.3 Evaluación de modelos.....	25
CAPÍTULO IV	
4. INTERPRETACIÓN Y DISCUSIÓN.....	27
CAPÍTULO V	
5. CONCLUSIONES Y RECOMENDACIONES.....	31
5.1 Conclusiones.....	31
5.2 Limitantes y recomendaciones.....	31
REFERENCIAS.....	33
ANEXOS.....	38

ÍNDICE DE TABLAS

Tabla 1: Fitolitos de palmas estudiados en la Amazonía.....	8
Tabla 2: Matriz de confusión. Describe el rendimiento de un modelo supervisado de machine Learning.....	16
Tabla 3: Morfotipos de fitolitos de las especies de palmas de Napo.....	19
Tabla 4: Comparación de precisión de validación para la identificación de fitolitos de palmas por variación de los parámetros de entrenamiento.....	22

ÍNDICE DE FIGURAS

Figura 1: Arquitectura típica de CNN.....	4
Figura 2: El parámetro Keras Conv2D.....	5
Figura 3: Sitios de muestreo de palmas para la extracción de fitolitos.....	12
Figura 4: Fitólitos extraídos con la metodología de incineración húmeda.....	17
Figura 5: Fitólitos extraídos con la metodología de incineración seca.....	18
Figura 6: Rendimiento de precisión y pérdida de entrenamiento en el modelo para incineración húmeda.....	23
Figura 7: Rendimiento de precisión y pérdida de entrenamiento en el modelo para incineración seca.....	24
Figura 8: Evaluación de modelos de fitólitos mediante extracción con incineración húmeda.....	25
Figura 9: Evaluación de modelos de fitólitos mediante extracción con incineración seca.....	26

LISTA DE ACRÓNIMOS

HCl: Ácido clorhídrico

ML: Machine learning

DL: Deep learning

CNN: Red neuronal convolucional

SVN: Support vector machine

KNN: K-nearest neighbors

Conv2D: Red convolucional de segunda dimensión

MaxPool2D: Capas de agrupación

InH: Incineración húmeda

InS: Incineración seca

RESUMEN

Las palmas son las plantas más abundantes en la Amazonía que juegan un papel fundamental en el ciclo del carbono y el clima. Sin embargo, aún se debate cómo las palmas han cambiado su distribución y abundancia a lo largo del tiempo bajo el impacto de las culturas precolombinas. Comprender si la distribución actual de las palmeras es natural o antropogénica es fundamental para delinear planes de conservación o restauración. Para reconstruir cómo ha cambiado la distribución de las palmas en el pasado, se pueden usar indicadores como los fitolitos.

Las palmas amazónicas producen grandes cantidades de fitolitos, que son cuerpos de sílice formados dentro de las células. Los fitolitos, debido a su composición química estable, baja solubilidad y resistencia a la degradación, se conservan en los suelos durante miles o millones de años. Esto significa que los suelos son capaces de registrar y almacenar información sobre las comunidades de palmeras que existieron en el pasado. Uno de los retos en el estudio de los fitolitos se centra en la descripción precisa de su morfología que permita su identificación. Los métodos tradicionales de identificación de fitolitos toman mucho tiempo, también puede existir sesgos en su identificación a pesar de ser realizados por personal capacitado. El desarrollo de nuevas herramientas como el aprendizaje automático, permite eliminar el sesgo humano a la hora de realizar tareas repetitivas, especialmente en el reconocimiento y clasificación de imágenes.

En este estudio se propone desarrollar una herramienta que permita la identificación de fitolitos basada en algoritmos de aprendizaje automático orientada a diferenciar palmas a nivel taxonómico de género o especie. Para ello, se recolectaron 20 especies de palmeras en Napo, Ecuador (*Aphandra*, *Astrocaryum*, *Bactris*, *Ceroxylon*, *Dyctocaryum*, *Euterpe*, *Geonoma*, *Iriarte*, *Mauritia*, *Oenocarpus*, *Prestoea* y *Wittinia*). La selección se hizo considerando su multiplicidad de usos antropogénicos, como indicador posible de uso por parte de las poblaciones precolombinas, así como la abundancia en las comunidades. Las muestras de fitolitos se prepararon por digestión química e incineración. Se tomaron 4 000 fotografías en un microscopio invertido con aumento de 100x y se evaluaron utilizando técnicas de aprendizaje automático para identificar especies de fitolitos y facilitar el proceso de reconstrucción del paisaje amazónico precolombino.

Palabras clave: Reconstrucción, restauración de paisaje y vegetación, digestión química, incineración, clasificación y reconocimiento de imágenes.

ABSTRACT

Palms are the most abundant plants in the Amazon that play a fundamental role in the carbon cycle and climate. However, how palms have changed their distribution and abundance over time under the impact of pre-Columbian cultures is still under debate. Understanding whether the current distribution of palms is natural or anthropogenic is fundamental to outlining conservation or restoration plans. To reconstruct how palm distribution has changed in the past, indicators such as phytoliths can be used.

Amazonian palms produce large quantities of phytoliths, which are silica bodies formed inside the cells. Phytoliths, due to their stable chemical composition, low solubility and resistance to degradation are preserved in soils for thousands or millions of years. This means that soils are capable of recording and storing information about the palm communities that existed in the past. However, one of the challenges in the study of phytoliths centers on the precise description of their morphology that allows their identification. Traditional methods of phytolith identification are carried out by trained personnel, take a long time and are susceptible to biases. The development of new tools such as machine learning, allows to eliminate human bias when performing repetitive tasks, especially in the recognition and classification of images.

In this study we propose to develop a tool that allows the identification of phytoliths based on machine learning algorithms oriented to differentiate palms at the taxonomic level of genus or species. For this purpose, 20 palm species were collected in Napo, Ecuador (Aphandra, Astrocaryum, Bactris, Ceroxylon, Dyctocaryum, Euterpe, Geonoma, Iriarteia, Mauritia, Oenocarpus, Prestoea and Wittinia). The selection was made considering their multiplicity of anthropogenic uses, as a possible indicator of use by pre-Columbian populations, as well as the abundance in the communities. The phytolith samples were prepared by chemical digestion and incineration. Four thousand photographs were taken under an inverted microscope at 100x magnification and evaluated using machine learning techniques to identify phytolith species and facilitate the process of reconstructing the pre-Columbian Amazonian landscape.

Keywords: *Reconstruction, landscape restoration and vegetation, chemical digestion, incineration, classification and recognition of image.*

CAPÍTULO I

1. PLANTEAMIENTO DEL PROBLEMA DE INVESTIGACIÓN

1.1 Antecedentes

1.1.1 *Formación y función de los fitolitos*

Las plantas terrestres son capaces de formar fitolitos a partir del silicio, el segundo elemento más abundante de la corteza terrestre que puede representar hasta el 45% del peso seco del suelo [1]. Este proceso se genera mediante la síntesis de minerales compuestos de óxido silicio (SiO_2) que se transforma en sílice [2]. La formación de fitolitos inicia con la absorción de ácido silícico ($\text{H}_4\text{O}_4\text{Si}$) cuyas concentraciones oscilan entre 0.1 y 0.6 mM. El ácido silícico es transportado de las raíces al cuerpo de la planta y se depositan como sólidos polímeros de sílice hidratada ($\text{SiO}_2 \cdot n\text{H}_2\text{O}$; opal-A) en el interior y alrededor de las células vegetales, y en los espacios intercelulares del tejido epidérmico de las hojas, frutos, tallos, raíces e inflorescencias, tomando la forma de las células que los contiene [3; 4]. Como hay tipos celulares característicos de cada especie, se pueden relacionar la forma fitolítica con la planta de origen [4].

Las plantas con una mayor concentración de sílice generan una mayor actividad de quitinasas, peroxidasas, polifenol oxidasas las que protegen a la planta contra patógenos fúngicos [5]. También, proporciona soporte estructural brindando rigidez y dureza a las hojas [6; 7]. La ausencia de silicio en las plantas provoca que estas sean estructuralmente más débiles, e incide en su crecimiento, desarrollo, viabilidad y reproducción [8]. De esta manera la presencia de sílice proporciona un sistema de defensa físico y químico contra la herbívora [5; 2] al hacer que los tejidos vegetales sean menos accesibles o digeribles para los herbívoros, ya que es capaz de ejercer este efecto protector evitando la penetración de plagas. Cuando las plantas mueren y se descomponen los fitolitos, debido a su composición química estable, baja solubilidad y resistencia, suelen quedar preservados en el suelo, durante miles o incluso millones de años, proporcionando evidencia física de la existencia de las plantas en las que se formaron en el tiempo y espacio [9; 10].

1.1.2 Extracción e identificación de fitolitos

Los fitolitos de plantas son extraídos mediante métodos que se pueden agrupar en dos categorías: incineración seca y digestión ácida [11]. La incineración seca fue el primer método para la separación de los fitolitos del material vegetal, este procedimiento incluye primero la quema del material vegetal seguido del tratamiento de las muestras mediante lavado con agua destilada o ácido clorhídrico (HCl) [12]. Por otro lado, la incineración húmeda se introdujo por Zimmerman en 1901, pero fue sustituida por el nombre y uso de digestión ácida como medios de oxidación [11]. Para la extracción de fitolitos se utilizan procedimientos que requieren mucho tiempo (semanas e incluso meses) y requieren de sustancias tóxicas y peligrosas [13] como la combinación de ácido nítrico y clorato de potasio o el uso de hipoclorito de sodio.

La descripción de la morfología de los fitolitos es un requisito previo para la aplicación de información que estos pueden ofrecer. Tradicionalmente los rasgos morfológicos de un fitolito como forma, margen, textura superficial, ornamentaciones y tamaños [14] son descritos por el ojo humano. Sin embargo, esta práctica introduce sesgos al describir la variación morfológica, ya que es difícil comparar los resultados de estudios en estos términos, porque diferentes autores pueden tener diferentes interpretaciones y tratamientos en sus propios estudios de identificación de morfologías [15; 16].

1.1.3 Machine learning

El machine learning es un conjunto de algoritmos que son utilizados especialmente para la predicción e identificación de diferentes características como la forma, el color y los patrones más importantes de un grupo de imágenes de entrenamiento [17; 18]. Durante la fase de aprendizaje los algoritmos observan entradas y respuestas para encontrar patrones dominantes, así las características halladas durante el entrenamiento se usan para reconocer y diferenciar un nuevo grupo de imágenes [17; 18; 19]. Esta tecnología ha sido aplicada en diversos campos como el reconocimiento de patrones, en la ingeniería de naves espaciales, la ecología, biología y aplicaciones biomédicas y médicas [20].

El campo de machine learning ha permitido el avance a una variedad de aprendizajes, uno de estos avances es la evolución de las redes neuronales artificiales hacia

arquitecturas de redes neuronales convolucionales cada vez más profundas y mejoradas, llamadas deep learning (DL) [21]. La aplicación de la red neuronal convolucional (CNN) ha permitido eliminar las características que son dependientes, por ejemplo, en una aplicación para detección de rostros, no es necesario que las caras en las imágenes se encuentren en la misma posición en la imagen, la única preocupación es detectarlos independientemente de su posición en las imágenes dadas [22].

Por lo tanto, es una herramienta clave para la identificación morfológica de fitolitos, ya que permite eliminar el sesgo humano. La precisión de estos algoritmos aumenta con el número de muestras de fitolitos empleados en el análisis, promoviendo el intercambio de datos morfológicos de fitolitos existentes [16]. El estudio realizado por Cai & Ge (2017) indicó por primera vez varios algoritmos de machine learning bien desarrollados para la identificación de fitolitos, como los algoritmos SVN (support vector machine) y KNN (k-nearest neighbors) obteniendo un 87% de diferenciación entre taxones a nivel de género de las subfamilias Bambusoideae, Ehrhartoideae y Pooideae, los fitolitos fueron clasificados con éxito en los taxones de los que se derivaron [19].

La arquitectura típica de una red neuronal convolucional (CNN) (Figura 1) consta de una capa de entrada, capas convolucionales, capas RELU, capas de agrupación y capas totalmente conectadas [23]:

1. Capa INPUT: es la capa encargada de la entrada de valores de píxeles sin procesar de la imagen como (ancho de la imagen, alto, rango de tres colores, canales R, G, B). Esta extracción de características se denomina (kernel) [23].
2. Capa CONV: la imagen de entrada se coloca en un conjunto de filtros de convolución cada uno de los cuales activa ciertas características en la imagen [23].
3. Capa POOL: muestreo descendente en dimensiones espaciales (ancho y altura) [23].
4. Capa RELU: logra que el entrenamiento sea más rápido y eficiente al mapear valores negativos a cero y mantener los valores positivos [23].
5. Capa FC (totalmente conectada): la capa totalmente conectada es para aplanar los resultados anteriores y luego recibir los más básicos [23].




Figura 1. Arquitectura típica de CNN.

Fuente: López, 2019

Elaboración: Vera Karla, 2022.

Para la creación de los modelos existen diferentes tipos de algoritmos como InceptionV3, VGG16, VGG19, MolibeNet, Xception, AlexNet, VGG16, ResNet50 entre otros. [24]. En este caso se utilizó la arquitectura Xception, debido a que es una red pre-entrenada para la extracción de características de alta robustez, consta de 36 capas convolucionales que forman la base de extracción de características de la red, las 36 capas están estructuradas en 14 nódulos, todos ellos con conexiones residuales lineales a excepción del primer y último nódulo [25] (Figura 1). El código se crea mediante el programa R con la biblioteca de alto nivel de keras o tensorflow.

El modelo puede evaluarse por medio de dos tareas de clasificación [25]. La primera es de una sola etiqueta de clase con 1 000 conjuntos de datos de ImageNet y la otra clase de 17 000 etiquetas múltiples de conjunto de datos JFT a gran escala [26]. En el caso de la red convolucional de segunda dimensión (conv2D), se utiliza un total de siete capas sobre las cuales la primera y la tercera son capas convolucionales (Conv2D), la segunda y la cuarta son una capa importante en CNN denominadas capas de agrupación (MaxPool2D), las dos últimas capas son densas completamente conectadas, es un clasificador artificial de redes neuronales [25].

La primera capa Conv2D la utilizamos con filtros de tamaño de lote que se define a cuantas de las entradas serán procesadas juntas, de 32 para el primero y 64 filtros para el último, cada filtro transforma una parte de la imagen definiendo el tamaño. Los filtros pueden verse como una transformación de la imagen con ciertas características del objeto de estudio (Figura 2).



Figura 2. El parámetro Keras Conv2D. Cada una de estas operaciones produce un mapa de activación 2D.

Elaboración: Vera Karla, 2022

1.1.4 Utilidad de los fitolitos

El estudio de los fitolitos data del siglo XVIII, pero no es hasta mediados del siglo XIX en 1836 que Ehrenberg desarrolló el primer sistema de clasificación de fitolitos [27], útil en campos como la botánica, la geología y la arqueología [6]. Para identificar la vegetación del pasado es fundamental tener material de referencia contemporáneo, sin embargo, para regiones neotropicales este es aún limitado. Por ello hasta fines de la década de 1970 y principios de 1980, no se había estudiado satisfactoriamente la producción, taxonomía, identificación de los fitolitos y aplicaciones ecológicas [28]. Arqueobotánicos estadounidenses comenzaron en tal año a utilizar fitolitos como marcadores del uso del suelo, para determinar el período en el que se produjo la domesticación de las plantas, y como una herramienta que permite realizar la reconstrucción de la vegetación y el paisaje [7; 29; 30; 31].

El uso de fitolitos ha sido muy útil por ejemplo en la reconstrucción del paisaje, como lo demostraron Evett y colaboradores (2012) en California, mediante un análisis de fitolitos de suelo comparando la vegetación moderna, con la pasada y estimando el cambio en periodos largos de tiempo después de la llegada de los colonos europeos a finales del

siglo XVIII. Con base al análisis de fitolitos, se pudo determinar que la composición de la vegetación no había cambiado y que se mantuvo estable. Este tipo de estudios permite identificar una línea base que puede ser empleada para realizar trabajos de restauración de la vegetación. Esta perspectiva fue exitosamente aplicada en proyectos de restauración en lugares como en el desierto de la Gran Cuenca en California, Virginia en EEUU y la Meseta de Loes en China [32]. Reconstruir cómo cambia la vegetación también permite entender los factores responsables de la pérdida y degradación del bosque, y así obtener información para el desarrollo de planes y estrategias de restauración [33].

Aunque las algas y plantas (angiospermas y gimnospermas) pueden formar fitolitos, las angiospermas son el grupo más estudiado [34]. Las palmas o familia Arecaceae, son las plantas con flores cuyo origen data alrededor de 80 Ma [35]. Son plantas claves por su diversidad y abundancia en toda la Amazonia [36] así como en las regiones tropicales y subtropicales del mundo. Las palmas tienen un alto valor socioeconómico, ya que proporcionan diferentes elementos de subsistencia como materiales de construcción, tejidos, alimentos, medicinas y también son ornamentales [37; 38].

Las palmas producen gran cantidad de fitolitos se considera que el principal órgano productor de fitolitos son las hojas, por ende, los árboles de hoja perenne son más silíceos que los de hoja caduca, y cuanto más viejas son las hojas de una misma planta más partículas de silicio tienen [14; 34; 39; 40]. También se pueden observar la presencia de fitolitos en inflorescencias y frutos (tejidos del exocarpio y del mesocarpio) [41]. Dado su valor ecológico, económico y sociocultural, reconstrucciones realizadas a partir de fitolitos de palmas permiten responder preguntas relacionadas con el grado de cambio del paisaje precolombino influenciado por las actividades humanas o procesos naturales como eventos climáticos, generando un aporte al debate científico entre quienes sugieren que la Amazonía es un paisaje prístino o si es antropogénico [42; 43].

1.2 Planteamiento del problema

Facilitar el proceso de identificación de fitolitos es de vital importancia para conocer cómo ha cambiado el paisaje amazónico bajo la influencia de la actividad humana [44; 45]. La falta de bases de datos de fitolitos y la dificultad de su identificación limita que se realicen reconstrucciones fiables de la historia del paisaje amazónico [40]. Existe un

debate científico acerca de la diversidad biológica de la Amazonía, sea como un paisaje prístino [42] o como el resultado de actividades antropogénicas [43].

Durante siglos, se creía que el paisaje y la vegetación de la Amazonía sufrió cambios mínimos por grupos pequeños de individuos dispersos por la región. Sin embargo, múltiples estudios sugieren que no todos los bosques tropicales son vírgenes. Algunas áreas muestran evidencia de haber sido transformados o domesticados por poblaciones humanas precolombinas [46]. Estos estudios también contradicen la idea de que los humanos que habitaron la Amazonía tuvieron un efecto insignificante sobre el paisaje amazónico [47]. Antes de la década de los setenta, se consideraba que los humanos que ocupaban la Amazonía eran unos “salvajes nobles” que vivían en un ambiente hostil que limitaba el desarrollo de sociedades complejas [47]. Sin embargo, investigaciones arqueológicas posteriores mostraron que en la Amazonía se desarrollaron sociedades complejas que causaron impactos ambientales significativos [43].

Algunos autores niegan la posibilidad de que en la actualidad los bosques tropicales se mantengan como mosaicos, compuestos por áreas sin y con impactos humanos [42]. Según Clement (2010) los pueblos precolombinos realizaron una domesticación de paisajes en la Amazonia, pero dejaron sin espacio a los bosques primarios o prístinos que presentan condiciones lo más naturales posible. Por consiguiente, el concepto de la antigua Amazonia como un bosque virgen está desacreditado, pero la hipótesis alterna de que la Amazonía entera es un paisaje antropogénico sigue sin ser probada [41].

Por otro lado, los ecosistemas se degradan por procesos antrópicos y/o naturales [18]. En la actualidad la región amazónica ha sido extensamente transformada, debido a las actividades humanas como la tala para la expansión de la frontera agrícola, la ganadería, y por supuesto la industria de explotación de petróleo y minería [49]. Sin embargo, la degradación de los ecosistemas también puede atribuirse a diversos factores naturales como atmosféricos (vientos monzones), hidrológicos (inundaciones, sequías), erupciones volcánicas, e incendios [14].

Según Morales-Hidalgo y colaboradores, (2015) Ecuador es uno de los 15 países que reportó mayores pérdidas de área de bosque primario con 2.1 millones de ha o 14,5% de bosques entre los años de 1990 y 2015 [50]. Los resultados de deforestación en el

período de 2016-2018 corresponden a un promedio de 82.529 ha/año. En la provincia de Napo existe una deforestación anual promedio de 2.267 ha/año [51]. La pérdida de estas áreas limita la provisión de servicios ecosistémicos como el secuestro de carbono relacionado con la modulación del clima global [52], disponibilidad de agua y alimento que impactan directamente a las poblaciones humanas amazónicas.



Los análisis de fitolitos permiten conocer y reconstruir el tipo de vegetación que presentaba un área y comprender el patrón de cambios del uso del suelo [34]. Particularmente en la Amazonía que es un ecosistema altamente diverso y vulnerable por diferentes actividades antropogénicas, comprender los patrones de la vegetación y los procesos evolutivos es importante para mantener la diversidad biológica y para la restauración ecológica en todas las escalas espaciotemporales [53].






Lamentablemente, el proceso de reconstrucción paleoecológica se ve truncado por la dificultad que representa realizar la identificación de los fitolitos. Este es un proceso laborioso que demanda tener personal especializado. Dentro de los estudios en palmas amazónicas encontramos los siguientes estudios que se indican en la Tabla 1



Tabla 1. Fitólitos de palmas estudiados en la Amazonía.

Fuente: Morcote-Ríos et al. (2013), Watting & Iriarte (2013), Morcote-Ríos et al. (2016), Piperno & McMichael (2020), Witteveen et al. (2022).

Elaboración: Vera Karla, 2022.

Especie	Ambiente	Fotografía de Fitólito	Fuente
<i>Astrocaryum murumuru</i>	Bosque pantanoso (Guayana Francesa)		[54]
<i>Mauritia flexuosa</i>	Bosque pantanoso (Guayana Francesa)		[54]

<i>Astrocaryum</i> <i>sp.</i>	La región está cubierta por un bosque tropical denso y húmedos, se exponen grandes afloramientos rocosos del Escudo Guayanés (Brasil)		[55]
<i>Bactris</i> <i>gasipaes</i>	La región está cubierta por un bosque tropical denso y húmedos, se exponen grandes afloramientos rocosos del Escudo Guayanés (Brasil)		[55]
<i>Attalea</i> <i>butyracea</i>	Piedemonte Caqueteño en la parte baja del río Caquetá (Colombia)		[40]
<i>Oenocarpus</i> <i>batua</i>	Piedemonte Caqueteño en la parte baja del río Caquetá (Colombia)		[40]
<i>Geonoma</i> <i>orbignyana</i>	Piedemonte Caqueteño en la parte baja del río Caquetá (Colombia)		[40]
<i>Geonoma</i> <i>camana</i>	Piedemonte Caqueteño en la parte baja del río Caquetá (Colombia)		[40]
<i>Prestoea</i> <i>schultzeana</i>	Bosque de tierras bajas de la Amazonía		[56]
<i>Oenocarpus</i> <i>mapora</i>	Material de referencia recopilado de Leiden Herbarium y Hortus Botanicus Amsterdam (Países Bajos)		[57]

<i>Euterpe precatoria</i>			[57]
<i>Dictyocaryu m</i>			[57]

Uno de los desafíos en el estudio de fitolitos se centra en la descripción precisa de la morfología y la utilización eficaz de los rasgos de los fitolitos en la identificación o descripción de taxones. Este estudio pretende implementar una herramienta que reemplace los métodos tradicionales de identificación de fitolitos con la finalidad de reducir sesgos durante el proceso de descripción morfológica de los fitolitos [58], ya que la identificación de los fitolitos se basa en un proceso de aprendizaje supervisado [59].

1.3 Justificación de la investigación

Para comprender la complejidad de la Amazonía en el presente [28], es necesario consolidar conocimientos del pasado [28; 32]. Las reconstrucciones paleoecológicas permiten conocer si los patrones contemporáneos de la biodiversidad y distribución de especies amazónicas, son el resultado de la evolución por efecto directo de las actividades humanas o si estuvieron principalmente controlados por procesos naturales. Para discernir entre estas dos alternativas se requiere de análisis e identificaciones precisas de fitolitos [40].

La abundancia de palmas útiles en la Amazonía se considera evidencia de la modificación antropogénica del paisaje [60; 43]. Los fitolitos han permitido mostrar la relación existente entre las palmas con la actividad humana precolombina en la Amazonía [40]. Sin embargo, el uso de fitolitos para realizar reconstrucciones paleoclimáticas es complejo. El proceso de identificación de fitolitos se ve limitado por el tiempo que se requiere para realizar las identificaciones y ausencia de bases de datos. Por lo tanto, implementar un proceso de identificación eficiente de fitolitos facilitará el número de reconstrucciones paleoclimáticas que permitan conocer los cambios de vegetación que se dieron en la Amazonía.

En resumen, para conocer los cambios que experimentó la Amazonía y para aportar al debate sobre los procesos evolutivos de las plantas, es necesario realizar la identificación adecuada y eficiente de fitolitos. Para hacerlo, se escogieron 20 especies de palmas dominantes y de importancia en la Amazonía cuya dinámica poblacional tiene repercusión en procesos globales como el secuestro de carbono. La identificación de fitolitos, empleando machine learning, se hizo utilizando los dos métodos rutinariamente empleados en la preparación de fitolitos. De este modo también es posible determinar el método que mejor resultados ofrece para ser trabajados con machine learning.

1.4 Preguntas de investigación

1. ¿El uso del machine learning es eficaz para diferenciar especies de palmas de la Amazonía ecuatoriana, a partir de sus fitolitos?
2. ¿Cuál de los dos métodos de extracción (incineración y digestión) es el óptimo para la clasificación de los fitolitos de palmas a diferentes niveles taxonómicos, mediante el uso de machine learning?

1.5 Objetivos de la investigación

1.5.1 Objetivo general

Identificar fitolitos de palmas de la provincia de Napo a nivel de especie, mediante el uso de machine learning.

1.5.2 Objetivos específicos

1. Describir las características morfológicas de fitolitos de palmas en la provincia de Napo.
2. Comparar la eficiencia de los dos métodos de extracción (incineración seca e incineración húmeda) para la identificación de fitolitos mediante machine learning.
3. Difundir los resultados de la investigación mediante un catálogo fotográfico de fitolitos de palmas de la provincia de Napo.

CAPÍTULO II:

2. MARCO METODOLÓGICO

2.1 Área de estudio

Para la identificación de sitios de muestreo se utilizó la base de datos de la plataforma GBIF con ocurrencia de palmas en la provincia de Napo (Figura 3). Se seleccionaron los cantones Tena, Archidona, Carlos Julio Arosemena Tola, y Quijos incluyendo las zonas de amortiguamiento de la Reserva Biológica Colonso Chalupas, la Reserva Ecológica Antisana, otras propiedades y reservas privadas.




Figura 3. Sitios de muestreo de palmas para la extracción de fitolitos.

Elaboración: Vera Karla, 2022.

2.2 Fase de campo

2.2.1 Recolección y preparación de muestras de plantas para análisis de fitolitos.

La colecta del material vegetal se realizó bajo el permiso del Ministerio de Ambiente, Agua y Transición Ecológica, número MAAE-ARSFC-2021-1365. Se colectaron 50

especies de palmas, en dos fases de recolección. La primera entre los meses de enero y marzo y la segunda época de verano correspondientes a los meses de agosto a diciembre.

Se seleccionaron 20 especies para el análisis de acuerdo a la importancia socioeconómica y cultural actual en la región (Anexo 1) pertenecientes a los géneros: *Aphandra*, *Astrocaryum*, *Bactris*, *Ceroxylon*, *Dyctocayrum*, *Euterpe*, *Geonoma*, *Iriarte*, *Mauritia*, *Oenocarpus*, *Prestoea* y *Wettinia*. Se tomaron fotografías *in situ*, con una detallada descripción del hábitat y características morfológicas de cada palma, así como las coordenadas geográficas (Figura 3). Considerando que las hojas son los órganos con mayor acumulación de fitolitos de palmas [61; 40; 34], se colectó una o dos hojas en función de la arquitectura de la planta. Posteriormente, fueron etiquetadas y transportada hasta el laboratorio de biomasa de la Universidad Regional Amazónica Ikiam, en donde fueron prensadas y secadas en una estufa casera por 72 horas. Los ejemplares fueron depositados en el Herbario Nacional del Ecuador (QCNE) con el número de depósito QCNE-029-2021.

2.3 Fase de laboratorio

Para la extracción y montaje de fitolitos, se utilizó como base un protocolo establecido por (Corbineau et al., 2013), mediante el cual diseñamos una metodología nueva con pruebas realizadas anteriormente en el laboratorio.

2.3.1 Incineración seca

Siguiendo a Corbineau et al, (2013) las muestras de hojas de las 20 muestras de palmas fueron sometidas para lograr reducir toda la materia orgánica a diferentes tratamientos como:

Primer tratamiento

Se pesó 5 g de muestra de hoja de cada palma, se secaron en una estufa a 200°C por 24 horas. Luego se colocó en la mufla a 600°C por 60 minutos. Se pesó la ceniza y se colocó en un frasco con 15 ml de agua oxigenada (H₂O₂) al 3%. Se realizó el proceso de montaje y las muestras presentaban una visible cantidad de materia orgánica, por lo que fue necesario aplicar un segundo tratamiento.

Segundo tratamiento

Las muestras fueron filtradas para eliminar el agua oxigenada, y se colocó la ceniza restante en cápsulas de porcelana y se dejó secar en una estufa a 200°C por 24 horas. Se colocó en la mufla a 600°C por 90 minutos.

Tercer tratamiento

Dos muestras (elección al azar) fueron sometidas a un tercer tratamiento (*Bactris gasipaes* y *Bactris sp*), sin haber pasado por el tratamiento uno y dos, como prueba al incrementar el número de tiempo en el quemado. Fueron recortadas, se pesó 5 g de muestra y se dejó secar en una estufa a 200°C por 24 horas. Posteriormente fueron quemadas en la mufla a 600°C por 240 minutos.

2.3.2 Incineración húmeda

Las muestras fueron sometidas a un solo tratamiento tomando en cuenta el procesamiento en el tiempo de quemado de las muestras con la metodología de incineración seca.

Las muestras fueron cortadas y se pesó 5 g, se colocó en frascos con 80 ml de agua oxigenada (H₂O₂) al 3%. Estas muestras permanecieron durante dos meses en agua oxigenada para su digestión. Luego fueron filtradas y secadas en una estufa a 200°C por 24 horas. Se quemaron en la mufla a 600°C por 240 minutos.

2.3.3 Preparación de láminas de fitolitos, para su observación en el microscopio.

En un cubreobjetos se colocó gotas de agua oxigenada hasta que se formó una curva cóncava, con una micropipeta de 20-200 ul se colocaron 50 ul de la muestra, y se dejó secar por 24 horas. Luego en un portaobjetos se colocó 20 ul del medio de montaje (Surgipath Micromount Mounting Media). Se aplicó cuidadosamente el cubreobjetos sobre el portaobjetos y se dejó secar por 48 horas, se realizó dos láminas por duplicado, para verificar la ausencia o presencia de fitolitos. Finalmente se observaron las láminas en un microscopio invertido (EVOS XL life technologies) con una magnificación de 100x y se tomaron entre 100 a 150 por lámina. Este procedimiento se aplicó para ambas metodologías.

2.4 Procesamiento y análisis de datos

2.4.1 Descripción e identificación de fitolitos

Se realizó una revisión bibliográfica, para identificar los diferentes tipos de morfologías de fitolitos de palmas descritos por otros estudios como: el Código Internacional de Nomenclatura de Fitólitos [15]. Benvenuto et al., (2015) quienes describen la variación morfológica de los fitolitos basándose en la longitud y densidad de las espinas; el estudio de Marcote-Ríos et al., (2016) que reconocen ocho morfotipos de fitolitos: globular equinado simétrico, globular equinado, globular equinado elongado, globular equinado con densas proyecciones cortas, equinado reniforme, globular equinado con largas proyecciones agudas, cónicos y cónicos con proyecciones basales agudas.

2.4.2 Conjunto de datos

Se tomaron entre 100 y 150 imágenes de las láminas de fitolitos por cada especie, para ambas metodologías. Para la creación de nuestro modelo se utilizó el programa R project [63] y Python. Para la clasificación de las imágenes se utilizó la paquetería de keras y tensorflow de Python y en R Project la paquetería de tidyverse, reticulate y class.

2.4.3 Creación de modelo

Se construyeron dos tipos de modelos: el primer modelo de red neuronal convolucional secuencial simple con las siguientes capas ocultas, 2 capas convolucionales (Conv2D), una capa de agrupación y una capa densa. El segundo tipo de modelo en el cual, para construir la arquitectura del modelo, se utilizó un modelo preentrenado llamado Xception que está basado en capas convolucionales separables en profundidad, esta es una red neuronal convolucional profunda que se entrena mediante un amplio conjunto de datos conocido como ImageNet, el cual permite clasificar imágenes con buenas precisiones. Los tamaños de escala de todas las imágenes de entrada para los modelos de fueron de 224x224 cm [64].

Ambos modelos fueron entrenados con diferentes parámetros como división de datos (datos para entrenamiento y datos para validación), velocidad o tasa de aprendizaje, número de épocas, tamaño de lote, tipo de algoritmo y tipo de optimizador.

2.4.4 Métricas de rendimiento del modelo

Para evaluar el rendimiento del modelo se utilizó una matriz de confusión con 2 etiquetas [56] (Tabla 2)

Tabla 2. Matriz de confusión. Describe el rendimiento de un modelo supervisado de Machine Learning [65].

Fuente: Westphal & Seitz (2021)

Elaboración: Vera Karla, 2022.

		Negativo	Positivo
Valores Actuales	Negativo	TN Verdadero negativo	FP Falso positivo
	Positivo	FN Falso negativo	TP Verdadero positivo

Acurrencia: Porcentaje de rendimiento de las clases.

$$Ocurrancia = \frac{TP + TN}{TP + TN + FP + FN}$$

Precisión: Porcentaje de la precisión del modelo cuando predice resultados positivos.

$$Precisión = \frac{TP}{TP + FP}$$

Recall o la tasa de verdaderos positivos: Es el porcentaje de positivos reales que se identificaron correctamente.

$$Recall = \frac{TP}{TP + FN}$$

CAPÍTULO III

3. RESULTADOS

3.1 Extracción e identificación de fitolitos

Se extrajeron los fitolitos de 20 especies de palmas de la provincia de Napo, mediante dos metodologías incineración húmeda e incineración seca como se indica en las Figuras 4 y 5.




Figura 4. Fitólitos extraídos con la metodología de incineración húmeda.

Las especies corresponden en orden alfabético: *Aphandra Natalia* (A), *Astrocaryum urostachys* (B), *Bactris gasipaes* (C), *Bactris sp* (D), *Ceroxylon cf. echinulatum* (E), *Dictyocaryum lamarckianum* (F), *Euterpe precatoria* (G), *Geonoma macrostachys* morf. *atrovirens* (H), *Geonoma macrostachys* var. *macrostachys* (I), *Geonoma stricta* sub. *trali* (J), *Geonoma stricta* var. *stricta* (K), *Iriartea deltoidea* (L), *Mauritia flexuosa* (M), *Oenocarpus batua* (N), *Oenocarpus mapora* (O), *Phytelephas macrocarpa* (P), *Phytelephas cf. tenuiculis* (Q), *Prestoea acuminata* var. *acuminata* (R), *Prestoea shultzeana* (S) y *Wettinia maynensis* (T).

Elaboración: Vera Karla, 2022.




Figura 5. Fitolitos extraídos con la metodología de incineración seca.

Las especies corresponden en orden alfabético: *Aphandra Natalia* (A), *Astrocaryum urostachys* (B), *Bactris gasipaes* (C), *Bactris sp* (D), *Ceroxylon cf. echinulatum* (E), *Dictyocaryum lamarckianum* (F), *Euterpe precatoria* (G), *Geonoma macrostachys* morf. *atrovirens* (H), *Geonoma macrostachys* var. *macrostachys* (I), *Geonoma stricta* sub. *trali* (J), *Geonoma stricta* var. *stricta* (K), *Iriartea deltoidea* (L), *Mauritia flexuosa* (M), *Oenocarpus batua* (N), *Oenocarpus mapora* (O), *Phytelephas macrocarpa* (P), *Phytelephas cf. tenuiculis* (Q), *Prestoea acuminata* var. *acuminata* (R), *Prestoea shultzeana* (S) y *Wettinia maynensis* (T).

Elaboración: Vera Karla, 2022.

La morfología general y las características específicas de ornamentación superficial de fitolitos, fueron descritos de acuerdo con las descripciones de ICPN y otros estudios de descripción de morfologías [15; 40; 66]. Se identificó siete morfotipos: globular granular, cónicos y cinco submorfotipos de globular equinado; alargado, simétrico con proyecciones densas, cortas, e irregulares. En la Tabla 3 se indican los tipos de morfologías a las que corresponden cada una de las 20 especies.

Tabla 3. Morfotipos de fitolitos de las especies de palmas de Napo.

Fuente: Madella et al, (2005), Morcote-Ríos et al, (2016), Huisman et al, (2018).

Elaboración: Vera Karla, 2022.

Especies	Cóni cos	Glob ular gran ulad o	Globul ar equin ado con acum ulació n de proye ccione s	Globul ar equina do con proyec ciones cortas	Glob ular equin ado simét rico	Glob ular equin ado alarg ado	Glob ular equin ado con proye ccion es irreg ulare s
<i>Aphandra Natalia (A)</i>					x		
<i>Astrocaryum urostachys (B)</i>	x						
<i>Bactris gasipaes (C)</i>	x						
<i>Bactris sp (D)</i>	x						
<i>Ceroxylon cf. echinulatum (E)</i>					x		
<i>Dictyocaryum lamarckianum (F)</i>	x						
<i>Euterpe precatoria (G)</i>				x			
<i>Geonoma macrostachys morf. atrovirens (H)</i>						x	
<i>Geonoma macrostachys var. macrostachys (I)</i>		x					
<i>Geonoma stricta sub. traili (J)</i>	x						
<i>Geonoma stricta var stricta (K)</i>	x						
<i>Iriartea deltoidea (L)</i>	x						
<i>Mauritia flexuosa (M).</i>							x
<i>Oenocarpus batua (N)</i>		x				x	
<i>Oenocarpus mapora (O)</i>			x				
<i>Phytelephas macrocarpa (P)</i>				x			
<i>Phytelephas cf. tenuiculis (Q)</i>							

<i>Prestoea acuminata</i> <i>var acuminata</i> (R)							
<i>Prestoea shultzeana</i> (S)			x				
<i>Wettinia maynensis</i> (T)	x						

Las descripciones morfológicas fueron descritas en base a la siguiente bibliografía [19; 3; 57]. Por otro lado, los tamaños de los fitolitos fueron medidos en las muestras obtenidas, a partir de los métodos de medición establecidos en Cai & Ge (2017).

1. Cónicos: Fitólitos con forma cónica, proyecciones de 3 a 6, que se encuentran dispuestas alrededor de la parte superior en un círculo. En muchos casos las proyecciones están evidentemente pronunciadas y fácilmente reconocibles. La ornamentación superficial es densamente granular. Las especies que presentan este tipo de morfologías de fitólitos son *Bactris gasipaes* con un tamaño de 6 a 10 μm *Iriarte deltoidea* con un tamaño de 10 μm *Dictyocaryum lamarckianum* con un tamaño de 8 a 10 μm *Geonoma stricta sub. traili* con un tamaño de 8 a 12 μm *Geonoma stricta var stricta* con un tamaño de 10 a 12 μm *Astrocaryum urostachys* con un tamaño de 7 a 12 μm y *Wettinia maynensis* con un tamaño de 10 μm .
2. Globular granulado: Este subtipo se diferencia claramente por sus proyecciones cortas y de diferentes formas muy granuladas que se encuentran distribuidos por la superficie del fitólito. Las especies con este tipo de morfología de fitólitos son *Oenocarpus batua* con un tamaño de entre 5 y 20 μm y *Geonoma macrostachys var. macrostachys* con un tamaño de 7 a 10 μm .
3. Globular equinado con acumulación de proyecciones: Este subtipo puede ser fácilmente confundido con un fitólito globular granulado debido a su alta densidad de proyecciones, este tipo de fitólito consta de muchas proyecciones muy pequeñas y poco agudas, no presenta el típico contorno equinado con espinas prominentes. Los fitólitos con estas características son de la especie *Oenocarpus mapora* con un tamaño de 5 μm y *Prestoea shultzeana* con un tamaño de 5 y 20 μm .

4. Globular equinado con proyecciones cortas: Este subtipo se identifica por la presencia de proyecciones cortas, pero no abundantes como, el subtipo descrito por Marcote-Ríos et al, (2016). Mantiene el típico contorno equinado espinoso. Los fitolitos con este tipo de morfología se encuentran en las especies *Euterpe precatoria* con un tamaño de 5 μm y *Phytelephas macrocarpa* con un tamaño de 5 y 10 μm .
5. Globular equinado simétrico: Consta de proyecciones agudas dispuestas simétricamente, de 8-12 proyecciones visibles, estas proyecciones con claras que se distribuyen de manera más o menos uniforme en la superficie. Tamaño de fitolitos de la especie *Ceroxylon cf. echinulatum* entre 3 y 5 μm y de la especie *Aphandra natalia* con un tamaño de 5 μm .
6. Globular equinado alargado: Tiene forma elíptica, la apariencia de este equinado se da debido a que aparece como comprimido bilateralmente. En la especie *Geonoma macrostachys morf. atrovirens* el tamaño de los fitolitos es de 8 a 10 μm .
7. Globular equinado con proyecciones irregulares: Sus proyecciones son muy irregulares no tiene la forma redondeada de un globular equinado normal, debido a sus proyecciones genera un fitolito con apariencia estrellada. Las especies con los fitolitos de esta morfología son la especie *Mauritia flexuosa* con un tamaño de 6 a 10 μm *Phytelephas cf. tenuiculis* con un tamaño de 7 a 10 μm y *Prestoea acuminata var acuminata* con un tamaño de 5 μm .

3.2 Identificación de fitolitos extraídos con metodología de incineración húmeda (InH) e incineración seca (InS), mediante machine learning.

Los modelos fueron ejecutados con la arquitectura Xception y la red convolucional de segunda dimensión (conv2D). Para ejecutar los modelos, se tomaron alrededor de 2 000 fotografías de fitolitos para cada metodología, en total alrededor de 4 000 imágenes. Se estableció este número de imágenes, debido a que los datos deben ser lo suficientemente representativos para la aplicación.

El entrenamiento de los modelos fue realizado con diferentes parámetros como: la división de datos con una relación de 70:30, lo que significa que se utilizó alrededor de 1572 imágenes para el entrenamiento y 663 imágenes para la validación que se define como el conjunto de datos conocidos, que sirven de apoyo para confirmar que el algoritmo se ajusta a la clasificación correcta. La velocidad de aprendizaje, el número de épocas, tipo de algoritmo y optimizador que se utiliza para mejorar la función de pérdida de entropía cruzada categórica (Tabla 4).

Tabla 4. Comparación de precisión de validación para la identificación de fitolitos de palmas por variación de los parámetros de entrenamiento.

Elaboración: Vera Karla, 2022.

No de modelo	División de datos	Parámetros de entrenamiento						Precisión de validación (%) (InH)	Precisión de validación (%) (InS)
		Velocidad de aprendizaje (%)	Layer dropout	Número de épocas	Tamaño de lote	Tipo de algoritmo	Tipo de Optimizador		
1	80:20	0.001	0.2	10	32	Xception	Adam	60.42	49.04
2	80:20	0.001	0.2	50	32	Xception	Adam	73.54	65.62
3	70:30	0.001	0.2	50	32	Xception	Adam	73.86	68.12
4	70:30	0.0001	0.2	50	32	Xception	Adam	71.02	64.06
5	70:30	0.001	0.3	50	32	Xception	Adam	75.14	66.41
6	70:30	0.0001	0.3	50	32	Xception	Adam	73.15	65.47
7	70:30	0.0001	0.25	10	32	Conv2D	RMSprop	87.50	57.66
8	70:20	0.0001	0.25	50	32	Conv2D	RMSprop	99.72	70.31

En las figuras 6 para incineración húmeda y la figura 7 para incineración seca, se observan las curvas de pérdida (loss), entrenamiento (accuracy) y validación de los modelos (val_accuracy). Las curvas en color azul corresponden para los datos de entrenamiento y el color verde para los datos de validación. Las curvas de entrenamiento y validación del modelo tienen un rango 0 a 1 en el eje y, debido a que corresponde al porcentaje en el que el modelo está logrando clasificar las imágenes siendo el 1 un 100% de precisión de entrenamiento y validación de los datos.

Los mejores modelos con un mayor porcentaje de precisión y validación de los datos, en la figura 6 fueron el modelo cinco, siete y ocho, y para el caso de la figura 5, fueron los modelos tres y ocho, debido a que en estos modelos las curvas de entrenamiento y validación se acercan a un estado de convergencia. De esta manera se puede determinar si el modelo ha aprendido o no, si se ajusta adecuadamente al conjunto de datos de entrenamiento y los resultados obtenidos.




Figura 6. Modelos con el conjunto de datos de incineración húmeda.
 *Modelos con mayor porcentaje de precisión en el entrenamiento y validación de los datos.
Elaboración: Vera Karla, 2022.




Figura 7. Modelos con el conjunto de datos de incineración seca.
 *Modelos con mayor porcentaje de precisión en el entrenamiento y validación de los datos.
Elaboración: Vera Karla, 2022.

3.3 Evaluación de modelos para incineración húmeda e incineración seca.

Para la evaluación de los modelos se usaron alrededor de 10 imágenes por muestra en total 200 imágenes, estas imágenes no deben constar en los datos empleados para el entrenamiento y validación del modelo.

En el caso de la evaluación del modelo número ocho con muestras procesadas por incineración húmeda (Figura 6), se logró tener un porcentaje de clasificación del 100 % para 15 especies de palmas. Con el proceso de incineración seca (Figura 9), el porcentaje de clasificación fue de 100% para 12 especies.




Figura 8. Evaluación de modelos de fitolitos mediante extracción con incineración húmeda.

Elaboración: Vera Karla, 2022




Figura 9. Evaluación de los modelos con mayor valor de precisión de validación, para los fitolitos extraídos con el método de incineración seca.

Elaboración: Vera Karla, 2022

CAPÍTULO IV

4. INTERPRETACIÓN Y DISCUSIÓN

En nuestro estudio se corrieron ocho modelos para cada uno de los métodos de incineración húmeda y seca. Los modelos siete y ocho tuvieron una precisión de validación de 87,54% y 99,72% para la incineración húmeda. Por el contrario, los modelos tres y ocho tuvieron una precisión de validación del 68,12 % y del 70,31 % para la incineración seca (Tabla 4).

El entrenamiento de modelos con una tasa de aprendizaje lenta $L=0,0001$ produjo mejores resultados que las tasas de aprendizaje rápidas ($L=0,001$). La relación entrenamiento-validación 70:30 produjo mejores resultados que la relación 80:20, debido a que utiliza el 70% de las imágenes para entrenamiento del modelo y 30% de las imágenes para la validación del modelo (Tabla 4). Cuando se aumenta el porcentaje de datos en el conjunto de datos de entrenamiento, tenemos valores más bajos de precisión de validación.

Por lo tanto, un aumento de datos en el entrenamiento podría tener una influencia negativa en la precisión de la predicción y la dificultad para aplicar los modelos, debido a que se puede que generar un sobreajuste que es cuando la capacidad de aprendizaje es tan grande que la red aprenderá características adulteradas en lugar de significativas [67]. Este hallazgo está en línea con otros trabajos publicados, existen varios estudios que demuestran tener mejores resultados de precisión de validación con la relación 70:30 [68; 69].

El incremento de número de épocas, se define a la cantidad de pases que el algoritmo ha completado durante el entrenamiento, un ciclo completo del conjunto de datos se compone de lotes e iteraciones, este parámetro es fundamental debido a que es necesario alcanzar la convergencia de entrenamiento. En el caso de la extracción con incineración húmeda el modelo siete con un conjunto de 10 épocas genera una precisión del 87.50 % mientras que el modelo ocho al incrementar el número de épocas a 50 produce un 99.72 % de precisión, estos resultados indican la importancia de entrenar a los modelos hasta que alcancen el estado de convergencia [64].

Asumimos que los valores obtenidos en estos modelos se deben a que es importante evitar un sobreajuste del modelo en el entrenamiento, de igual forma el aumento de datos se utiliza como un mecanismo regulatorio, como indica en el estudio realizado por Westphal E, & Seitz H. (2021) en la detección y visualización de defectos en piezas mediante modelos de machine learning, en el cual realizaron tres experimentos con diferentes tipos de algoritmos y variaciones en sus hiperparámetros (tasa de aprendizaje, optimizador, número de épocas, tamaño de lote) determinaron que el método presentado con un aumento de datos y con el preentrenamiento con ImageNet es ventajoso para lograr modelos con arquitecturas más robustas.

Por ello, con el aumento de datos se debe realizar un ajuste de hiperparámetros (división de datos, velocidad o tasa de aprendizaje, número de épocas, tipo de algoritmo, tipo de optimizador) en el conjunto de datos de entrenamiento que es un proceso esencial [65];[70]. La utilización de un número suficiente de datos (imágenes) es particularmente importante para la generalización de los modelos y evitar el sobreajuste.

En la evaluación de los modelos para cada una de las metodologías de extracción de fitolitos se identificó que, en el caso de incineración seca, el modelo ocho, generó un porcentaje de clasificación correcto con el 100% para 12 especies de palmas. Sin embargo, el porcentaje de clasificación fue menor a 80% en seis especies (*Wettinia maynensis*, *Euterpe precatoria*, *Prestoea acuminata var acuminata*, *Oenocarpus batua*, y *Dictocaryum lamarckianum*). La clasificación fue inefectiva para el caso de la especie *Mauritia flexuosa* cuyo porcentaje fue de 0% (Figura 9).

Por otro lado, en el caso de la extracción de fitolitos mediante incineración húmeda la evaluación del modelo ocho (Figura 8) tuvo un mejor valor de precisión de validación. Este modelo logró clasificar correctamente las imágenes de fitolitos de 15 especies de palmas, con un porcentaje de clasificación del 100% mientras que una especie fue del 40 % (*Bactris gasipaes*) y cuatro especies que no se clasificaron en ninguna categoría con un 0% de inefectividad (*Prestoea acuminata var acuminata*, *Prestoea shultzeana*, *Phytelephas macrocarpa* y *Phytelephas cf. tenuiculis*).

Estos resultados pueden estar condicionados por factores como el clima, estadio de crecimiento, cantidad de agua en el suelo, la edad de la planta y la afinidad taxonómica de la planta misma [71, 28]. Es evidente que la clasificación de fitolitos mediante la

superposición de variables morfológicas como el tamaño entre las especies de palmas se dificulta, debido a que a simple vista muchas especies comparten un similar morfotipo, dificultando la clasificación taxonómica a nivel de especie [57].

Las características de las proyecciones de los fitolitos permiten generar un diagnóstico de diferenciación de morfologías entre los fitolitos de palmas (Tabla 3). Dentro de los morfotipos de fitolitos de palmas de una misma especie existen sutiles variaciones en cuanto a sus tamaños. Asumimos que esta variación se debe, primero a que la forma y tamaño de los fitolitos suele ser similar a la célula en el que se forma, por otro lado, al tiempo de depósito de sílice en las células. La senescencia tiene un papel importante en la deposición de sílice, debido a que en las hojas más viejas de la planta habrá mayor contenido de sílice que en las partes u hojas más jóvenes [72].

Morcote-Ríos y colaboradores (2016), mencionan que la especie *Prestoea shultzeana* presenta tres submorfotipos: 1) globular equinado con proyecciones alargadas, 2) con densas proyecciones cortas y 3) equinado reniforme. En nuestro estudio identificamos solo un submorfotipo globular equinado con acumulación de proyecciones. En el caso de *Phytelephas macrocarpa*, Morcote-Ríos y colaboradores (2016) identificaron el morfotipo globular equinado. Los resultados de las morfologías muestran claramente el predominio de morfologías equinadas y globulares. Los fitolitos globulares se han asignado principalmente a palmeras, árboles leñosos y otras familias de monocotiledóneas de zonas tropicales, los cuales son diferenciados entre ellos mediante sus proyecciones, tamaños de espigas. Los resultados obtenidos en la evaluación del modelo para el caso de incineración húmeda con una clasificación del 0% para cuatro especies puede ser debido a que los fitolitos de estas especies son muy variables.

Otro factor que puede alterar la identificación de fitolitos es el método de extracción. Cuando se utiliza ácidos fuertes en la extracción, estos pueden alterar la morfología de los fitolitos. De acuerdo con Katz y colaboradores (2010), algunos fitolitos que son tratados con ácido clorhídrico (HCl) diluido se disuelven en cuestión de días. Los fitolitos con una morfología y estructura más frágil pueden romperse en varios fragmentos en comparación con los más robustos. De igual forma, Cabanes e investigadores. (2011) mencionan que los fitolitos extraídos de plantas actuales presentes son más solubles que los fitolitos fósiles. Por eso, en nuestro estudio se logró extraer fitolitos sin la

aplicación de productos químicos ácidos, reduciendo el riesgo de daño de estas estructuras. En las dos metodologías incineración húmeda y seca, las muestras de fitolitos fueron sometidas en peróxido de hidrogeno al 3% para evitar la disolución de los fitolitos. Este proceso evita generar sesgos por alteraciones morfológicas de los fitolitos al momento de realizar reconstrucciones paleoecológicas [12].

La incineración húmeda eliminó la mayor parte de los desechos de la materia orgánica, lo que permitió obtener mejores imágenes de fitolitos que la incineración seca. Demostrando que la eliminación de los residuos de materia orgánica es uno de los pasos más importantes al preparar muestras [12] para el análisis de aprendizaje automático o aplicación de machine learning.

CAPÍTULO V

5. CONCLUSIONES Y RECOMENDACIONES

5.1 Conclusiones

El rendimiento del modelo fue mayor con el proceso de extracción de incineración húmeda, con una precisión de clasificación del 100% de 15 especies de palmas, demostrando que los algoritmos de machine learning son una herramienta viable para la mejorar en tiempo y eficacia la identificación morfológica de fitolitos a nivel de especie.

De igual forma, se generó datos de fitolitos correspondientes a 20 especies de palmas de la provincia de Napo, proporcionando una base para futuras investigaciones en temas de reconstrucciones de la vegetación y el paisaje en la Amazonía ecuatoriana, debido a que con la información acerca de la vegetación del presente se puede proporcionar material para que las reconstrucciones de dinámicas ecológicas pasadas sean más detalladas, y así entender el grado de modificación de los bosques ya sea por impactos humanos o naturales. Conocer la dinámica de los cambios del uso del suelo, ayuda a definir el potencial de los ecosistemas y situar prácticas sostenibles de manejo de los recursos de los pueblos o comunidades en un contexto histórico, contribuyendo a la conservación.

5.2 Limitantes y recomendaciones

El método de extracción de fitolitos puede impedir seriamente la identificación y la precisión de clasificación de fitolitos de las palmas, mediante machine learning. En nuestro estudio utilizando material fotográfico se ha evidenciado que las muestras procesadas mediante incineración húmeda contienen una menor cantidad de materia orgánica que la incineración seca, proporcionando fitolitos limpios y desarticulados.

La edad de la hoja juega un papel muy importante en la acumulación y formación de fitolitos, para este estudio se colectaron hojas jóvenes, lo cual generó sutiles variaciones en los tamaños de los fitolitos. Por lo que se recomienda la recolección de hojas viejas para tener una mayor acumulación y mejor formación de los fitolitos.

La creación de los modelos se estableció con una etapa en el que se utilizó una red preentrenada (Xception). Sin embargo, se recomienda realizar un segundo paso para optimizar el modelo a través de un ajuste al incorporar el aumento de datos utilizando diferentes técnicas geométricas.

REFERENCIAS

1. Sommer, M., Kaczorek, D., Kuzyakov, Y., & Breuer, J. (2006). Silicon pools and fluxes in soils and landscapes—a review. *Journal of Plant Nutrition and Soil Science*, 169(3), 310-329.
2. Trembath-Reichert, E., Wilson, J. P., McGlynn, S. E., & Fischer, W. W. (2015). Four hundred million years of silica biomineralization in land plants. *Proceedings of the National Academy of Sciences*, 112(17), 5449-5454.
3. Kumar, S., Milstein, Y., Bami, Y., Elbaum, M., & Elbaum, R. (2017). Mechanism of silica deposition in sorghum silica cells. *New Phytologist*, 213(2), 791-798.
4. Nawaz MA, Zakharenko AM, Zemchenko IV, Haider MS, Ali MA, Imtiaz M, Chung G, Tsatsakis A, Sun S, Golokhvast KS. (2019) Phytolith Formation in Plants: From Soil to Cell. *Plants*. 8(8):249. <https://doi.org/10.3390/plants8080249>.
5. Currie, H. A., & Perry, C. C. (2007). Silica in plants: biological, biochemical and chemical studies. *Annals of botany*, 100(7), 1383-1389.
6. Zurro, D. (2006). El análisis de fitolitos y su papel en el estudio del consumo de recursos vegetales en la prehistoria: bases para una propuesta metodológica materialista. *Trabajos de Prehistoria* 63(2):35-54.
7. Albert Rosa M, Portillo María (2014). Historia Antigua y Arqueología. Aportaciones de los estudios de fitolitos en la prehistoria: formación, metodología y casos de estudio; 2339-6490.
8. Conley, D. J. (2002). Terrestrial ecosystems and the global biogeochemical silica cycle, *Global Biogeochem. Cycles*, 16(4), 1121, doi:10.1029/2002GB001894.
9. M. B. Bush, C. H. McMichael, D. R. Piperno, M. R. Silman, J. Barlow, C. A. Peres, M. Power y M. W. Palace. (2018) «Anthropogenic influence on Amazonian forests in pre-history: An ecological perspective, » *Journal of Biogeography*; 2278.
10. Morcote-Ríos, G., Bernal, R., & Raz, L. (2016). Phytoliths as a tool for archaeobotanical, palaeobotanical and palaeoecological studies in Amazonian palms. *Botanical journal of the Linnean Society*, 182(2), 348-360.
11. Corbineau Rémi, Paul E. Reyerson, Anne Alexandre, Guaciara M. Santos. (2013). Towards producing pure phytolith concentrates from plants that are suitable for carbon isotopic analysis, *Review of Palaeobotany and Palynology*, Volume 197; 179-185.
12. Parr, J. F., Lentfer, C. J., & Boyd, W. E. (2001). A Comparative Analysis of Wet and Dry Ashing Techniques for the Extraction of Phytoliths from Plant Material. *Journal of Archaeological Science*, 28(8), 875–886. doi:10.1006/jasc.2000.0623
13. Madella M, Powers-Jones AH & Jones MK. (1998). A simple method of extraction of opal phytoliths from sediments using a non-toxic heavy liquid. *J Archaeol Sci* 25, 801–803
14. Yannick Devos, Martin J. Hodson & Luc Vrydaghs (2021) Auto-Fluorescent Phytoliths: A New Method for Detecting Heating and Fire, *Environmental Archaeology*, 26:4, 388-405, DOI: 10.1080/14614103.2020.1777056
15. Madella, Marco; Alexandre, A.; and Ball, Terry. (2005). International Code for Phytolith Nomenclature 1.0 Faculty Publications. 3540. <https://scholarsarchive.byu.edu/facpub/3540>.
16. Hart TC. (2016). Issues and directions in phytolith analysis. *Journal of Archaeological Science* 68: 24–31.

17. Bradley E, Panagiotis Korfiatis, Zeynettin Akkus, Timothy L. Kline. (2017). Machine Learning for Medical Imaging. 10.1148/rg.2017160130.
18. Loussaief, S., & Abdelkrim, A. (2016). Machine learning framework for image classification. 2016 7th International Conference on Sciences of Electronics, Technologies of Information and Telecommunications (SETIT). doi:10.1109/setit.2016.7939841
19. Cai, Z., & Ge, S. (2017). Machine learning algorithms improve the power of phytolith analysis: A case study of the tribe Oryzeae (Poaceae). *Journal of Systematics and Evolution*, 55(4), 377–384. doi:10.1111/jse.12258
20. El Naqa I., Murphy M.J. (2015) What Is Machine Learning? In: El Naqa I., Li R., Murphy M. (eds) *Machine Learning in Radiation Oncology*. Springer, Cham. https://doi.org/10.1007/978-3-319-18305-3_1
21. Janiesch, C., Zschech, P., & Heinrich, K. (2021). Machine learning and deep learning. *Electronic Markets*. doi:10.1007/s12525-021-00475-2
22. Albawi, S., Mohammed, T. A., & Al-Zawi, S. (2017). Understanding of a convolutional neural network. 2017 International Conference on Engineering and Technology (ICET). doi:10.1109/icengtechnol.2017.830.
23. Johnson, J.M., Khoshgoftaar, T.M. (2019). Survey on deep learning with class imbalance. *J Big Data* 6, piper. <https://doi.org/10.1186/s40537-019-0192-5>
24. Jie, B. X., Zulkifley, M. A., & Mohamed, N. A. (2020). Remote Sensing Approach to Oil Palm Plantations Detection Using Xception. 2020 11th IEEE Control and System Graduate Research Colloquium (ICSGRC). doi:10.1109/icsgrc49013.2020.9232547
25. Kumar Reddy, R. V., Srinivasa Rao, B., & Raju, K. P. (2018). Handwritten Hindi Digits Recognition Using Convolutional Neural Network with RMSprop Optimization. 2018 Second International Conference on Intelligent Computing and Control Systems (ICICCS). doi:10.1109/iccons.2018.8662969
26. Chollet F. (2017). Xception: Deep Learning with Depthwise Separable Convolutions. Recuperado el 2022.
27. Baker, G. (1960). Phytolitharien. *Australian Journal of Science* 22: 392-393.
28. Piperno D., (2006). Phytoliths: A Comprehensive guide for Archaeologists and Paleoecologists.
29. Mulholland S.C., Rapp G. (1992) Phytolith Systematics: An Introduction. In: Rapp G., Mulholland S.C. (eds) *Phytolith Systematics. Advances in Archaeological and Museum Science*, vol 1. Springer, Boston, MA. https://doi.org/10.1007/978-1-4899-1155-1_1
30. Chen, I., Li, Kt. & Tsang, Ch. (2020). Silicified bulliform cells of Poaceae: morphological characteristics that distinguish subfamilies. *Bot Stud* 61, 5. <https://doi.org/10.1186/s40529-020-0282-x>
31. Clement, C. R., Casas, A., Parra-Rondinel, F. A., Levis, C., Peroni, N., Hanazaki, N., ... Mazzochini, G. G. (2021). Disentangling Domestication from Food Production Systems in the Neotropics. *Quaternary*, 4(1), 4. doi:10.3390/quat4010004
32. Evett, R. R., Dawson, A., & Bartolome, J. W. (2012). Estimating Vegetation Reference Conditions by Combining Historical Source Analysis and Soil Phytolith Analysis at Pepperwood Preserve, Northern California Coast Ranges, U.S.A. *Restoration Ecology*, 21(4), 464–473. doi:10.1111/j.1526-100x.2012.00912.
33. Newton, A.C. y Tejedor, N. (Eds.) (2011). *Principios y práctica de la restauración del paisaje forestal: Estudios de caso en las zonas secas de América Latina*. Gland, Suiza: UICN y Madrid, España: Fundación Internacional para la Restauración de Ecosistemas.

34. An, Xiaohong, and Binrong Xie. (2022). "Phytoliths from Woody Plants: A Review" *Diversity* 14, no. 5: 339. <https://doi.org/10.3390/d14050339>
35. Eiserhardt, W. L., Svenning, J. C., Kissling, W. D., & Balslev, H. (2011). Geographical ecology of the palms (Arecaceae): determinants of diversity and distributions across spatial scales. *Annals of Botany*, 108(8), 1391-1416.
36. Ter Steege, H., Pitman, N. C., Sabatier, D., Baraloto, C., Salomão, R. P., Guevara, J. E., ... & Silman, M. R. (2013). Hyperdominance in the Amazonian tree flora. *Science*, 342(6156).
37. Sosnowska J, Balslev H. (2009). American palm ethnomedicine: a meta-analysis. *J Ethnobiol Ethnomed*. Dec 24; 5:43. doi: 10.1186/1746-4269-5-43. PMID: 20034398; PMCID: PMC2804589.
38. Albert, R. M., Bamford, M. K., & Esteban, I. (2015). Reconstruction of ancient palm vegetation landscapes using a phytolith approach. *Quaternary International*, 369, 51-66.
39. Bamford, M. K., Albert, R. M., & Cabanes, D. (2006). Plio–Pleistocene macroplant fossil remains and phytoliths from Lowermost Bed II in the eastern palaeolake margin of Olduvai Gorge, Tanzania. *Quaternary International*, 148(1), 95-112.
40. Morcote-Ríos, G., Bernal, R., & Raz, L. (2016). Phytoliths as a tool for archaeobotanical, palaeobotanical and palaeoecological studies in Amazonian palms. *Botanical journal of the Linnean Society*, 182(2), 348-360.
41. Piperno, D. R., (1991) - The status of phytolith analysis in the American tropics. *Journal of World Prehistory*, 5(2):155-191.
42. J. Barlow, T. A. Gardner, A. C. Lees, L. Parry y C. A. Peres. (2011). How pristine are tropical forests? An ecological perspective on the pre-Columbian human footprint in Amazonia and implications for contemporary conservation. *Elsevier Biological Conservation*, pp. 2-3.
43. Bush, M. B., McMichael, C. H., Piperno, D. R., Silman, M. R., Barlow, J., Peres, C. A., ... Palace, M. W. (2015). Anthropogenic influence on Amazonian forests in pre-history: An ecological perspective. *Journal of Biogeography*, 42(12), 2277–2288. doi:10.1111/jbi.12638.
44. McMichael, C.N., Piperno, D.R., Neves, E.G., Bush, M.B., Almeida, F.O., Mongeló, G.Z., & Eyjolfssdottir, M.B. (2015). Phytolith Assemblages Along a Gradient of Ancient Human Disturbance in Western Amazonia. *Frontiers in Ecology and Evolution*, 3, 1-15.
45. M. B. Bush, C. H. McMichael, D. R. Piperno, M. R. Silman, J. Barlow, C. A. Peres, M. Power y M. W. Palace. (2018). Anthropogenic influence on Amazonian forests in pre-history: An ecological perspective. *Journal of Biogeography*; 2278.
46. M. J. Heckenberger, J. C. Russell, J. R. Toney y M. J. Schmidt. (2007) The legacy of cultural landscapes in the Brazilian Amazon: implications for biodiversity. The Royal Society Publishing, p. 197.
47. Meggers B.J. (1984). The indigenous peoples of Amazonia, their cultures, land use patterns and effects on the landscape and biota. In: Sioli H. (eds) *The Amazon. Monographiae Biologicae*, vol 56. Springer, Dordrecht.
48. Clement. C. R. y A. B. Junqueira. (2010). Between a Pristine Myth and an Impoverished Future. *Wiley Online Library*, p. 535.
49. Lai, S., Leone, F., & Zoppi, C. (2017). Anthropization processes and protection of the environment: An assessment of land cover changes in Sardinia, Italy. *Sustainability*, 9(12), 2174.
50. Morales-Hidalgo, D., Oswalt, S.N., Somanathan, E., (2015). Status and trends in global primary forest, protected areas, and areas designated for conservation of biodiversity from the Global Forest Resources Assessment 2015. *For. Ecol. Manag.* 352:68–77. <https://doi.org/10.1016/j.foreco.2015.06.011>.

51. SUIA. (2018). Sistema Integrado de Transición Ecológica de Ambiente y Agua- SITEAA.
52. Foley, J. A., Asner, G. P., Costa, M. H., Coe, M. T., DeFries, R., Gibbs, H. K., ... & Snyder, P. (2007). Amazonia revealed: forest degradation and loss of ecosystem goods and services in the Amazon Basin. *Frontiers in Ecology and the Environment*, 5(1), 25-32.
53. Mohsina Anjum & Prakash Basavarajappa Nagabovanalli (2021) Assessing production of phytolith and phytolith occluded carbon in above-ground biomass of intensively cultivated rice ecosystems in India, *Carbon Management*, 12:5, 509-519, DOI: 10.1080/17583004.2021.1978552
54. Watling, J., & Iriarte, J. (2013). Phytoliths from the coastal savannas of French Guiana. *Quaternary International*, 287, 162–180. doi:10.1016/j.quaint.2012.10.03
55. Morcote-Ríos G, Raz L, Giraldo Canas D, Franky C, Leon Sicard T. (2013). Terras pretas de Índio of the Caquetá-Japurá River (Colombian Amazonia). *Tipití: Journal of the Society for the Anthropology of Lowland South America* 11: 30–39.
56. Piperno, D. R., & McMichael, C. (2020). Phytoliths in modern plants from amazonia and the neotropics at large: Implications for vegetation history reconstruction. *Quaternary International*. doi:10.1016/j.quaint.2020.10.043.
57. Witteveen N, Hobus C, Piperno D. R, McMichael C. N. (2022). The variability of Amazonian palm phytoliths. <https://doi.org/10.1016/j.revpalbo.2022.104613>
58. Lo, W. W., Yang, X., & Wang, Y. (2019). An Xception Convolutional Neural Network for Malware Classification with Transfer Learning. 2019 10th IFIP International Conference on New Technologies, Mobility and Security (NTMS). doi:10.1109/ntms.2019.8763852
59. Mohri M, Rostamizadeh A, Talwalkar A. (2012). Foundations of machine learning. Cambridge: MIT Press.
60. C. Levis, P. Figueira de Souza, J. Schietti, E. Thaise, J. L. Purri da Veiga, C. R. Clement y F. R. C. Costa. (2012). «Historical Human Footprint on Modern Tree Species Composition in the Purus-Madeira Interfluve, Central Amazonia,» Open Access Freely available online, p. 2.
61. Piperno, Dolores R. and Pearsall, Deborah M. 1998. "The Silica Bodies of Tropical American Grasses: Morphology, Taxonomy, and Implications for Grass Systematics and Fossil Phytolith Identification." *Smithsonian Contributions to Botany*. 1–40. <https://doi.org/10.5479/si.0081024X.85>
62. Benvenuto, M. L., Fernández Honaine, M., Osterrieth, M. L., & Morel, E. (2015). Differentiation of globular phytoliths in Arecaceae and other monocotyledons: morphological description for paleobotanical application. *TURKISH JOURNAL OF BOTANY*, 39, 341–353. doi:10.3906/bot-1312-72
63. RStudio Team (2015) RStudio: Integrated Development for R. RStudio, Inc., Boston, MA (Computer Software v0.98.1074). <http://www.rstudio.com>
64. Jie, B. X., Zulkifley, M. A., & Mohamed, N. A. (2020). Remote Sensing Approach to Oil Palm Plantations Detection Using Xception. 2020 11th IEEE Control and System Graduate Research Colloquium (ICSGRC). doi:10.1109/icsgrc49013.2020.9232547
65. Westphal, E., & Seitz, H. (2021). A machine learning method for defect detection and visualization in selective laser sintering based on convolutional neural networks. *Additive Manufacturing*, 41, 101965. doi:10.1016/j.addma.2021.101965
66. Huisman, S. N., Raczka, M. F., & McMichael, C. N. H. (2018). Palm Phytoliths of Mid-Elevation Andean Forests. *Frontiers in Ecology and Evolution*, 6. doi:10.3389/fevo.2018.00193
67. Eelbode, T., Sinonquel, P., Maes, F., & Bisschops, R. (2020). Pitfalls in training and validation of deep learning systems. *Best Practice & Research Clinical Gastroenterology*, 101712. doi:10.1016/j.bpg.2020.101712

68. Chaman Vermaa, Veronika Stoffova, Zoltan Illés. (2020). Prediction of residence country of student towards information, communication and mobile technology for real-time: preliminary results. <https://doi.org/10.1016/j.procs.2020.03.213>
69. Nguyen, P. T., Ha, D. H., Jaafari, A., Nguyen, H. D., Van Phong, T., Al-Ansari, N., ... Pham, B. T. (2020). Groundwater Potential Mapping Combining Artificial Neural Network and Real AdaBoost Ensemble Technique: The DakNong Province Case-study, Vietnam. *International Journal of Environmental Research and Public Health*, 17(7), 2473. doi:10.3390/ijerph17072473
70. Shorten, C., Khoshgoftaar, T.M. (2019) A survey on Image Data Augmentation for Deep Learning. *J Big Data* 6, 60. <https://doi.org/10.1186/s40537-019-0197-0>
71. Hodson, M. J., White, P. J., Mead, A., & Broadley, M. R. (2005). Phylogenetic Variation in the Silicon Composition of Plants. *Annals of Botany*, 96(6), 1027–1046. doi:10.1093/aob/mci255
72. Rodrigues Dias, R., Gomes Coe, H. H., Lepsch, I. F., Domingues Fricks Ricardo, S., Vitorino da Silva, L. M., Alvarenga, A. C., & Rasbold, G. G. (2019). Morphological variation of phytoliths according to leaf senescence and position in the organs of *Brachiaria decumbens*. *Flora*, 260, 151478. doi:10.1016/j.flora.2019.151478
73. Katz, O., Cabanes, D., Weiner, S., Maeir, A.M., Boaretto, E., Shahack-Gross, R., 2010. Rapid phytolith extraction for analysis of phytolith concentrations and assemblages during an excavation: an application at Tell es-Safi/Gath, Israel. *J. Archaeol. Sci.* 37, 1557e1563.
74. Cabanes, D., Weiner, S., & Shahack-Gross, R. (2011). Stability of phytoliths in the archaeological record: a dissolution study of modern and fossil phytoliths. *Journal of Archaeological Science*, 38(9), 2480–2490. doi:10.1016/j.jas.2011.05.020.
75. Valencia R., Montúfar R., Navarrete H., y Balslev H. (2013). *Palmas Ecuatorianas: biología y uso sostenibles*, p. 3-13.
76. Aguilar Zornitza. (2006). Influence of the Huaorani on the conservation of *Oenocarpus bataua*, Arecaceae in Yasuni National Park and Biosphere Reserve, Amazonian Ecuador.
77. Jarretr C, Cummins Ian, Logan-Hines E. (2018). Adapting Indigenous Agroforestry Systems for Integrative Landscape Management and Sustainable Supply Chain Development in Napo, Ecuador. Volume 12, pp 283-309.

ANEXOS

Anexo 1. Revisión bibliográfica de la importancia cultural y socioeconómica de las palmas.

Fuente: Aguilar Z, (2006), Valencia R et al, (2013), Jarretr C, (2018).

Elaboración: Vera Karla, 2022.

Géneros	Importancia cultural y socioeconomía	Bibliografía
<i>Aphandra</i>	Las comunidades kichwas y achuar, utilizan en el comercio la especie <i>Aphandra natalia</i> , que suministra fibras.	[75] [76] [77]
<i>Astrocaryum</i>	Los palmitos y frutos son comestibles. Sin embargo, se explotan principalmente sus fibras para la creación de hamacas, redes de pesca, bolsas (chigras), cuerdas y otros artículos.	
<i>Ceroxylon</i>	Las especies pertenecientes a este género tienen un alto valor económico, se obtienen varios productos como cera, hojas para techar. Sin embargo, sus especies como <i>Ceroxylon amazonicum</i> se encuentra en estado de peligro, mientras que <i>Ceroxylon echinulatum</i> en estado vulnerable, debido a la recolección de sus hojas en la temporada de semana santa.	
<i>Geonoma</i>	Las hojas de la especie <i>Geonoma macrostachys</i> están entre las más empleadas a la hora de cubrir los techos, debido a su resistencia y porque permiten la aireación de las casas.	
<i>Iriarte</i>	Los troncos de la especie <i>Iriarte deltoidea</i> , al ser duros y pesados son utilizados como postes para sostener plantaciones, utilizan la madera para crear mueble. En los pueblos indígenas, utilizan los troncos para construir muros, pilares y pisos en sus casas tradicionales.	
<i>Mauritia</i>	Proveen alimentos para las comunidades y comercialización de los mismos.	
<i>Oenocarpus</i>	La especie <i>Oenocarpus batua</i> es una parte fundamental de la dieta de diferentes grupos étnicos. Se utiliza prácticamente todo, las hojas, la fibra, la madera, el palmito, las flores, frutos y sobre todo el aceite. En el tema simbólico y espiritual en el pueblo Waorani los frutos constituyen una fuente de vitaminas y por lo tanto alarga la vida.	