

**PONTIFICIA UNIVERSIDAD  
CATÓLICA DEL PERÚ**

**Facultad de Letras y Ciencias Humanas**



**ESTADO DE CONSERVACIÓN DE LA *PUYA RAIMONDII*  
HARMS MEDIANTE TÉCNICAS DE TELEDETECCIÓN Y  
MODELOS DEEP LEARNING EN EL ÁREA DE  
CONSERVACIÓN REGIONAL BOSQUE DE PUYA RAIMONDI-  
TITANKAYOCC, AYACUCHO**

Tesis para optar el título profesional de Licenciado en Geografía y Medio

Ambiente que presenta el Bachiller:

***JOSÉ LUIS RICARDO ZÁRATE SOTELO***

ASESOR:

***DR. MARTIN ENRIQUE TIMANA DE LA FLOR***

Lima, 2023



# PUCP

Facultad de Letras  
y Ciencias Humanas

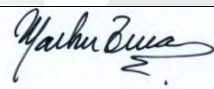
### Informe de Similitud

Yo, MARTÍN ENRIQUE TIMANÁ DE LA FLOR, docente de la Facultad de LETRAS Y CIENCIAS HUMANAS de la Pontificia Universidad Católica del Perú, asesor(a) de la tesis titulado:

ESTADO DE CONSERVACIÓN DE LA PUYA RAIMONDII HARMS MEDIANTE TÉCNICAS DE TELEDETECCIÓN Y MODELOS DEEP LEARNING EN EL ÁREA DE CONSERVACIÓN REGIONAL BOSQUE DE PUYA RAIMONDI - TITANKAYOCC, AYACUCHO, de lo siguiente:

- El mencionado documento tiene un índice de puntuación de similitud de 18%. Así lo consigna el reporte de similitud emitido por el software *Turnitin* el 08/06/2023.
- He revisado con detalle dicho reporte y la Tesis o Trabajo de Suficiencia Profesional, y no se advierte indicios de plagio.
- Las citas a otros autores y sus respectivas referencias cumplen con las pautas académicas.

Lugar y fecha: Lima, 08 de junio de 2023

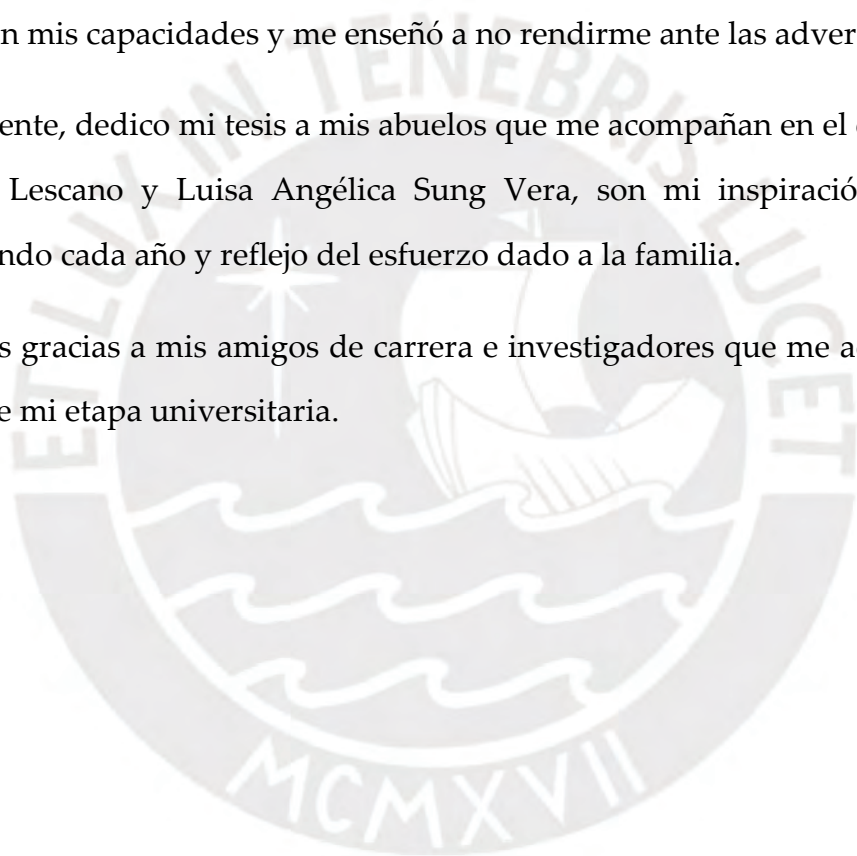
TIMANA DE LA FLOR, MARTIN ENRIQUE	
DNI: 25696637	 Firma
ORCID: 0000-0003-1559-4449	

## AGRADECIMIENTOS

Agradezco a mi familia por su infinito apoyo para culminar la presente tesis en una de las más prestigiosas universidades del país. A mi asesor de tesis Martín Timaná por las reuniones y consejos dados para aprobar mi investigación académica. A los docentes María Alejandra Cuentas y José Luis Zuloaga por sus retroalimentaciones dadas durante el periodo de la pandemia. A mi compañera Kiara García por su motivación y ser un ejemplo de esfuerzo para alcanzar mis metas profesionales. A mi profesor de la escuela secundaria, Alfonso Tan, quien creyó en mis capacidades y me enseñó a no rendirme ante las adversidades.

Finalmente, dedico mi tesis a mis abuelos que me acompañan en el cielo, Matías Zárate Lescano y Luisa Angélica Sung Vera, son mi inspiración de seguir mejorando cada año y reflejo del esfuerzo dado a la familia.

Muchas gracias a mis amigos de carrera e investigadores que me acompañaron durante mi etapa universitaria.



## RESUMEN

Los estudios de la *Puya raimondii* Harms en el Perú son escasos, pese a su valor ecológico y económico para los ecosistemas altoandinos. Actualmente, su situación es grave debido a las amenazas climáticas y antropogénicas que afectan en el crecimiento poblacional de la especie. Consecuencia de ello, la *P. raimondii* se encuentra declarada en peligro de extinción, ya que presenta poca variabilidad genética para soportar dichos cambios; además, produce una sola inflorescencia al final de su periodo vegetativo. De manera que, el objetivo general de esta tesis es estudiar y evaluar el estado de conservación de la *P. raimondii* a través de la teledetección y el uso de nuevas técnicas de detección de objetos como son los algoritmos de *Deep Learning* aplicado en un área representativa de puyas como es el Área de Conservación Regional Bosque de Puya Raimondi - Titankayoc, departamento de Ayacucho. La metodología implica el uso de herramientas de Sistemas de Información Geográfica y análisis espacial basado en la geoestadística para estimar el número de individuos a través de imágenes satelitales de Google Earth; posteriormente, calcular los valores de las variables ambientales como el Índice de Vegetación de Diferencia Normalizada (NDVI) y el Índice de Rugosidad del Terreno (TRI) provenientes de satélites de alta resolución, CBERS-4A y SRTM respectivamente; finalmente, discretizar la información hallada para caracterizar el hábitat de la *P. raimondii* dentro del área de conservación. En ese sentido, los resultados alcanzados concluyeron en la detección de 58 607 individuos usando imágenes Google Earth. Asimismo, la actividad fotosintética registrada tenía como valor promedio un 0.23 según el NDVI; de igual manera, para el caso del TRI se identificaron los hábitats más propicios para la especie los cuales fueron suelos rugosos ligeros a elevados ubicados principalmente en los ejes Este y Sur. Dicho esto, la propuesta de nuevas estrategias para el estudio de conservación implicó abordar los conceptos relacionados a la ecología vegetal, análisis espacial e inteligencia artificial.

## ABSTRACT

Studies on *Puya raimondii* Harms in Peru are scarce, despite its ecological and economic value for high Andean ecosystems. Currently, its situation is serious due to climate and anthropogenic threats that affect the population growth of the species. As a result, *P. raimondii* has been declared in danger of extinction since it has little genetic variability to withstand such changes; in addition, it produces only one inflorescence at the end of its vegetative period. Therefore, the general objective of this thesis is to study and evaluate the conservation status of *P. raimondii* through remote sensing and the use of new object detection techniques such as *Deep Learning* algorithms applied in a representative area of puyas, namely the Regional Conservation Area of Puya Raimondi Forest - Titankayocc, department of Ayacucho. The methodology involves the use of Geographic Information Systems tools and spatial analysis based on geostatistics to estimate the number of individuals through Google Earth satellite images; subsequently, calculate the values of environmental variables such as the Normalized Difference Vegetation Index (NDVI) and the Terrain Roughness Index (TRI) from high-resolution satellites, CBERS-4A and SRTM respectively; finally, discretize the information found to characterize the habitat of *P. raimondii* within the conservation area. In this sense, the results achieved concluded in the detection of 58,607 individuals using Google Earth images. Likewise, the registered photosynthetic activity had an average value of 0.23 according to the NDVI; similarly, in the case of the TRI, the most favorable habitats for the species were identified, which were light rugged soils to elevated ones located mainly in the eastern and southern axes. That said, the proposal of new strategies for conservation study implied addressing concepts related to plant ecology, spatial analysis and artificial intelligence.

## ÍNDICE DE CONTENIDO

<b>1. CAPÍTULO I: PLANTEAMIENTO DE LA INVESTIGACIÓN .....</b>	<b>4</b>
1.1. Problemática.....	4
1.2. Justificación .....	6
1.3. Preguntas de investigación .....	7
1.4. Hipótesis .....	8
1.5. Objetivos .....	8
1.5.1. Objetivo General .....	8
1.5.2. Objetivos Específicos .....	8
<b>2. CAPÍTULO 2: MARCO CONCEPTUAL.....</b>	<b>9</b>
2.1. Marco teórico.....	9
2.1.1. Características de la <i>Puya raimondii</i> Harms.....	9
2.1.2. Clasificación de los rodales de <i>Puya raimondii</i> Harms.....	11
2.1.3. Amenazas y problemáticas a los rodales de <i>Puya raimondii</i> Harms ...	12
2.1.4. Análisis espacial para la conservación.....	13
2.1.5. Clasificación por medio de la Inteligencia Artificial Geoespacial .....	15
2.2. Estado del arte.....	19
2.2.1. Investigaciones relacionadas a Geo AI aplicada a la cobertura vegetal .....	20
2.2.2. Investigaciones relacionadas a métodos de clasificación de imágenes con Deep Learning a través de Convolutional Neural Networks .....	22
2.2.3 Investigaciones relacionadas a parámetros de entrenamiento con Deep Learning de ArcGIS Pro .....	23
2.3. Estudios previos sobre la <i>Puya Raimondii</i> Harms .....	26
<b>3. CAPÍTULO 3: ÁREA DE ESTUDIO .....</b>	<b>28</b>
3.1. Ubicación política .....	28
3.2. Origen y establecimiento del ACR Titankayocc .....	29
3.3. Descripción geográfica física .....	30
3.3.1. Factores climáticos .....	30
3.3.2. Característica geomorfológicas y fisiográficas .....	33
3.3.3. Ecología .....	36
3.4. Descripción geográfica social.....	41
3.4.1. Accesibilidad .....	41
3.4.2. Actividades socio-económicas y dinámicas territoriales .....	44
3.4.3. Ámbito de Influencia del ACR Titankayocc .....	46
<b>4. CAPÍTULO 4: MARCO METODOLÓGICO .....</b>	<b>48</b>
4.1. Aspectos teóricos de la metodología .....	48

4.2. Esquema metodológico de la investigación.....	49
4.2.1. Primera Etapa: Propuesta de investigación y recopilación de datos .	51
4.2.2. Segunda Etapa: Pre procesamiento de datos espaciales .....	51
4.2.3. Tercera Etapa: Procesamiento, análisis y resultados .....	51
4.2.4. Cuarta Etapa: Evaluación final y cierre de la investigación .....	52
4.3. Metodología general .....	52
4.3.1. Descarga de imágenes satelitales de alta resolución de Google Earth con SAS Planet.....	52
4.3.2. Delimitación de áreas de entrenamiento y validación .....	56
4.3.3. Detección de objetos con Deep Learning integrado a los SIG.....	57
4.3.4. Técnicas de análisis espacial aplicado a las condiciones ambiental de la <i>Puya raimondii</i> Harms.....	68
4.3.5. Geoestadística y tabulación de información a nivel planta .....	80
<b>5. CAPÍTULO 5: RESULTADOS .....</b>	<b>83</b>
5.1. Distribución espacial de la <i>Puya raimondii</i> Harms.....	83
5.2. Caracterización ambiental de la <i>Puya raimondii</i> Harms.....	85
5.2.1. Histograma de Frecuencias aplicado al NDVI .....	89
5.2.2. Análisis de Tendencias aplicado al TRI.....	90
5.3. Densidad por cuadrícula de la <i>Puya raimondii</i> Harms .....	91
<b>6. CAPÍTULO 6: DISCUSIÓN.....</b>	<b>93</b>
6.1. Delimitación de las poblaciones de <i>Puya raimondii</i> Harms .....	93
6.2. Evaluación del modelo de detección de objetos con Deep Learning.....	95
6.3. Análisis de parámetros ambientales.....	97
6.4. Importancia de la <i>Puya raimondii</i> Harms para su conservación .....	98
<b>7. CAPÍTULO 7: CONCLUSIONES Y RECOMENDACIONES.....</b>	<b>100</b>
7.1. Conclusiones .....	100
7.2. Recomendaciones .....	101
7.3. Contribuciones de la presente investigación.....	103

## ÍNDICE DE TABLAS

<b>Tabla 3. 1.</b> Red Vial Nacional - Provincia de Huamanga .....	<b>42</b>
<b>Tabla 4. 1.</b> Informe de evaluación de precisión.....	<b>68</b>
<b>Tabla 4. 2.</b> Diferencias entre los satélites de 1ra y 2da generación del programa CBERS.....	<b>69</b>
<b>Tabla 4. 3.</b> Características de las cámaras CBERS-4A .....	<b>70</b>
<b>Tabla 5. 1.</b> Promedio de NDVI de <i>P. raimondii</i> por clase .....	<b>86</b>
<b>Tabla 5. 2.</b> Clasificación de TRI de <i>P. raimondii</i> .....	<b>87</b>



## ÍNDICE DE FIGURAS

<b>Figura 2. 1.</b> Estructura AI-ML-DL .....	15
<b>Figura 2. 2.</b> Clasificación del <i>Machine Learning</i> .....	17
<b>Figura 2. 3.</b> Taxonomía de <i>Deep Learning</i> aplicado a la teledetección .....	22
<b>Figura 3. 1.</b> Monitoreo anual de la temperatura.....	31
<b>Figura 4. 1.</b> Esquema metodológico de la investigación .....	50
<b>Figura 4. 2.</b> Ruta de descarga e instalación de SAS Planet .....	53
<b>Figura 4. 3.</b> Selección de mapa base satelital .....	54
<b>Figura 4. 4.</b> Visualización de alta resolución dentro del ACR Titankayocc .....	54
<b>Figura 4. 5.</b> Creación de polígono que contenga todo el ACR Titankayocc.....	55
<b>Figura 4. 6.</b> Definición de parámetros para la exportación de la imagen.....	55
<b>Figura 4. 7.</b> Marco de <i>Mask R-CNN</i> para la segmentación instantánea.....	58
<b>Figura 4. 8.</b> Fotointerpretación de la imagen satelital sas planet para etiquetado de la <i>P. Raimondii</i> .....	58
<b>Figura 4. 9.</b> Asignación de etiquetas de <i>P. Raimondii</i> .....	59
<b>Figura 4. 10.</b> Cantidad de muestras digitalizadas por etiqueta .....	60
<b>Figura 4. 11.</b> Flujo de trabajo en el <i>Model Builder</i> para detectar la <i>P. Raimondii</i> ..	61
<b>Figura 4. 12.</b> Uso de la herramienta <i>Train Deep Learning Model</i> .....	63
<b>Figura 4. 13.</b> Uso de la herramienta <i>Detect Objects Using Deep Learning</i> .....	64
<b>Figura 4. 14.</b> Detección de puyas utilizando algoritmos de <i>Deep Learning</i> .....	65
<b>Figura 4. 15.</b> Ejemplo de falsos positivos en la detección de <i>P. Raimondii</i> .....	66
<b>Figura 4. 16.</b> Uso de la herramienta <i>Compute Accuracy For Object Detection</i> .....	67
<b>Figura 4. 17.</b> Catálogo de imágenes INPE .....	71
<b>Figura 4. 18.</b> Configuración de búsqueda .....	72
<b>Figura 4. 19.</b> Previsualización de la imagen y verificación de los metadatos .....	72
<b>Figura 4. 20.</b> Indicación de elementos de descarga.....	73
<b>Figura 4. 21.</b> Uso de la herramienta <i>RGBN Composite</i> .....	74
<b>Figura 4. 22.</b> Uso de la herramienta <i>Pansharpening</i> .....	75
<b>Figura 4. 23.</b> Uso de la herramienta <i>Georeference</i> .....	76
<b>Figura 4. 24.</b> Relleno de filtros de búsqueda.....	79
<b>Figura 4. 25.</b> Uso de la herramienta <i>Ruggedness Index</i> .....	80
<b>Figura 4. 26.</b> Uso de la herramienta <i>Zonal Statistics As Table</i> .....	81
<b>Figura 4. 27.</b> Uso de la herramienta <i>Geostatistical Analyst</i> .....	81
<b>Figura 4. 28.</b> Uso de la herramienta <i>Create Grid</i> .....	82
<b>Figura 5. 1.</b> Gráfico de análisis de patrones de puntos promedio usando la herramienta <i>Average Nearest Neighbor</i> .....	84
<b>Figura 5. 2.</b> Promedio de tri de la <i>P. Raimondii</i> por etiqueta.....	87
<b>Figura 5. 3.</b> Diagrama de dispersión entre el TRI y NDVI.....	89
<b>Figura 5. 4.</b> Gráfico de histograma de NDVI de la <i>P. Raimondii</i> .....	90
<b>Figura 5. 5.</b> Gráfico de análisis de tendencias del TRI.....	91
<b>Figura 6. 1.</b> Actividades antrópicas .....	999

## ÍNDICE DE MAPAS

<b>Mapa 3. 1.</b> Mapa de ubicación del ACR Titankayocc.....	<b>28</b>
<b>Mapa 3. 2.</b> Mapa de clasificación climática 1981-2010 del ACR Titankayocc.....	<b>32</b>
<b>Mapa 3. 3.</b> Mapa de unidades fisiográficas, orientación-pendiente y relieve del ACR Titankayocc .....	<b>34</b>
<b>Mapa 3. 4.</b> Mapa geomorfológico del ACR Titankayocc .....	<b>35</b>
<b>Mapa 3. 5.</b> Mapa de unidades de vegetación y ecosistemas del ACR Titankayocc .....	<b>36</b>
<b>Mapa 3. 6.</b> Mapa de Zonas de Vida del ACR Titankayocc .....	<b>38</b>
<b>Mapa 3. 7.</b> Mapa de accesibilidad del ACR Titankayocc.....	<b>43</b>
<b>Mapa 3. 8.</b> Mapa de Zonificación Ecológica y Económica (ZEE) y Capacidad de Uso Mayor (CUM) del ACR Titankayocc.....	<b>45</b>
<b>Mapa 3. 9.</b> Mapa de Zonificación del ACR Titankayocc.....	<b>47</b>
<b>Mapa 4. 1.</b> Mapa de ubicación de cuadrículas de entrenamiento y validación en el ACR Titankayocc .....	<b>56</b>
<b>Mapa 5. 1.</b> Mapa de distribución geográfica y poblacional de la <i>P. raimondii</i> por clases en el ACR Titankayocc.....	<b>85</b>
<b>Mapa 5. 2.</b> Mapa clasificado de NDVI de la <i>P. raimondii</i> en el ACR Titankayocc .....	<b>86</b>
<b>Mapa 5. 3.</b> Mapa clasificado de TRI en el ACR Titankayocc.....	<b>88</b>
<b>Mapa 5. 4.</b> Mapa de biomasa aérea y área foliar de la <i>P.raimondii</i> en el ACR Titankayocc.....	<b>92</b>

## SIGLAS Y ACRÓNIMOS

ACR	Área de Conservación Regional
AI	Artificial intelligence
ALOS	Advanced Land Observation Satellite
ANA	Autoridad Nacional del Agua
ANN	Artificial neural networks
ANP	Área Natural Protegida
ASF	Alaska Satellite Facility
BCRP	Banco Central de Reserva del Perú
CAM	Crassulacean Acid Metabolism
CAST	China Academy of Space Technology
CBERS	China-Brazil Earth Resources Satellite
CEDES	Centro de Estudio de Estado y Sociedad
CNN	Convolutional Neural Networks
CUM	Capacidad de Uso Mayor
DNN	Dense Neural Networks
DL	Deep Learning
ESRI	Environmental Systems Research Institute
GeoAI	Geospatial Artificial Intelligence
GPS	Global Positioning System
INDECI	Instituto Nacional de Defensa Civil
INEI	Instituto Nacional de Estadística e Informática
INGEMMET	Instituto Geológico, Minero y Metalúrgico
INPE	Instituto Nacional de Pesquisas Espaciais
INRENA	Instituto Nacional de Recursos Naturales
IoU	Intersection over Union
JAXA	Japan Aerospace Exploration Agency
KML	Keyhole Markup Language

MDE	Modelo Digital de Elevación
MINAM	Ministerio del Ambiente
ML	Machine Learning
NDVI	Normalized Difference Vegetation Index
OBIA	Object-Based Image Analysis
ONG	Organización No Gubernamental
PALSAR	Phased Array type L-band Synthetic Aperture Radar
RMS	Root Mean Square
RNN	Recurrent Neural Networks
SENAMHI	Servicio Nacional de Meteorología e Hidrología del Perú
SERFOR	Servicio Nacional Forestal y de Fauna Silvestre
SERNANP	Servicio Nacional de Áreas Naturales Protegidas por el Estado
SIG	Sistemas de Información Geográfica
SINANPE	Sistema Nacional de Áreas Naturales Protegidas por el Estado
SRC	Sistema de Referencia de Coordenadas
SRTM	Shuttle Radar Topography Mission
TIFF	Tagget Image File Format
TRI	Terrain Ruggedness Index
UNSCH	Universidad Nacional de San Cristóbal de Huamanga
VAB	Valor Agregado Bruto
ZEE-OT	Zonificación Ecológica Económica y Ordenamiento Territorial

## INTRODUCCIÓN

El Perú está considerado como uno de los países más “megadiversos” del mundo (MINAM, 2019). Su flora y fauna silvestre es el resultado de la gran variedad de ecosistemas únicos y presentes en cada región, así lo demuestra el investigador Pulgar Vidal quien ratificaba que el territorio nacional presenta una gran diversidad y heterogeneidad térmica, pluvial, lumínica y/o eólica en un mismo espacio; además de la complejidad de las elevaciones producto de las cadenas de montañas (1981). Ante ese escenario surge la *Puya raimondii* Harms, especie famosa por su elevado tallo floral (inflorescencia) el cual alcanza una altura de hasta los 10 metros aproximadamente (Lambe, 2008); siendo considerado por su alto valor estético y científico para las zonas altoandinas.

La *P. raimondii*, llamada también como “Titanka” o “Cahua” por los pobladores de la región altoandina de Perú y Bolivia, pertenece a la Familia botánica de las Bromeliáceas el cual se caracteriza por ser monocárpica, es decir, produce una sola inflorescencia al final de su vida; además, esta planta puede vivir entre un periodo de 40 a 100 años hasta florecer (Hornung-Leoni y Sosa, 2005). No obstante, debido a las variaciones climáticas sólo unos pocos individuos dentro de una población determinada podrán florecer en cualquier año (Zuschlag, 2014). Durante el proceso de florecimiento, según lo reportando por Valverde (2009) (citado por Zuschlag, 2014), la *P. raimondii* cubre el tallo de floración con unas 6 a 10 mil flores las cuales sirven de alimento para muchas especies como insectos y pájaros; asimismo, las hojas cuentan con espinas que protegen a dichas especies para construir sus nidos en ellas (Valverde, 2009 citado por Zuschlag, 2014). De esta manera, la *P. raimondii* sirve de refugio y fuente de alimento para diversas especies altoandinas que habitan en espacios de conservación como son las Áreas Naturales Protegidas (ANP) cuyo caso corresponde al ACR Titankayocc.

Los bosques relictos de *P. raimondii*, compuestos también de *Polylepis sp.* y *Escallonia sp.*, confieren un gran valor y singular belleza escénica para el paisaje altoandino de Ayacucho, rompiendo así la monotonía presente del lugar que se encuentra configurada sólo por grandes pastizales en su mayoría (De la Cruz, 1994). En ese sentido, la *P. raimondii* es considerada como una riqueza natural con gran potencial ecoturístico dada su atractivo que sobresale y contrasta con las otras especies con las que comparte el mismo hábitat, además de presentar una de las inflorescencias más grandes del mundo vegetal (Vadillo et al., 2007). De manera que, los paisajes naturales andinos tienden a ser un gran potencial por su riqueza en flora y fauna silvestre y las condiciones de humedad de su territorio, confiriendo así características adecuadas para el desarrollo de diversas actividades como turismo, conservación, recreación, entre otros (Zavaleta, 2017).

Sin embargo, esta especie endémica se ve amenazada por el cambio climático y acción de los humanos, ya que son quemadas o removidas de sus lugares originales con el fin de que sus tierras pasen a ser usadas para la agricultura, ganadería o asentamiento de comunidades. Ello se ve contrastado por Szykulski et al. (2016), quienes sostienen que la temperatura es uno de los principales factores climáticos que genera el decrecimiento poblacional de la *P. raimondii*, alterando también la cadena alimentaria de otras especies como los picaflores (*Oreotrochilus stolzmanni*, *Patagona gigas* y *Metallura phoebe*). De igual modo, según lo manifestado por el Plan Maestro del Área de Conservación Regional Bosque de Puya Raimondi - Titankayocc 2014-2019, los rodales de *P. raimondii* se encuentran en constante intervención antropogénica debido al establecimiento de botaderos de basura y quema de pajonales de puna y puyas (GRRNGMA - Gobierno Regional de Ayacucho, 2014; Apolinario y Carmen, 2015).

Adicionalmente, la *P. raimondii* tiene por característica la poca adaptabilidad para soportar dichos cambios ambientales; ello debido a la carencia de variabilidad genética (genoma) y limitada variación de su fenotipo (rasgos físicos y

conductuales) presente en la planta (Sgorbati et al., 2004). Ante este panorama, la *P. raimondii* se ve catalogada como una especie en peligro de extinción, según lo indicado por el Decreto Supremo N° 043-2006-AG (2006); de manera que, si se siguen manteniendo estos cambios negativos en el ecosistema altoandino, esta especie relictiva pasaría entonces a su pronta extinción y repercutiría en el bienestar humano a través de la pérdida de los servicios ecosistémicos que este ofrece.

Dada su condición frágil de la especie, se propone un sistema de monitoreo de identificación inmediata, con el fin de evitar mayores daños a la *P. raimondii*, por lo que se recomienda utilizar modelos y técnicas relacionadas a sensores remotos los cuales han ido evolucionando de tal manera que se tienen disponibles nuevas fuentes de información satelital con una mayor resolución espacial, que a su vez aumenta en gran medida la precisión de la identificación y caracterización de objetos pequeños a escalas espaciales que antes solo estaban disponibles en plataformas aéreas (Turner et al., 2003; Gillespie et al., 2008).

En ese sentido, las imágenes satelitales de alta resolución pueden ser una alternativa para el monitoreo de la condición vegetal, ya que proporciona mejores conocimientos de los patrones y procesos espaciales bajo resoluciones más detalladas o finas (Ostendorf, 2011). Asimismo, el uso de Sistemas de Información Geográfica (SIG) y herramientas de teledetección, otorgan una gama de datos sobre las condiciones ambientales, así como técnicas para explorar y utilizar dicha información para la comprensión de la biodiversidad y su respectiva conservación (Foody, 2008). De esta manera, la vigilancia a través de nuevos insumos geoespaciales, es decir, aplicación de imágenes satelitales y modelos digitales libres de alta resolución serán de gran soporte para identificar y conocer el estado de las especies amenazadas y sus condiciones ambientales que atraviesan en la actualidad, tal como es el caso de estudio de la *P. raimondii*, resultando relevante para su preservación en los ecosistemas altoandinos.

# CAPÍTULO 1

## PLANTEAMIENTO DE LA INVESTIGACIÓN

La presente tesis académica busca proponer el uso de nuevas herramientas vinculadas a las disciplinas de la teledetección e inteligencia artificial para interpretar, explorar y analizar espacialmente los seres vivos y sus hábitats donde se desarrollan. Por lo tanto, tiene como objetivo evaluar el estado de las poblaciones de *Puya raimondii* Harms presentes en el Área de Conservación Regional (ACR) Titankayoc, ubicado en el departamento de Ayacucho.

### 1.1. Problemática

En la actualidad la pérdida de diversidad biológica resulta ser importante no solo para la subsistencia de los seres humanos quienes extraen recursos naturales provenientes del medio ambiente, sino que también altera las dinámicas de desarrollo de distintos organismos, los cuales interactúan y brindan servicios ecosistémicos en determinadas áreas geográficas como son las zonas altoandinas; por lo que los cambios que experimentan estos ecosistemas pueden deberse por la presión antrópica que ha afectado de diversas maneras el bienestar humano (Canza Sucasaca, 2019). La provincia de Vilcas Huamán en Ayacucho es conocida por albergar el rodal de *P. raimondii* más denso a nivel nacional y, por tanto, los procesos ecológicos generan beneficios a favor de las poblaciones (Apolinario y Carmen, 2015). Sin embargo, estos rodales andinos que incluyen a la *Polylepis incana* y la *P. raimondii* se encuentran dentro de la lista roja de especies amenazadas debido a su peculiar característica morfológica y fisiológica (Canza Sucasaca, 2019). Asimismo, la destrucción de sus hábitats naturales por el reemplazo por especies exóticas, generan modificaciones del paisaje que pueden traer consecuencias negativas si no son utilizados de manera adecuada y no reciben un buen tratamiento (Dueñas et al., 2017).

De esta manera, su condición crítica en la que se encuentra la planta altoandina no sólo afecta a la especie en sí, sino a todo su ecosistema pues obliga a otras especies de la zona como es el picaflor altoandino que se alimenta del néctar como principal recurso (Salinas et al., 2007). De modo que, su pérdida no solo implicaría un dramático empobrecimiento del hábitat altoandino, incluida la erosión y desertificación de suelos, sino la desaparición de otras especies (Gobierno Regional de La Libertad, 2011).

Por otro lado, una de las principales amenazas que atraviesa la *P. raimondii* nace a partir de las propias necesidades de las comunidades locales, quienes reducen esta especie a través de la quema, explotación de tierras, cambio de uso de suelo, pastoreo y tala furtiva. Asimismo, según Hermitaño Leon (2018), otro factor a mencionar es la variable climatológica que no se tiene información a detalle y actualizada de cómo influye en su desarrollo y logro de inflorescencia. Esto último podría relacionarse con el cambio climático que provoca alteraciones en el sistema climatológico a consecuencia del calentamiento global.

La riqueza de la diversidad biológica del departamento de Ayacucho es de gran importancia por sostener servicios ecológicos (Gobierno Regional de Ayacucho, 2012); cabe señalar que la poca información sobre la ecología, distribución, estado poblacional de la *P. raimondii* no permite desarrollar un plan de manejo sostenible de esta especie (Canza Sucasaca, 2019).

El objetivo de la investigación es conocer el estado de conservación de la planta relictas llamada *Puya raimondii* Harms, ubicado en el departamento de Ayacucho, a través de herramientas geoespaciales y algoritmos de *Deep Learning* tomando como zona de estudio el ACR Titankayoc para contribuir con la preservación e investigación de la especie.

## 1.2. Justificación

No se han encontrado muchos estudios relacionados a la *P. raimondii*, de manera que la información es escasa y, por ende, se debe promover o incentivar mayor número de investigaciones. Asimismo, estudios realizados en ecosistemas altoandinos siguen siendo de interés geográfico no solo porque identifican valores paisajísticos, sino que también representa la provisión de recursos naturales disponibles para las comunidades del lugar. Sin embargo, estos recursos pueden verse afectados a través del cambio de uso de suelo y variaciones climatológicas, ocasionando daños y peligros a determinadas especies vulnerables, como es el caso de la *P. raimondii*, que es objeto de estudio para la presente investigación.

La *P. raimondii* tiende a ser relevante no sólo por sus características genéticas, fisiológicas y biológicas que muestra la planta en sí (Sgorbati et al., 2004), sino también porque brinda relaciones mutualistas con otros organismos (fuente de alimento, hábitats, entre otros servicios ecosistémicos) que puedan verse perjudicadas. En ese sentido, desde un punto de vista biológico, las comunidades ecológicas son afectadas directamente, ya que perjudica al conjunto de poblaciones de distintas especies que dependen entre ellos mismos. Por otro lado, el espacio que habita la planta altoandina es también considerado como un lugar de interacción humano-naturaleza, por lo que es necesario darle una importancia social de cómo debe ser aprovechado y valorado a su vez.

De esta manera, la siguiente investigación busca contribuir en la conservación de la *P. raimondii* por medio del conocimiento de ecología vegetal, análisis espacial e inteligencia artificial, el cual ha demostrado ser una especie importante dentro del ecosistema altoandino. Es relevante entender las relaciones sociales y biológicas presentes en los sistemas altoandinos para poder seguidamente identificar los principales impactos y dinámicas que se asocian para el ACR Titankayoc ubicado en el distrito de Vischongo.

Finalmente, el presente estudio tiene como objetivo conocer el estado de conservación de la *Puya raimondii* Harms y, de esta manera, poder desarrollar mecanismos tecnológicos a partir del uso de nuevas herramientas de geoprocésamiento y teledetección. Asimismo, parte de la investigación implica el análisis de la distribución espacial de la especie, el cual requiere desarrollar e innovar nuevas metodologías de registro de datos con el fin de lograr una supervisión y control de la planta de manera más eficiente. En ese sentido, la vigilancia por medio de nuevos insumos geoespaciales, es decir, el uso de imágenes satelitales libres de alta resolución además de técnicas de *Deep Learning* será de mucha utilidad para la localización y reconocimiento de esta especie.

Cabe señalar que los resultados a obtener serán explicados bajo conceptos teóricos de ecología vegetal cuyo criterio aplica a las gradientes ambientales que están en relación con las dinámicas distributivas de los taxones individuales y colectivos a los problemas relacionados con la conservación de la biodiversidad (Whittaker et al., 2005). Visto de esa forma, el mantener estos rodales servirá a largo plazo descubrir nuevos beneficios que todavía no han podido ser descubiertos y que requieren del uso de técnicas y herramientas geográficas para su adecuada conservación.

### **1.3. Preguntas de investigación**

A partir de la problemática señalada se desarrollaron las siguientes preguntas de investigación.

- ¿Cómo es la distribución espacial y en qué condiciones fenológicas se encuentra la *Puya raimondii* Harms en el ACR Titankayocc, región de Ayacucho?
- ¿Qué relaciones físicas y/o ambientales importantes hallamos en los rodales de *Puya raimondii* Harms en el ACR Titankayocc, región de Ayacucho?

- ¿De qué manera los sensores remotos y técnicas de *Deep Learning* pueden ayudar a mejorar en la preservación de la *Puya raimondii* Harms en el ACR Titankayocc, departamento de Ayacucho?

#### **1.4. Hipótesis**

La hipótesis central plantea la integración de sensores remotos de alta resolución y algoritmos de *Deep Learning* puede contribuir en la preservación de especies amenazadas, como es el caso de la *Puya raimondii* Harms, ubicado en zonas altoandinas. Asimismo, se argumenta que estas herramientas tecnológicas de información geográfica tienen el potencial de mapear la distribución geográfica de la especie y procesar grandes volúmenes de información de manera efectiva, lo que contribuiría para los estudios de conservación y teledetección.

#### **1.5. Objetivos**

##### **1.5.1. Objetivo General**

Conocer el estado de conservación de la *Puya raimondii* Harms a través del manejo de nuevos modelos referidos a sensores remotos para contribuir en la preservación de la especie en el ACR Titankayocc, región de Ayacucho.

##### **1.5.2. Objetivos Específicos**

1. Cartografiar la distribución geográfica y poblacional de la *Puya raimondii* Harms, basada en técnicas de *Deep Learning*, para la contabilización y ubicación de la especie en el ACR Titankayocc, departamento de Ayacucho.
2. Diagnosticar el estado de conservación de la *Puya raimondii* Harms a partir de imágenes satelitales en el distrito de Vischongo, provincia de Vilcas Huamán.
3. Determinar la efectividad del uso de imágenes satelitales multiespectrales y de alta resolución para la detección y preservación de la *Puya raimondii* Harms en el ACR Titankayocc, departamento de Ayacucho.

## CAPÍTULO 2

### MARCO CONCEPTUAL

El capítulo expone las aproximaciones teóricas relacionadas al estudio de la *P. raimondii* y técnicas de conservación en el marco de la investigación; ello busca denotar la importancia ambiental, biológica y social de la especie para la región.

#### 2.1. Marco teórico

##### 2.1.1. Características de la *Puya raimondii* Harms

La *Puya raimondii* Harms, llamada también Reina de los Andes por su tamaño colosal y florescencia resaltante, es una de las especies más antiguas del planeta y se la ha calificado como un fósil vivo, considerado una de las plantas que más tarda en florecer en el mundo, con un crecimiento paquicaule (gigante) con la inflorescencia de miles de flores, que se prolonga verticalmente y puede llevar la altura total de hasta los diez metros (Grau et al., 2010; Canza Sucasaca, 2019). Esta planta altoandina presenta un comportamiento monocárpico, cuyo significado es la producción de una sola inflorescencia al final de su vida; los individuos pueden vivir entre 40 a 100 años hasta florecer (Hornung-Leoni y Sosa, 2005).

Generalmente la *P. raimondii* crece a manera de “rodales” (que significan terrenos o campos pequeños), aunque en algunas ocasiones se pueden encontrar individuos aislados (Davila, 2004); por lo que viven en ambientes de grandes altitudes (como son los Andes), siendo observados en forma de “parches” con preferencia a desarrollarse en lugares rocosos. Esto último ofrece ventajas como es el difícil acceso y bajo aprovechamiento para el pastoreo, protección mecánica contra los fuertes vientos y mantiene el calor específico favoreciendo el pronto derretimiento de la nieve e irradiando el calor hacia la planta (Rivera, 1985). De modo que, se encuentra en rodales desde pocos ejemplares a varios centenares de individuos en el norte (Huaraz, La Libertad, Lima) y sur (Cuzco, Apurímac, Ayacucho, Junín, Huancavelica) del país y en Bolivia (Gómez y Miranda, 1998).

En cuanto a la descripción botánica, la *P. raimondii* presenta una raíz fasciculada y superficial; su tronco mide casi 1 m de diámetro, mientras que las hojas imbricadas se agrupan en el tallo fibroso, formando rosetas de hasta 2.50 m de diámetro con espinas en forma de gancho en los bordes (Rivera, 1985; Baldeón et al., 2005). En su estructura interna, las láminas de las hojas presentan tricomas compuestos en ambas superficies, permitiendo obtener la humedad ambiental y reduciendo la pérdida de humedad por los estomas (Morales y Suni, 2003; Baldeón et al., 2005). De esta manera, la *P. raimondii* se caracteriza por ser una perenne cespitosa, que muestra un sistema radicular muy reducida, como es común en bromelias (Sgorbati, 2004).

La inflorescencia de la *P. raimondii*, es una panícula compuesta, en el raquis central es grueso, fibroso y liviano, en ella se insertan alrededor de 200 espigas en forma ortóstica (Apolinario y Carmen, 2015); donde la inflorescencia puede llegar a medir entre los 6 a 8 m de altura (Vadillo et al., 2007). Asimismo, la espiga alberga más de ocho mil flores que se convertirán en frutos, con aproximadamente 800 semillas cada uno, lo que hace que una sola planta produzca más de 6 millones cuatrocientos mil semillas (Dueñas et al., 2017). Su crecimiento se inicia entre los meses de mayo y junio, comenzando a florecer a finales de julio y llegando a su máximo desarrollo hasta el mes de diciembre; posteriormente se inicia la fructificación para luego dispersar sus semillas en julio del siguiente año (Cerrate, 1979 citados por Salazar et al., 2010). Cabe señalar, que los rodales presentan crecimientos de inflorescencias de varias plantas al mismo tiempo, lo que conlleva a estar relacionado con el clima (Rivera, 1985).

Las características de las semillas de *P. raimondii*, indican su naturaleza albuminosa predominantemente amilácea, permite su dispersión por el viento y retención de humedad durante la germinación y su permanencia en su medio natural (Pascual et al., 2003). Además, estas semillas dependen de la luz y adecuadas condiciones de humedad para poder germinar, por lo que su

dispersión es numerosa, pequeña (3 a 4 mm), liviana (0,48 mg/semilla), alada y con alto porcentaje de germinación (Vadillo et al., 2004).

Finalmente, estudios genéticos recientes como Tumi Calisaya (2021) indica que la planta altoandina presenta una diversidad genética moderada la cual puede verse afectada por la acción antrópica y tipo de vegetación presente en la zona; asimismo, los daños ocasionados por las aves, hongos y larvas de polilla en la fructificación disminuyen el número de semillas viables y vigorosas (Vadillo et al., 2004). En ese sentido, estas amenazas conducirían a una paulatina extinción de la *P. raimondii* la cual además es una especie rara que exige mantener su diversidad genética como prioridad alta (Pullin, 2002).

### **2.1.2. Clasificación de los rodales de *Puya raimondii* Harms**

El concepto de rodal comprende a una comunidad de árboles que generalmente son uniformes en composición, tamaño, edad o condición de especies y son manejados como una sola unidad (Carpio, 2017). Estos a su vez varían en el tiempo y el espacio, representado cambios en las condiciones del lugar y estructura de la cobertura vegetal (Jardel-Peláez, 2015).

Para el caso de la *P. raimondii* esta puede clasificarse según su morfología y fisiología, la cual se encuentra intrínsecamente relacionada a las condiciones ambientales del lugar. Sin embargo, existen otras variables que pueden intervenir y que intentan describir la ocupación espacial de estos individuos (Donoso, 1993). Tal es así que pueden ser agrupadas por alturas de la planta y la presencia o no de su inflorescencia; de modo que, se clasifican por su estado de desarrollo y condición actual, otorgándoles nombres como plantas tiernas, jóvenes, adultas, muerte natural o muerte antrópica (Venero, 1984). Otra manera de clasificación se da a través de micro variaciones al interior de cada rodal, el cual puede ocurrir cambios continuos o discretos, pero que no son distinguidos espacialmente (Corvalán y Hernández, 2006).

Desde la rama geográfica, la clasificación de especies puede asociarse según a las condiciones ambientales y humanas presentes del lugar, por lo que se conciben el concepto de unidades paisajísticas, las cuales se definen a determinada escala geográfica con el propósito de poder identificar eventos de perturbación y procesos de regeneración natural y sucesión post-perturbación. Dentro de esta unidad se considera el tipo de formación vegetal y condiciones de clima, geomorfología y suelos asociados a la composición de la especie a evaluar (Jardel-Peláez, 2015). De manera que para el estudio de conservación de la *P. raimondii* en el ACR Titankayoc, se requiere de la descripción de las condiciones físicas del lugar para conocer la calidad de su hábitat y, paralelamente, definir cuáles son los componentes son claves para su desenvolvimiento.

### **2.1.3. Amenazas y problemáticas a los rodales de *Puya raimondii* Harms**

En el Perú, desde los años sesenta del siglo XX, ha realizado esfuerzos para poder contar con espacios geográficos para la conservación a largo plazo de la naturaleza y de sus servicios ecosistémicos, así como los valores culturales asociados de cada lugar (SERNANP, 2011). La razón principal se debe al continuo deterioro de la vegetación natural por parte de los pobladores quienes, a causa de su imprudencia y poco conocimiento, dañan y destruyen estos recursos que afectan también a otros organismos del medio natural (Brack, 2000). Este caso no es ajeno para los Andes peruanos, ya que estos han sufrido más de mil años de impacto humano reflejados a través de la destrucción de vegetación, pastoreo intensivo, introducción de especies exóticas e incendios forestales. De esta manera, la *P. raimondii* se ve amenazada principalmente como resultado de la presión humana prolongada, el cual es depredada intensamente para ser usado como muebles, vigas de construcción, forraje y hasta combustible biodegradable por el contenido de su resina altamente incinerable (Sgorbati et al., 2004).

Por otro lado, la pérdida de diversidad genética, específica y ecosistémica está avanzando aceleradamente, teniendo como resultado, el cambio de hábitat y

desplazamiento forzado de las especies a condiciones ambientales menos favorables (Secretaría del Convenio de Diversidad Biológica y Comisión Holandesa para Evaluación Ambiental, 2006). Esto último representa contraproducente para las comunidades que estén relacionadas con el crecimiento de la plántula en sí, pues se estaría eliminando uno de los pocos recursos claves que existen en los ecosistemas altoandinos, provocándose una reacción en cadena (Salinas et al., 2007). De modo que, se recomienda mantener la heterogeneidad de los hábitats a escala de paisaje y su variabilidad natural o histórica, con el fin de garantizar su prologada presencia con el transcurso de los años (Lindenmayer y Franklin, 2002).

De esta manera, los cambios en la biodiversidad, como es el caso de los rodales de *P. raimondii*, repercuten directa o indirectamente en el bienestar humano, ya que comprometen en el funcionamiento de los ecosistemas y su capacidad de generar servicios esenciales para la sociedad (Crispin Cuya, 2015), por lo que se propone la conservación de la especie altoandina como alternativa viable, con el fin de mejorar las condiciones de vida de las comunidades locales a través de los insumos obtenidos de la planta relictas que se encuentra en estado de peligro.

#### **2.1.4. Análisis espacial para la conservación**

El uso de herramientas geoespaciales para los campos de conservación, biodiversidad y monitoreo ambiental son de gran aporte operacional, ya que estos permiten mapear a las especies en un corto plazo. Ello a través del procesamiento y manejo de softwares cartográficos como son los SIG, los cuales permiten conocer el impacto de las acciones de conservación y las políticas ambientales en todo el mundo (Skidmore et al., 2015). De ese modo, el análisis y modelado de datos de biodiversidad contribuyen a la evaluación y conservación de especies que pueden verse amenazadas por impactos naturales y/o humanos.

El procesamiento de datos espaciales para el estudio de conservación de especies implica de la participación de profesionales ambientales, ecologistas y agencias espaciales que tienen por objetivo determinar las variables más prescindibles relacionadas a la biodiversidad (Skidmore et al., 2015). En ese sentido, se ha desarrollado diversas técnicas de clasificación para la identificación y descripción de su estado en el que habita. Algunas de las técnicas más usadas para el análisis de imágenes basado en objetos se encuentra en la segmentación y la clasificación.

La segmentación tiene por concepto agrupar y dividir un conjunto de regiones inconexas según las propiedades específicas de una imagen tal como es la textura, el color, la forma, el tamaño y el nivel de gris (Lucchese y Mitray, 2001). Según el artículo publicado por Zhang et al., (2017), las ventajas halladas en el uso de técnicas de segmentación son efectivas para explotar las características de los objetos en las imágenes además permite delinear las entidades geográficas en comparación a los píxeles. No obstante, la segmentación aplicada a la cobertura vegetal requiere ir acompañada con las condiciones del campo, ya que la segmentación incorrecta podría afectar seriamente la precisión de la detección de plantas (Hamuda et al., 2016); del mismo modo, Slaughter et al. (2008) señala que la iluminación natural tiene un rol importante en la segmentación efectiva de las plantas, y que la iluminación deficiente puede generar errores en su delimitación.


Dicho esto, en la actualidad las categorías de segmentación disponibles para discriminar los elementos se resumen con las siguientes técnicas (Hossain y Chen, 2019): a) basada en píxeles (Mardia y Hainsworth, 1988); b) basada en bordes (Perona y Malik, 1990); c) basada en regiones (Beveridge et al., 1989); y d) método híbrido basado en el método de identificación de objetos (Haris et al., 1998). Cabe destacar, que los métodos basados en píxeles consisten en la umbralización de imágenes y segmentación en el espacio de características (Schiewe, 2002).

### 2.1.5. Clasificación por medio de la Inteligencia Artificial Geoespacial

El campo científico del *Geospatial Artificial Intelligence* (GeoAI), también conocido como Inteligencia Artificial Geoespacial parte de la combinación de innovaciones de la ciencia espacial con metodologías de la Inteligencia Artificial o *Artificial Intelligence* (AI) para el desarrollo de temas como es la minería de datos y la informática de alto rendimiento para datos espaciales (Mazzola, 2020). En ese sentido, la GeoAI supone un gran paso para proyectos ambientales y/o de conservación que emplean los SIG con herramientas de AI para el estudio de especies biológicas que se encuentran en amenaza.

La AI tiene por concepto a los sistemas que imitan la inteligencia humana la cual realiza tareas que mejoran iterativamente en función a la información recopilada (Oracle<sup>1</sup>, s.f.). Esta denominada inteligencia parte del interior de la psicología la cual permite elaborar diferentes categorías como es la emulación de la conducta inteligente basadas en la experiencia y el conocimiento continuo del ambiente (Delgado, 1998; Nebendah, 1988; Valdés, 2019). Posteriormente, con el paso de los años la IA fue avanzando rápidamente generando nuevas subdisciplinas orientadas a las necesidades espaciales, por lo que surgen metodologías como es el aprendizaje automático y el aprendizaje profundo (ver figura 2.1.).

**Figura 2. 1.** Estructura AI-ML-DL



*Fuente: Elaboración propia.*

---

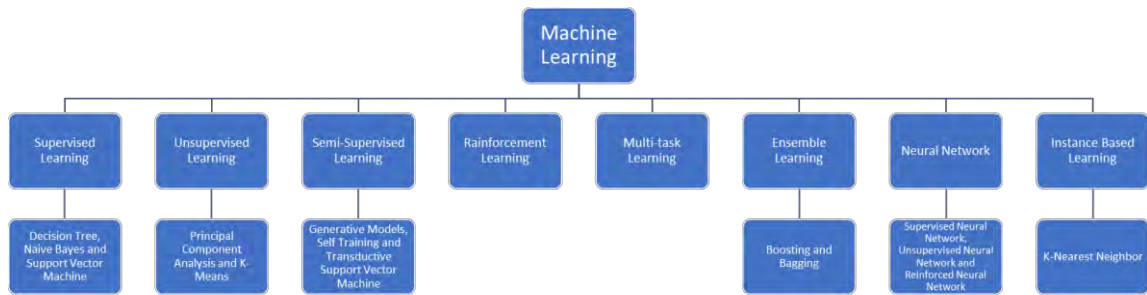
<sup>1</sup> <https://www.oracle.com/artificial-intelligence/what-is-ai/>

El aprendizaje automático o *Machine Learning* (ML) es un subconjunto de la AI que emplea algoritmos de aprendizaje estadístico el cual construye sistemas inteligentes. El ML tiene como proceso de inducción el conocimiento de máquinas que son capaces de auto programarse aprendiendo de su propia experiencia (Valdés, 2019). Este subconjunto posee dos tipos de modelos (agrupamiento y gradiente), los cuales se dividen en dos grandes categorías: supervisados y no supervisados (Valdés, 2019).

El aprendizaje supervisado es aquel que centra su atención en la predicción precisa y que requiere de asistencia externa para dividir los datos en dos clases: entrenamiento (*train*) y prueba (*test*) (Valdés, 2019). Los datos entrenamiento sirven para optimizar un modelo y tienen relación directa con la calidad de este. Por su parte, los datos de prueba son aquellos que validan el modelo realizado a partir de los datos entrenamiento. Dentro del aprendizaje supervisado se tienen distintos algoritmos (Support Vector Machine, Decision Tree, Random Forest, Naive Bayes, etc.) los cuales detectan determinados patrones en base a sus propias características que logran predecir. Ello a través de etiquetas las cuales proporcionan información que permiten al algoritmo aprender a asociar características específicas de las imágenes (ver figura 2.2.).

Por otro lado, la definición del aprendizaje no supervisado refiere a los algoritmos con procesamiento sin etiquetas o clases definidas previamente; en ese sentido, infiere el valor de los datos de entrada según el grupo por descripciones precisas y compactas (Karim, 2018; Valdés, 2019). Según Guo et al., (2016), los métodos de aprendizaje no supervisados (K-means, Isodata, PCA, etc.) presentan dificultad para aprender las características de las imágenes a un nivel satisfactorio debido a su capacidad de distinción limitada y falta de conocimiento previo. No obstante, este tipo de clasificación cumple un rol importante como son estudios pioneros, exploratorios o sin mayor disponibilidad de datos in-situ.

**Figura 2. 2.** Clasificación del *Machine Learning*



*Fuente: Elaboración propia adaptado de Dey, 2016.*

Finalmente, el término *Deep Learning* (DL) o aprendizaje profundo en los últimos años ha generado grandes avances en el campo de la teledetección, dentro los cuales se encuentra la clasificación de coberturas vegetales y el análisis de imágenes basado en objetos; asimismo, los modelos DL pueden aproximarse con precisión la complicada relación no lineal entre los parámetros ambientales debido al aprendizaje multicapa (Bengio et al., 2013; LeCun et al., 2015).

El aprendizaje profundo forma parte del subcampo específico del ML. Este consiste en aprender representaciones a partir de datos que pone énfasis en aprender capas sucesivas de representaciones cada vez más significativas (Woolf, 2018). La profundidad del DL refiere a las capas del modelo que mapean entradas (*images*) a objetivos (*labels*) a través de la secuencia profunda de transformaciones de datos (*layers*) y dicha transformación se aprende mediante la exposición a los ejemplos (Chollet, 2017; Woolf, 2018). En otras palabras, la primera capa oculta refiere a la detección de características simples como bordes o esquinas, mientras que las capas posteriores detectan características más complejas como formas o contornos de objetos (Krizhevsky et al., 2017). A diferencia de los métodos tradicionales que utilizan una cantidad limitada de características espaciales y espectrales para la detección de objetos en coberturas vegetales, el *Deep Learning* tiene la capacidad de aprender rasgos discriminatorios de forma adaptativa a través del aprendizaje supervisado y las redes neuronales (Zeiler y Fergus, 2014).

La red neuronal o *Neural Network* (NN) es un sistema computacional que consiste en conectar varios elementos de procesamientos entre sí con el objetivo de realizar una tarea en específica, tal como ocurre en el cerebro humano (Pineda, 2017). Entre ellas se encuentra las redes neuronales artificiales o *Artificial Neural Network* (ANN), la cual comprende una red de nodos dispuestos en capas conectadas entre sí. Estas conexiones reciben capas de entradas y producen capas salidas e intermedias (llamadas capas ocultas) que entrenan a través del proceso iterativo (Hennig, 2021). Las redes han ganado popularidad por ser adaptables, robustas, tolerantes a fallos y ruidos y masivamente paralelas; de manera que, una NN mejora su desempeño a través del aprendizaje, lo que permite presentar cierto comportamiento inteligente (Yao y Liu, 2005). En la actualidad, las redes más aplicadas para la transformación digital son las DNN, RNN y CNN.

Las redes neuronales densas o *Dense Neural Network* (DNN) se define como una red de nodos dispuestos en múltiples capas conectadas entre sí. Estas conexiones pueden aprender y resumir las características de los datos de forma estadística basándose en innumerables datos con la oportunidad de superar la precisión de la interpretación humana (Sze et al., 2017). Por otro lado, las redes neuronales recurrentes o *Recurrent Neural Network* (RNN) guardan la salida de los nodos de procesamiento y retroalimentan el resultado al modelo haciendo además que no pasen la información en una sola dirección. Sin embargo, si la predicción de la red es incorrecta, el sistema se autoajusta y continúa trabajando en la retropropagación para lograr la predicción correcta (Gupta, 2022). Finalmente, las redes neuronales convolucionales o *Convolutional Neural Network* (CNN) es un conjunto de nodos dispuestos en capas que reciben entradas y producen salidas, cuyas primeras capas son convolucionales, que resultan en filtros que escanean los datos de entrada para producir un mapa de activación que mantiene las características importantes y capas de agrupación (Grekousis, 2019).

La presente investigación está vinculada al ámbito del *Deep Learning* el cual dará uso de herramientas CNN integradas a los SIG. Esta arquitectura comprende tres categorías: las capas convolucionales, compuesta por varias capas y tipos de información resumidas en categorías que identifican rasgos importantes (Hu et al., 2015); las capas de agrupación, que se insertan entre capas convolucionales sucesivas y reducen progresivamente el tamaño de la capa de entrada a través de operaciones locales no lineales (Castelluccio et al., 2015); las capas normalizadas, tienen la intención de implementar esquemas de inhibición observados en el cerebro biológico (Russakovsky et al., 2015); y las capas totalmente conectadas, las cuales se utilizan en las últimas capas de la red (Hu et al., 2015). Dicho esto, las redes convolucionales permiten mejorar las tareas de detección y clasificación de objetos a partir de gráficos tal como son las imágenes satelitales libres de alta resolución. No obstante, se debe señalar las desventajas para procesar grandes cantidades de datos y un alto costo de computación (Yuan et al., 2020).

## **2.2. Estado del arte**

En las últimas décadas, la comunidad geocientífica ha buscado mejorar las prácticas tradicionales de clasificación de imagen, las cuales describen características y objetos capturados en una o varias escenas satelitales. Ello se debe a la extracción de información semántica de alto nivel que proviene de propiedades a niveles inferiores, tal como es la representación de los píxeles (Zhang et al., 2016). De manera que, el uso de técnicas de DL es relevante para el análisis de datos espaciales, ya que en el presente siglo XXI se requiere procesar grandes volúmenes de información y desarrollar nuevos modelos (Bengio, 2009).

El presente capítulo expone los antecedentes vinculados al uso de herramientas Geo AI, la cual examina estudios análogos de preprocesamiento, clasificación e identificación de objetos aplicando conceptos de *Deep Learning*, teledetección y SIG. A continuación, se detallan aquellas investigaciones relacionadas con el tema de investigación expuesto por medio de los siguientes subtemas.

### **2.2.1. Investigaciones relacionadas a Geo AI aplicada a la cobertura vegetal**

El surgimiento de algoritmos avocados a la *Artificial Inteligencia* (AI), el *Machine Learning* (ML) y el *Deep Learning* (DL) son tecnologías emergentes que permiten mejorar los Sistemas de Información Geográfica (SIG) por medio del aprendizaje de los datos por parte de máquinas inteligentes que tienen por objetivo simplificar y reemplazar aquellos trabajos manuales, los cuales demandan mayores esfuerzos y posibles errores humanos en el mapeo de la vegetación (Choi, 2023). En ese sentido, la principal contribución del presente subtema es mostrar los principales métodos de procesamiento y análisis de grandes conjuntos de datos geográficos para visibilizar las potencialidades en la precisión y la eficiencia de estas tareas, en comparación con los métodos SIG tradicionales.

La detección remota antiguamente requería de elementos imprescindibles como es la selección heurística de transformaciones apropiadas y la elaboración manual de variables latentes a partir de los datos de entrada antes del modelado (Kattenborn et al., 2021). Ello significaba aprender las características exclusivas de los datos, conllevando funciones hechas a mano que dependían, en gran medida, del conocimiento específico del dominio (Li et al., 2018). Ejemplos en el campo de la teledetección son los índices espectrales y métricas de textura, cuyas variables son a menudo difíciles de derivar para la definición de datos predictores; además, las propiedades bioquímicas y fisiológicas de la planta pueden afectar en la interacción con la señal electromagnética medida por el sensor del satélite (Kattenborn et al., 2021). Por tal motivo, la clasificación precisa del bosque de montaña de los Andes sigue siendo difícil para su detección y clasificación debido a la complejidad del terreno y la coexistencia de árboles con especies de arbustos y suelo existirá ruido en los datos de entrenamiento.

En el contexto nacional, los investigadores Vega, Hirata, Santos y Torobeo (2018) mencionaron que los bosques de los Andes presentan un bajo porcentaje de cobertura de copa, tal como se evidencia en la zona de estudio ubicado en la

región de Ayacucho, donde una imagen satelital con resolución media (tamaño de píxel 2 m a 30 m) puede contener más de una sola clase de cobertura terrestre, como suelo y arbustos; en consecuencia, los datos obtenidos son una mezcla de la radiación reflejada de diferentes tipos. Además, es relevante considerar el factor topográfico pues un relieve accidentado reduce la precisión de la clasificación de la cobertura vegetal debido a las variaciones en la iluminación de la superficie terrestre entre áreas sombreadas y aquellas que reciben luz directamente (Vega et al., 2018). De modo que, existe dificultad de hallar píxeles completamente homogéneos para tipos de vegetación endémica y degradados que crezcan en áreas de difícil acceso tal como es el caso de *Puya raimondii* Harms.

Frente a la situación expuesta, existen estudios donde se proponen la mezcla espectral para cálculos de porcentajes de cobertura terrestre a escala de subpíxel, además del análisis de la corrección topográfica para reducir el factor lumínico (Meyer et al., 1993; Song, 2005). Asimismo, otras investigaciones apuntan por el uso de datos de radar, ópticos y texturales para mejorar la detección y estimación de parámetros forestales, ya que se emplean modelos paramétricos semi-empíricos y no paramétricos para la reducción de la dimensionalidad y rendimiento de algoritmos de aprendizaje automático (Morin et al., 2019).

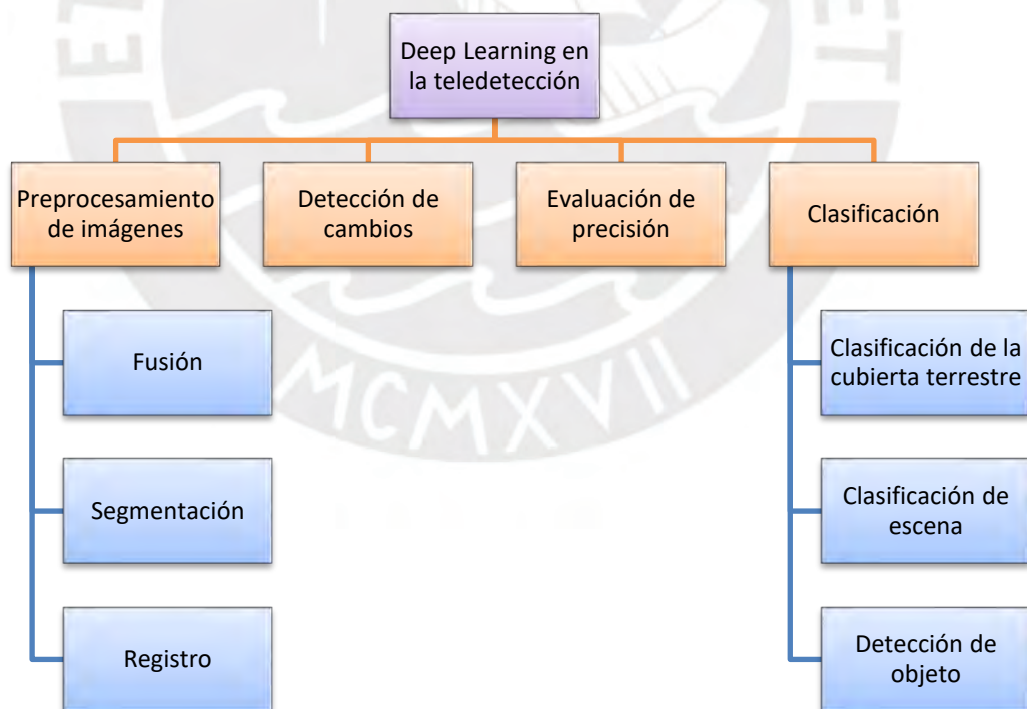
Ante este escenario, el *Deep Learning* puede representar una alternativa para organizar múltiples niveles de información y expresar relaciones complejas entre los datos, ya que permite mapear diferentes niveles de abstracción de las imágenes y combinarlos (Riesenhuber y Poggio, 1999; Ciresan et al., 2010). Por otro lado, A diferencia de los clasificadores tradicionales, el modelo Deep Learning tiene la ventaja de predecir el límite preciso de un objeto a nivel de píxel, junto con su clase y cuadro delimitador (Yekeen et al., 2020; Alburshaid y Mangoud, 2021). De manera que, las redes neuronales tienen la habilidad de aprender las transformaciones de datos y características discriminativas de forma adaptativa (Zeiler y Fergus, 2014; Kattenborn et al., 2021).

## 2.2.2 Investigaciones relacionadas a métodos de clasificación de imágenes con Deep Learning a través de Convolutional Neural Networks

Los métodos de clasificación con DL más usados para el reconocimiento de objetos se dividen en dos categorías: supervisados y no supervisados. El primero aprende las características de los datos de entrada conociendo las etiquetas correlacionadas o información proporcionada por el usuario, caso contrario al segundo que es independiente y no requiere de etiquetas (Zhang et al., 2016).

Las aplicaciones llevadas a cabo para el procesamiento de imágenes satelitales relacionadas con el uso de DL se clasificaron en el siguiente gráfico basado por los investigadores Ma et al. (2019), quienes elaboraron una taxonomía relacionada con DL en la teledetección la cual comprende desde el preprocesamiento hasta la evaluación de la precisión (ver figura 2.3.).

**Figura 2. 3.** Taxonomía de *Deep Learning* aplicado a la teledetección



*Fuente: Elaboración propia adaptado de Ma et al., 2019.*

Para llevar a cabo un análisis y procesamiento efectivo de imágenes espaciales, es fundamental contar con las CNN. Este tipo de red neuronal permite realizar tareas de reconocimientos de objetos en imágenes tal como ocurre en el campo de la teledetección (Yuan et al., 2020). Autores como Lee y Kwon (2017), obtuvieron resultados positivos en tareas de detección de objetos usando imágenes hiperespectrales comparando distintos métodos de arquitectura CNN; Jiang et al. (2018), amplió la aplicación del CNN para la identificación objetos en imágenes radar; Vetrivel et al. (2018), integró funciones de CNN y funciones de nube de puntos 3D a partir de imágenes aéreas oblicuas para detectar edificios dañados por un terremoto; Ding et al. (2018), mejoraron la estructura del algoritmo base VGG16-Net para mejorar la precisión de la detección de aviones y automóviles; y, finalmente, Li et al. (2017) utilizaron CNN para detectar palmeras de aceite en imágenes de QuickBird.

Los enfoques de aprendizaje profundo han demostrado su eficacia en muchos dominios de aplicación tal como es el reconocimiento de objetos visuales a través de la combinación de CNN con técnicas tradicionales de análisis de imágenes, como OBIA (Object-Based Image Analysis) y campo aleatorio condicional, o CNN integradas con otros clasificadores de DL o ML (Parente et al., 2019; Yuan et al., 2020). Por tal motivo, las CNN son una técnica de aprendizaje profundo adecuada para el procesamiento de datos de alta dimensión en tareas de clasificación y detección de objetos en imágenes (Krizhevsky et al., 2017).

### **2.2.3 Investigaciones relacionadas a parámetros de entrenamiento con Deep Learning de ArcGIS Pro**

En la actualidad, ArcGIS Pro es un software SIG desarrollado por la empresa ESRI el cual permite a los usuarios crear, analizar, editar y visualizar datos geográficos. El programa tiene integrando herramientas de inteligencia artificial como es el uso de técnicas de *Deep Learning* para la clasificación de imágenes, detección de objetos y otras tareas vinculadas con la fotointerpretación.

Las principales herramientas de geoprocесamientos en imágenes que ofrece ArcGIS Pro usando *Deep Learning* comprenden los siguientes cuatro modelos: "Classify Pixels Using Deep Learning", "Classify Objects Using Deep Learning", "Detect Change Using Deep Learning" y "Detect Object Using Deep Learning". Para la presente investigación, se empleó únicamente el último modelo.

Previamente al uso de esta herramienta, se debe crear las etiquetas para cada clase siendo "Label Objects for Deep Learning" el panel para anotar los objetos o muestras a predecir. La cantidad y forma de registro de muestras son de suma importancia para entrenar el modelo. De modo que, el número de etiquetas debe tener lo suficiente para cubrir la variabilidad de las clases a detectar (Girshick et al., 2014). No obstante, otros autores recomiendan crear mínimamente 1000 etiquetas para lograr un buen rendimiento del modelo (Ronneberger et al., 2015).

El tratamiento de las etiquetas recopiladas puede ser exportadas en base a parámetros como son tamaño de teselas, distancia de desplazamiento, ángulo de rotación y formato de metadatos (PASCAL VOC, KITTI, RCNN MASK). A continuación, se presentan algunos ejemplos de investigadores que utilizaron distintos parámetros en el panel "Label Objects for Deep Learning" y herramienta de exportación "Export Training Data For Deep Learning".

En el artículo científico de Khalid y Shahrol (2021), el preprocesamiento de ortofotos RGB obtenidas del dron consistió en crear pares de mosaicos o chips a partir de la imagen de entrada y la clase de entidad poligonal de entrenamiento otorgando un tamaño específico a las teselas de 256 x 256; la distancia de desplazamiento, se estableció 128 x 128 para obtener un 50% de superposición; asimismo, la rotación asignada fue de 45 grados para el aumento significativo en la precisión de la clasificación; finalmente, el formato de metadatos se colocó "Classfield Tiles" por ser mapa de clase. Por otro lado, Hao et al. (2021) realiza un estudio sobre la detección automatizada de altura y copa de árboles, donde

utilizó como formato de metadato el "Mask R-CNN" y dividió los mosaicos en  $256 \times 256$ , con una distancia de desplazamiento de  $128 \times 128$  píxeles. También empleó la rotación de  $90^\circ$ ,  $180^\circ$  y  $270^\circ$  para compensar el tamaño limitado de las muestras de entrenamiento y mejorar la robustez del modelo (Braga et al., 2020). Esto último, también es recomendado por los autores Davis et al. (2021), quienes señalan que para aumentar el tamaño de las muestras recomiendan generar más datos de entrenamiento mediante rotaciones tomando como ejemplo el valor de  $45^\circ$ , el cual crece sintéticamente los tamaños de muestra en un factor de 8.

Posteriormente, la herramienta "Train Deep Learning Model" permite crear modelos de detección utilizando modelos de CNN o editor de modelos personalizados. Para su empleo es necesario configurar los siguientes parámetros tales como máximo de ciclos, tipo de modelo (Single Shot Detector, RetinaNet, MaskRCNN, YOLOv3), argumentos (ej: cuadrícula, zoom y ratios), tamaño del lote y modelo de base (RESNET18, VGG11, DARKNET53, REID\_V1, etc.).

Las ponderaciones para entrenar el modelo varían según el tamaño del objeto, la resolución de imágenes satelitales y el conocimiento in situ del área a evaluar. Por ejemplo, Pepe et al. (2021) utilizó el modelo Single Shot Detector con un ciclo máximo de 25, tamaño de lote de 32 y argumentos como cuadrícula, zoom y ratios, para detectar edificios. Por otro lado, Shiu et al. (2023) comparó los modelos Mask R-CNN y Faster R-CNN para la detección y segmentación de piñas, utilizando un ciclo máximo de 300, un tamaño de lote de 2 y un modelo de base ResNet101, con edición de argumentos como el ratio 6:4.

Por último, "Detect Object Using Deep Learning" es la herramienta que permite detectar objetos en imágenes satelitales, aéreas o terrestres. Su ventana presenta los parámetros de argumentos (relleno, tamaño de mosaico, umbral), supresión no máxima y radio máximo de solapamiento. Cabe señalar que, existen otros parámetros más avanzados que se puede manipular para el ajuste y precisión del

modelo tal como lo define Shiu et al. (2023), quienes establecen la tasa de aprendizaje, el decaimiento de peso, el momento y el tamaño de anclaje. Por su parte, el estudio de Khalid y Shahrol (2021), los parámetros de entrada fueron el tamaño de mosaico de 8, el relleno de 64 y el umbral de 0.7. Mientras que, Hao et al. (2021), activaron el algoritmo de supresión no máxima para eliminar la identificación de objetos superpuesta y redundante además emplearon el umbral de confianza a 0.2. Sin embargo, un umbral tan bajo puede afectar el modelo ya que al disminuirlo, aumenta el número de objetos reconocidos de forma inversa, provocándose que la huella del objeto se aleje de su forma real (Pepe et al., 2021).

### **2.3. Estudios previos sobre la *Puya Raimondii* Harms**

A lo largo de la historia, trabajos referentes a la conservación de especies altoandinas, como es el caso de la *P. raimondii*, al parecer son escasos; de manera que existe un limitado número de investigaciones científicas, desarrolladas por universidades (Universidad Nacional de San Cristóbal de Huamanga (Ayacucho), Universidad Nacional del Centro del Perú (Junín), Universidad Nacional del Altiplano (Puno), Universidad Nacional Mayor de San Marcos (Lima)), instituciones públicas (SERNANP, SERFOR, MINAM, gobiernos regionales) y Organizaciones No Gubernamentales (ONGs). De modo que, el interés de estudio por la *P. raimondii* aún queda mucho por descubrir y analizar respecto a sus propiedades vegetativas, beneficios económicos y/o medicinales, influencia con el medio ambiente y su rol en el ecosistema altoandino.

El descubrimiento de la *P. raimondii* se da en el año 1830 por el científico francés Alcides d'Orbigny (1802-1857), según lo manifestado por el investigador Antonio Lambe (2008). Posteriormente, el reconocido naturalista, geógrafo y explorador italiano Antonio Raimondi (1867) llega al Perú con el afán de conocer la riqueza de la flora peruana; fue así que, en uno de sus viajes en la Cordillera Blanca, departamento de Ancash, descubre la planta altoandina en el distrito de Cashapampa llamándola en ese entonces "*Pourretia gigantea*" (Venero, 1984).

Años más tarde en 1928, el botánico alemán Hermann Harms (1870-1952) reclasificó el nombre científico de la especie por el de "*Puya raimondii* Harms", en honor a su descubridor. Asimismo, Harms realizó descripciones botánicas y su distribución a lo largo del territorio peruano, siendo los departamentos de Ancash, Lima, Ayacucho, Apurímac, Cusco, Junín, Puno y La Libertad como lugares más reportados de bosque de *P. raimondii* (De la Cruz, 1994). Su descubrimiento y clasificación motivó a distintos investigadores, tales como Hartman (1981), Villiger (1981), Venero (1984) y Rivera (1985), realizar estudios más profundos en cuanto a sus características bioecológicas, fitogeográficas y reproducción de la planta. Asimismo, los autores reconocen su importancia y rol que tienen en los ecosistemas altoandinos, por lo que se requieren mayores conocimientos sobre su crecimiento, expansión y distribución geográfica.

Ante ese suceso, se tiene investigaciones hechas por Gómez y Miranda (1998), quienes hicieron levantamiento de información de campo con el fin de comparar y evaluar el crecimiento poblacional de la *P. raimondii* con los reportes más antiguos realizados por Dourojeanni y Tovar (1966) en siete rodales ubicados en Bolivia, calculando el número de individuos y su densidad por hectárea y obteniéndose resultados de crecimiento significativo de la planta. No obstante, para el caso del sector Carpa (Áncash), Sanchez y otros investigadores (1998), hallaron que la cantidad de puyas en este sector había sufrido una disminución considerable durante los últimos 10 años. Esta metodología convencional de conteo numérico, se aplicó en otros lugares del territorio peruano por medio de investigadores como Castro y Oviedo (2001), Franke et al. (2005) y Zuschlag (2014), quienes comparan el estado de las puyas y el número de individuos actuales a través de la estimación de la densidad en un área específica. Cabe señalar que, para el desarrollo de dichas metodologías, se emplearon herramientas SIG y dispositivos GPS (Global Positioning System) con el objetivo de mejorar la localización de los rodales y reducir el tiempo de carga en campo.

## CAPÍTULO 3

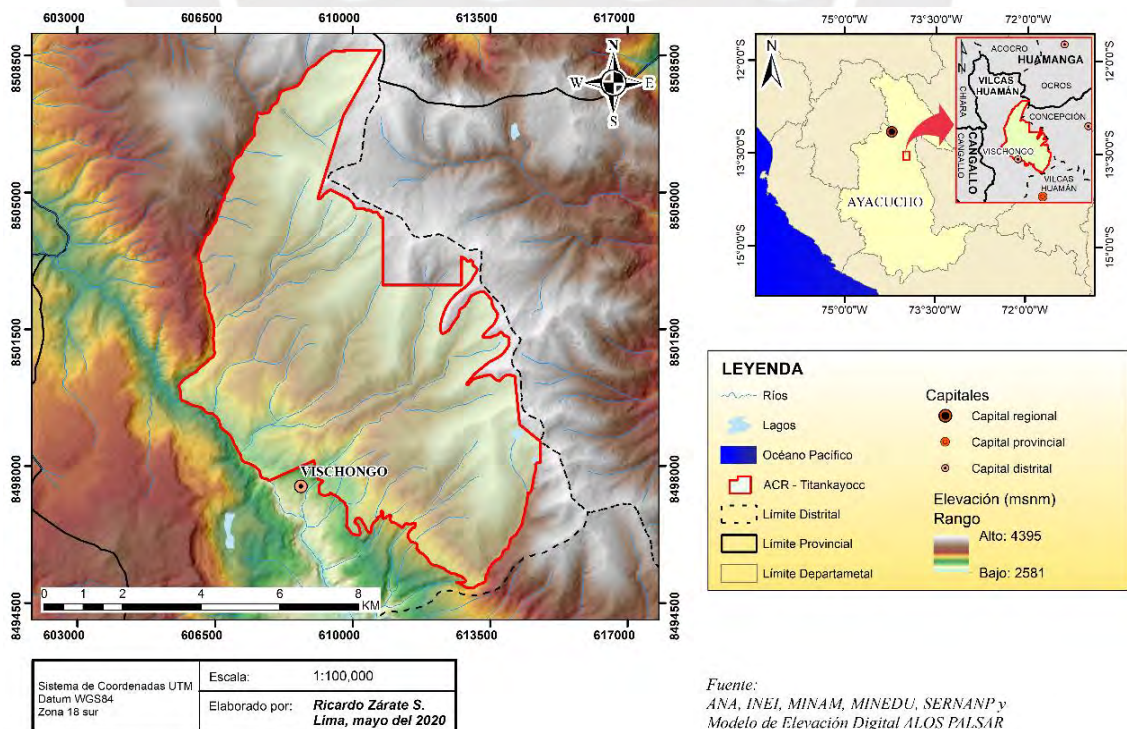
### ÁREA DE ESTUDIO

El presente capítulo describe las bases físicas, biológicas y socio-culturales que comprende el Área de Conservación Regional Bosque de Puya Raimondi - Titankayocc; asimismo, se define y localiza el área muestral con la finalidad de validar los resultados obtenidos de las imágenes satelitales de alta resolución. La información que se desarrolla a continuación proviene de búsqueda de fuentes bibliográficas, así como visitas de campo realizadas en los años 2019 y 2020.

#### 3.1. Ubicación política

El ACR Titankayocc se ubica en el distrito de Vischongo, provincia de Vilcas Huaman. Esta área tiene como localidades cercanas los centros poblados de Ccachubamba, Ñahuincucho, Qocha, Saywarumi, Teccoybamba, Paqcha y Vischongo según lo reportado en el último censo 2017 realizado por el Instituto Nacional de Estadística e Informática (INEI).

Mapa 3. 1. Mapa de ubicación del ACR Titankayocc



Fuente: Elaboración propia.

### 3.2. Origen y establecimiento del ACR Titankayocc

Los inicios del Bosque de Puya Raimondi - Titankayocc en la región de Ayacucho datan desde el año 1977, cuando el Instituto Italiano de Cultura de Lima emite una alarma acerca del peligro en el cual se encontraba el Bosque Titankayocc debido a la expansión desorganizada de las actividades agrícolas y urbanas por parte de las localidades de Cochas, Ccachubamba, Pallcacancha, Illapascca, Chanchayllo, Raccaraccay y Quisuarcancha, ubicados en los distritos de Chiara, Vilcas Huamán y Vischongo (Rozzi y Nazionale, 2015); asimismo, este hecho no habría sido desapercibido por Dourojeanni y Ponce (1978), a través de la publicación de su libro Los Parques Nacionales del Perú, en donde reconocían estas amenazas y, por ende, la necesidad de considerar a Titankayocc (vocablo local que se le da a los bosques de Puya Raimondi) como área protegida.

Sin embargo, fue en el año 1988, que se le asigna el título de "Refugio Naturalístico Bosque de Titankayocc" por ser la superficie más grande de *P. raimondii* a nivel nacional, a partir de lo cual, el Instituto Nacional de Recursos Naturales de Ayacucho (1999) muestra interés por conseguir la incorporación de Titankayocc al Sistema Nacional de Áreas Naturales Protegidas (SINANPE). Del mismo modo, algunos organismos locales y no gubernamentales hacían esfuerzos para la creación de dicha reserva (Rozzi y Nazionale, 2015).

Con la creación del ACR Titankayocc, de fecha 23 de diciembre del 2010<sup>2</sup>, mediante el Decreto Supremo N°023-2010-MINAM (2010), se establece una superficie de 6272.30 ha, con el objetivo de conservar una muestra ejemplar de bosque de *P. raimondii*, de amplia importancia local y nacional, y que además alberga una flora y fauna única y representativamente catalogada en amenaza: vicuña (*Vicugna vicugna*), colibrí gigante de los andes (*Patagona gigas*), nogal (*Juglans neotropica*), queñoales (*Polylepis spp*), entre otros.

---

<sup>2</sup> Durante el mandato de Alan García y por intermedio del primer ministro del ambiente Antonio Brack Egg

### **3.3. Descripción geográfica física**

El departamento de Ayacucho presenta un relieve accidentado con clima variado ubicado entre dos franjas latitudinales: la región latitudinal tropical con una superficie de 44,798.73 ha (0.34%) y la región latitudinal subtropical con una superficie de 13,259,220.31 ha (99.66%) (Gobierno Regional de Ayacucho, 2012). Asimismo, la Cordillera de los Andes, que atraviesa de sur a norte de dicho departamento, define las áreas ecológicas y fisiográficas variables, como algunos valles profundos en la zona baja como las de Umarmar, Parí y Bellavista mientras que otras áreas muy accidentadas en la zona media como la de Quillque y ligeramente accidentada en Pomacocha y Vischongo (Vásquez Tineo, 2018), por lo que resulta ser considerado como uno de los departamentos con mayor diversidad biológica de la sierra central peruana, tanto a nivel de ecosistemas como de especies (INDECI, 2004).


#### **3.3.1. Factores climáticos**

La estación más cercana a la zona de estudio y que además se encuentra a una altitud semejante es la estación meteorológica de Sachabamba (3566 msnm), perteneciente al Proyecto Especial Río Cachi y toma registros del clima desde hace diez años (GRRNGMA - Gobierno Regional de Ayacucho, 2014).

“Según el informe ejecutivo de la Oficina Regional de Estudios e Investigación del departamento de Ayacucho (2010), la zona presenta un contraste climático que corresponde al piso inferior de la puna, donde la temperatura media anual corresponde a 10.2 °C con un máximo de 12.4 °C y un mínimo de 7.9 °C, la temperatura máxima media mensual se da en los meses de noviembre a enero, con registros de 11.3 °C a 12.4 °C; los meses de junio y julio son los más fríos, teniendo una temperatura media mensual diaria de 0.92 °C bajando hasta los -7 °C en el mes de Agosto, mientras que el registro de las temperaturas máximas media absoluta diaria es de 20.1 °C; sus máximos valores se presentan en el mes de octubre con 23 °C y en noviembre con 23.3 °C” (citados por Apolinario y Carmen, 2015).

Esta última información, es contrastada con la base de datos hidrometeorológico del Servicio Nacional de Meteorología e Hidrología del Perú (SENAMHI), el cual se tiene acceso a la estación meteorológica-convencional “VILCASHUAMAN” ubicado en la localidad de Vilcas Huamán, con coordenadas 13°40'7.7"S y 73°57'8.6"O a 3518 msnm. Los datos obtenidos para el año 2019 y 2020 señalan los registros de precipitación total media anual son de 2.47 y 1.51 mm/año, registrándose un valor máximo de 6.55 mm en febrero del 2020, los meses de diciembre a marzo presentan mayor cantidad de precipitación que los meses de abril a octubre notándose en algunos casos la ausencia total de lluvias; también las temperaturas máximas corresponden entre los meses de octubre a diciembre, mientras que los valores de temperatura menos cálidos se da en el mes de julio (ver figura 3.1.).

**Figura 3. 1.** Monitoreo anual de la temperatura. Temperaturas máximas (línea roja), promedio (línea verde) y mínimas (línea azul) en la estación de Vilcas Huamán, Ayacucho, año 2019 y 2020.

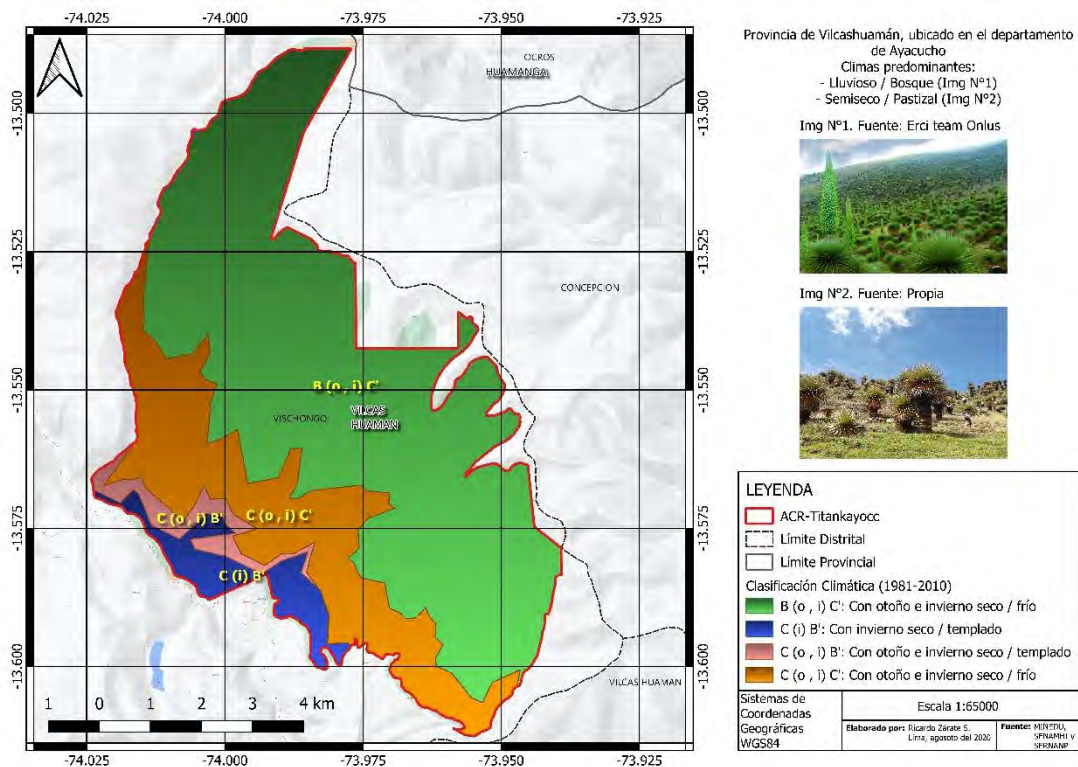


*Fuente: Elaboración propia.*

De esta manera, el área de estudio está considerada como una zona climática muy húmeda, de modo que no presenta meses con déficit hídricos, la velocidad del viento se mantiene constante durante el año, variando de -1 hasta 2.2 m/s y la

amplitud térmica de dicha zona es considerablemente alta, de más de 24 °C de junio a diciembre (Apolinario y Carmen, 2015). Asimismo, según la caracterización descrita por Dueñas y otros autores (2017) señalan que las localidades de Vischongo y Vilcas Huamán, presentan temperaturas que oscilan entre los 6 y 20 °C con precipitaciones que varían entre 100 y 500 mm anuales, provocando que la evaporación sea baja para la mayoría de los centros poblados ubicados entre 3000 y 4000 msnm; además, las precipitaciones pluviales pueden alcanzar los 800 mm anuales y la temperatura puede descender hasta los 4 °C, resultando una región con una sensación frígida helada (Dueñas et al., 2017). Cabe señalar que, considerando la información en las publicaciones del Atlas del Perú (1985) y del INGEMMET (1996), en la región las precipitaciones pluviales están influenciadas por dos estaciones: una seca (abril a noviembre) y otra lluviosa (diciembre a marzo), los cuales varían marcadamente con la altitud en diversos sectores de la zona de estudio (Baldeón et al., 2005).

**Mapa 3. 2.** Mapa de clasificación climática 1981-2010 del ACR Titankayocc



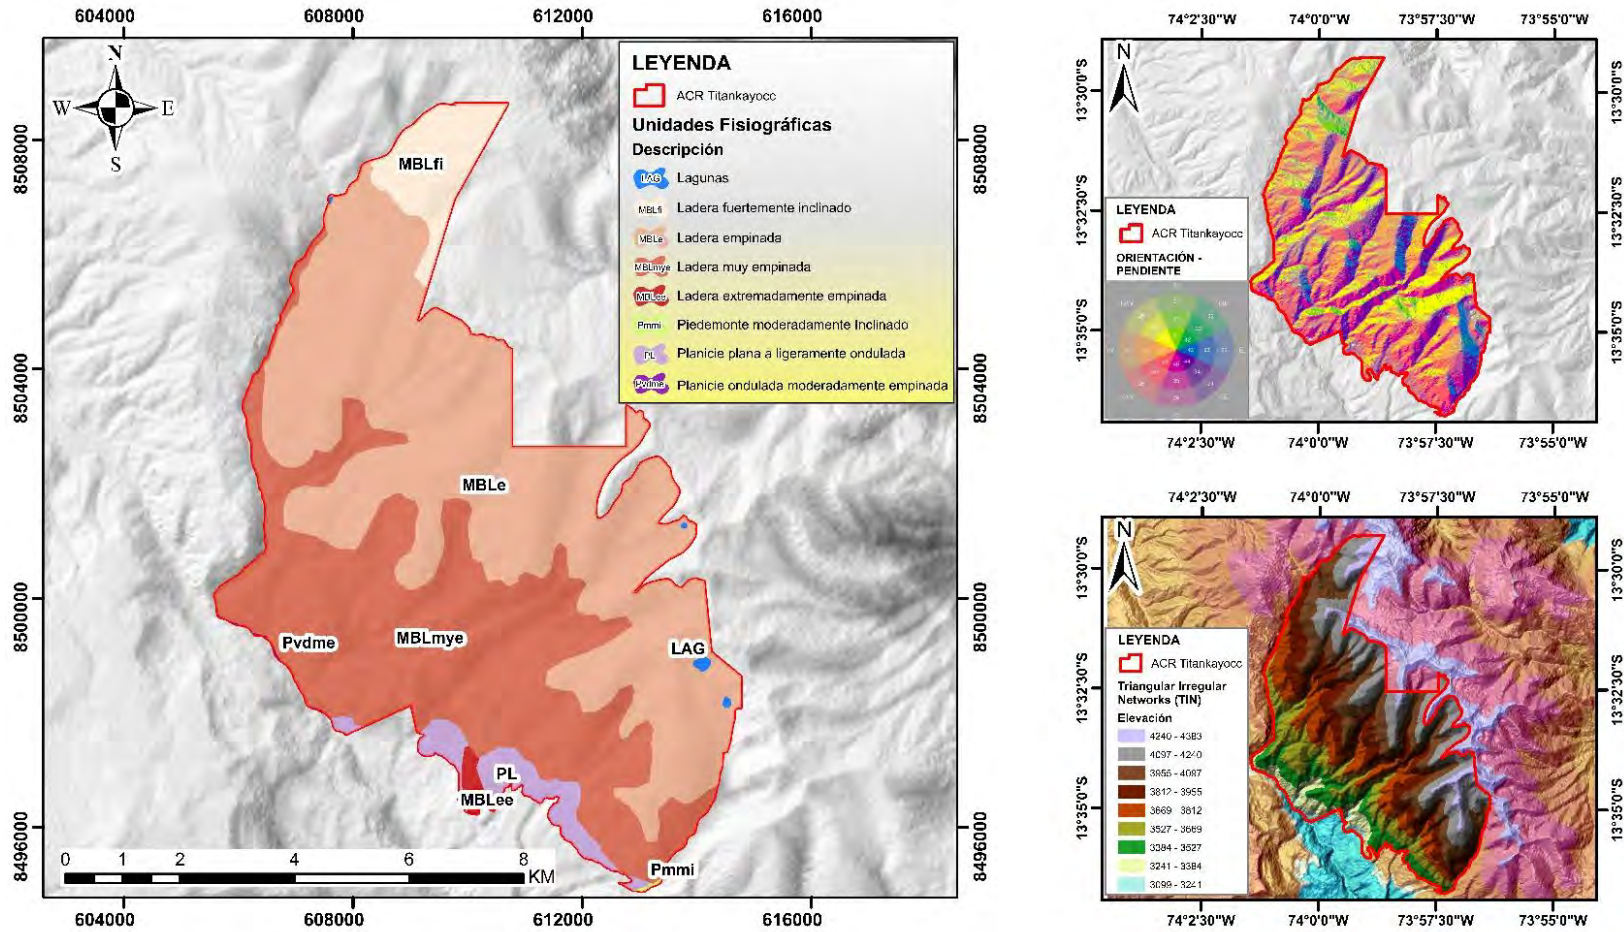
Fuente: Elaboración propia.

### **3.3.2. Característica geomorfológicas y fisiográficas**

La configuración física de la región está conformada e influenciada por la Cordillera de los Andes, el cual atraviesa de sur a norte la región de Ayacucho y que define las áreas ecológicas y fisiográficas (Vásquez Tineo, 2018); de manera que, presenta heterogeneidad del medio natural, situación que no ha beneficiado una correcta articulación ni integración entre las localidades por las condiciones agreste del medio físico (Vásquez Tineo, 2018). Dicho esto, se sabe que el relieve entre Vischongo - Vilcas Huamán se ubica entre los 3100-3400 msnm de cuyas faldas desciende las vertientes, inclinándose hacia el sureste de la zona, recortadas por taludes verticales (Baldeón et al., 2005).

En cuanto al distrito de Vischongo, presenta una fisiografía de montaña de litología sedimentaria/volcánica/intrusiva de ladera empinada (25 - 50%), así también sus suelos presentan una gruesa clase textural de franco arenoso (Gobierno Regional de Ayacucho, 2013b). Estas características físicas han ayudado en el aprovechamiento del suelo, asentamiento poblacional, desarrollo de actividades agrícolas y proyectos viales (ver mapa 3.3.).

Mapa 3.3. Mapa de unidades fisiográficas, orientación-pendiente y relieve del ACR Titankayocc



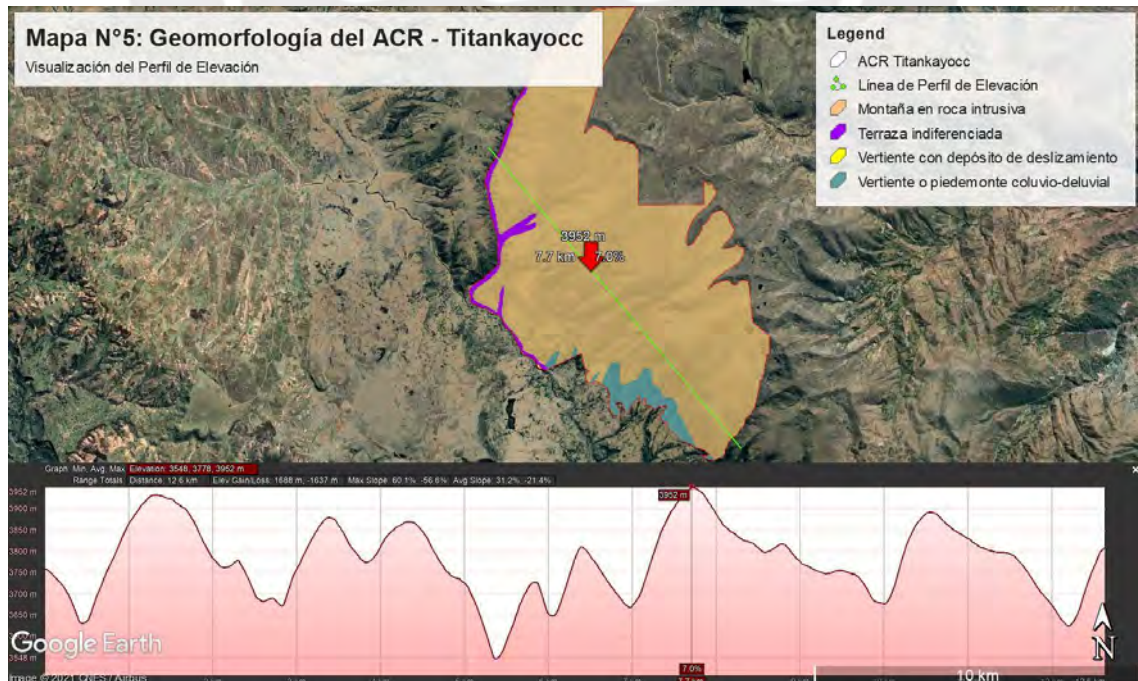
Sistema de Coordenadas UTM Datum WGS84 Zona 18 sur	Escala: 1:100,000
	Elaborado por: <b>Ricardo Zárate S.</b> <b>Lima, agosto del 2020</b>

Fuente:  
SERNANP, ZEE - AYACUCHO y  
Modelo de Elevación Digital ALOS PALSAR

Fuente: Elaboración propia.

Finalmente, el ACR Titankayocc presenta una topografía muy abrupta, con laderas disectadas, rocosa y superficie de roquedales (ver mapa 3.4). La pendiente del bosque de *P. raimondii* oscila entre 2 y 80 %, es decir, presenta pendientes ligeramente inclinado, empinado y extremadamente empinado (Carpio, 2017). Asimismo, comprende una zona dentro del flanco oriental de la Cordillera Occidental, al este de la divisoria de aguas, donde se desarrolla un interfluvio regional, las mesetas altioplánicas y valles (Apolinario y Carmen, 2015); de manera que, se aprecia una compleja geografía compuesta de laderas de pendiente suave, pendiente fuerte, conos de deyección, pampas, punas, lomas, fondos de valle, huaycos, puquiales y cañones delimitados por la presencia de ríos como Vischongo y Mayobamba, de naturaleza endorreica (desemboca sus aguas en el río Pampas) y origen pluvial las cuales son captadas y conducidas por canales de concreto y acequias de tierra para el abastecimiento de localidades próximas al lugar como Illapasca, Pallcacancha, Vischongo, Ccachubamba, Qocha, y Pomacocha (Dueñas et al., 2017; Vásquez Tineo, 2018).

**Mapa 3. 4.** Mapa geomorfológico del ACR Titankayocc

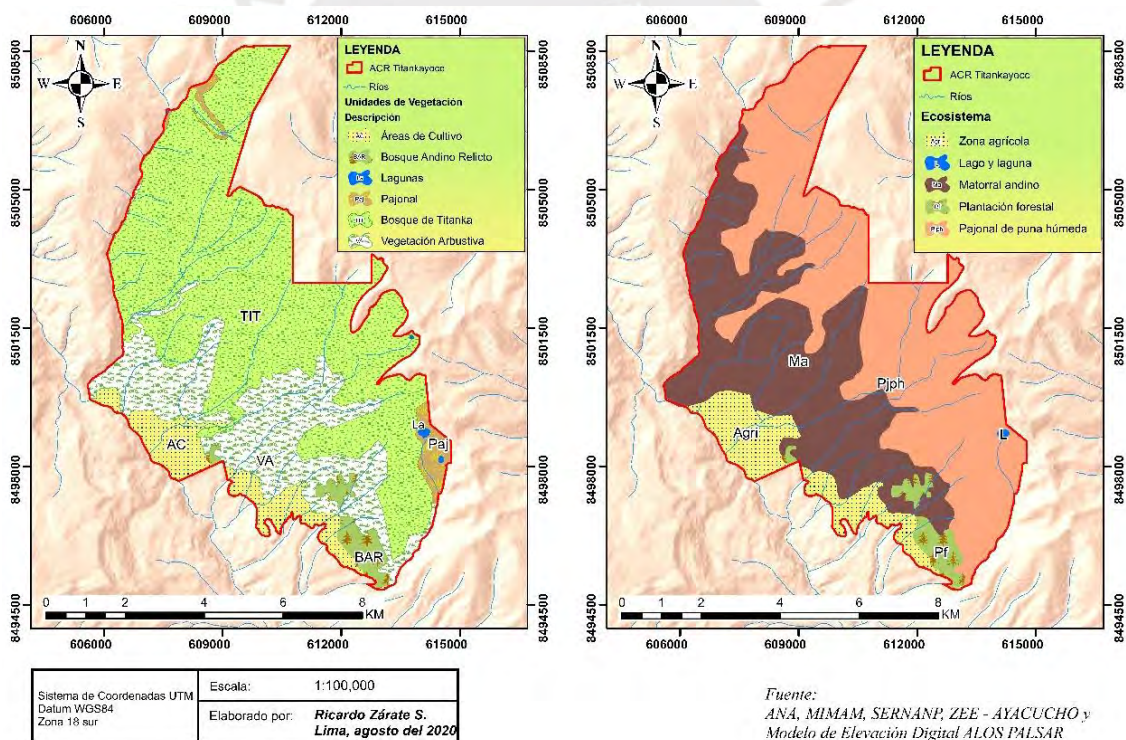


Fuente: Elaboración propia.

### 3.3.3. Ecología

La vegetación o cobertura vegetal de la región de Ayacucho muestra un total de 16 unidades vegetales de las cuales destacan la vegetación arbustiva, césped de puna y pajonales cada uno representan un 23.23, 21.98 y 20.73% respectivamente (Gobierno Regional de Ayacucho, 2013b). Asimismo, existen otras unidades vegetales en menor proporción tales como los bofedales (1.3%), bosques de andino relicto (0.31%), chachacomo (0.04%), queñua (0.49%), paty (0.01%) y titanka (0.16%), este último sobresale por su reducida extensión e importancia al ser hábitats para especies altoandinas (Gobierno Regional de Ayacucho, 2013b) (ver mapa 3.5.).

Mapa 3. 5. Mapa de unidades de vegetación y ecosistemas del ACR Titankayoc



Fuente: Elaboración propia.

Por otro lado, según las Zonas de Vida del Proyecto ZEE-OT Ayacucho (2012) citado por el Gobierno Regional de Ayacucho (2013a), Ayacucho presenta 44 Zonas de Vida de las 84 que existen en el Perú en donde la provincia de Vilcas Huamán es la que menor Zonas de Vida posee (4); ello debido a que se encuentra

en una región con poca extensión territorial, variabilidad climática y reducida heterogeneidad respecto a la vegetación existente. No obstante, alberga el mayor número de puyas con formaciones peculiares en sus distintas localidades tales como Vischongo, Pariamarca, Bellavista, entre otros.

La provincia de Vilcas Huamán lugar donde se ubica el ACR Titankayocc, posee un área de 120,829.29 ha de las cuales la unidad de vegetación con mayor extensión o predominancia es la arbustiva con 52,916.45 ha que representan el 43.79% del total, distribuidos en las laderas montañosas de valle de Vischongo, comprendidas desde aproximadamente 3600 a 3900 msnm (Gobierno Regional de Ayacucho, 2012). Sin embargo, existe la presencia mixta de asociaciones arbustivas de carácter siempre verde (perennifolias) y de asociaciones deciduas (caducifolias), las cuales crecen formando matas de hasta 2.5 m de altura y en forma dispersa sobre el terreno (Gobierno Regional de Ayacucho, 2012).

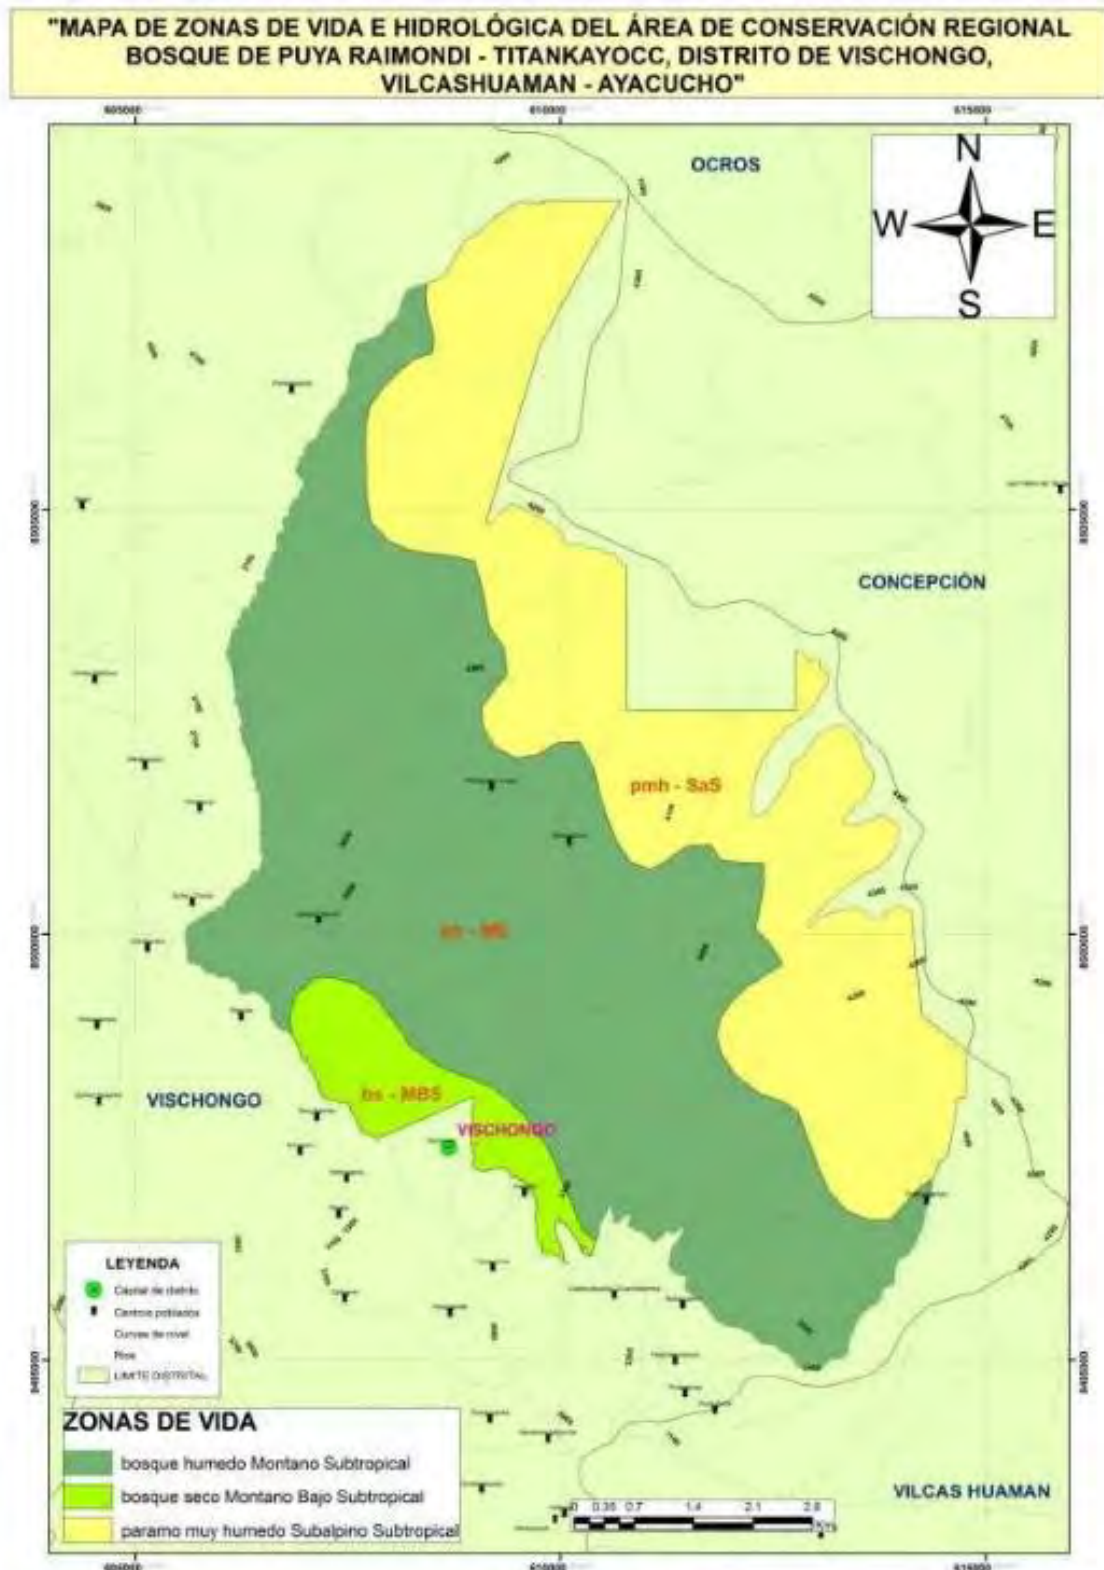
Finalmente, el ACR Titankayocc se encuentra sobre la zona de vida de bosque húmedo – MONTANO SUBTROPICAL (bh–MS) (ver mapa 3.6.). Esta zona según el diagrama Bioclimático de Holdridge (1967), indica que la biotemperatura media anual mínima es de 6 °C y la máxima es de 12 °C, el volumen de precipitación anual se encuentra entre los 500 y 1000 mm y el promedio de evapotranspiración potencial varía entre 0.5 y 1 vez el valor de precipitación (Gobierno Regional de Ayacucho, 2012). Además, las unidades ecosistémicas del año 2018 señalan que el ACR está compuesto por dos grandes mosaicos: el matorral andino<sup>3</sup> (1500-4500 msnm, extendido al lado occidental de la cordillera andina) y el pajonal de puna húmeda<sup>4</sup> (3800-4500 msnm, al norte: Áncash, Ayacucho, Huancavelica, Junín, La Libertad, Lima y Pasco) (MINAM, 2019).

---

<sup>3</sup> Constituido por plantas leñosas de hasta 5 metros de altura. Se denomina matorral al bioma o ecosistema con predominio de arbustos (MINAM, 2010).

<sup>4</sup> Espacios despoblados de arbustos y árboles. Están ubicados por encima de las quebradas boscosas, y gozan de vegetación predominantes como la poáceas que están asociadas a las formas herbáceas (MINAM, 2010).

Mapa 3. 6. Mapa de Zonas de Vida del ACR Titankayocc



Fuente: GRRNGMA - Gobierno Regional de Ayacucho, 2014.

### 3.3.3.1 Estado del hábitat de la *Puya raimondii* Harms

El bosque de Titanka o Puya Raimondi según lo señalado por la Zonificación Ecológica y Económica (ZEE), es una unidad independiente ubicada dentro de la Zona de protección y Conservación ecológica. Este hábitat se ubica en la provincia de Vilcas Huamán, abarcando territorios de los distritos de Concepción y Vischongo, con una extensión de 1218.35 y 5380.66 ha respectivamente que representan el 0.015% del territorio de la región (citado por Gobierno Regional de Ayacucho, 2012).

“Encontramos titankales en las faldas del cerro Atin Ccocha, en las partes altas de la quebrada Orcoccocha, debajo de la laguna China Ccocha, entre las pampas de Patahuasi y en la parte alta de la laguna Pomaccocha, entre 3870 a 4100 msnm. También se observan en gran cantidad de plántulas de 10 cm hasta las gigantes en floración, lo que nos hace suponer que hay una extensión del área de dispersión desde el norte, de los titankales de Vischongo” (Baldeón et al., 2005).

Es precisamente por ello, que el bosque de Puya Raimondi es uno de los ambientes más impresionantes que existe sobre la Tierra, debido al ser una planta con características únicas por su inflorescencia y pertenecer a la familia de las bromeliáceas, cuya importancia radica por ser fuente importante de proteínas de varias maneras: como fruta fresca, bebidas o vegetales (Hornung-Leoni, 2011). Cabe mencionar que la planta altoandina es una de las pocas especies que son la excepción a la regla que afirma en los altos andes, dado que sólo se encuentran en pajonales y arbustos pequeños (Dourojeanni y Tovar, 1966; Venero, 1984).

“Según el piso altitudinal de Weberbauer (1945), estas se distribuyen en las estepas de gramíneas con arbustos dispersos en el límite superior de los 3800 msnm y de acuerdo con el mapa ecológico del Perú (INRENA, 1995) se distribuyen en el Bosque húmedo Montano tropical, Estepa montano Tropical y Páramo muy húmedo Subalpino Tropical” (citados por Aquino et al., 2018).

De esta manera, la unidad de *P. raimondii* está constituida por agrupaciones de 10 a 30 individuos, se ubica entre el límite del ecosistema de bosque húmedo y pajonales los cuales ocupan laderas protegidas o áreas planas; y distribuidas de manera aislada y al azar, con presencia de individuos en diferentes estadios fenológicos (Baldeón et al., 2005; Dueñas et al., 2017).

Por otro lado, situándose en el ACR Titankayocc está área de conservación contiene el mayor número de ejemplares de puyas a nivel nacional. Según estudios realizados por la Universidad Nacional San Cristóbal de Huamanga (UNSCH), se sabe que estos rodales poseen una población mayor a los 600,000 ejemplares. El bosque más grande y conocido en las zonas es el de Titankayocc, que con 1200 ha de área de bosque posee 250,000 ejemplares, superando los 32,000 ejemplares del Parque Nacional del Huascarán y los 130,392 ejemplares reportados para el Santuario Nacional de Calipuy (Rozzi y Nazionale, 2015).

Lastimosamente, las hojas inferiores de las puyas, son quemadas por los ganaderos para proteger al ganado de no enredarse en las espinas. Mientras que las plantas jóvenes sirven de forraje; asimismo, la inflorescencia una vez seca, se utiliza para el enchapado de casas y chozas y también son cortados para diseñar bancos (Baldeón et al., 2005). Por estas razones, la creación del ACR Titankayocc contribuye a la preservación de la biodiversidad tal como ocurre con los rodales de *P. raimondii* e influye en la calidad de vida de los pobladores asentados en los distritos limítrofes con el ACR, por medio del desarrollo de actividades ecológicas, turísticas, recreativas e investigativas.

Finalmente, este hábitat alberga otros bosques tales como los naturales y andinos relictos, los cuales representan un total de 7171.56 (5.94%) y 559.24 ha (0.46%) de la provincia de Vilcas Huamán. Los bosques de titanka están conformados por otras especies nativas del lugar (*Polylepis sp*, *Escallonia sp* y *Puya raimondii* Harms), entre los 2800 a 3200 msnm, distribuidos de manera fraccionada similar a los

bosques de montaña del piso altitudinal superior (Gobierno Regional de Ayacucho, 2012). De igual modo, su importancia deviene por la representatividad de biodiversidad de flora y fauna silvestre de alto valor ecológico brindado para la zona; asimismo, la potencial existencia de especies valiosas, tanto maderables como no maderables (Gobierno Regional de Ayacucho, 2012). Así pues, pese a la vegetación predominante que es la *P. raimondii* en el ACR Titankayocc, se reconoce la existencia y asociatividad con otras especies de arbustos y forestales.

### **3.4. Descripción geográfica social**

Los ecosistemas de montaña propician una amplia gama de bienes y servicios a la humanidad, tanto a las personas que viven en las montañas como quienes viven fuera de ellas (Grêt-Regamey et al., 2012). En ese sentido, el departamento de Ayacucho refleja el desarrollo de distintas dinámicas como la actividad agropecuaria, minería, construcción, comercio y otros servicios. Según los resultados finales del IV Censo Nacional Agropecuario del 2012, la región dispone de un área agropecuaria de 2,246,988.07 ha y en total de 112,901 productores agropecuario, siendo la tercera fuente de trabajo más importante, con una participación de 15% en el Valor Agregado Bruto (VAB) departamental de 2020 (BCRP, 2021). De esta manera, la geografía de Ayacucho resalta por la diversidad de especies silvestres, endemismos y agrodiversidad, las cuales son aprovechadas por actividades económicas vinculadas al campo (MINAM, 2019).

#### **3.4.1. Accesibilidad**

Para llegar al destino, el cual es el ACR Titankayocc, previamente se debe conocer la disposición de vías de transportes que cuenta el departamento de Ayacucho.

La accesibilidad hacia la región es posible a través de vías de transporte terrestre y aéreo. La vía terrestre cuenta con ejes principales como es la carretera Panamericana Sur y la vía Los Libertadores, el cual presenta un recorrido de 559

km para llegar a la ciudad de Huamanga (Baldeón et al., 2005). Ambos articulan la ciudad con la costa y sierra del país, siendo vías de carácter interprovincial.

**Tabla 3. 1.** Red Vial Nacional - Provincia de Huamanga.

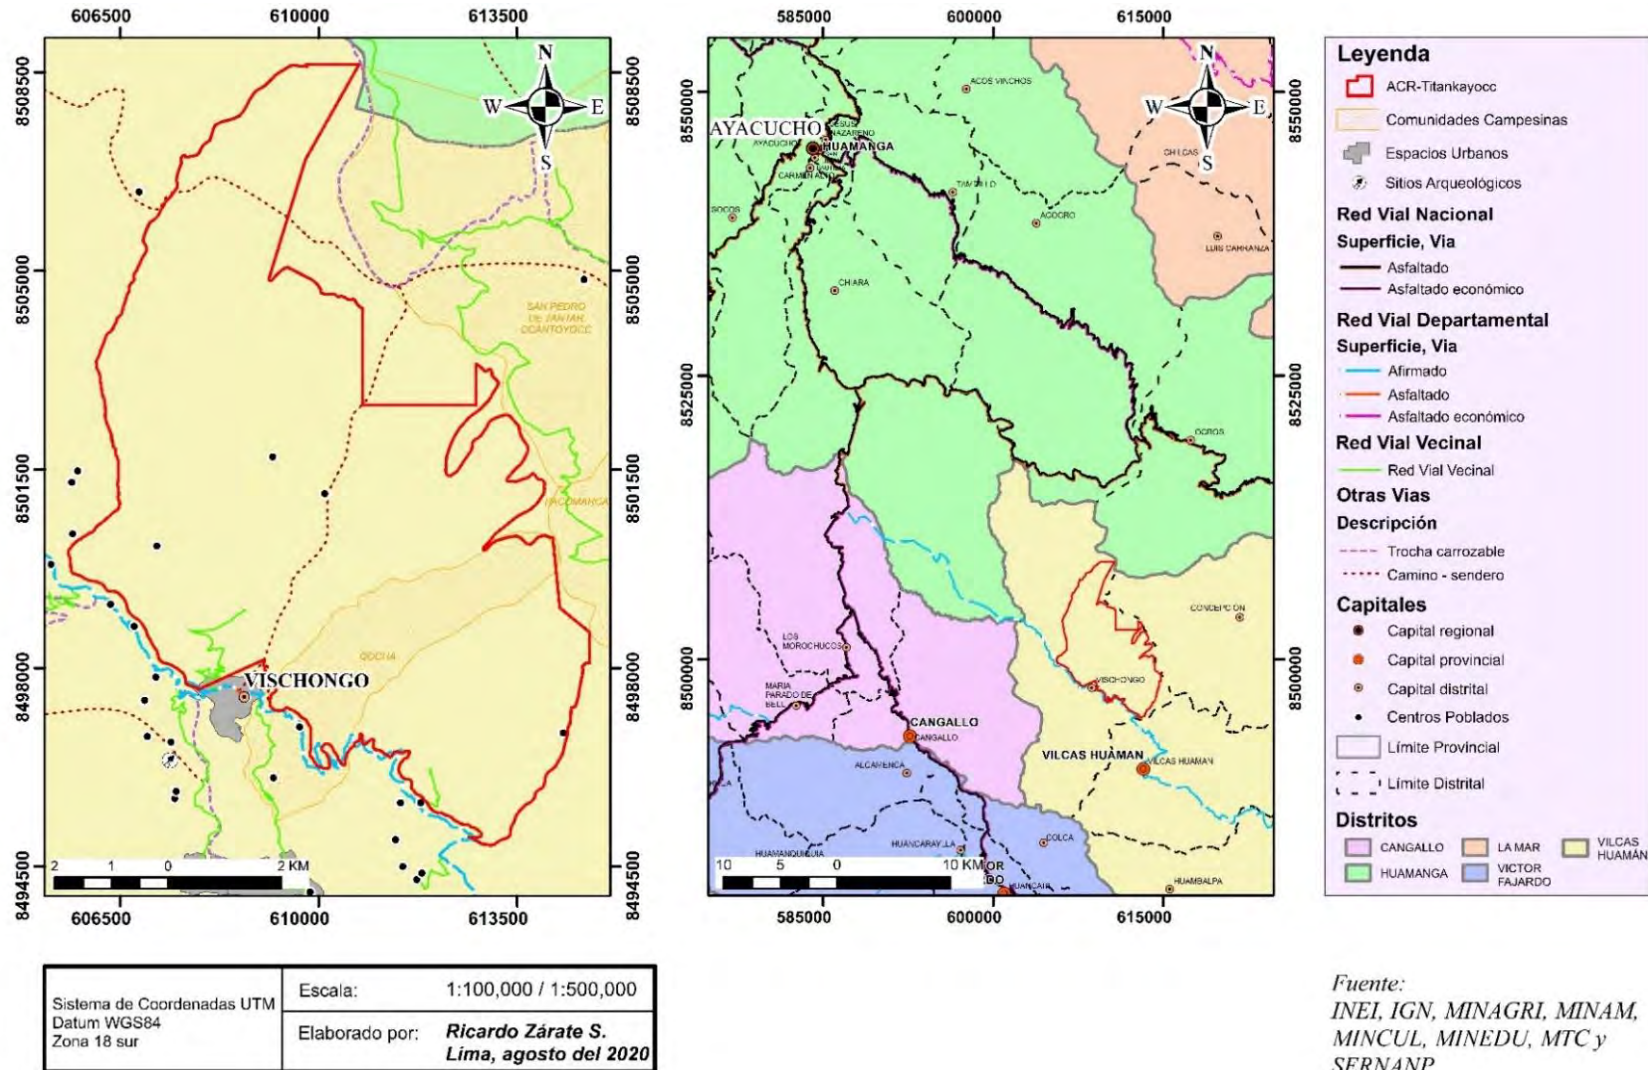
Lima - Ayacucho :	585 Km. (8 a 9 horas - carretera asfaltada). El viaje inicia en la carretera Panamericana Sur hasta la ciudad de Pisco (Departamento de Ica) y continúa por la vía Los Libertadores en el trayecto se atraviesa por zonas de gran altitud que superan los 4,000 m.s.n.m., es la ruta más recomendable.
Huancayo - Ayacucho :	275 Km. (8 horas - carretera afirmada).
Abancay – Ayacucho :	393 Km. (15 horas - carretera afirmada).
Cuzco - Ayacucho :	590 Km. (18 horas - carretera asfaltada y afirmada).
Ica - Ayacucho :	389 Km. (6 horas - carretera asfaltada).
Andahuaylas - Ayacucho :	261 Km. (10 horas - carretera afirmada).
Ayacucho - San Francisco :	197 Km. (6 horas - carretera afirmada).
Ayacucho - Huanta	48 km.(45 minutos - carretera asfaltada )

*Fuente: INDECI, 2004.*

Sin embargo, estas infraestructuras no están acondicionadas en todo el territorio departamental, puesto que, para poblaciones pequeñas y alejadas, sus rutas están conformadas por caminos de herradura que limitan el ingreso y flujo constante de personas tal es el caso del eje vial Vischongo - Vilcas Huamán (Baldeón at al., 2005). Asimismo, las vías locales sirven para formar la red que articula el interior de los barrios y sectores urbanos (INDECI, 2004); de esta manera, se denota que son vías secundarias que articulan las vías principales con las locales y de nexo.

Finalmente, para llegar a la provincia de Vilcas Huamán, lugar donde se ubica el ACR Titankayocc, el viaje se da únicamente por vía terrestre, primero con destino a la ciudad de Huamanga en Ayacucho, siguiendo la carretera afirmada y eje Ayacucho - Chiara - Vischongo - Vilcas Huamán. El recorrido dura aproximadamente 4 horas desde la ciudad de Huamanga; para llegar al ACR también se sigue la ruta afirmada Ayacucho - Vilcas Huamán, pasando por el paraje de Condorqocha, hasta llegar a la localidad de Vischongo en un tiempo de viaje aproximado en vehículo de 3.5 horas (Apolinario y Carmen, 2015); por último, el distrito de Vischongo se accede a través de 3 rutas: el primero es la ruta Ayacucho - Toccto - Vischongo 90 km; el segundo, por Cangallo 30 km; y el tercero, por Vilcas Huamán 25 km (Vásquez Tineo, 2018) (ver mapa 3.7.).

Mapa 3. 7. Mapa de accesibilidad del ACR Titankayocc



Fuente: Elaboración propia.

### **3.4.2. Actividades socio-económicas y dinámicas territoriales**

La región de Ayacucho posee un valioso patrimonio cultural, que guarda relación armónica con el paisaje y el medio natural propio de los Andes; produciéndose una interacción dinámica de la capacidad creativa e imaginativa de sus habitantes que se manifiestan a través del fervor religioso, arte, poesía, música, entre otros (Gobierno Regional de Ayacucho, 2012). Asimismo, en base a su ordenamiento territorial, se desarrollan los distintos corredores de articulación e integración en el ámbito regional en donde cada una de estas ciudades desempeñan distintas tareas y funciones particulares; respondiendo a sus costumbres y procesos históricos, en función de las actividades de sus habitantes y el aprovechamiento de sus recursos naturales (INDECI, 2004).

En ese sentido, según el Plan de Desarrollo Concertado Local de la Provincia de Vilcas Huamán (2009 - 2021) (Municipalidad Provincial de Vilcas Huamán, s.f.), el turismo es una de las actividades con mucho futuro que puede generar divisas y promover la conservación del medio natural; sin embargo, estos paisajes que son un potencial aprovechamiento son alterados por actividades antrópicas que dañan la belleza escénica de los ecosistemas altoandinos.

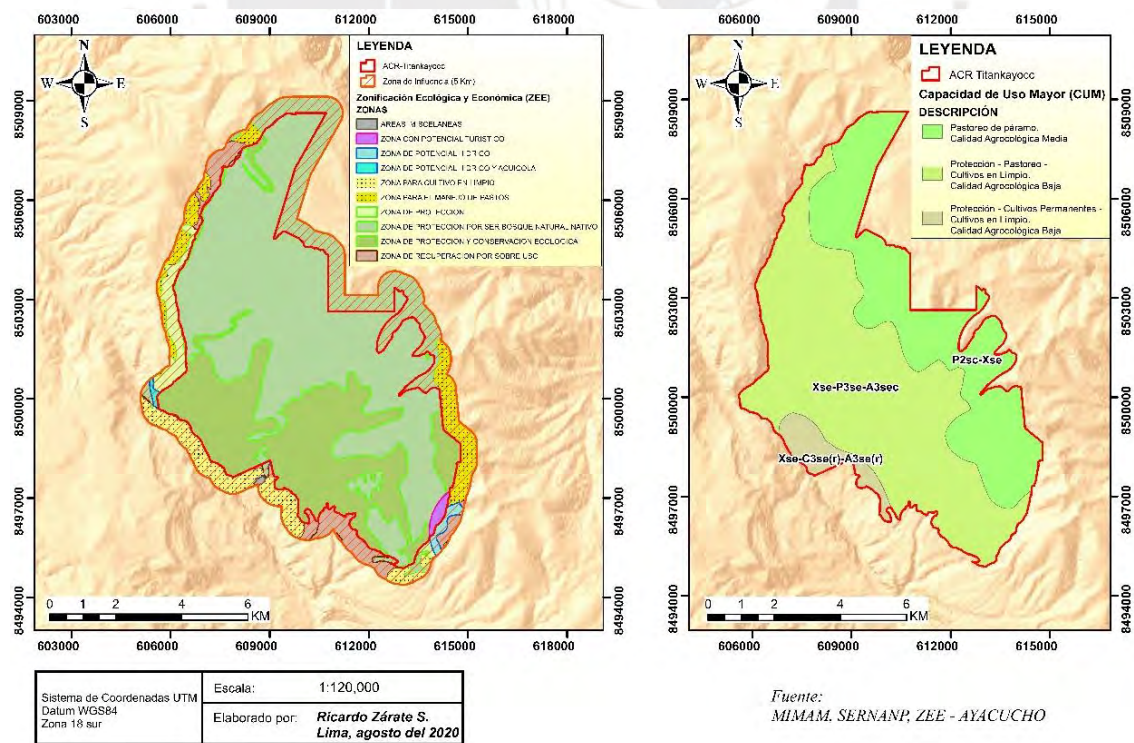
En efecto, el distrito de Vischongo posee zonas de protección conformadas por bosques, montes y tierras eriazas de 16,734 km<sup>2</sup> que equivalen al 67.6% de la superficie total del distrito, resaltando las especies nativas de árboles, arbustos y plantas medicinales (Vásquez Tineo, 2018). Por lo que algunos pobladores desarrollan actividades agroforestales a través del apoyo de instituciones tales como AGRORURAL, quienes organizan los comités conservacionistas en algunas localidades de Vischongo y benefician con asistencia técnica, suministros de materiales, semillas y/o fertilizantes (Vásquez Tineo, 2018).

No obstante, para el caso de la población de Vischongo, se sabe que su principal desarrollo económico es la agricultura tradicional sin uso de tecnologías; es decir,

bajo conocimiento de los agricultores para el control de plagas y enfermedades, inexistencia de organizaciones de productores, escasa articulación al mercado local y regional, entre otros (Vásquez Tineo, 2018). Asimismo, la existencia de despoblación causada por el post conflicto armado interno ha generado el abandono y la subsistencia de las poblaciones más vulnerables como son los ancianos, discapacitados, niños y madres solteras (Baldeón et al., 2005).

De esta manera, el ACR Titankayocc presenta limitaciones muy severas que las hacen inapropiadas para propósitos agrícolas y pecuarios, tienen un gran valor económico para otros usos como suministro de energía, áreas recreacionales, paisajísticos, arqueológicos y turísticos; asimismo, las tierras de protección cumplen un rol importante dentro del contexto integrado del manejo sostenible de los recursos naturales y refugio de vida silvestre (Carpio, 2017) (ver mapa 3.8.).

**Mapa 3. 8.** Mapa de Zonificación Ecológica y Económica (ZEE) y Capacidad de Uso Mayor (CUM) del ACR Titankayocc



Fuente: Elaboración propia.

### **3.4.3. Ámbito de Influencia del ACR Titankayocc**

Según el Plan Maestro ACR - Titankayocc 2014-2019, el área de conservación comprende los territorios de tres comunidades campesinas: Ccachubamba, Ccocha y Vischongo, que tiene un total de 824 viviendas según los datos estimados del Censo 2007 elaborado por el INEI. Sin embargo, ante el crecimiento poblacional de la región ha generado que el número de hogares vaya en aumento en los últimos años; de manera que, se tiene en la actualidad un predominio de vivienda rurales cuyas actividades y dinámicas se basan en el desarrollo agrícola estacional, manejo de actividades forestales, ganadería extensiva y, en algunos sectores, la fruticultura (GRRNGMA - Gobierno Regional de Ayacucho, 2014).

A continuación, se describe los dos tipos de zonas de influencia presente en el ACR Titankayocc (ver mapa 3.9.):

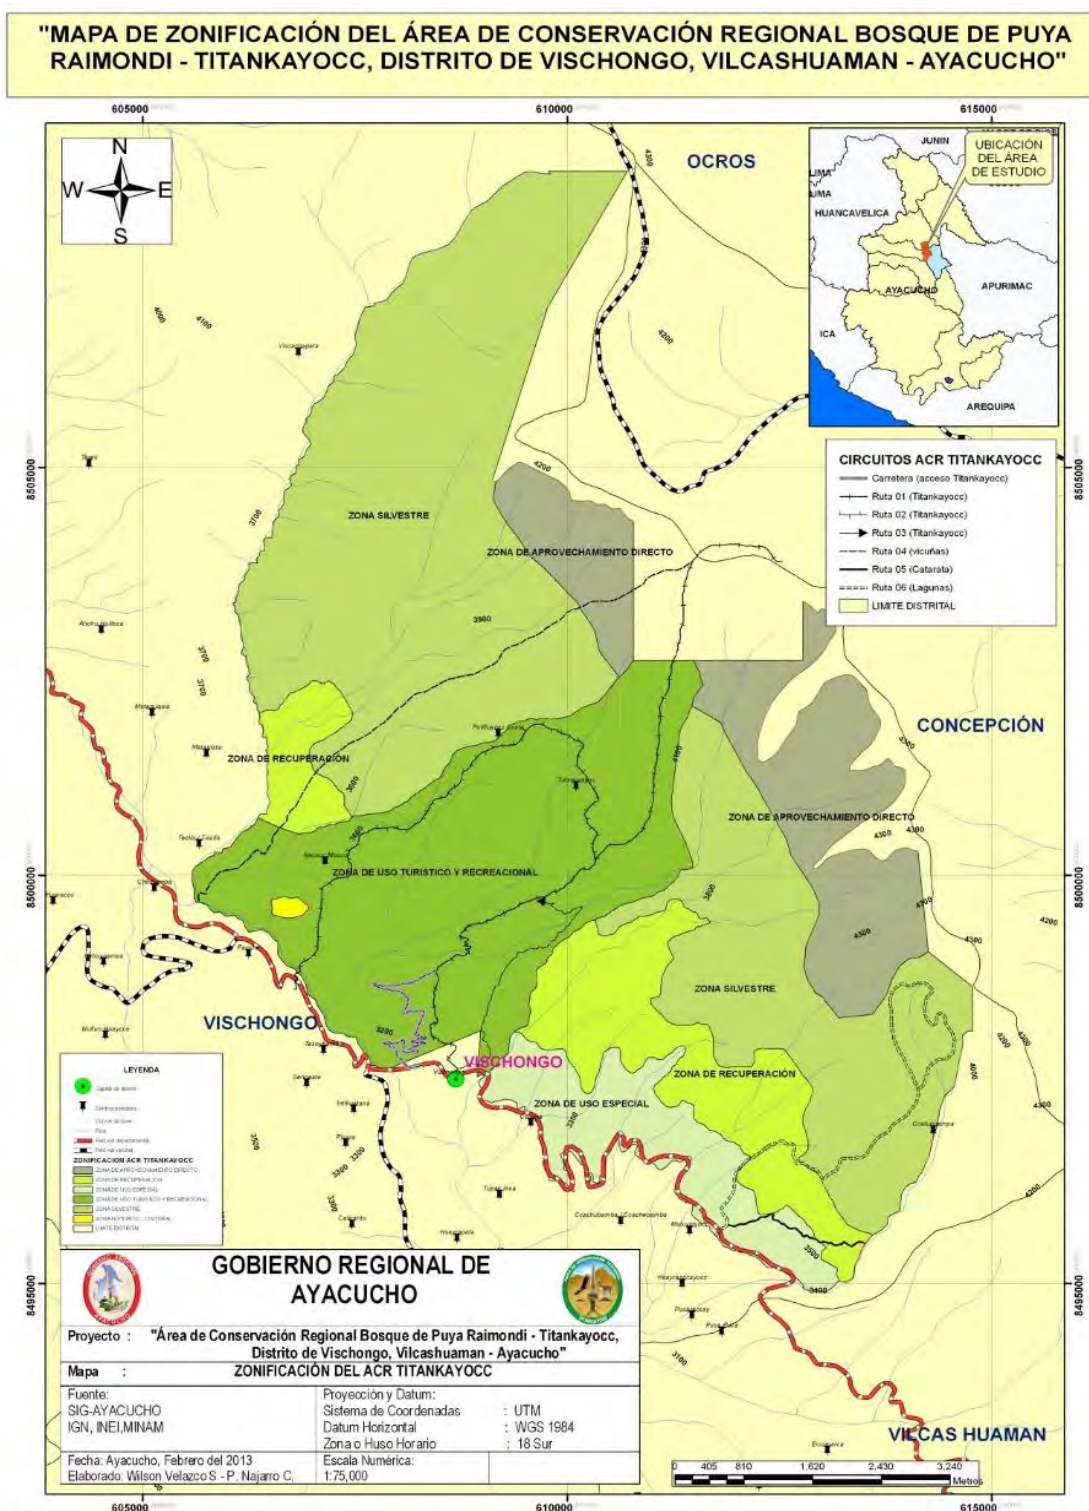
#### **Zona de Influencia Directa**

Se consideran al distrito de Vischongo directamente vinculado al ACR Titankayocc. Esta área, que puede funcionar como una Zona de Amortiguamiento; asimismo, está sujeta al uso intenso y directo de los bienes y servicios ambientales que ofrece el área de conservación como es el consumo de agua, leña, pastos, disposición del paisaje para el funcionamiento de actividades de comercio, recreacional, turismo, entre otros (GRRNGMA - Gobierno Regional de Ayacucho, 2014).

#### **Zona de Influencia Indirecta**

Debido a la importancia de los bosques de Puya Raimondi o titanka ubicado en el distrito de Vischongo, se tiene una influencia que llega hasta la misma ciudad de Ayacucho - Huamanga. Esto se debe a los beneficios que otorga a la capital del departamento de Ayacucho por medio de la producción agropecuaria de los centros poblados cercanos al ACR Titankayocc (GRRNGMA - Gobierno Regional de Ayacucho, 2014).

Mapa 3. 9. Mapa de Zonificación del ACR Titankayocc



Fuente: Gobierno Regional de Ayacucho, 2013 citado por GRRNGMA - Gobierno Regional de Ayacucho, 2014.

## CAPÍTULO 4

### MARCO METODOLÓGICO

El enfoque de estudio realizado está orientado tanto de técnicas cuantitativas como cualitativas. El primero porque se realizó el análisis a estas imágenes obtenidas y procesadas por medio de índices, técnicas de *Deep Learning* y datos geoestadísticos, los cuales representan una naturaleza numérica; mientras que, para el segundo caso, estos datos se caracterizarán por criterio de la interpretación que se le otorga a nuestra área de estudio.

#### 4.1. Aspectos teóricos de la metodología

La investigación se encuentra bajo lineamientos de la fitogeografía, análisis espacial y *Deep Learning*, donde se realizarán aportes continuos para mapear la distribución de la especie y su densidad que pueden tener para la planificación de la conservación (Foody, 2003; Whittaker et al., 2005). De tal modo, que se desarrollarán estudios de terreno exhaustivos e inventarios de la *P. raimondii* a partir de imágenes satelitales de acceso libre (Prasad et al., 2015).

Por otro lado, la estrategia a desarrollar busca innovar y proponer un modelo de “conservación digital” con la capacidad de identificar cambios que se encuentren directamente vinculados entre prácticas sociales y organizaciones relacionadas con la conservación de la naturaleza (Arts et al., 2015). Asimismo, la importancia que existe por el lado de la fitogeografía para el caso de la *P. raimondii* es integrar distintas disciplinas (biológicas, ecológicas y sociales) con la finalidad de generar nuevos conocimientos que sean de aporte para la conservación y sostenibilidad del lugar (*diversitas-international.org* citado en Wei, 2017); de esta manera, se busca establecer un monitoreo para la conservación, el cual implique la proporción de información cada vez más específica sobre las características de la especie (Skidmore et al., 2015).

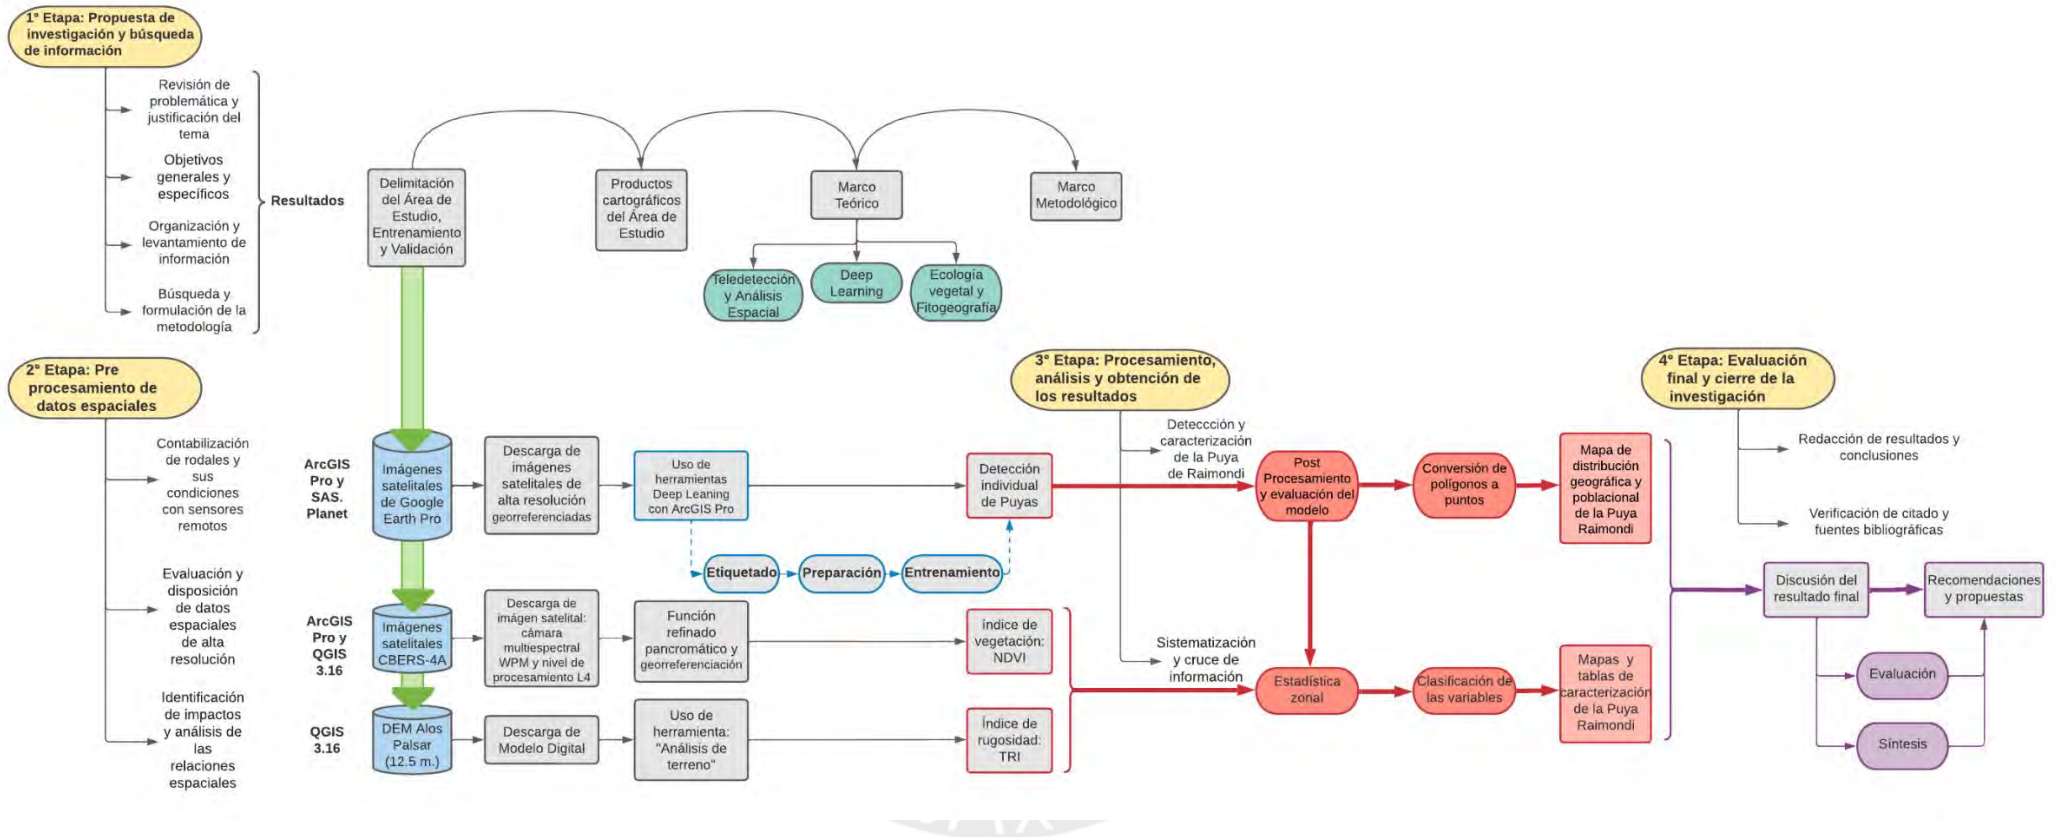
Finalmente, el papel de los métodos de detección remota para evaluar y cuantificar la *P. raimondii*, comprenden el uso de sensores multiespectrales y de imágenes satélites de alta resolución, ya que proveen información sobre la variación espacial y temporal que existen en la zona permitiendo configurar patrones de biodiversidad (Pettorelli et al., 2014).

#### **4.2. Esquema metodológico de la investigación**

El proceso metodológico para llevar a cabo la problemática la cual es la situación vulnerable en la que se encuentra la *P. raimondii*, se dará a partir de la clasificación y estado fenológico de la especie por medio de (1) mapas de dimensión y distribución espacial de individuos; (2) teledetección aplicada a las condiciones ambientales (NDVI y TRI); y (3) geoestadística aplicada al análisis y representación de los datos fenológicos. Ello a través del dominio de diferentes programas que permitan alcanzar los objetivos específicos del estudio.

Establecida las bases teóricas sobre la metodología, se mostrará el siguiente esquema gráfico de trabajo (flujograma de etapas y actividades) (ver figura 4.1.). Este esquema presenta en todas sus fases trabajo de gabinete, por lo que en la primera etapa se enfatiza en el objetivo y búsqueda de información con la finalidad de armar la propuesta de investigación; de modo que, se incluyen tópicos como problemática y justificación del tema, objetivos, planificación de la investigación y levantamiento de información bibliográfica. Seguidamente, la segunda etapa consiste en el procesamiento de datos geospaciales implicando el uso de programas como SAS Planet, QGIS y ArcGIS Pro. Finalmente, las dos etapas restantes consistirán en la sistematización e interpretación de los datos empleados además de la discusión de los resultados.

Figura 4. 1. Esquema metodológico de la investigación.



Fuente: Elaboración propia.

#### **4.2.1. Primera Etapa: Propuesta de investigación y recopilación de datos**

- Definición del tema (área de estudio, objetivos, problemática, justificación marco teórico y metodológico)
- Revisión bibliográfica de la especie a evaluar (levantamiento de información – secundaria)
- Elaboración de mapas temáticos (línea base)
- Planificación de las siguientes fechas para las etapas correspondientes a la investigación (cronograma, materiales y softwares)

#### **4.2.2. Segunda Etapa: Pre procesamiento de datos espaciales**

- Descarga de imágenes satelitales, modelos digitales y datos cartográficos
- Uso de programas geoespaciales (SIG, Google Earth Pro y SAS Planet)
- Fotointerpretación de imágenes Google Earth (delimitación de áreas de entrenamiento y validación)
- Ortorrectificación de imágenes satelitales CBERS-4A, cálculo de índices ambientales, uso de herramientas de geoestadística y detección de objetos con *Deep Learning*

#### **4.2.3. Tercera Etapa: Procesamiento, análisis y resultados**

- Mapas de distribución geográfica y poblacional de la *P. raimondii* en el ACR Titankayocc
- Gráficos y tablas geoestadísticos de la *P. raimondii* en el ACR Titankayocc
- Identificación de condiciones ambientales más alterables que repercuten en el crecimiento de la *P. raimondii* en el ACR Titankayocc
- Desempeño del modelo *Deep Learning* usando métricas de precisión para la detección de la *P. raimondii* en el ACR Titankayocc

#### **4.2.4. Cuarta Etapa: Evaluación final y cierre de la investigación**

- Interpretación de resultados (conclusiones y recomendaciones)
- Discusión y retroalimentación con panel de expertos (propuestas y recomendaciones)
- Revisión y corrección de citado y bibliografía

#### **4.3. Metodología general**

Esta investigación parte del uso de imágenes gratuitas de Google Earth a partir de la descarga con el software ruso llamado SAS Planet. Este programa facilita la extracción de imágenes de muy alta resolución espacial de hasta 0.7 m – depende de la información disponible en el área de estudio. Luego, para el procesamiento de dichas imágenes se recurre a los SIG con la finalidad de realizar metodologías de filtrado y convolución del pixel para la identificación de elementos con imágenes de colores primarios (luz visible). Finalmente, una vez terminado el trabajo de gabinete y haber contabilizado espacialmente la cantidad de puyas en el área de conservación, se verifica los datos por medio de áreas de validación y monitoreo de parcelas. Como resultados se obtiene un mapa de distribución espacial y densidad de *P. raimondii*.

##### **4.3.1. Descarga de imágenes satelitales de alta resolución de Google Earth con SAS Planet**

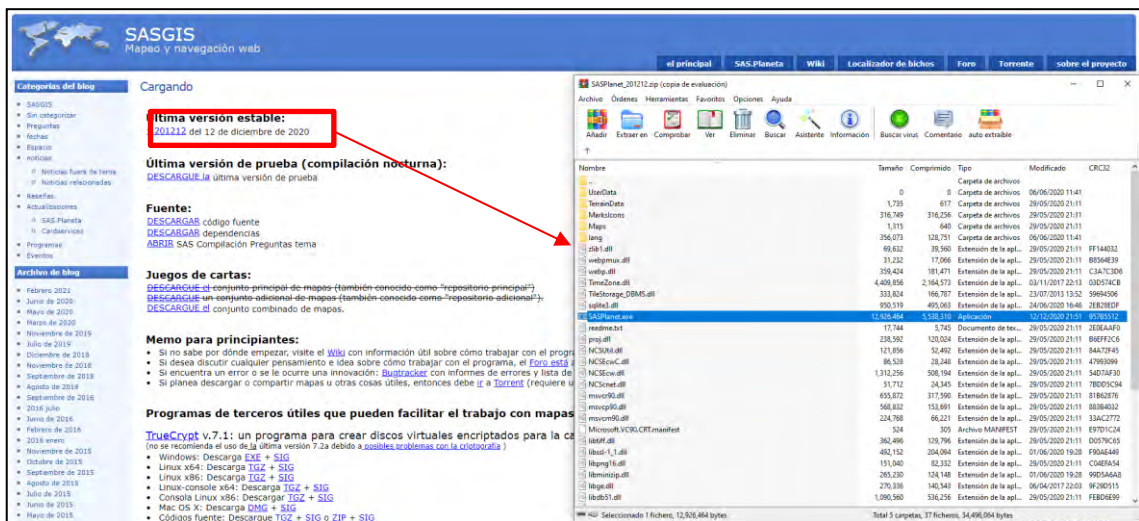
Como se señaló previamente, SAS Planet es un programa ruso que facilita la descarga gratuita de imágenes georreferenciadas de alta resolución y mapas convencionales de servidores como: Google Earth, Here Maps, ESRI, entre otros. De esta manera, este programa contiene una variedad mapas e imágenes además de permitir el nivel de resolución deseado para un área de interés.

El proceso metodológico para la descarga de imágenes de alta resolución a través del programa SAS Planet, es el siguiente:

a) Instalación del programa SAS Planet v.201212

La página de descarga del programa se llama "SASGIS" el cual se encuentra en su idioma original (ruso) y se hará la descarga de la última versión disponible hasta la fecha actual (12 de diciembre de 2020). Para dar inicio al programa se deberá ejecutar el archivo "SASPlanet.exe" tal como se muestra en la figura 4.2.

Figura 4. 2. Ruta de descarga e instalación de SAS Planet.



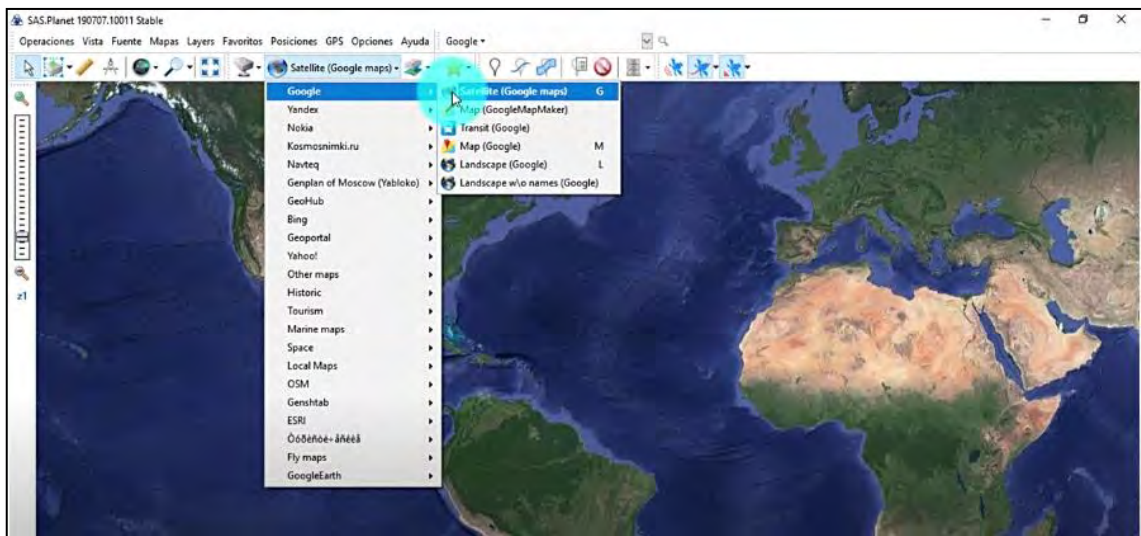
Fuente: Elaboración propia.

b) Obtención de imagen satelital de alta resolución de Google Earth

La figura 4.3. muestra el interfaz del programa, allí deberemos ubicar el área de interés de forma manual o introduciéndose el archivo KML (Keyhole Markup Language) de nuestra zona. Asimismo, en el ícono del planeta podemos escoger los mapas e imágenes que nos ofrece el mismo programa.

<sup>5</sup> Mapeo Web y la Navegación (<http://www.sasgis.org/download/>) (Acceso en julio del 2021)


**Figura 4. 3.** Selección de mapa base satelital.



*Fuente: Elaboración propia.*

Ubicado el área de estudio, se realiza un barrido a mínima escala en toda la superficie delimitada (ver figura 4.4.). Este paso es importante, ya que se busca evitar errores para su posterior descarga; adicionalmente, permite conocer la fecha que corresponde la imagen satelital según el programa Google Earth Pro, el cual reporta el mes de agosto del 2019.

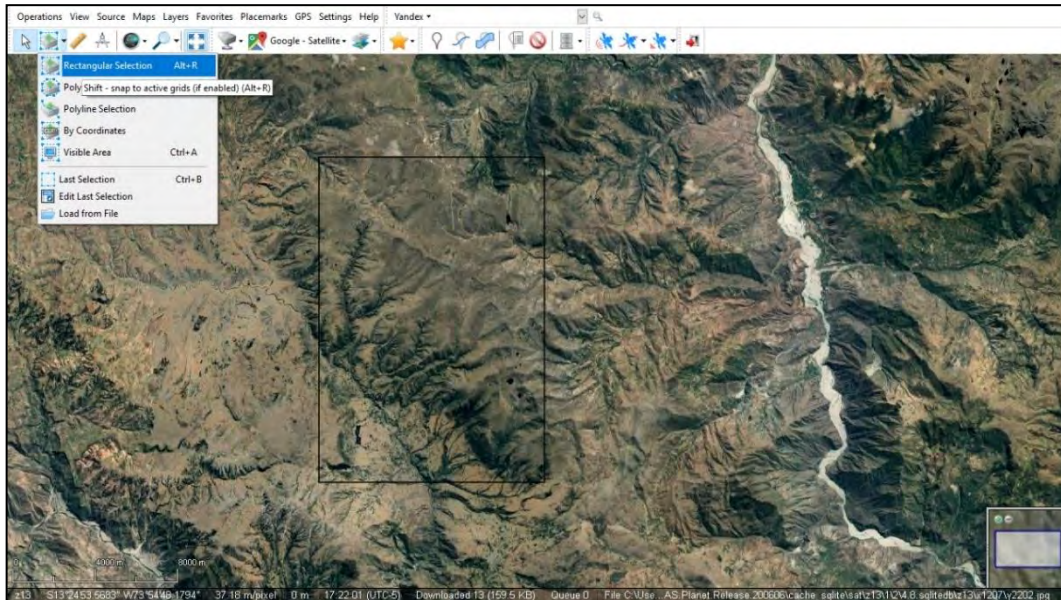
**Figura 4. 4.** Visualización de alta resolución dentro del ACR Titankayocc.



*Fuente: Elaboración propia.*

Seguidamente, se procede a recortar el área seleccionada con el botón “Selection manager” que contiene varias opciones para guardar la imagen (ver figura 4.5).

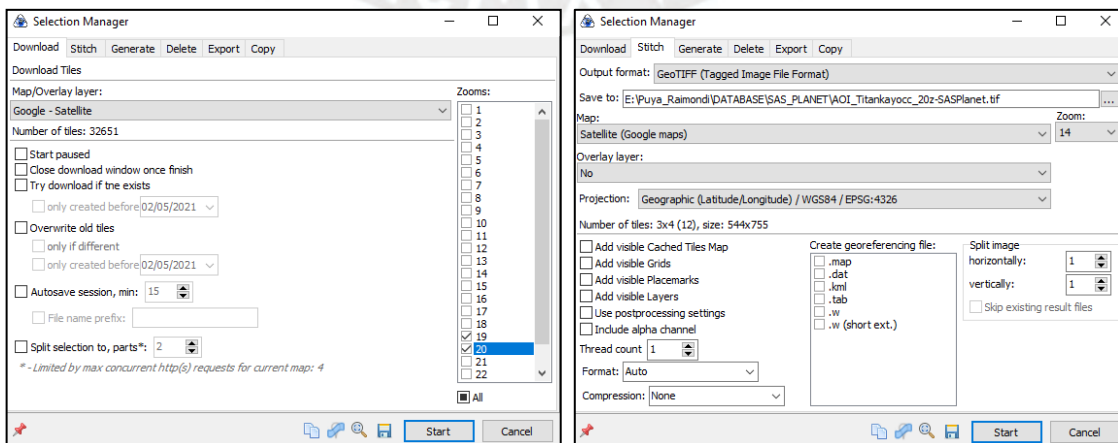
**Figura 4. 5.** Creación de polígono que contenga todo el ACR Titankayocc.



*Fuente: Elaboración propia.*

Una vez seleccionado el área de interés, se mostrará una nueva pestaña (ver figura 4.6.) donde se define el tipo de mapa, nivel de zoom y formato de salida de la imagen que deseamos. Para la presente investigación, se empleó imágenes satélites de Google Earth, nivel de zoom 20, formato GeoTIFF (Tagget Image File Format) y sistema de referencia WGS84 geográfico.

**Figura 4. 6.** Definición de parámetros para la exportación de la imagen.




*Fuente Elaboración propia.*

### 4.3.2 Delimitación de áreas de entrenamiento y validación

La definición y ubicación de las áreas de entrenamiento y validación servirán como principal fuente de trabajo para la identificación y conteo de la especie; de modo que, se define un total de 10 zonas arbitrarias de entrenamiento basado en el diseño de muestreo aleatorio estratificado en superficies considerándose la población estadística histórica (Mostacedo y Fredericksen, 2000). Asimismo, se generó otras 10 parcelas aleatorias de validación con un área de una hectárea (ha.) ubicadas dentro del ACR Titankayocc (ver mapa 4.1.).

Mapa 4. 1. Mapa de cuadrículas de entrenamiento y validación




Fuente: Elaboración propia.

### 4.3.3. Detección de objetos con Deep Learning integrado a los SIG

El programa ArcGIS Pro cuenta con módulos vinculados a herramientas de *Machine Learning* para la detección de objetos; dentro de los cuales, ofrece la clasificación usando técnicas *Deep Learning*. Este modelo se basa en múltiples capas de procesamiento no lineal para la identificación de características y el reconocimiento de patrones (ESRI, 2021). Asimismo, la herramienta *Deep Learning* de ArcGIS Pro trabaja con modelos y clasificadores de imágenes conocidos que han ido dominando los campos de la inteligencia artificial.

El método utilizado se basó en la aplicación de CNN para el reconocimiento de la *P. raimondii*. Las CNN son arquitecturas jerárquicas formadas en conjuntos de datos a gran escala que, en los últimos años, han mostrado un rendimiento notorio para identificar y clasificar objetos (Hu et al., 2015). En ese sentido, el programa ArcGIS Pro ofrece la segmentación instantánea que es una combinación de detección de objetos y segmentación semántica (Pešek, 2018); asimismo, dentro de sus variantes, ofrece el *Mask R-CNN* que es una extensión del *Faster R-CNN*. El *Mask R-CNN* es un modelo que sirve para detectar objetos en una imagen y genera una máscara de segmentación de alta calidad para cada instancia (Odemakinde, 2021). Esta máscara de segmentación comprende dos salidas para cada objeto candidato, una etiqueta de clase y un desplazamiento de cuadro delimitador; de manera que, expresa la clasificación por medio de un cuadro y uso de regresión en paralelo (He et al., 2020) (ver figura 4.7.).

**Figura 4. 7.** Marco de *Mask R-CNN* para la segmentación instantánea.




*Fuente: He et al., 2020.*

A continuación, para el presente ejercicio de clasificación de la *P. raimondii* a partir de imágenes satelitales libres de alta resolución, se dividirá el trabajo en tres etapas de la siguiente manera:

#### **4.3.3.1. Preparación de la información**

Para detectar la especie altoandina con el software ArcGIS Pro se necesitó crear muestras para el entrenamiento del modelo. Para ello, la identificación se basó en el artículo de Helder Mallqui (2017), quien emplea técnicas geomáticas aplicado a imágenes satelitales de Google Earth para el reconocimiento de rosetas de puyas en la Comunidad Campesina Cajamarquilla, Ancash; de esta manera, se realizó una clasificación considerándose los distintos tamaños de roseta e inflorescencia representativos de la misma especie a partir del uso de la imagen satelital descargada de SAS Planet (ver figura 4.8.).


**Figura 4. 8.** Fotointerpretación de la imagen satelital SAS Planet para etiquetado de la *P. raimondii*. Izquierda: Puya A; Centro: Puya B; y Derecha: Puya C.



*Fuente: Elaboración propia.*

El siguiente paso fue crear las características de la *P. raimondii* presente en la imagen satelital con el objetivo de enseñar al modelo datos como tamaño, forma y firma espectral de la planta relicta. Estas muestras se crean y administran a través de la herramienta *Etiquetar objetos para el aprendizaje profundo* (Label Objects for Deep Learning) (ver figura 4.9.), el cual permite definir la clase y el valor del objeto que se desea detectar.

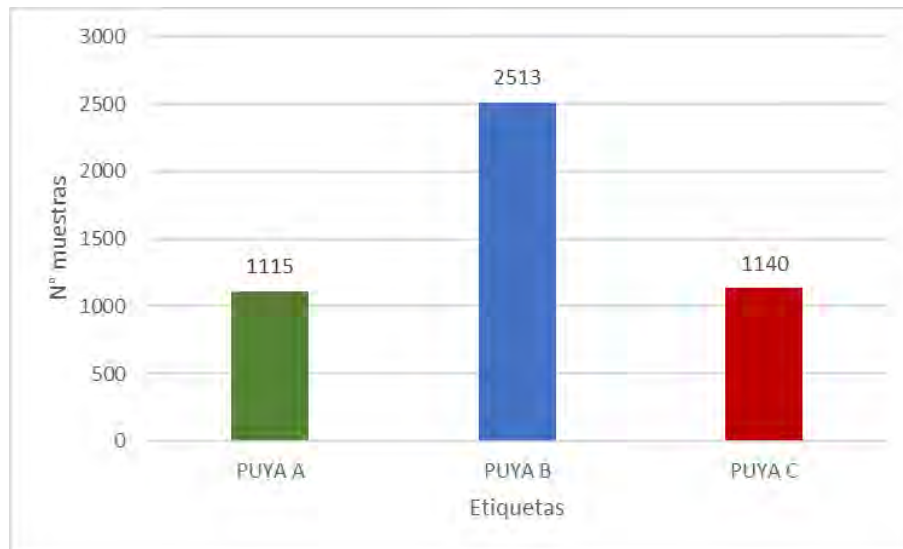
**Figura 4. 9.** Asignación de etiquetas de *P. raimondii*.



*Fuente: Elaboración propia.*

La digitalización de muestras por tipo de clases puede ser un proceso largo y tedioso, puesto que se recomienda tener una gran cantidad de ejemplos en los registros. De manera que, para mejores resultados se requerirá un mayor número de datos el cual será proporcionado al modelo durante el entrenamiento (ESRI, 2020). Es así como la clasificación de la especie altoandina se trazaron un total de 4768 individuos (ver figura 4.10.).

**Figura 4. 10.** Cantidad de muestras digitalizadas por etiqueta.



*Fuente: Elaboración propia.*

Después de crear las muestras de entrenamiento, se exportaron los datos de acuerdo con los parámetros que solicita la herramienta de clasificación. A continuación, se completa los siguientes campos:


- Carpeta de salida (Output folder), la carpeta de trabajo del proyecto con el nombre llamada "RCNN\_140x70xROT45".
- Característica de polígono de máscara (Mask Polygon Feature), se ingresó el polígono del ACR Titankayocc.
- Formato de imagen (Image Format), se eligió formato TIFF.
- Tamaño de mosaico X (Tile Size X) y Tamaño de mosaico Y (Tile Size Y), se puso 140 y 70 píxeles respectivamente.
- Ángulo de rotación (Rotation Angle) se asignó 45° grados.
- Formato de metadatos (Meta Data Format), se eligió "RCNN\_Masks".

El proceso de creación de muestras requiere mucho tiempo; asimismo, las características generadas para el modelo de *Deep Learning* se verán representadas por chips de imagen; es decir, pequeños bloques de imágenes recortadas de la imagen original que contienen la entidad o clase de interés (ESRI, 2020).

#### 4.3.3.2. Entrenamiento y definición de parámetros

ArcGIS Pro permite el uso de herramientas de geoprocamiento propias del programa, así como el acceso a la API de ArcGIS de Python, con Jupyter Notebook, para completar el análisis por medio de códigos (ESRI, 2020). En esta sección, se utilizó el panel de geoprocamiento y flujo de trabajo *Model Builder* (ver figura 4.11.) para conocer la secuencia de pasos que se llevó a cabo.

**Figura 4. 11.** Flujo de trabajo en el *Model Builder* para detectar la *P. raimondii*.



*Fuente: Elaboración propia.*

#### 4.3.3.3. Instalación de dependencias para entorno de trabajo Deep Learning

Antes de empezar a utilizar las herramientas disponibles de ArcGIS Pro, se debe instalar ciertos paquetes específicos (*fastai*, *scikitimage*, *pytorch*, *tensorflow*, *keras*, etc.) del lenguaje Python para el entrenamiento de modelos de detección de objetos con *Deep Learning*. De manera que, se dispone del uso del símbolo del sistema de Python (Python Command Prompt) para ejecutar los siguientes comandos descrito en la documentación de ayuda del programa (ESRI, 2021):

- 1) Abrir el símbolo del sistema de Python desde Windows para colocar el código que permita crear y clonar el entorno de ArcGIS Pro Python:

```
conda create --name deeplearning --clone arcgispro-py3
```

- 2) Luego de terminar de clonar, debe cambiar la dirección de la carpeta hacia al entorno creado usando el siguiente comando:

```
cd C:\Program Files\ArcGIS\Pro\bin\Python\envs\deeplearning
```

- 3) Después, ejecutar el comando para activar el nuevo entorno:

```
activate deeplearning
```

- 4) Posteriormente, se instalan los paquetes con versiones específicas según los marcos señalados para *Deep Learning*:

```
conda install -c esri -c fastai -c pytorch arcgis=1.8.1 scikitimage=0.15.0  
pillow=6.2.2 libtiff=4.0.10 fastai=1.0.60 pytorch=1.4.0 torchvision=0.5.0  
tensorflow-gpu=2.1.0  
  
conda install keras-gpu=2.3.1 --no-deps
```

- 5) Por último, cerrar el símbolo del sistema de Python usando la siguiente línea de código, el cual establece el entorno del proyecto creado:

```
activate deeplearning
```

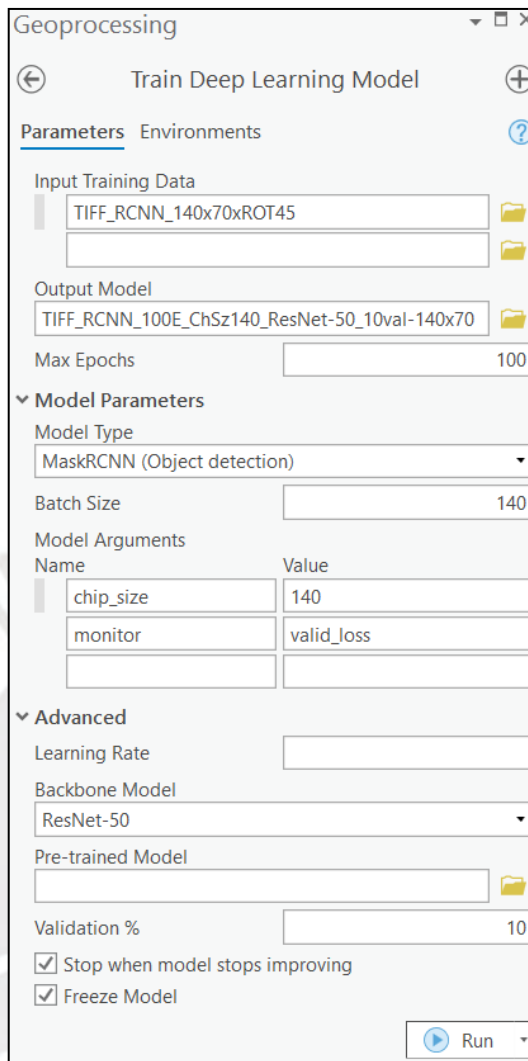
#### 4.3.3.4. Entrenamiento de modelo con herramientas de geoprocésamiento

El primer paso a realizar es el uso de la herramienta *Entrenamiento del modelo con aprendizaje profundo* (Train model with Deep Learning) ubicado en la extensión de *Análisis de Imágenes* (Image Analyst) (ver figura 4.12.). Allí se define la carpeta de salida del modelo resultante (Output Model) y la cantidad de 100 ciclos (Epochs) para que la red neuronal procesará los chips de la imagen original. Asimismo, se indica el tipo de modelo (Model Type), el cual será “MaskRCNN - Object detection”, y tamaño de tesela<sup>6</sup> (Chip Size) que tendrá un valor de 140. Estas ponderaciones partieron de los artículos de investigación revisados en el estado de arte tales como Hennig (2021), Khalid y Shahrol (2021), Paredes y Tamayo (2022), Davis et al. (2021), Hao et al. (2021), Pepe et al. (2021) y Shiu et al. (2023). Adicionalmente, en opciones avanzadas escogemos como modelo de columna vertebral (Backbone Model) como tipo de capa “ResNet-50” y otorgándole un porcentaje de validación de 10%. Cabe precisar que, se recomienda marcar las últimas dos casillas para evitar el consumo innecesario de recursos computacional y ahorro de tiempo durante el procesamiento.

---

<sup>6</sup> Número de muestras de entrenamiento que se utilizarán en cada iteración del modelo. Fuente: <https://pro.arcgis.com/en/pro-app/latest/help/analysis/image-analyst/deep-learning-in-arcgis-pro.htm>

**Figura 4. 12.** Uso de la herramienta *Train Deep Learning Model*.

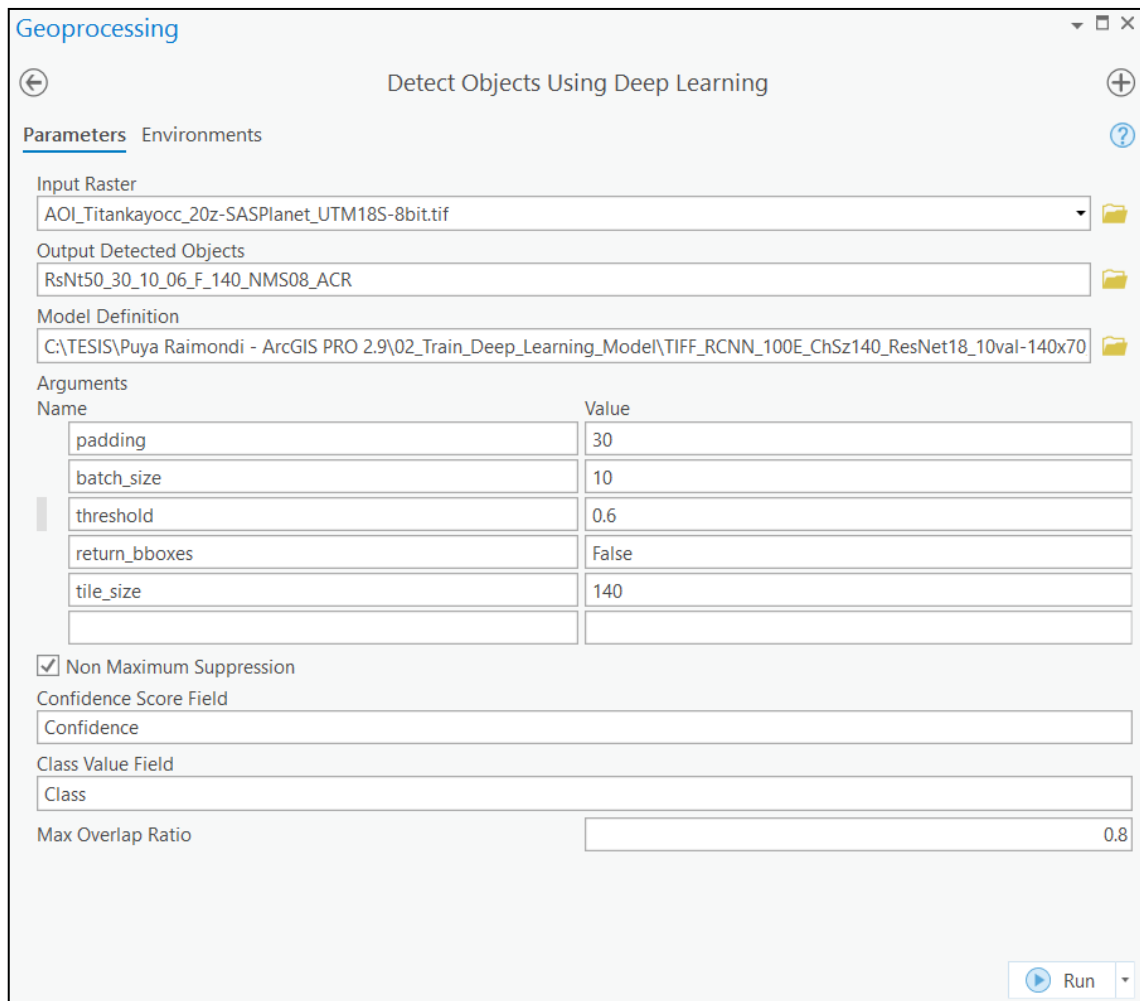


*Fuente: Elaboración propia.*

#### **4.3.3.5. Detección de la *Puya raimondii* Harms empleando modelos de Deep Learning**

Finalmente, el empleo de la herramienta *Detección de objetos mediante el aprendizaje profundo* (Detect Objects Using Deep Learning), ubicada también en la misma extensión, requiere de múltiples ensayos para lograr los resultados deseados (ver figura 4.13.), por lo cual, se recomienda modificar los parámetros del modelo con el objetivo de mejorar el reconocimiento orientado a la detección de las puyas; de manera que implica editar constantemente las variables que se encuentran en los campos de argumentos (Arguments) y la relación de superposición máxima (Max Overlap Ratio).

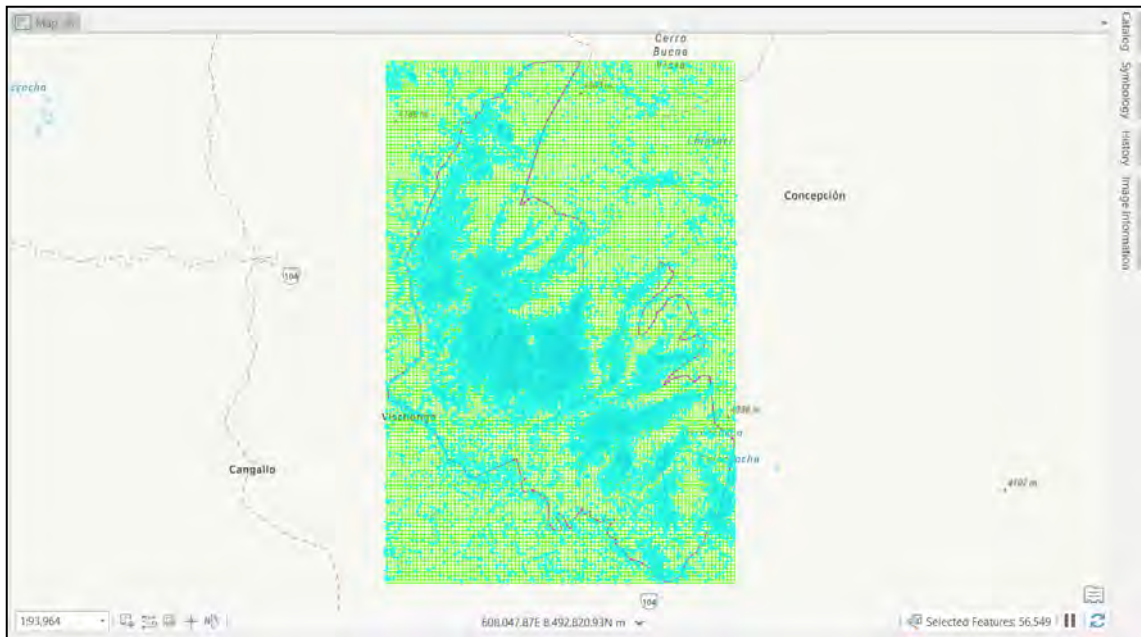
**Figura 4. 13.** Uso de la herramienta *Detect Objects Using Deep Learning*.



*Fuente: Elaboración propia.*

Una vez realizado las pruebas a pequeña escala, se definió los parámetros más idóneos para el reconocimiento de la especie altoandina en toda la imagen descargada de SAS Planet, obteniéndose así el siguiente resultado preliminar de detección individual de puyas (ver figura 4.14.).

**Figura 4. 14.** Detección de puyas utilizando algoritmos de *Deep Learning*.  
Sombreado de color celeste de todas las puyas identificadas.



*Fuente: Elaboración propia.*

#### **4.3.3.6. Post procesamiento de los resultados**

Con el fin de reducir la cantidad de falsos positivos en el modelo de detección de puyas generado para el ACR Titankayocc, se consideró eliminar aquellos puntos predichos ubicados en zonas fluviales; ello debido al efecto de luminiscencia o refracción solar la cual genera formas y valores de píxeles similares a la planta relictas. De tal modo que, se dispuso de datos geoespaciales de la Autoridad Nacional del Agua (ANA) para delimitar los cuerpos de aguas y ríos presentes en el área de conservación. Asimismo, el uso de técnicas de fotointerpretación sirvió para contrastar con otros lugares donde podrían existir predicciones incorrectas (ej: cotas, áreas urbanas, floraciones rocosas, etc.) (ver figura 4.15.).

Este proceso, puede tardar varias horas y dependerá del nivel de conocimiento previo de la zona de interés además del nivel de calidad requerido por parte del usuario.

**Figura 4. 15.** Ejemplo de falsos positivos en la detección de *P. raimondii*.



*Fuente: Elaboración propia.*

#### 4.3.3.7. Evaluación del modelo de detección de objetos con Deep Learning

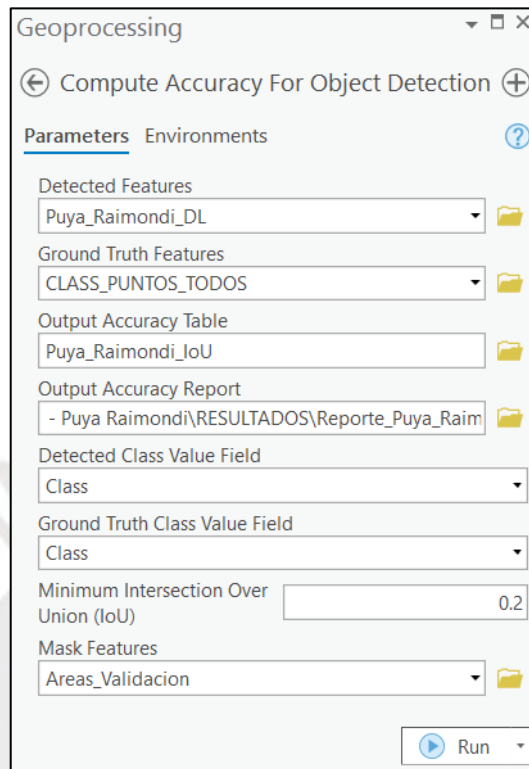
El uso de técnicas de *Deep Learning* con ArcGIS Pro permitió identificar un total de 58 607 puyas con geometría semicircular utilizando imágenes satelitales de Google Earth. Asimismo, este número de individuos fue contrastado con las áreas de validación designadas y polígonos de puyas fotointerpretados previamente creados, reflejándose así el porcentaje de precisión de 75.06% según la relación IoU (Intersection over Union).

La IoU o Intersección sobre Unión es una métrica que evalúa el porcentaje de acierto de un detector de objetos y mide el rendimiento de una red neuronal. Este umbral tiene como fórmula el área de intersección dividida por el área de unión entre las máscaras predichas y digitalizadas manualmente, tal como se describe en la Ecuación (1) (Maxwell et al., 2020).

$$IoU (1) = \frac{\text{Área de Intersección}}{\text{Área de Unión}}$$

Para el cálculo IoU se utilizó la herramienta *Precisión Informática para la Detección de Objetos* (Compute Accuracy For Object Detection) (ver figura 4.16.), el cual calcula la precisión del modelo *Deep Learning* a través de la comparación de los objetos detectados por la herramienta *Detección de Objetos mediante el aprendizaje profundo* y los datos reales del terreno (ESRI, s.f.-b).

**Figura 4. 16.** Uso de la herramienta *Compute Accuracy For Object Detection*. Se establece como rango de intersección 0.2.



*Fuente: Elaboración propia.*

Esta herramienta además calcula otras métricas derivadas de la IoU que evalúan la clasificación del modelo *Deep Learning*: precisión (Ecuación (2)), recuperación (Ecuación (3)), puntuación F1 (Ecuación (4)) y precisión promedio (promedio de todos los valores de recuperación entre 0 y 1). Los resultados de estas variables se muestran en la tabla 4.1.

$$\text{Precisión (2)} = \frac{VP}{VP + FP}$$

$$\text{Recuperación (3)} = \frac{VP}{VP + FN}$$

$$\text{Puntuación F1 (4)} = 2 * \frac{\text{Recuperación} * \text{Precisión}}{\text{Recuperación} + \text{Precisión}}$$

VP, FP y FN son verdadero positivo, falso positivo y falso negativo.

**Tabla 4. 1.** Informe de evaluación de precisión. Precisión = 75.06%; Precisión Promedio (AP) = 37.08%; Puntuación F1 = 57.83%; Recuperación = 47.03%

IoU >= 0.2000	Precision	Recall	F1 Score	AP	True Positive	False Positive	False Negative
All Classes	0.7506	0.4703	0.5783	0.3708	340.0000	113.0000	384.0000
Puya_C	0.8354	0.1768	0.2918	0.1511	66.0000	13.0000	312.0000
Puya_A	0.9322	0.8800	0.9053	0.8339	110.0000	8.0000	15.0000
Puya_B	0.6406	0.7523	0.6920	0.5477	164.0000	92.0000	54.0000

*Fuente: Elaboración propia.*

#### 4.3.4. Técnicas de análisis espacial aplicado a las condiciones ambiental de la *Puya raimondii* Harms

Se planteó durante el desarrollo de la metodología usar imágenes satelitales multiespectrales de alta resolución para el análisis de la planta.

##### 4.3.3.1. Descarga y manejo de datos CBERS-4A

El programa CBERS (China-Brazil Earth Resources Satellite) nace en asociación única entre Brasil y China en el sector técnico-científico espacial para la tecnología primaria de generación de datos de teledetección, este acuerdo involucra a entidades como es el INPE (Instituto Nacional de Pesquisas Espaciais) y la CAST (China Academy of Space Technology) (Julio Filho et al., 2019). Este programa en principio contemplaba dos satélites, CBERS-1 y 2. Sin embargo, ambos gobiernos decidieron ampliar e incluir tres satélites más de la misma categoría, los satélites CBERS-2B, 3 y 4 (ver tabla 4.2.).

Debido al éxito del lanzamiento del CBERS-4, Brasil y China decidieron firmar un nuevo protocolo complementario para la fabricación de un nuevo satélite del programa CBERS: CBERS-4A, lanzado el 20 de diciembre del 2019 en la provincia de Shanxi, China (Flores 2020). Este último tiene por objetivo reemplazar al CBERS-4, que se lanzó en el 2014, para continuar con la misión del satélite el cual es proporcionar imágenes de teledetección para observar y monitorear la vegetación, los recursos hídricos, la agricultura, crecimiento urbano, el uso del suelo y la educación.

**Tabla 4. 2.** Diferencias entre los satélites de 1ra y 2da generación del programa CBERS.

Elemento / Parámetro	1ra Generación		2da Generación
	CBERS-1,-2 y -2B	CBERS-3 y -4	CBERS-4A
Satélite	CBERS-1,-2 y -2B	CBERS-3 y -4	CBERS-4A
Peso total (kg)	1450	2080	1980
Año de lanzamiento	1999, 2003 y 2007	2013 y 2015	2019
Vida de servicio (años)	2	3	5
Velocidad de datos (Mbit/s)	100	300	900

*Fuente: Elaboración propia adaptado del INPE, 2018.*

El satélite CBERS-4A está equipado con tres cámaras para observaciones ópticas de todo el mundo, además de un sistema de recolección de datos y monitoreo ambiental (INPE, 2019) (ver tabla 4.3.).

Las cargas útiles del CBERS-4A son todos los instrumentos directamente relacionados con la adquisición de datos científicos o monitoreo ambiental. A continuación, se indica los tipos de cámaras, equipos de grabación y transmisión de datos (INPE, 2019):

- Cámara Pancromática y Multiespectral de Escaneo Amplio (WPM);
- Cámara multiespectral (MUX);
- Cámara de imágenes de Campo Largo (WFI);
- Transmisor de datos de imagen (DTS) para cámaras MUX, WFI y WPM;
- Grabador de datos digitales (DDR);
- Sistema de recopilación de datos (DCS);
- Monitor de entorno espacial (SEM).

**Tabla 4. 3.** Características de las cámaras CBERS-4A.

Característica / Escáneres multiespectrales	Cámara WPM	Cámara MUX	Cámara WFI
Resolución espectral	0.45-0.52 $\mu\text{m}$ (B) 0.52-0.59 $\mu\text{m}$ (G) 0.63-0.69 $\mu\text{m}$ (R) 0.77-0.89 $\mu\text{m}$ (NIR) 0.45-0.90 $\mu\text{m}$ (PAN)	0.45-0.52 $\mu\text{m}$ (B) 0.52-0.59 $\mu\text{m}$ (G) 0.63-0.69 $\mu\text{m}$ (R) 0.77-0.89 $\mu\text{m}$ (NIR)	0.45-0.52 $\mu\text{m}$ (B) 0.52-0.59 $\mu\text{m}$ (G) 0.63-0.69 $\mu\text{m}$ (R) 0.77-0.89 $\mu\text{m}$ (NIR)
Resolución radiométrica	10 bits	8 bits	10 bits
Resolución espacial	2 metros (pancromático) 8 metros (multiespectral)	16.5 metros	55 metros
Resolución temporal	31 días	31 días	5 días
Medida de una escena	92 kilómetros	95 kilómetros	684 kilómetros

*Fuente: Elaboración propia adaptado del INPE, 2018.*

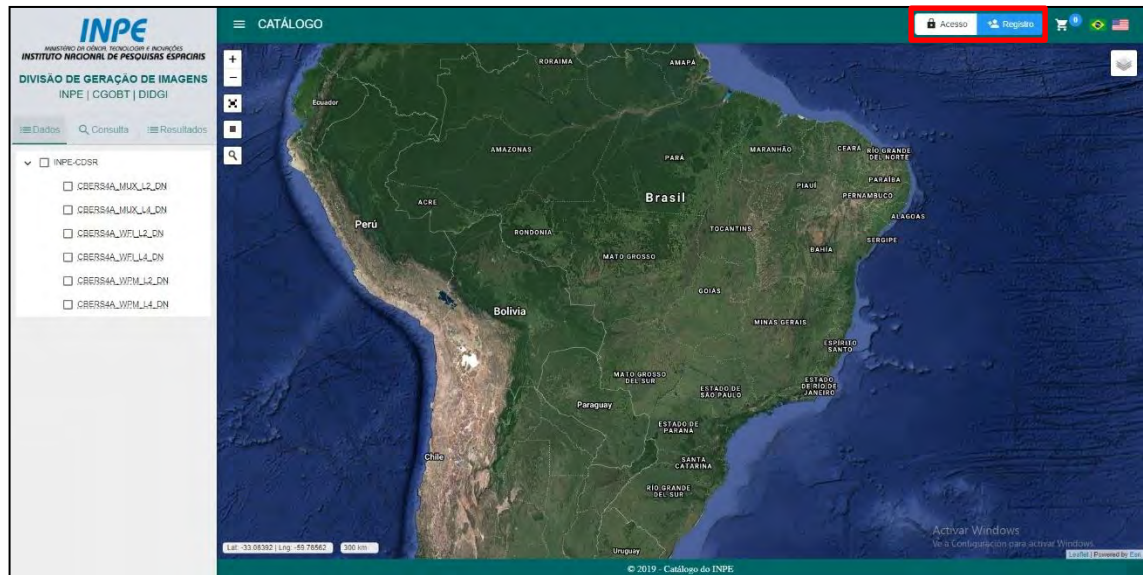
Para la presente investigación, se usó la cámara WPM y nivel de procesamiento de descarga L4 el cual representa ser la imagen ortorrectificada; es decir, una imagen con corrección radiométrica y una corrección geométrica de un sistema refinado mediante el uso de puntos de control y un modelo de elevación digital (Qualitydata.com). De esta manera, se descargó imágenes del satélite chino-brasileño llamado CBERS el cual admite el libre acceso y posee resoluciones espaciales de hasta 2 metros.

A continuación, se desarrollará una breve guía de pasos para el acceso de imágenes CBERS-4A a través de la página oficial del INPE.

a) Registro de cuenta

La descarga de imágenes satelitales es gratuita a través del acceso a la página web de la División de Generación de Imágenes del INPE<sup>7</sup>. Allí deberá ingresar su usuario o registrar una nueva cuenta en el sistema (ver figura 4.17.).

**Figura 4. 17.** Catálogo de imágenes INPE.



*Fuente: Elaboración propia.*

#### b) Criterios de búsqueda y definición de parámetros

La búsqueda de imágenes satelital se definió a partir del área de interés que cubra toda la superficie del ACR Titankayocc. Asimismo, completar las especificaciones de descarga como tipo de satélite, intervalo de tiempo, porcentaje de cobertura máxima de nubosidad y número de imágenes a mostrar (ver figura 4.18.).

<sup>7</sup> <http://www2.dgi.inpe.br/catalogo/explore> (Acceso en agosto del 2021)

**Figura 4. 18.** Configuración de búsqueda. Izquierda: Selección de satélite, sensor y nivel de procesamiento; Derecha: definición de parámetros y criterios.

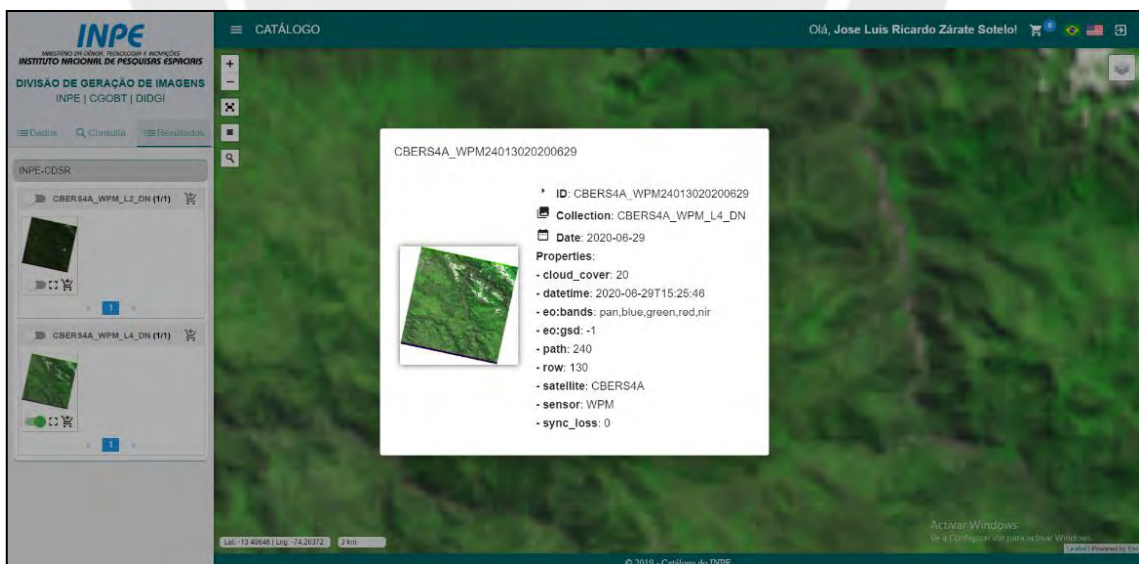


*Fuente: Elaboración propia.*

c) Selección de las imágenes y descarga

Se escoge la imagen con menor nubosidad presente en el área de estudio. Para visualizar las imágenes, deslizando la barra azul debajo de cada imagen satelital, se habilitará la superposición y el ámbito que esta cubre. Asimismo, dando clic a la escena obtendremos información de sus metadatos (ver figura 4.19).

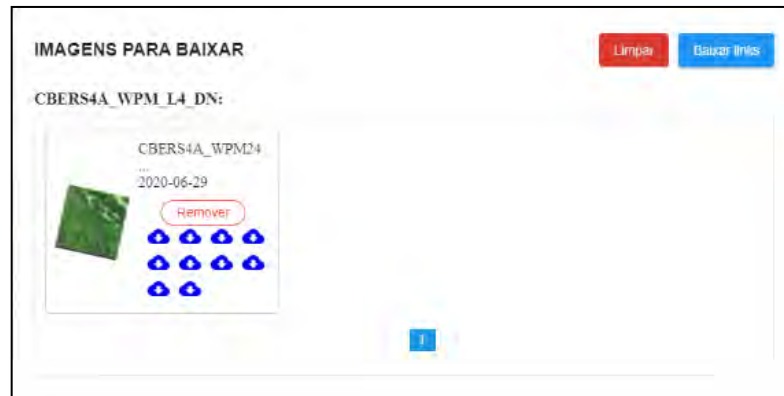
**Figura 4. 19.** Previsualización de la imagen y verificación de los metadatos.



*Fuente: Elaboración propia.*

Una vez definida la imagen satelital, esta deberá ser agregada en el “carro de compras” que ofrece la plataforma. Allí se descarga las bandas espectrales disponibles en formato ".tif", dando clic al ícono de nube azul (ver figura 4.20.).

**Figura 4. 20.** Indicación de elementos de descarga.



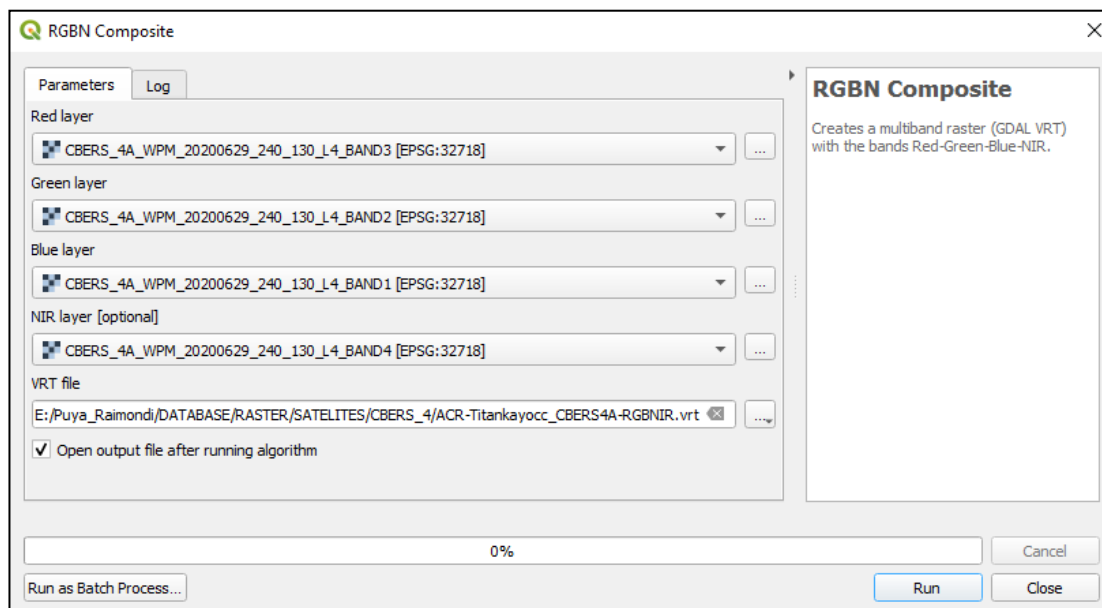
*Fuente: Elaboración propia.*

Otra alternativa de descarga imágenes satelitales CBERS-4A es a través del software QGIS. Esta opción, requiere instalar un plugin llamado *CBERS4A Downloader*. Para usarlo, bastará con activar e ingresar la credencial del usuario de la plataforma Catálogo de Imágenes del INPE.

d) Procesamiento básico de imágenes satelitales descargadas

Guardadas las imágenes en el ordenador, se procede a cargar dichas bandas espectrales para realizar la composición del rojo, verde, azul e infrarrojo en el programa QGIS; de manera que, se utiliza las herramientas predefinidas del plugin instalado (ver figura 4.21.).

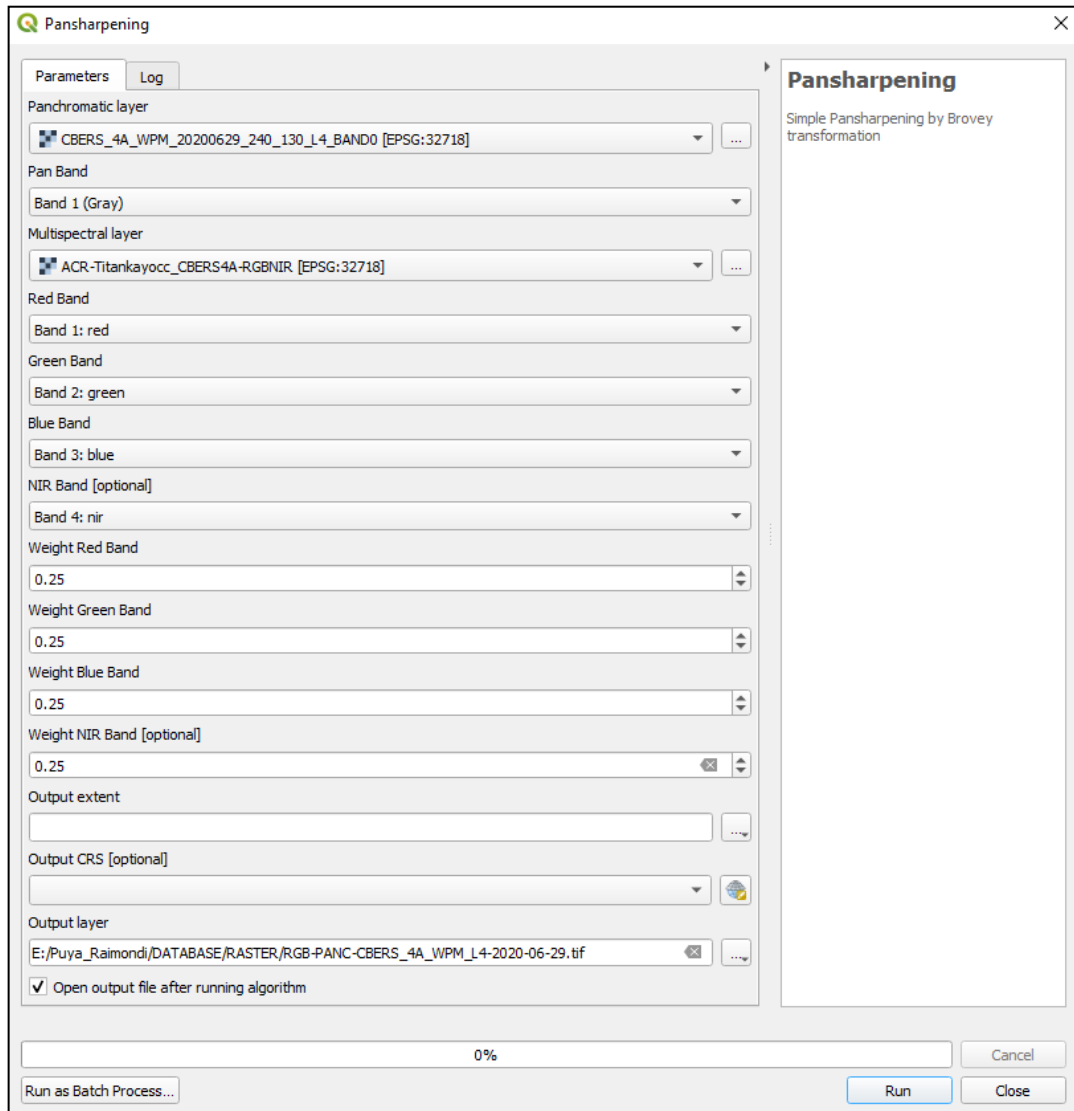
**Figura 4. 21.** Uso de la herramienta *RGBN Composite*. Ingreso de bandas multiespectrales: rojo, verde, azul e infrarrojo cercano.



*Fuente: Elaboración propia.*

Posteriormente, se emplea la herramienta de *refinado pancromático* (Pansharpening) (ver figura 4.22.) para fusionar la banda pancromática con el ráster multibanda de menor resolución. Dando como resultado una resolución espacial de 2.5 metros.

**Figura 4. 22.** Uso de la herramienta *Pansharpening*. Ingreso de la banda pancromática.



*Fuente: Elaboración propia.*

#### 4.3.3.2. Georreferenciación y NDVI

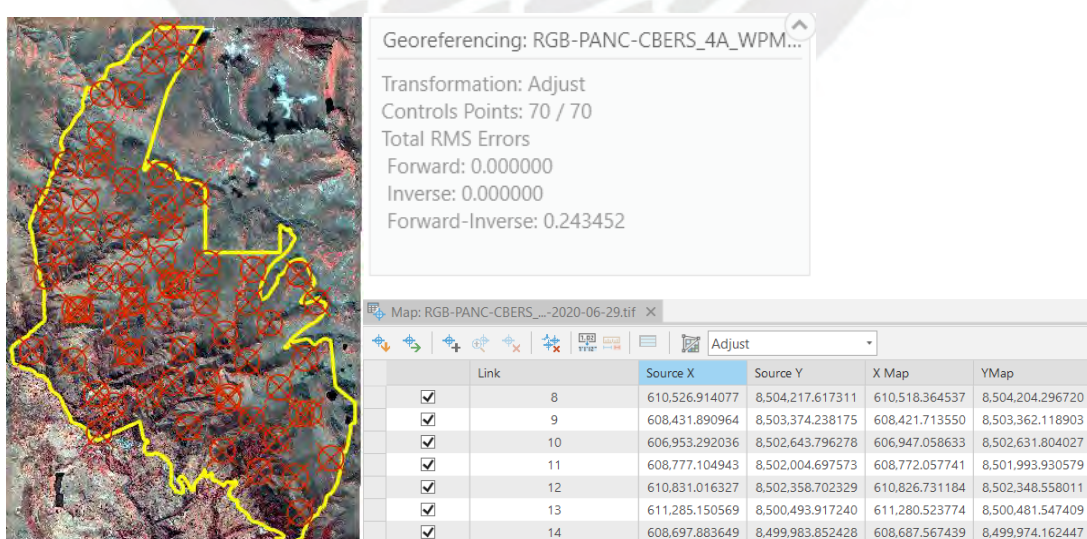
Esta fase consta de dos etapas. La primera da énfasis a reducir las distorsiones geométricas de la imagen satelital, teniendo como alternativa el uso de la herramienta de georreferenciación hacia el mosaico CBERS-4A en ArcGIS Pro. Por otro lado, el Índice de Vegetación de Diferencia Normalizada (NDVI, por las siglas en inglés) es un índice que ayuda a diferenciar la vegetación de otros tipos de cobertura presentes en la superficie del suelo, además permite definir y visualizar las áreas de cada tipo de vegetación, como es el caso de la *P. raimondii*.

#### 4.3.3.2.1. Georreferenciación de imágenes satelitales CBERS-4A

La georreferenciación es el proceso de asignar coordenadas geográficas a los datos de una imagen; es decir, convierte en un formato estándar de datos espaciales, ya que se caracterizan por hacer referencia a un Sistema de Referencia de Coordenadas (SRC) definido por parámetros como proyección y punto de origen (datum) (Herbei et al., 2010). Dicho esto, la georreferenciación permite mejorar la precisión de varias escenas satelitales (metros/píxeles) en ambos ejes.

El método de georreferenciación que se llevó a cabo fue el uso de la herramienta *Georeference* de ArcGIS Pro, el cual consiste en colocar marcadores que sean similares para ambas imágenes satelitales a comparar. De esta manera, se generó 70 puntos de control para la escena satelital CBERS-4A con el objetivo de conseguir un error cuadrático medio (Root Mean Square - RMS) menor a 1 (ver figura 4.23.). Cabe precisar, que la ubicación de los puntos tuvo como prioridad cubrir la mayor área del ACR Titankayocc, ya que se busca minimizar las diferencias de posiciones relativas y permitiéndose así la comparación de píxel a píxel (Flores, 2020).

**Figura 4. 23.** Uso de la herramienta *Georeference*. Cantidad total de puntos de control = 70 y RMS = 0.243.



Fuente: Elaboración propia.

#### 4.3.3.2.2. Cálculo de NDVI con imágenes satelitales CBERS-4A

Una vez corregido el producto satelital con menor RMS de error, se procede con la segunda etapa que alude conceptos de teledetección. Para ello, se continua con el uso del software ArcGIS Pro donde se emplea la herramienta *Calculadora raster* (Raster Calculator) para obtener índices vinculados a la vigorosidad y salud de la flora presente en la imagen satelital CBERS-4A.

Los índices de vegetación son medidas cuantitativas que divide en píxeles entre el nivel digital almacenado en dos o más bandas de la misma imagen. Asimismo, se emplea para mejorar la discriminación entre vegetación y no vegetación (suelo, agua, viviendas, vías, etc.); por último, sirve para reducir el efecto del relieve (pendiente y orientación) en la caracterización espectral (Chuvienco, 1995).

El NDVI (Normalized Difference Vegetation Index) (Rouse et al., 1974) es un índice que permite evaluar el estado de salud y desarrollo fenológico de la vegetación, ello a partir de la medición de la radiación que las plantas emiten o reflejan. De modo que, altos valores de índices de vegetación identifican píxeles de vegetación saludable que sirve de ayuda en el monitoreo de la cobertura vegetación (Flores, 2020). El cálculo del NDVI consiste en el uso matemático de dos bandas, el Infrarrojo Cercano (NIR) y el rojo (RED):

$$\text{NDVI} = (\text{float (NIR)} - \text{float (RED)}) / (\text{float (NIR)} + \text{float (RED)})$$

Cabe señalar que el “float”<sup>8</sup> convierte los valores de los píxeles de números enteros a decimales entre un rango de -1,0 a 1,0.

---

<sup>8</sup> Valores numéricos con valores fraccionales dentro de un rango específico. Fuente: <https://desktop.arcgis.com/es/arcmap/10.3/manage-data/geodatabases/arcgis-field-data-types.htm>

#### 4.3.3.3. Cálculo de TRI a partir de Modelos Digitales de Elevación provenientes del satélite SRTM

El segundo índice calculado fue el TRI (Terrain Ruggedness Index) (Riley et al., 1999), el cual se expresa como  $Y(\sum(X_a - X_{00})^2)^{1/2}$ , donde Y es la columna en la cuadrícula del modelo a la celda,  $X_a$  es la elevación de una de las ocho celdas vecinas y  $X_{00}$  es la elevación de una celda central (0,0). Este índice sirve para cuantificar la heterogeneidad topográfica de un terreno; de manera que, mide la variabilidad de la superficie terrestre a través de la diferencia de elevación entre celdas adyacentes del mismo Modelo Digital del Elevación (MDE).

Este índice pretende ser un indicador de la morfología del terreno a pequeña escala, sin necesidad de estar relacionado necesariamente con la altitud; por lo que, ayuda a diferenciar las zonas altas en planicies de las zonas de baja altitud en un rango de valor de cero a más dependiendo de la resolución del MDE de entrada (Goerlich y Cantarino, 2010). Su importancia en la presente investigación es para conocer las características o patrones a encontrar en la dispersión de los organismos, caso *P. raimondii*, presentes en el ACR Titankayoc.

El TRI o Índice de Rugosidad del Terreno parte de un MDE remuestreado y corregido radiométricamente del satélite Advanced Land Observation Satellite (ALOS), también llamado en japonés como “Daichi”, con sensor Phased Array type L-band Synthetic Aperture Radar (PALSAR) de la agencia espacial Japan Aerospace Exploration Agency (JAXA). Este modelo se encuentra disponible en el sitio web *Alaska Satellite Facility (ASF)*<sup>9</sup>. La descarga del MDE ALOS PALSAR requiere del trazo del área de interés, así como el uso de la herramienta de “Filtros de búsqueda” (ver figura 4.24.) para definir el rango de la toma de los datos se seleccionó los dos últimos años (2010 y 2011), la definición del nivel de procesamiento “Terreno de alta resolución corregido” y modo de haz “FUP”.

---

<sup>9</sup> <https://search.asf.alaska.edu> (Acceso en agosto del 2021)

**Figura 4. 24.** Relleno de filtros de búsqueda.

The image shows a search filter window titled "Filtros de búsqueda". It is divided into several sections:

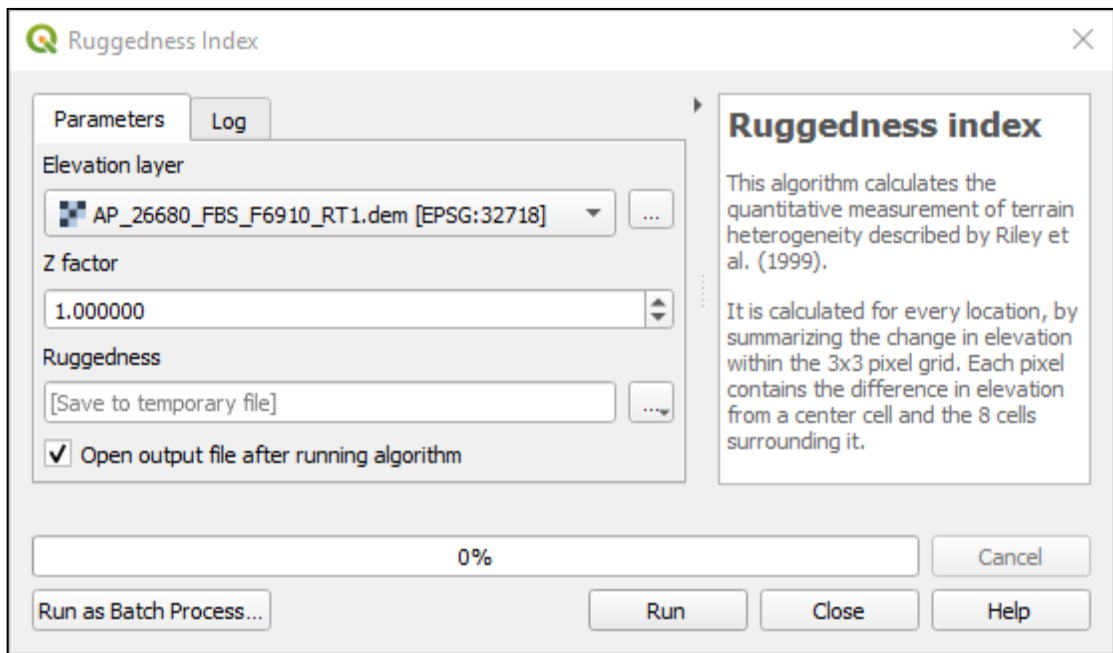
- Filtros de fecha:** Contains "Fecha de inicio" (1/1/2010) and "Fecha final" (4/21/2011), both with calendar icons. A red box highlights this entire section.
- Búsqueda estacional:** A section with a small icon and the text "Búsqueda estacional".
- Filtros adicionales:** Contains four dropdown menus: "Tipo de archivo" (highlighted with a red box, showing "Terreno de alta resol..."), "Modo haz" (highlighted with a red box, showing "FUP"), "Polarización", and "Dirección". Below these are counts: "1/7 tipos de archivos seleccionados", "1/6 modos de haz seleccionados", "0/9 polarizaciones seleccionadas", and "0/2 direcciones de vuelo seleccionadas". A "Subtipo" section below indicates "No hay subtipos para seleccionar".
- Filtros de ruta y marco:** Contains buttons for "Inicio de ruta", "Final del camino", "Inicio de cuadro", "Extremo del m...", "Claro", and "Limpiar el área de búsqueda".
- Footer:** Shows "250 de 11 archivos" and a "BUSCAR" button.

*Fuente: Elaboración propia.*

Como resultado, el archivo a descargar se encontrará en formato GeoTIFF con una resolución espacial de 12.5 m parte del producto interpolado de la resolución original de 30 metros del sensor SRTM (Shuttle Radar Topography Mission) (Laurencelle et al., 2015). Cabe precisar que, para la presente investigación, se necesitó de una sola escena con fecha 27 de octubre del 2010 (AP\_25338\_FBD\_F6910\_RT1) que cubriera todo el ACR Titankayocc.

Finalmente, con el apoyo del programa QGIS se usó la herramienta *Índice de Rugosidad* (Ruggedness Index) (ver figura 4.25.), ubicado en la carpeta de análisis del terreno. Cabe mencionar que el programa ArcGIS Pro, también cuenta con este índice para obtener las unidades de medidas que describan las características morfológicas del territorio.

**Figura 4. 25.** Uso de la herramienta *Ruggedness Index*.



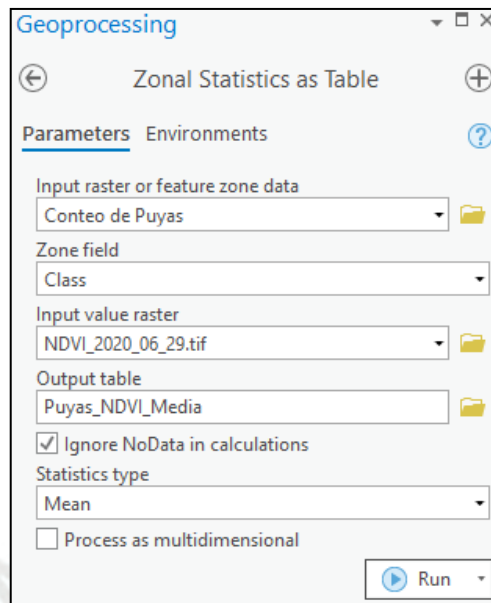
*Fuente: Elaboración propia.*

#### **4.3.5. Geoestadística y tabulación de información a nivel planta**

La geoestadística comprende un conjunto de datos relacionado a los fenómenos espaciales presentes en la superficie terrestre. Esta rama que deriva de la estadística sirve para generar estimaciones y predicciones a partir de muestras, las cuales representan ser variables distribuidas espacialmente. Es por esta razón que para la presente investigación se realizó cruces de información con el objetivo de encontrar relaciones de las variables físicas y biológicas relacionadas al estado de la *P. raimondii*.

El primer paso que se generó fue el cálculo promedio de NDVI y TRI presente de la especie altoandina. De modo que, se utilizó la herramienta de *Estadística zonal como tabla* (Zonal Statistics as Table) de ArcGIS Pro para hallar la media de la firma espectral de cada planta (ver figura 4.26.).

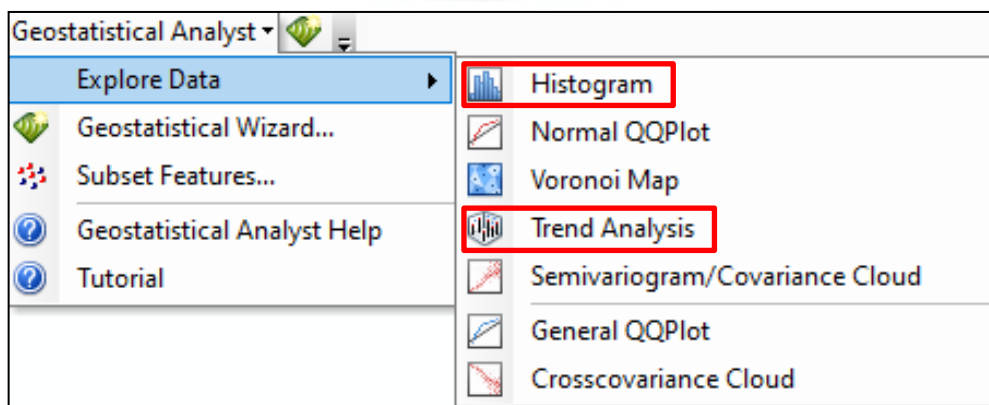
**Figura 4. 26.** Uso de la herramienta *Zonal Statistics as Table*.



*Fuente: Elaboración propia.*

Posteriormente, se desarrolla un análisis exploratorio de los datos para conocer la naturaleza de ambas variables. De manera que, se aplicó la herramienta *Análisis de tendencias* (Trend Analysis) del programa ArcGIS Desktop para obtener una perspectiva tridimensional de los datos del TRI. Asimismo, para el caso del NDVI se utilizó el gráfico de *Histograma* (Histogram) el cual permite la descripción univariante (una variable) de los valores registrados de cada *P. raimondii*; de tal modo que se reclasificó el resultado, siendo el rango entre 0.2 a 1, la clase que representa a la vegetación viva. (ver figura 4.27.).

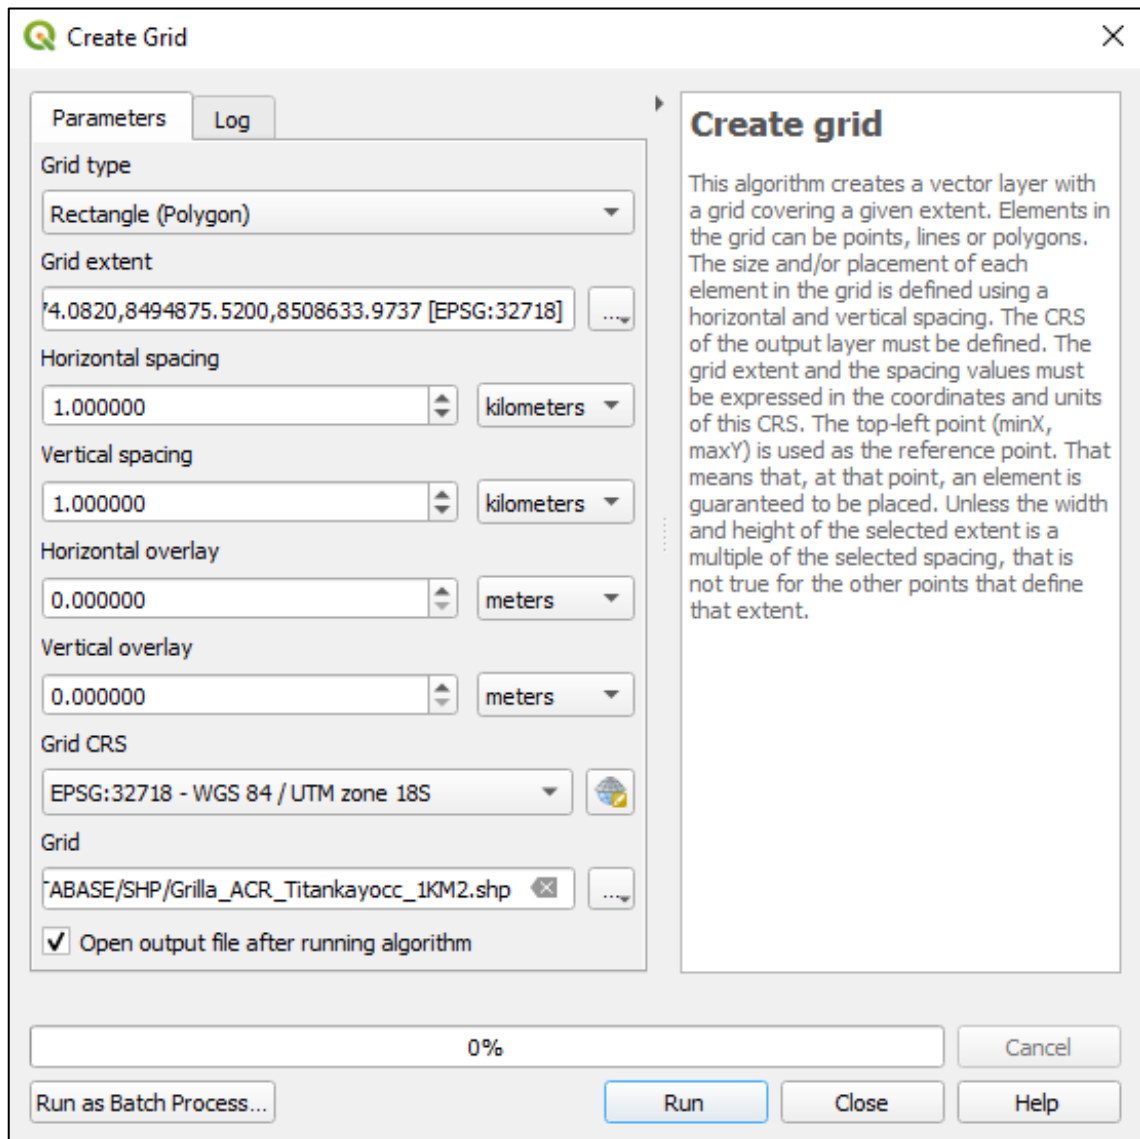
**Figura 4. 27.** Uso de la herramienta *Geostatistical Analyst*.



*Fuente: Elaboración propia.*

Finalmente, se generó una malla de muestreo (ver figura 4.28.) que cubra todo el ACR Titankayocc con el fin de proporcionar una biomasa específica y cantidad de puyas vivas presentes en cada cuadrícula. Sin embargo, una vez que se obtuvo las grillas, en los límites del ACR Titankayocc se tuvo que editar para que las cuadrículas sean lo más homogéneo para el análisis de las puyas.

**Figura 4. 28.** Uso de la herramienta *Create Grid*. Dimensión de 1 km por lado.



*Fuente: Elaboración propia.*

## CAPÍTULO 5

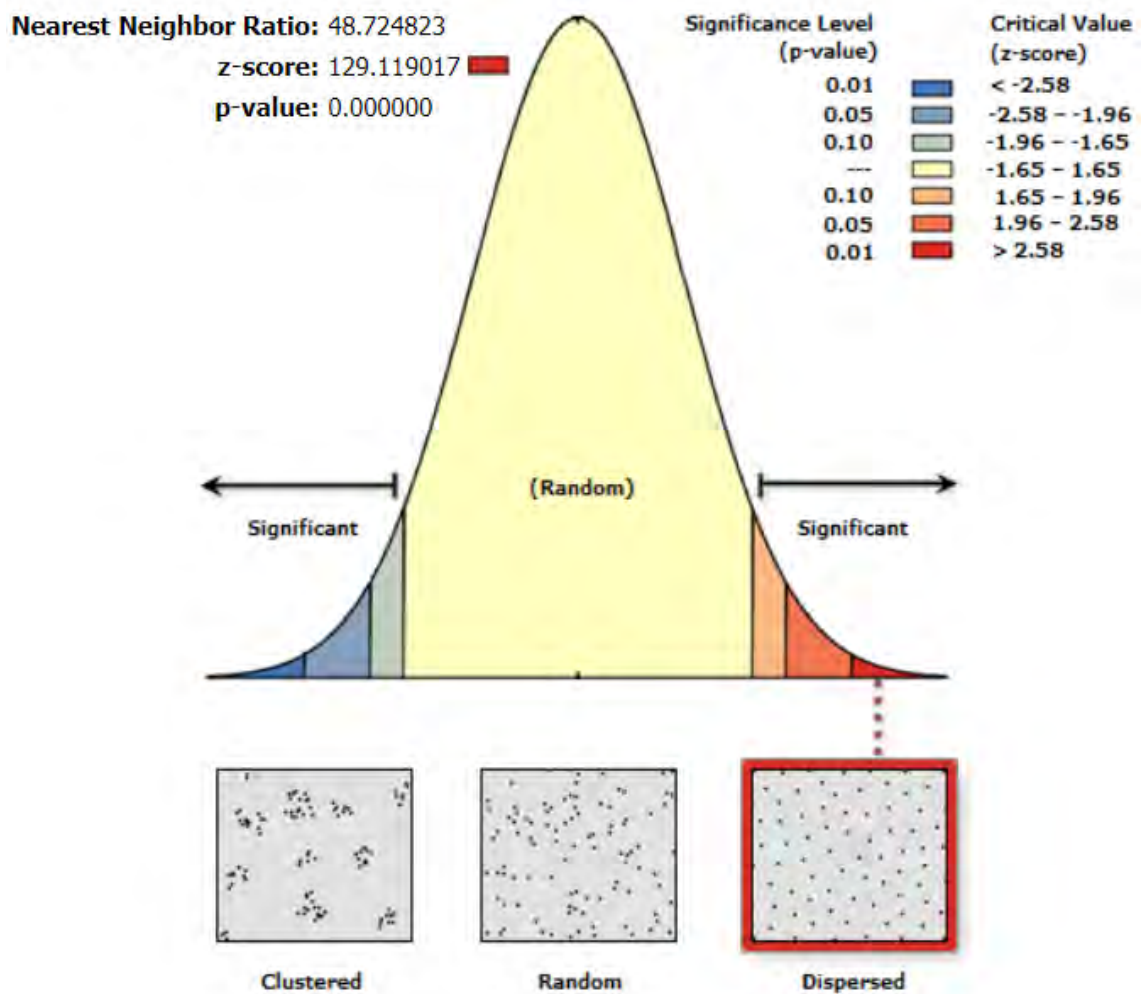
### RESULTADOS

Los resultados y productos finales de la presente investigación están enmarcados dentro de los objetivos trazados; de manera que, se presenta el desempeño del algoritmo *Deep Learning*, el mapeo de la de *P. raimondii* en el ACR Titankayocc, el análisis de las variaciones físicas y biológicas y la generación de tablas y gráficos geoestadísticos para la caracterización.

#### 5.1. Distribución espacial de la *Puya raimondii* Harms

En cuanto a su distribución geográfica, la *P. raimondii* se caracteriza por albergar el mayor número de individuos en los ejes del centro, norte y oeste del área de conservación; de igual modo, se evidencia tener una distribución muy dispersa con disminución poblacional en las periferias y, por tanto, resulta ser variado y heterogéneo en el territorio. Esto último, fue contrastado a través de la herramienta *Índice del vecino más cercano promedio* (Average Nearest Neighbor) (ver figura 5.1.), el cual se expresa como la relación entre la distancia media observada y la distancia media esperada; de manera que, si el índice es menor a 1, el patrón exhibe como agrupado, pero si el índice es mayor a 1, significa que la tendencia es la dispersión (ESRI, s.f.-a).

Figura 5. 1. Gráfico de análisis de patrones de puntos promedio usando la herramienta *Average Nearest Neighbor*<sup>10</sup>.

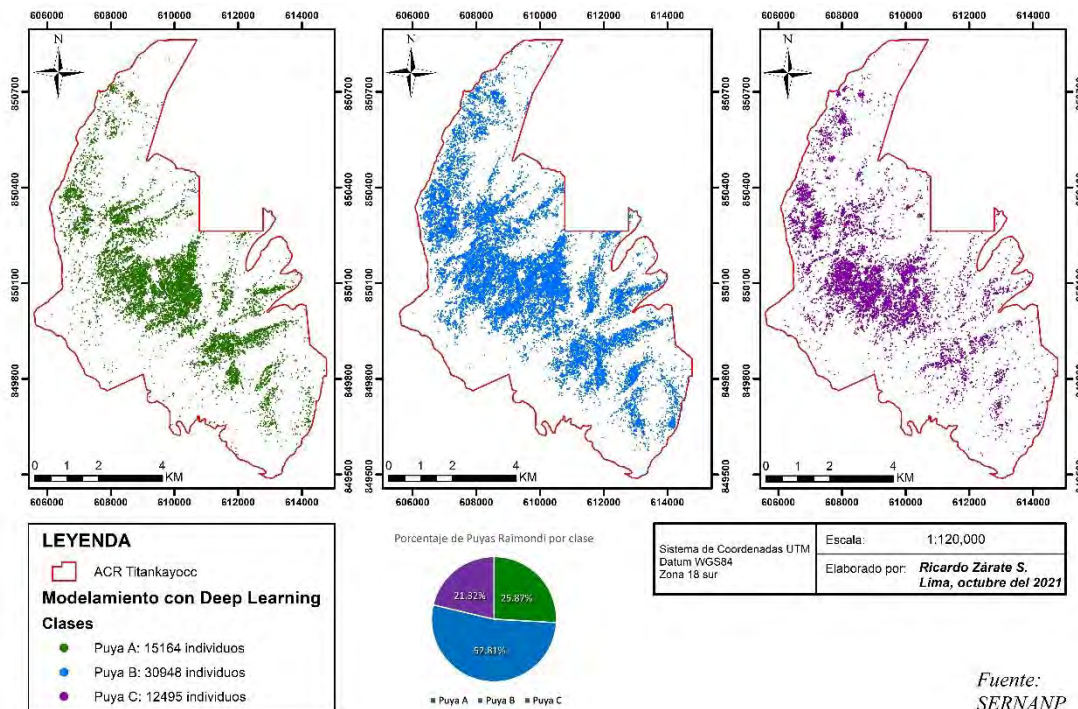


Fuente: Elaboración propia.

Finalmente, el mapa distribución geográfica y poblacional de la *P. raimondii* (ver mapa 5.1.) muestra las formas de dispersión de los tres tipos de puyas clasificados con *Deep Learning* obteniéndose un promedio de precisión de 75.09%, 58.93% y 31.78% para las clases Puya A, Puya B y Puya C respectivamente (ver Anexo 3). Como resultado, se obtuvo además que la clase B registra el mayor número de individuos con un total de 30,946 puyas contadas.

<sup>10</sup> Los resultados de la puntuación z y el valor p son medidas de significancia estadística que indican si se debe rechazar o no la hipótesis nula.

**Mapa 5. 1.** Mapa de distribución geográfica y poblacional de la *P. raimondii* por clases en el ACR Titankayocc<sup>11</sup>



Fuente:  
SERNANP

Fuente: Elaboración propia.

## 5.2. Caracterización ambiental de la *Puya raimondii* Harms

El estudio de las variables físicas y biológicas de un espacio geográfico ayuda a explicar las causas de la distribución de una especie (Nicholson, 2018). Por ello, se considera la extracción de valores NDVI y TRI para determinar el estado actual de la *P. raimondii* y las condiciones ambientales que forman parte de su hábitat.

De acuerdo con lo obtenido por la estadística zonal del NDVI, se infiere que el número total de puyas vivas fue de 39,204 individuos que equivale el 66.89% de la población detectada. En la tabla 5.1. se muestra un recuento de la cantidad de puyas vivas y muertas por clase, obteniéndose como mayor registro la "Puya B". Por su parte, las clases A y C tuvieron la menor cantidad de entidades para los campos de Puyas No Vivas y Puyas Vivas respectivamente.

<sup>11</sup> Datos vectoriales se transformaron a formato de puntos con el fin de mejorar la visualización espacial de la Puya.

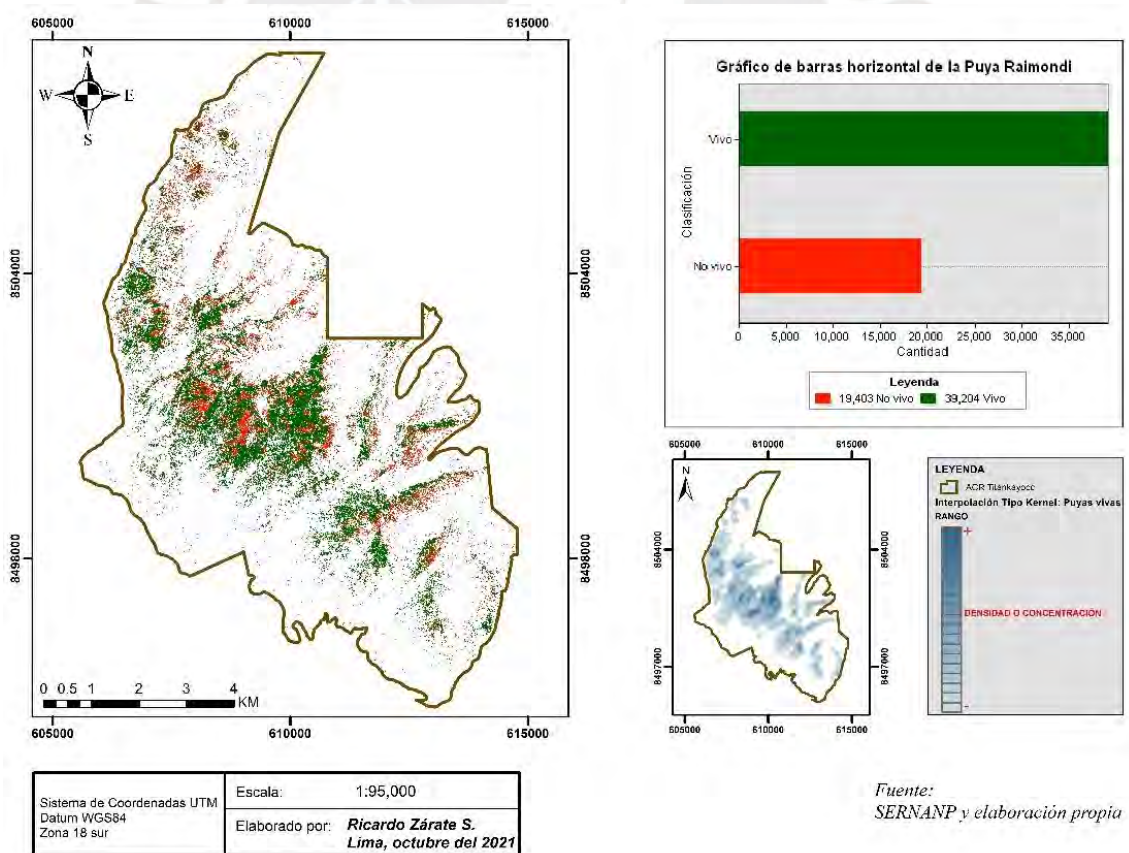
**Tabla 5. 1.** Promedio de NDVI de *P. raimondii* por clase.

CLASE	PUYAS VIVAS	% PUYAS VIVAS	PUYAS NO VIVAS	% PUYAS NO VIVAS
PUYA A	10413	26.561%	4751	24.486%
PUYA B	22058	56.265%	8889	45.818%
PUYA C	6733	17.174%	5761	29.696%
<b>TOTAL</b>	<b>39204</b>	<b>100%</b>	<b>19403</b>	<b>100%</b>

*Fuente: Elaboración propia.*

Seguidamente, el promedio de NDVI de Puyas Vivas arroja un valor de 0.26 el cual refleja tener una baja actividad fotosintética con doseles de escasa cobertura vegetal. De modo que, para la fecha tomada con el satélite CBERS-4A la mayoría de estos rodales se encuentran en condiciones vulnerables. Cabe señalar que, el área ocupada de las puyas vivas potenciales es de 2655.81 ha aprox. (42.34%) según por el método de interpolación Kernel (ver mapa 5.2).

**Mapa 5. 2.** Mapa clasificado de NDVI de la *P. raimondii* en el ACR Titankayocc




*Fuente: SERNANP y elaboración propia*

*Fuente: Elaboración propia.*

Para el análisis del TRI, se utilizaron todas las puyas detectadas para cuantificar la heterogeneidad del territorio e incorporar información sustancial diferente de la altitud (Goerlich y Cantarino, 2010). Asimismo, se clasificó en siete clases de igual área, y en consecuencia distinta longitud de intervalo (Riley et al., 1999) (ver mapa 5.3.). Resultado de ello, el promedio global del TRI de las tres clases de *P. raimondii* fue el valor de 12.5 con desviación estándar de  $\pm 4.5$  (ver figura 5.2.). Este resultado significa que la especie altoandina habita principalmente en lugares donde la morfología presenta rugosidad intermedia (ver tabla 5.2.).

**Figura 5. 2.** Promedio de TRI de la *P. raimondii* por etiqueta.



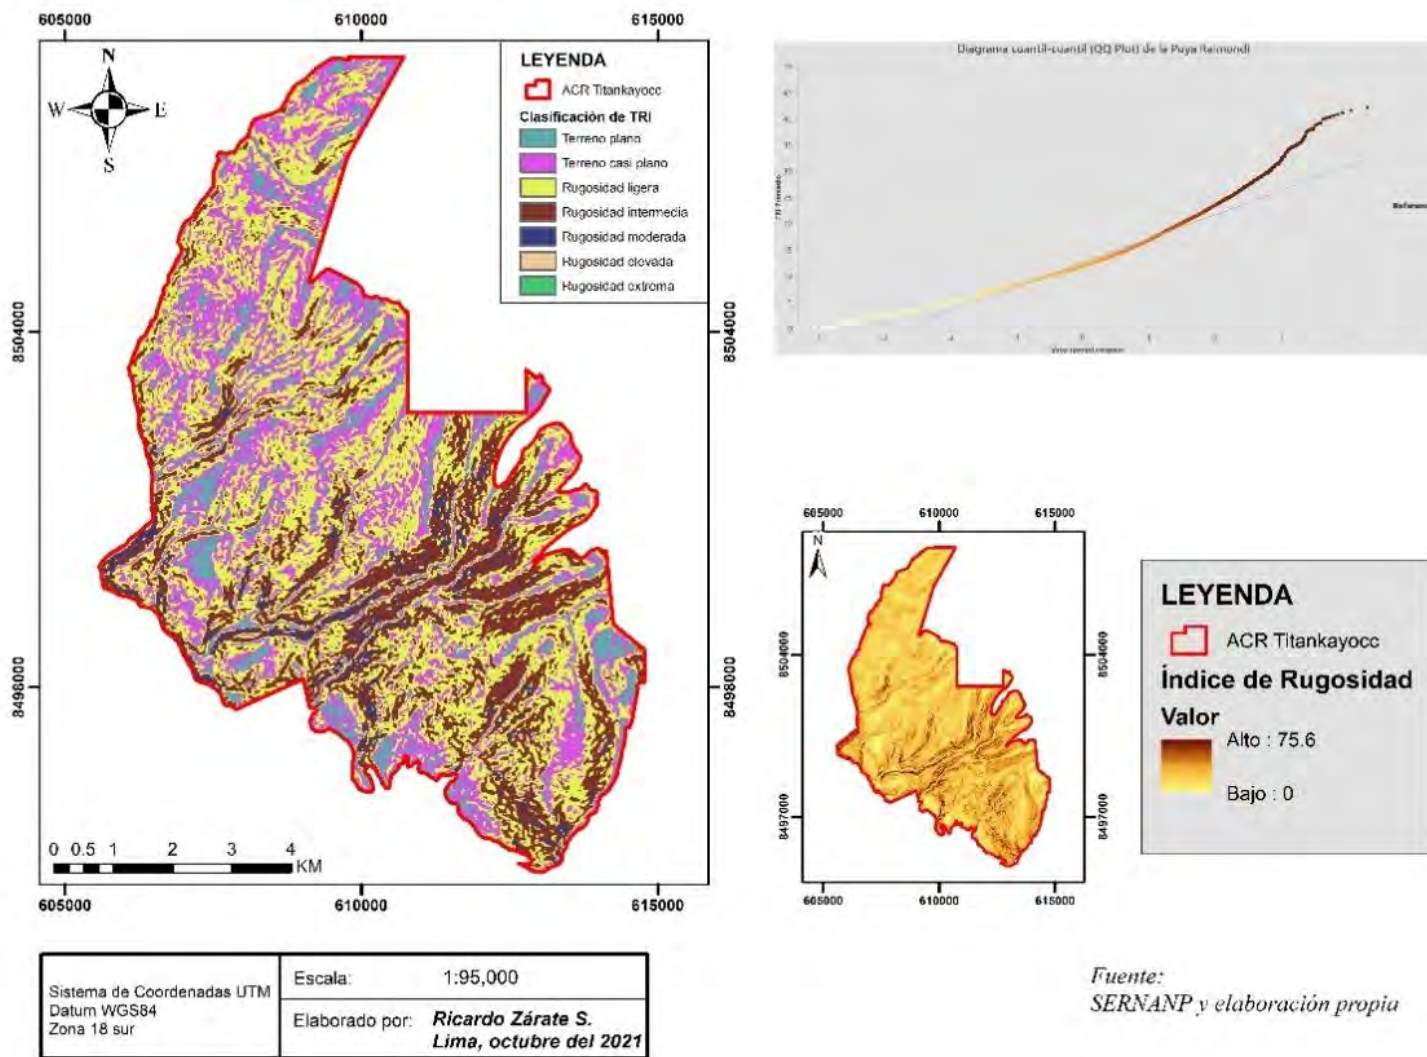
Fuente: Elaboración propia.

**Tabla 5. 2.** Clasificación de TRI de *P. raimondii*.

CLASE (INTERVALOS)	NÚMERO DE PUYAS	PORCENTAJE
TERRENO PLANO [0, 7]	5030	8.58%
TERRENO CASI PLANO (7, 9]	7960	13.58%
RUGOSIDAD LIGERA (9, 11]	11294	19.27%
RUGOSIDAD INTERMEDIA (11, 13]	11314	19.30%
RUGOSIDAD MODERADA (13, 15]	8540	14.57%
RUGOSIDAD ELEVADA (15, 19]	9125	15.57%
RUGOSIDAD EXTREMA > 19	5344	9.12%
<b>TOTAL</b>	<b>58607</b>	<b>100.00%</b>

Fuente: Elaboración propia.

Mapa 5. 3. Mapa clasificado de TRI en el ACR Titankayocc




Fuente: SERNANP y elaboración propia

Fuente: Elaboración propia.

Finalmente, el coeficiente de correlación de Pearson se aplicó para medir el grado de asociación y dirección de una relación lineal entre estas dos variables cuantitativas. Como resultado, se obtuvo una correlación nula con valor negativo de -0.05, lo cual significa que entre el NDVI y TRI no existe relación estadística (ver figura 5.3.).

**Figura 5. 3.** Diagrama de dispersión entre el TRI y NDVI.




*Fuente: Elaboración propia.*

### 5.2.1. Histograma de Frecuencias aplicado al NDVI

El cálculo del NDVI con imágenes satelitales CBERS-4A arrojó un valor promedio de puyas vivas y muertas de 0.23 al interior del ACR Titankayocc, con valores mínimo y máximo de 0.017 y 0.59 respectivamente. De esta manera, el siguiente gráfico estadístico (ver figura 5.4.) representa una muestra sistemática del área de conservación el cual además nos resume una población específica y tipo de condición fenológica presentes en la planta relicta.

**Figura 5. 4.** Gráfico de histograma de NDVI de la *P. raimondii*.




*Fuente: Elaboración propia.*

### 5.2.2. Análisis de Tendencias aplicado al TRI

El gráfico de análisis de tendencias (ver figura 5.5.) nos señala que los puntos de las puyas generadas con *Deep Learning* y su terreno tienen una variación ascendente de valores de TRI de Oeste a Este en el plano XZ (línea verde). Asimismo, para el otro plano YZ (línea azul) representa una uniformidad a lo largo del eje Norte a Sur, pero con aumento mínimo. Ello demuestra una menor dispersión de los datos con una predisposición a aumentar conforme nos desplazamos hacia el Sur y el Este.

**Figura 5. 5.** Gráfico de análisis de tendencias del TRI.



*Fuente: Elaboración propia.*

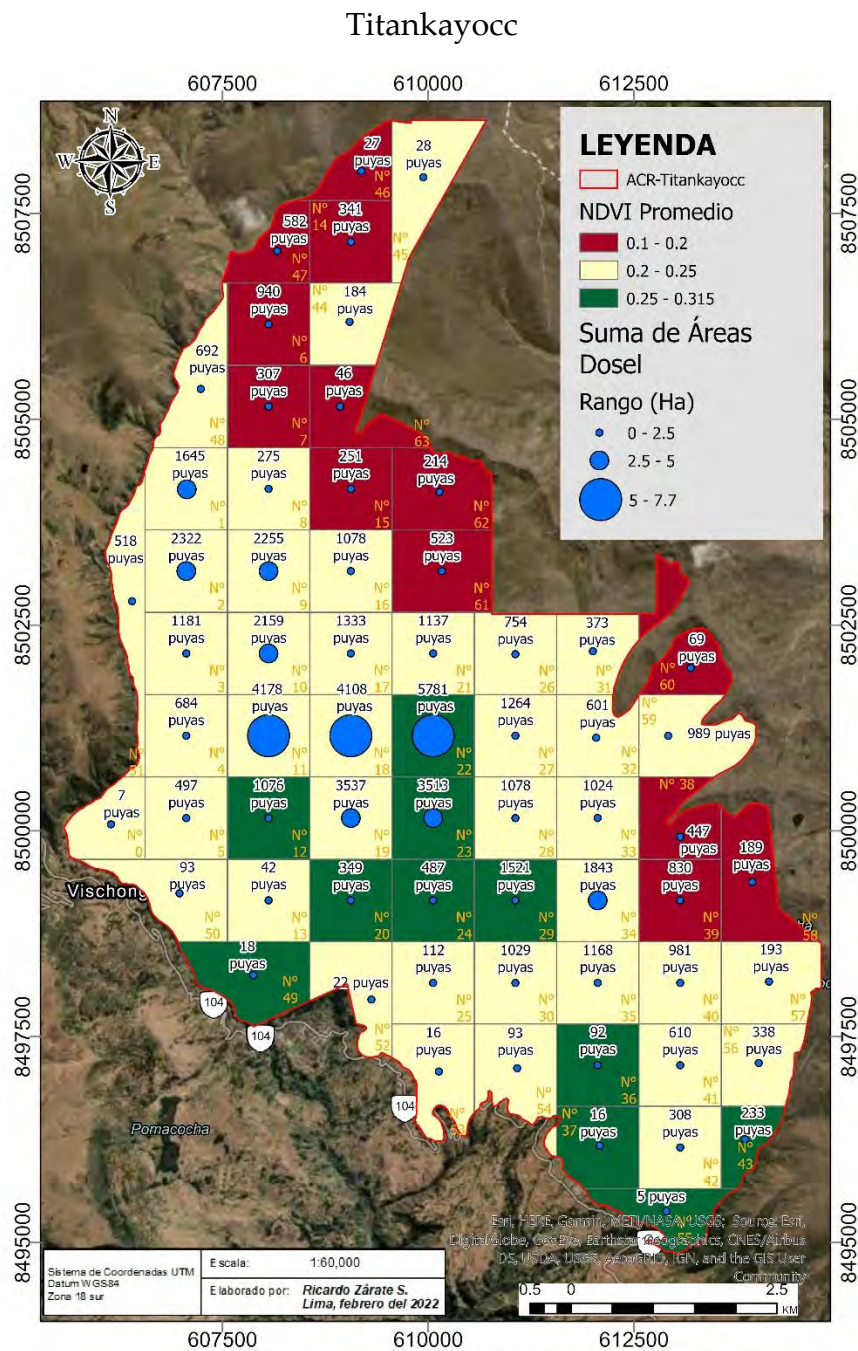
### **5.3. Densidad por cuadrícula de la *Puya raimondii* Harms**

La densidad por cuadrícula en el estudio de la *P. raimondii* tiene por objetivo determinar el aporte medioambiental presente en el ACR Titankayocc, lo cual se refleja a través de la captura de carbono que almacena por el tipo de fotosíntesis llamado sistema CAM (Crassulacean Acid Metabolism). Este sistema consiste en abrir sus estomas durante la noche con la finalidad de absorber el dióxido de carbono (Grau et al., 2010).

Para determinar el secuestro de carbono, se hizo la suma de las dimensiones de las rosetas generadas con el modelamiento de *Deep Learning*; de esta manera, se halló la superficie estimada de 86.75 ha que equivalen al 1.38% de ocupación del ACR Titankayocc. Seguidamente, a partir del área de cada individuo y, asumiendo la forma geométrica de circunferencia, se obtuvo el diámetro promedio de todas las rosetas detectadas el cual resultó ser de 4.34 metros.

Finalmente, para identificar las zonas con mayor reserva de carbono dentro del ACR Titankayocc se realizó la discretización de datos por cuadrículas de 1 kilómetro cuadrado aproximadamente (ver mapa 5.4). Como resultado, se obtuvo que tres cuadrículas (ver Anexo 1) ubicadas en el centro-oeste tenían el mayor número de área foliar con un NDVI regular para la captura de carbono.

**Mapa 5. 4.** Mapa de biomasa aérea y área foliar de la *P.raimondii* en el ACR



Fuente: Elaboración propia.

## CAPÍTULO 6

### DISCUSIÓN

En esta sección de la investigación se analizaron los resultados descritos del capítulo anterior. De tal modo que, se pretende comparar y discutir con investigaciones afines que utilizaron estas herramientas geoespaciales pero aplicadas en diferentes temáticas; además, la inclusión de la percepción propia permite mejorar el análisis del rendimiento del modelo propuesto. Dentro del presente estudio se contaron con aspectos positivos como negativos, lo cual fortalece nuestros resultados alcanzados, pues promueve a seguir indagando.

#### **6.1. Delimitación de las poblaciones de *Puya raimondii* Harms**

La metodología realizada tenía como uno de sus objetivos mapear la mayor cantidad de puyas presentes en el ACR Titankayocc además de estudiar el estado vegetativo y el grado de diseminación de la planta altoandina utilizando imágenes satelitales y analizando los datos basados en las ciencias de la computación. Como resultado del procedimiento, se obtuvo un total de 58 607 ejemplares con promedio de actividad fotosintética baja. Este registro se consideró representativo para el área de conservación, puesto que estudios pasados indican que posee una población aproximada de 200 000 puyas, las cuales han ido disminuyéndose con el paso de los años debido al cambio climático y la acción antrópica (Apolinario y Carmen, 2015).

Por otro lado, según el Plan Maestro ACR - Titankayocc 2014-2019, señala que la densidad en el área de conservación registra una densidad de 300 a 467 individuos por hectárea (CEDES, s.f.), cantidad distinta comparada al promedio hallado que fue de 14.81 ind/ha con un valor máximo de hasta 102 puyas lo cual demostraría una subestimación a consecuencia de la calidad de la imagen satelital, número de etiquetas por clase o rendimiento del algoritmo escogido para el reconocimiento de la planta altoandina.

En cuanto a la evaluación de precisión aplicada a la cobertura terrestre, se denota que el diseño y asignación de las muestras de entrenamiento y validación son de mucha relevancia para el mapeo de la *P. raimondii*, ya que según Olofsson et al., (2014) el método de muestreo probabilístico que facilita la implementación, rentabilidad, distribución espacial representativa y se adapta a los cambios de cualquier diseño, es el aleatorio conglomerado. Este tipo de muestreo divide la población en grupos y luego selecciona algunas unidades espaciales (etiqueta de puyas) (Stehman y Foody, 2019). Sin embargo, este método presenta algunas desventajas como es la reducción de la precisión y complica la estratificación cuando los estratos son clases de mapa y la unidad de evaluación es un píxel (Olofsson et al., 2014). Ante este hecho, se recomienda la guía de “buenas prácticas” que abogan por la estimación del área basada en la clasificación de referencia y el uso de la información contenida en la matriz de error para mejorar la precisión del estimador (McRoberts, 2011; Olofsson et al., 2013, 2014).

Dicho todo esto, se difiere que el estudio poblacional realizado a los rodales de *P. raimondii* utilizando imágenes satelitales de Google Earth permitió delimitar las zonas con mayor número de individuos los cuales se encontraron agrupados principalmente en el núcleo del ACR Titankayocc. Este resultado guarda relación con el trabajo cartográfico elaborado por Fritz Kleinschroth et al. (2009) para el Proyecto MARSINCA 2008 (ver Anexo 2), quienes dividen la presencia de puyas en dos clases: disperso y denso; concordando las áreas densas con el modelamiento generado. En ese sentido, se puede suponer que las zonas más densas se caracterizan por estar alejadas a los cambios antropogénicos debido a su ubicación geográfica; coincidiendo también con Anthelme et al. (2015), mencionando que el patrón de decrecimiento de abundancia desde el centro del área hacia los bordes probablemente sea consecuencia de las condiciones ambientales actuales y herencia de su distribución histórica.

## 6.2. Evaluación del modelo de detección de objetos con Deep Learning

El proceso metodológico tuvo como principal logro reconocer la *P. raimondii* mediante algoritmos de *Deep Learning* e imágenes satelitales de Google Earth. Este flujo comprendió el uso de modelos preconfigurados como fue la ResNet, el cual contiene una columna vertebral de arquitectura CNN, cuya principal ventaja es explotar la correlación entre píxeles vecinos (Hamdi et al., 2019). Asimismo, el diseño del muestreo fue fundamental para la evaluación estadística en el conteo y extracción de índices para la caracterización ambiental, ya que existen criterios como son la facilidad de implementar tanto para seleccionar la muestra como producir estimaciones de precisión y área, la versatilidad de aumentar o reducir el tamaño de la muestra, reducir la mayor cantidad de errores estándares y tener una distribución equitativa en toda el área de estudio (Stehman y Foody, 2019).

El trabajo realizado consiguió una precisión promedio para cada clase (Puya A, Puya B y Puya C) de 75.09%, 58.93% y 31.78% respectivamente. Estos resultados son analizados con artículos relacionados al uso de herramientas *Deep Learning* y datos geoespaciales; de manera que, investigadores como Davis et al. (2021) y Sabine Hennig (2021), quienes realizaron estudios orientados a la identificación de restos arqueológicos y árboles frutales, aplicaron metodologías afines a la presente investigación, pero con la diferencia en el insumo de datos satelitales y recurso computacional. Resultado de ello, las precisiones alcanzadas en sus estudios comprenden rangos entre 38% y 80% por etiqueta. Cabe señalar que, la variación de la precisión puede deberse a problemas en el momento de elegir las unidades de evaluación, la heterogeneidad de la cobertura terrestre y la mala construcción y selección de muestra de la lista de objetos (Stehman y Foody, 2009)

En cuanto a la evaluación de la precisión del modelo se señaló el uso de la IoU con intersección mínima de 0.2; dicho valor asignado radica por las imprecisiones de las características de la *P. raimondii* presentes en la imagen satelital de Google Earth. Según el informe de evaluación de precisión, se logró alcanzar un rango

de confianza de las características detectadas de [60.07, 98.51] a partir del uso de la herramienta *Detección de Objetos mediante el aprendizaje profundo*. Asimismo, se concluye que la clase Puya\_A tuvo el mejor desempeño de precisión, puntuación F1 y recuperación, mientras que la clase Puya\_C fue la menor de las tres clases. Estas métricas son de suma importancia para el análisis del modelo, ya que representan la calidad de la precisión y cantidad para identificar los objetos. Los mapas OBIA introducen nuevas dimensiones a los protocolos de componente de evaluación de precisión debido a los tamaños variables de los objetos mapeados (Stehman y Czaplewski, 1998); de manera que, se recomienda las buenas prácticas de Radoux y Bogaert (2017) que proporcionan avances en esta dirección a medida que los protocolos siguen desarrollándose y probándose en la práctica.

Por otro lado, la propuesta metodológica relacionado al conteo y delimitación espacial de la *P. raimondii* ha logrado innovar e integrar el mapeo de especies con el cálculo de área de las poblaciones frente a otras estrategias de trabajo similares que estiman el número de individuos y diseñan evaluaciones demográficas por medio de inventarios con tomas fotográficas y uso de imágenes satelitales de Google Earth (Goñi et al., 2006; Salazar y Villasante, 2012; Montesinos, 2014; Aquino et al., 2018), censos y parcelas de monitoreo (Rozzi y Nazionale, 2015; Zavaleta, 2017; Zuschlag, 2014), técnicas de geomática basado en escala de grises (Mallqui, 2017) y empleo de recuadros delimitadores (Prado-Aliaga et al., 2021).

Finalmente, la detección de objetos con *Deep Learning* aplicado a la conservación ofrece algoritmos de reconocimiento automático para el análisis espacial y la cartografía de organismos catalogados en peligro de extinción; de manera que, según lo señalado por Davis et al. (2021), los detectores podrían ser considerados para la mejora de inventarios y esfuerzos prospectivos. Asimismo, la propuesta metodológica del presente trabajo permite el estudio de las unidades naturales presentes en áreas de conservación, cuyos cambios de sus parámetros dependen de sus procesos poblacionales (Prado-Aliaga et al., 2021).

### 6.3. Análisis de parámetros ambientales

La información generada sirvió posteriormente describir las variables físicas y biológicas relacionadas al estado de la planta relictas; de modo que, los resultados ambientales aportan en el conocimiento de la especie a escala local y evalúa las condiciones de sus hábitats.

Para el caso del NDVI, estudios afines de teledetección y SIG por Silverio Torres y Jaquet (2003; 2009) realizados en el Parque Nacional Huascarán, mencionan que la *P. raimondii* presenta valores entre 0.01 y 0.21 siendo clasificadas como “vegetación escasa” ubicada en tierras altas (>3650 m). Este resultado, respaldaría nuestro histograma de NDVI de puyas el cual guarda relación con los autores citados, puesto que el promedio de puyas arroja 0.23 con desviación estándar  $\pm 0.06$ . De manera que, supone la firma espectral para la planta relictas debido al análisis único de este. Cabe señalar, que dichos artículos científicos emplearon imágenes satelitales Landsat 5 y 7 que tienen resolución espacial de 30 metros además de variar el rango espectral de la banda infrarrojo cercano que difiere mínimamente con el satélite CBERS-4A.

Por otro lado, el índice TRI indica el tipo de terreno que crece la *P. raimondii* el cual resulta ser principalmente rugoso ligero e intermedio con tendencia al aumento de su valor hacia los ejes Sur y Este. No obstante, este aumento no guarda relación con la cantidad de puyas en mencionada zona, ya que se exhibe poca radiación solar a través de los mapas físicos generados; resultado de ello, la planta altoandina prospera en los lados Oeste y Nor-Oeste. Esta información es corroborada por Villiger (1981), quien manifiesta que los rodales de mayor desarrollo y densidad se encuentran localizados en zonas rocosas con pendientes moderadas a muy fuerte. Asimismo, los autores Apolinario y Carmen (2015), señalan en su estudio realizado en el ACR Titankayoc que la topografía del terreno y la exposición de las puyas hacia el sol probablemente influyen directamente en el crecimiento de la misma.

#### **6.4. Importancia de la *Puya raimondii* Harms para su conservación**

Estudios de conservación realizados en distintas partes del país han permitido caracterizar y estimar las poblaciones de *P. raimondii*. Uno de estos trabajos es el de Quispe y Elías (2020), quienes a través de modelos de distribución potencial actual y futura buscan identificar áreas prioritarias para la futura conservación de la especie endémica; en ese sentido, dentro de las áreas prioritarias generadas se encuentra el ACR Titankayocc el cual es un paisaje natural que fomenta el turismo y la investigación por parte de estudiantes, científicos e institucionales públicas y privadas (Montesinos, 2014).

Sin embargo, se evidencia que el área de conservación tiende a degradarse a consecuencia del cambio climático y la acción antrópica. El primer factor porque muchas especies no tienen la capacidad de migrar o adaptarse lo suficientemente rápido al ritmo acelerado del cambio climático tal como sucede con la *P. raimondii* (Evangelista et al., 2016; Harrison y Noss, 2017). Mientras que el segundo, puesto que los cambios directos e indirectos asociados al uso del suelo son el principal impulsor de la pérdida de biodiversidad (Tscharntke et al. 2005).

En cuanto a las amenazas mencionadas se evidenció con la descarga de imágenes satelitales y su análisis multitemporal, el incremento de prácticas relacionadas al uso del suelo dentro del área de estudio, así como la presencia de zonas urbanas o centros poblados en las fronteras (ver figura 6.1.). Este hecho influyó directamente con el tipo de distribución que tiene la *P. raimondii*, tal como lo indica Lambe (2009) ya que son quemadas o removidas producto del enredo de los animales entre sus hojas espinosas, provocando la pérdida gradual de ejemplares y limitando la germinación para futuras generaciones. De igual modo, la falta de condiciones adecuadas y los obstáculos de migración como el factor fisiográfico, lumínico o climático, alteran el proceso de reproducción y propagación de la especie (Aquino et al., 2018).

**Figura 6. 1.** Actividades antrópicas. (1) Agricultura; (2) Área urbana; (3) viales.



*Fuente: Elaboración propia.*

Ante lo expuesto en los párrafos anteriores, se demuestra el grado vulnerabilidad frente los cambios físicos e intervención humana que afectaría a la *P. raimondii*; asimismo, su presencia es relevante para el equilibrio de sus ecosistemas y sus relaciones con diferentes seres vivos (Montesinos, 2014). De manera que, la conservación y protección de esta especie endémica con limitada diversidad genética exige mantenerlas tal como lo afirma Aquino et al. (2018) y Rodríguez et al. (2020), quienes concuerdan que la *P. raimondii* está siendo llevada a la extinción y por tal motivo, existe la necesidad de tomar medidas inmediatas integrando una visión ecosistémica y holística ante la posible pérdida irreversible de la flora y fauna con la cual se encuentra asociada.

## CAPÍTULO 7

### CONCLUSIONES Y RECOMENDACIONES

Los resultados finales de la presente tesis han permitido conocer las condiciones en la cual habita la *P. raimondii* dentro del ACR Titankayocc; asimismo, detalla los alcances y logros, así como los problemas y limitaciones que tienen los SIG con algoritmos de *Deep Learning* para estudios de conservación de especies. De manera que, en este último capítulo se evalúa la utilidad e importancia que se alcanzó en la investigación realizada.

#### 7.1. Conclusiones

- La detección y conteo de individuos de *P. raimondii* situada en el ACR Titankayocc presenta una precisión de 75.06% estimándose una población de 58 607 individuos aplicando herramientas de *Deep Learning* con ArcGIS Pro e imágenes satelitales de Google Earth. Ello significa que la metodología permite estimar otras especies empleando datos libres para hallar los patrones espaciales de distribución de los organismos sésiles.
- Las condiciones ambientales presentes de la *P. raimondii* muestran que la planta relictiva tiene una clorofila baja el cual se refleja con el 0.23 de NDVI promedio hallado; asimismo el número de puyas muertas representa la tercera parte (33.11%) de la población total calculada, evidenciándose cierto grado de vulnerabilidad. Por otro lado, los espacios que ocupa la *P. raimondii* son terrenos rugosos, entre ligeros (19.27%) a elevados (15.57%), y con tendencia a poblar los ejes Este y Sur; sin embargo, su crecimiento puede verse limitado por la presencia de actividades antrópicas dentro del área de conservación, lo cual genera una amenaza ya que son removidas o quemadas para apropiarse de esas tierras.

- El uso de herramientas vinculadas a *Deep Learning* para el estudio de la conservación y su análisis espacial, han generado alternativas positivas como es el mapeo de la *P. raimondii* y su caracterización; además, la actualización de técnicas convencionales de clasificación (supervisada y no supervisada) permiten optimizar la gestión de los datos y alcanzar resultados más precisos debido al análisis basado en objetos. De manera que, es alternativa eficaz para obtener datos espaciales y espectrales en lugares lejanos o inaccesibles para el ser humano.
- Finalmente, los resultados alcanzados para el caso de la *P. raimondii* es una propuesta para mejorar el estudio de poblaciones endémicas y su relación con las variables ambientales de su hábitat; en ese sentido, la metodología realizada aporta nuevas herramientas para el estudio de la conservación.

## 7.2. Recomendaciones

- Es importante realizar estudios de campo para la presente investigación, puesto que mejoraría a delimitar y ubicar las áreas de entrenamiento y validación propuestas para la caracterización de la *P. raimondii*.
- Es necesario complementar la metodología con datos espaciales más actuales y de mejor resolución espacial, ya que el uso de imágenes satelitales libres como Google Earth presentan alteraciones en su textura y nitidez los cuales afectan en el conteo de la planta altoandina.
- Es recomendable aumentar el número de etiquetas de objetos para la mejora del modelo de *Deep Learning* con ArcGIS Pro. Se estima que para cada clase se debe registrar una cantidad mínima de 10,000 elementos y ello podría variar dependiendo de la superficie y número de objetos presentes en la imagen.

- El flujo de trabajo empleado durante el proceso de detección de objetos con *Deep Learning* de ArcGIS Pro, puede apoyarse con fundamentos de programación para la automatización de pruebas; asimismo, se recomienda el uso de otros entornos de desarrollo (Spyder, PyCharm, Rodeo, etc.) y librerías vinculadas a *Machine Learning* (Scikit-learn, SciPy, Pytorch, OpenCV, etc.) que ayuden a obtener resultados más precisos.
- Es preferible incorporar otros parámetros ambientales (precipitación, temperatura, evapotranspiración, etc.) para hallar correlaciones relevantes que puedan existir entre los factores abióticos y el estado fenológico de la planta relicta en la cual se encuentra.
- El modelo de detección de puyas usado para la presente tesis recomienda ser comparado con otras metodologías similares, ya sea por técnicas de segmentación y filtrado; extracción por características; o clasificación supervisada y no supervisada. De esta manera, el análisis comparativo ayudará a identificar los alcances del procedimiento realizado además de establecer mejores prácticas para otros casos similares.
- Conocer el tipo de diseminación y distribución geográfica de la *P. raimondii* es de relevancia para el análisis espacial debido al grado de complejidad que puede existir para el reconocimiento individual de cada planta presente en una imagen satelital.
- Es recomendable contar con equipos informáticos de alto desempeño para la presente metodología, puesto que las pruebas de identificación de puyas requieren de varios ensayos que permitan determinar los parámetros más adecuados provenientes de las herramientas de detección de objetos con *Deep Learning* de ArcGIS Pro.

### 7.3. Contribuciones de la presente investigación

El cierre de la presente investigación mostró los alcances y limitaciones que tuvieron las herramientas y datos vinculados a las ciencias geográficas. Es así como el uso de técnicas de *Deep Learning* permitió mejorar el análisis y la exploración de datos como fueron las imágenes satelitales libres de alta resolución (CBERS-4A y Google Earth).

Sin embargo, estos resultados no fueron del todo exacto, puesto que la calidad de las imágenes satelitales, como las de Google Earth, presentaba distorsiones en las figuras de la *P. raimondii* ocasionando mayor esfuerzo para el reconocimiento basado en objetos con *Deep Learning*. Asimismo, la forma y el color de la planta altoandina era muy similar a otros elementos naturales como rocas, sedimentos y otras vegetaciones presentes en el área de conservación.

En ese sentido, los problemas expuestos abren la posibilidad de profundizar los conceptos de la IA para el desarrollo de modelos espaciales más eficientes que incluyan parámetros más afines a la detección de la especie evaluada.

Por otro lado, la proporción de nuevos insumos geoespaciales libres de alta resolución permitió caracterizar las condiciones más idóneas en el área que habita; por lo que una posterior línea en la investigación sería la introducción de nuevas variables provenientes de salidas de campos para el análisis más profundo de la planta altoandina.

Finalmente, durante el contexto de la pandemia por el COVID-19, no se pudo contar con data *in situ* para el modelo de detección de puyas en el ACR Titankayocc. De manera que, el trabajo de gabinete es la principal base del presente estudio geográfico frente a los temas expuestos para estimar las densidades poblacionales, estudiar las relaciones bióticas y abióticas y analizar el grado de deterioro de los ecosistemas.

## BIBLIOGRAFÍA

- Alburshaid, E. A., & Mangoud, M. A. (2021). Palm Trees Detection Using the Integration between GIS and Deep Learning. *2021 International Symposium on Networks, Computers and Communications, ISNCC 2021, October 2021*. Obtenido de <https://doi.org/10.1109/ISNCC52172.2021.9615721>
- Apolinario, J., & Carmen, K. (2015). *Capacidad de almacenamiento de carbono en un bosque joven y maduro de Puya raimondii Harms, Vilcashuaman – Ayacucho* [Tesis de pregrado, Universidad Nacional del Centro del Perú]. Perú. Obtenido de <http://hdl.handle.net/20.500.12894/3493>
- Aquino, W., Condo, F., Romero, J., & Yllaconz, R. (2018). Distribución geográfica y poblacional de *Puya Raimondii* Harms en el distrito e Huarochirí, provincia de Huarochirí, Lima, Perú. *The Biologist* (Lima), 16(1). Obtenido de <https://doi.org/10.24039/rtb2018161219>
- Arts, K., van der Wal, R., & Adams, W. M. (2015). Digital technology and the conservation of nature. *Ambio*, 44 (4), 661-73. Obtenido de <https://doi.org/10.1007/s13280-015-0705-1>
- Baldeón, S.M., Allende, C.T., & Vivanco, P.C. (2005). Análisis territorial de Vilcashuaman (Volumen II). *Dirección Nacional del Instituto Nacional de Cultura*. (1ª ed). INC / LASERGE.
- BCRP. (2021). *Caracterización de la región Ayacucho*. Obtenido de <https://www.bcrp.gob.pe/docs/Sucursales/Huancayo/ayacucho-caracterizacion.pdf>
- Bengio, Y. (2009). Learning deep architectures for AI. *Foundations and trends® in Machine Learning*, 2(1), 1-127.
- Bengio, Y., Courville, A., & Vincent, P. (2013). Representation learning: a review and new perspectives. *IEEE transactions on pattern analysis and machine intelligence*, 35(8), 1798–1828. Obtenido de <https://doi.org/10.1109/TPAMI.2013.50>
- Beveridge, J. R., Griffith, J., Kohler, R. R., Hanson, A. R., & Riseman, E. M. (1989). Segmenting images using localized histograms and region merging. *International Journal of Computer Vision*, 2(3), 311–347. <https://doi.org/10.1007/BF00158168>
- Brack, A. (2000). *El medio ambiente en el Perú*. Instituto Cuánto (Lima), 402.

- Braga, J. R., Peripato, V., Dalagnol, R., P. Ferreira, M., Tarabalka, Y., O. C. Aragão, L. E., F. de Campos Velho, H., Shiguemori, E. H., & Wagner, F. H. (2020). Tree Crown Delineation Algorithm Based on a Convolutional Neural Network. *Remote Sensing*, 12(8), 1288. Obtenido de <https://doi.org/10.3390/rs12081288>
- Canza Sucasaca, D. M. (2019). *Modelamiento de los Servicios Ecosistémicos de Rodales de la Puya Raimondii Harms; del Distrito de Ayaviri-Región Puno* [Proyecto de Investigación, Universidad Andina Néstor Cáceres Velasquez]. Perú. Obtenido de <http://repositorio.uancv.edu.pe/handle/UANCV/2098>
- Carpio, J. (2017). *Flora arbórea y arbustiva del bosque de Ustuna, centro poblado Santa Isabel de Chumbes, distrito Ocros, provincia Huamanga* [Tesis de pregrado, Universidad Nacional de San Cristóbal de Huamanga]. Perú. Obtenido de <http://repositorio.unsch.edu.pe/handle/UNSCH/1672>
- Castelluccio, M., Poggi, G., Sansone, C., Verdoliva, L., & Aug, C. V. (2015). *Land Use Classification in Remote Sensing Images by Convolutional Neural Networks*. 1–11.
- Castro, C., & Oviedo I. (2001). *“La Titánica” Puya raimondii Harms, en el departamento de Apurímac* [Tesis de pregrado no publicada]. Universidad Nacional San Antonio de Abad del Cusco. Perú.
- CEDES. (s.f.). Promoción, protección y conservación del Titankayoc como zona de reserva natural y de las Puyas de Raimondi como especies en extinción.
- Choi, Y. (2023). GeoAI: Integration of Artificial Intelligence, Machine Learning, and Deep Learning with GIS. *Applied Sciences*, 13(6), 3895. MDPI AG. Obtenido de <http://dx.doi.org/10.3390/app13063895>
- Chollet, F. (2017). *Deep Learning with Python*. Manning.
- Chuvieco, E. (1995). *Fundamentos de teledetección espacial*. (3ª ed). RIALP.
- Condori Paitan, H. (2014). *Efecto de medios de cultivo in vitro para producir plántulas de puya raimondi (pouretia gigantea harmas) en condiciones de laboratorio* [Tesis de pregrado, Universidad Nacional de Huancavelica]. Perú. Obtenido de <http://repositorio.unh.edu.pe/handle/UNH/179>
- Corvalán, P., & Hernández, J. (2006). Estructura de rodal. *Universidad de Chile. Facultad de Ciencias Forestales Depto. Manejo de Recursos Forestales Cátedra de Dasometría*. 6pp.
- Crispin Cuya, M. (2015). *Valoración económica ambiental de los bofedales del distrito de Pilpichaca, Huancavelica, Perú* [Tesis de maestría, Universidad Nacional de

San Cristóbal de Huamanga]. Obtenido de <https://hdl.handle.net/20.500.12996/1584>

- Davila, B. (2004). *Evaluación ecológica y de conservación en los rodales de Puya raimondii, Huinipampa (Espinar – Cusco); y una propuesta para forjar valores y bienestar humano común* [Tesis de Doctorado no publicada]. Universidad Nacional de San Agustín. Perú.
- Davis, D. S., Caspari, G., Sanger, M. C., & Lipo, C. P. (2021). Using deep learning to detect rare archaeological features: A case from coastal South Carolina, USA. *First International Meeting for Applied Geoscience & Energy Expanded Abstracts*. Obtenido de <https://doi.org/10.1190/segam2021-3574963.1>
- De la Cruz, J. (1994). *Estudio de la densidad poblacional e importancia económica de Puya raimondii Harms. Ayacucho - 1993* [Tesis de pregrado no publicada]. Universidad Nacional de San Cristóbal de Huamanga. Perú.
- Decreto Supremo N° 043-2006-AG de 2006. Aprueban categorización de especies amenazadas de flora silvestre. 13 de julio de 2006. El Peruano N° 323527.
- Decreto Supremo N° 023-2010-MINAM de 2010. Establecen el Área de Conservación Regional Bosque de Puya Raimondi – Titankayocc. 24 de diciembre de 2010. El Peruano N° 431537.
- Dey, A. (2016). Machine Learning Algorithms: A Review. *International Journal of Computer Science and Information Technologies*, 7(3), 1174–1179.
- Ding, P., Zhang, Y., Deng, W.-J., Jia, P., & Kuijper, A. (2018). A light and faster regional convolutional neural network for object detection in optical remote sensing images. *ISPRS Journal of Photogrammetry and Remote Sensing: Official Publication of the International Society for Photogrammetry and Remote Sensing (ISPRS)*, 141, 208–218. Obtenido de <https://doi.org/10.1016/j.isprsjprs.2018.05.005>
- Donoso, C. (1993). *Bosques Templados de Chile y Argentina*. (1ª ed). Editorial Universitaria.
- Dourojeanni, M.J., & Ponce, C. (1978). Los Parques Nacionales del Perú. *INCAFO 1978*, 224pp.
- Dourojeanni, M.J., & Tovar, A. (1966). Apuntes sobre *Puya raimondii* Harms (Bromeliaceae) en la provincia de Canta, Perú. *Anales Científicos*, 4, 113-120.
- Dueñas, H., Rojas Fox, J., & Mujica, F. (2017). *Caracterización de los Ecosistemas del distrito de Vischongo, Provincia de Vilcashuamán (Ayacucho-Perú)*. Editorial Académica Española. (1ª ed).

- ESRI. (2020). *Spatial Data Science: The New Frontier in Analytics (MOOC)*. Obtenido de [www.esri.com/training/catalog/5d76dcf7e9ccda09bef61294/](http://www.esri.com/training/catalog/5d76dcf7e9ccda09bef61294/)
- ESRI. (2021). *Install deep learning libraries ArcGIS Pro 2.8 | ArcGIS Image Server 10.9*. Obtenido de <https://github.com/Esri/deep-learning-frameworks/blob/master/include/install-deep-learning-frameworks-manually-2-8.pdf>
- ESRI. (s.f.-a). *Average Nearest Neighbor*. Obtenido de <https://desktop.arcgis.com/en/arcmap/10.3/tools/spatial-statistics-toolbox/average-nearest-neighbor.htm>
- ESRI. (s.f.-b). *Compute Accuracy For Object Detection (Image Analyst)*. Obtenido de <https://pro.arcgis.com/en/pro-app/latest/tool-reference/image-analyst/compute-accuracy-for-object-detection.htm>
- Evangelista, A., Frate, L., Carranza, M. L., Attorre, F., Pelino, G., & Stanisci, A. (2016). Changes in composition, ecology and structure of high-mountain vegetation: a revisitation study over 42 years. *AoB PLANTS*, 8, plw004. Obtenido de <https://doi.org/10.1093/aobpla/plw004>
- Flores, N. (2020). *Evaluación de las unidades de vegetación en Los Pantanos De Villa (Lima, Perú) mediante Sistemas de Información Geográfica y Teledetección* [Tesis de pregrado, Universidad Católica Sedes Sapientiae]. Obtenido de <https://repositorio.ucss.edu.pe/handle/20.500.14095/706>
- Foody, G.M. (2003). Remote sensing of tropical forest environments: Towards the monitoring of environmental resources for sustainable development. *International Journal of Remote Sensing*, 24(20), 4035-4046. Obtenido de <https://doi.org/10.1080/0143116031000103853>
- Foody, G.M. (2008). GIS: biodiversity applications. *Progress in Physical Geography: An International Review of Geographical Work in the Natural and Environmental Sciences*, 32(2), 223-235.
- Franke, I.J., Mattos, J., Salinas, L., Mendoza, C., & Zambrano, S. (2005). Áreas importantes para la conservación de aves en el Perú. En: *BirdLife International & Conservation International (eds.). Áreas importantes para la conservación de las aves en los Andes Tropicales: Sitios prioritarios para la conservación de la biodiversidad. BirdLife International (Serie de conservación de BirdLife N° 14)*, 471-619.
- Gerencia de Recursos Naturales y Gestión del Medio Ambiente (GRRNGMA) - Gobierno Regional de Ayacucho. (2014). *Plan Maestro del Área de Conservación Regional Bosque de Puya Raimondi - Titankayocc*. Vischongo, Ayacucho: s.n.

- Gillespie, T. W., Foody, G. M., Rocchini, D., Giorgi, A. P., & Saatchi, S. (2008). Measuring and modelling biodiversity from space. *Progress in Physical Geography*, 32(2), 203-221.
- Girshick, R., Donahue, J., Darrell, T., & Malik, J. (2014). Rich feature hierarchies for accurate object detection and semantic segmentation. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 580–587. Obtenido de <https://doi.org/10.1109/CVPR.2014.81>
- Gobierno Regional de Ayacucho. (2012). Desarrollo de capacidades en Zonificación Ecológica Económica y Ordenamiento Territorial en la Región Ayacucho. “Estudio Temático: Cobertura vegetal”.
- Gobierno Regional de Ayacucho. (2013a). *Estrategia y plan de acción regional para la diversidad biológica Ayacucho al 2021*. Obtenido de <https://www.cbd.int/doc/nbsap/sbsap/pe-sbsap-ayacucho-es.pdf>
- Gobierno Regional de Ayacucho. (2013b). Estudio: Zonificación Ecológica Económica - Ayacucho. “Propuesta de Zonificación Ecológica Económica de la Región Ayacucho”. Obtenido de <https://sinia.minam.gob.pe/documentos/zonificacion-ecologica-economica-ayacucho>
- Gobierno Regional de La Libertad. (2011). *Plan de Manejo para la Conservación de la Puya raimondii Harms en el Santuario Nacional de Calipuy*. Gerencia Regional del Ambiente.
- Goerlich, F. J., & Cantarino, I. (2010). Un índice de rugosidad del terreno a escala municipal a partir de modelos de elevación digital de acceso público. Fundación BBVA.
- Gómez, G. M., & Mahecha, O. D. (1998). Espacio, territorio y región: conceptos básicos para un proyecto nacional. *Cuadernos de geografía: Revista colombiana de geografía*, 7(1-2), 120-134.
- Gómez, L., & Miranda, F. (1998). Estado de conservación de Puya raimondii (Harms): Evaluación y sugerencias para un plan de acción. *Centro de Datos para la Conservación (CDC)*. La Paz–Bolivia. CDC/IT/002/98.
- Goñi, D., García, M.B., & Guzmán, D. (2006). Métodos para el censo y seguimiento de plantas rupícolas amenazadas. *Pirineos*, 161, 33–58.
- Grau, A., Gómez Romero, S.E., & Aráoz, E. (2010). Puyas andinas. *Ciencia Hoy*, 20(118), 8-15.

- Grekousis, G. (2019). Artificial neural networks and deep learning in urban geography: A systematic review and meta-analysis. *Computers, Environment and Urban Systems*, 74, 244-256.
- Grêt-Regamey, A., Brunner, S. H., & Kienast, F. (2012). Mountain Ecosystem Services: Who Cares? *Mountain Research and Development*, 32, 23–34. Obtenido de <https://doi.org/10.1659/mrd-journal-d-10-00115.s1>
- Guo, Z., Shao, X., Xu, Y., Miyazaki, H., Ohira, W., & Shibasaki, R. (2016). Identification of village building via Google Earth images and supervised machine learning methods. *Remote Sensing*, 8(4), 271.
- Gupta, A. (2022). *Difference between ANN, CNN and RNN*. Recuperado de Geeks for Geeks: <https://www.geeksforgeeks.org/difference-between-ann-cnn-and-rnn/>
- Hamdi, Z. M., Brandmeier, M., & Straub, C. (2019). Forest damage assessment using deep learning on high resolution remote sensing data. *Remote Sensing*, 11(17), 1–14. Obtenido de <https://doi.org/10.3390/rs11171976>
- Hamuda, E., Glavin, M., & Jones, E. (2016). A survey of image processing techniques for plant extraction and segmentation in the field. *Computers and electronics in agriculture*, 125, 184-199.
- Hao, Z., Lin, L., Post, C. J., Mikhailova, E. A., Li, M., Chen, Y., Yu, K., & Liu, J. (2021). Automated tree-crown and height detection in a young forest plantation using mask region-based convolutional neural network (Mask R-CNN). *ISPRS Journal of Photogrammetry and Remote Sensing*, 178, 112–123. Obtenido de <https://doi.org/10.1016/j.isprsjprs.2021.06.003>
- Haris, K., Efstratiadis, S. N., Maglaveras, N., & Katsaggelos, A. K. (1998). Hybrid image segmentation using watersheds and fast region merging. *IEEE Transactions on Image Processing*, 7(12), 1684–1699. Obtenido de <https://doi.org/10.1109/83.730380>
- Harrison, S., & Noss, R. (2017). Endemism hotspots are linked to stable climatic refugia. *Annals of botany*, 119(2), 207–214. Obtenido de <https://doi.org/10.1093/aob/mcw248>
- Hartman, O. (1981). *Puya raimondii* cada vez son menos. *Boletín de Lima*, 10, 79-83.
- He, K., Gkioxari, G., Dollár, P., & Girshick, R. (2020). Mask R-CNN. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 42(2), 386–397. Obtenido de <https://doi.org/10.1109/TPAMI.2018.2844175>

- Hennig, S. (2021). Orchard Meadow Trees: Tree Detection Using Deep Learning in ArcGIS Pro. *GI\_Forum*, 9(2), 82–93. Obtenido de [https://doi.org/10.1553/giscience2021\\_02\\_s82](https://doi.org/10.1553/giscience2021_02_s82)
- Herbei, M. V., Ciolac, V., Şmuleac, A., Nistor, E., & Ciolac, L. (2010). Georeferencing of topographical maps using the software ARCGIS. *Research Journal of Agricultural Science*, 42(3), 595-606. Obtenido de [https://www.researchgate.net/publication/267557639\\_GEOREFERENCING\\_OF\\_TOPOGRAPHICAL\\_MAPS\\_USING\\_THE\\_SOFTWARE\\_ARCGIS](https://www.researchgate.net/publication/267557639_GEOREFERENCING_OF_TOPOGRAPHICAL_MAPS_USING_THE_SOFTWARE_ARCGIS)
- Hermitaño Leon, S. M. (2018). *Escenarios de la Puya Raimondi en relación con los factores meteorológicos de temperatura y precipitación y los antropogénicos en el santuario Nacional de Calipuy (La Libertad) y el Parque Nacional Huascarán (Áncash)* [Tesis de pregrado, Universidad Cesar Vallejo]. Obtenido de <https://hdl.handle.net/20.500.12692/18312>
- Hornung-Leoni, C. T. (2011). Bromelias: plantas alimenticias tradicionales desde tiempos prehispánicos en Latinoamérica. *Polibotánica*, (32), 219–229.
- Hornung-Leoni, C.T., & Sosa, V. (2005). Morphological variation in Puya (Bromeliaceae): an allometric study. *Plant Systematics and Evolution*, 256, 35-53. Obtenido de <https://doi.org/10.1007/s00606-005-0302-z>
- Hossain, M. D., & Chen, D. (2019). Segmentation for Object-Based Image Analysis (OBIA): A review of algorithms and challenges from remote sensing perspective. *ISPRS Journal of Photogrammetry and Remote Sensing*, 150, 115-134.
- Hu, F., Xia, G.-S., Hu, J., & Zhang, L. (2015). Transferring Deep Convolutional Neural Networks for the Scene Classification of High-Resolution Remote Sensing Imagery. *Remote Sensing*, 7(11), 14680–14707. MDPI AG. Obtenido de <http://dx.doi.org/10.3390/rs71114680>
- INDECI. (2004). *Plan De Prevención Ante Desastres: Usos Del Suelo Y Medidas De Mitigación: Ciudad De Ayacucho*.
- INPE. (2018). *Catálogo de imágenes*. Obtenido de <http://www.dgi.inpe.br/CDSR/>
- INPE. (2019). CBERS 04A Imaging Cameras. Obtenido de <http://www.cbbers.inpe.br/sobre/cameras/cbers04a.php>
- Jardel-Peláez, E. (2015). Guía para la caracterización y clasificación de hábitats forestales. *Comisión Nacional Forestal-Programa de las Naciones Unidas para el Desarrollo. Primera Edición. México*.

- Jiang, T., Cui, Z., Zhou, Z., & Cao, Z. (2018). Data augmentation with Gabor filter in deep convolutional neural networks for SAR target recognition. *International Geoscience and Remote Sensing Symposium (IGARSS), 2018*, 689–692. Obtenido de <https://doi.org/10.1109/IGARSS.2018.8518792>
- Julio Filho, A. C., Ambrosio, A. M., Ferreira, M. G. V., & Loureiro, G. (2019). The China-Brazil Earth Resources Satellite-CBERS-4A: a proposal for ground segment based on the space link extension protocol services. En *International Astronautical Congress 70<sup>o</sup>, Washington, DC*.
- Karim, R. (2018). 10 Gradient Descent Optimisation Algorithms + Cheat Sheet. Obtenido de <https://towardsdatascience.com/10-gradient-descent-optimisation-algorithms-86989510b5e9>.
- Kattenborn, T., Leitloff, J., Schiefer, F., & Hinz, S. (2021). Review on Convolutional Neural Networks (CNN) in vegetation remote sensing. *ISPRS Journal of Photogrammetry and Remote Sensing*, 173, 24–49. Obtenido de <https://doi.org/10.1016/j.isprsjprs.2020.12.010>
- Khalid, N., & Shahrol, N. A. (2022). Evaluation the accuracy of oil palm tree detection using deep learning and support vector machine classifiers. In *IOP Conference Series: Earth and Environmental Science* (Vol. 1051, No. 1, p. 012028). IOP Publishing.
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2017). Imagenet classification with deep convolutional neural networks. *Communications of the ACM*, 60(6), 84–90.
- Lambe, A. (2008). IUCN Red List of Threatened Species: *Puya raimondii*. IUCN Red List of Threatened Species™. Obtenido de <https://www.iucnredlist.org/en>
- Lambe, A. (2009). Queen of the Andes (*Puya raimondii*). IUCN Red List of Threatened Species™ 2009. Obtenido de <https://dx.doi.org/10.2305/IUCN.UK.2009-2.RLTS.T168358A6482345.en>
- Laurencelle, J., Logan, T., & Gens, R. (2015). ASF radiometrically terrain corrected ALOS PALSAR products. *ASF-Alaska Satellite Facility*, 1, 12. Obtenido de [https://asf.alaska.edu/wp-content/uploads/2019/03/rtc\\_product\\_guide\\_v1.2.pdf](https://asf.alaska.edu/wp-content/uploads/2019/03/rtc_product_guide_v1.2.pdf)
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436.
- Lee, H. & Kwon, H., (2017). Going deeper with contextual CNN for hyperspectral image classification. *IEEE Trans. Image Process.* 26, 4843–4855.

- Li, W., Fu, H., Yu, L., & Cracknell, A. (2017). Deep Learning Based Oil Palm Tree Detection and Counting for High-Resolution Remote Sensing Images. *Remote Sensing*, 9(1), 22. Obtenido de <https://doi.org/10.3390/rs9010022>
- Li, Y., Zhang, H., Xue, X., Jiang, Y., & Shen, Q. (2018). Deep learning for remote sensing image classification: A survey. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, 8(6), 1–17. Obtenido de <https://doi.org/10.1002/widm.1264>
- Lindenmayer, D.B., & Franklin, J.F. (2002). Conserving forest biodiversity: a comprehensive multiscale approach. *Island Press*, 351.
- Lucchese, L., & Mitra, S. K. (2001). Colour image segmentation: a state-of-the-art survey. *Proceedings-Indian National Science Academy Part A*, 67(2), 207-222.
- Ma, L., Liu, Y., Zhang, X., Ye, Y., Yin, G., & Johnson, B. A. (2019). Deep learning in remote sensing applications: A meta-analysis and review. *ISPRS Journal of Photogrammetry and Remote Sensing*, 152, 166–177. Obtenido de <https://doi.org/10.1016/j.isprsjprs.2019.04.015>
- Mallqui, H.E. (2017). Cuento de individuos de *Puya raimondii* mediante técnicas geomáticas en territorio de la comunidad campesina Cajamarquilla, Ancash. *Revista de Glaciares y Ecosistemas de Montaña*, 2, 79-86. Obtenido de <https://doi.org/10.36580/rgem.i2.79-86>
- Mamani Quispe, D. M., & Mamani Mamani, H. O. (2019). *Determinación del secuestro de dióxido de carbono (CO<sub>2</sub>) en el suelo mediante sumideros de carbono: Puyas de Raimondi (Puya raimondii Harms), Pajonal con Chillihuares y Bofedal, en el distrito de Putina – Puno, 2018* [Tesis de pregrado, Universidad Peruana Unión]. Obtenido de <http://hdl.handle.net/20.500.12840/2181>
- Mardia, K. V., & Hainsworth, T. J. (1988). A Spatial Thresholding Method for Image Segmentation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 10(6), 919–927. Obtenido de <https://doi.org/10.1109/34.9113>
- Maxwell, A. E., Pourmohammadi, P., & Poyner, J. D. (2020). Mapping the topographic features of mining-related valley fills using mask R-CNN deep learning and digital elevation data. *Remote Sensing*, 12(3), 1–23. Obtenido de <https://doi.org/10.3390/rs12030547>
- McRoberts, R.E. (2011). Satellite image-based maps: Scientific inference or pretty pictures? *Remote Sensing of Environment*, 115, 715-724. Obtenido de <https://doi.org/10.1016/j.rse.2010.10.013>

- Meyer, P., Itten, K. I., Kellenberger, T., Sandmeier, S., & Sandmeier, R. (1993). Radiometric corrections of topographically induced effects on Landsat TM data in an alpine environment. *ISPRS Journal of Photogrammetry and Remote Sensing: Official Publication of the International Society for Photogrammetry and Remote Sensing (ISPRS)*, 48(4), 17–28. Obtenido de [https://doi.org/10.1016/0924-2716\(93\)90028-1](https://doi.org/10.1016/0924-2716(93)90028-1)
- MINAM. (2010). Guía de evaluación de flora silvestre. Dirección General de Evaluación Valoración y Financiamiento del Patrimonio Natural. Obtenido de <https://www.gob.pe/institucion/minam/informes-publicaciones/275137-guia-de-evaluacion-de-la-flora-silvestre>
- MINAM. (2019). Sexto informe nacional sobre Diversidad Biológica. La biodiversidad en cifras. Viceministerio de Desarrollo Estratégico de los Recursos Naturales. Obtenido de <https://www.gob.pe/institucion/minam/informes-publicaciones/281709-sexto-informe-nacional-sobre-diversidad-biologica>
- Montesinos, D. (2014). Inventario y estado de conservación de *Puya raimondii* (Bromeliaceae) en el departamento de Moquegua, Perú. *Chloris Chilensis*, 17, 1-9.
- Morales M., & Suni M. (2003). Estudio anatómico foliar de *Puya raimondii* Harm (Bromeliaceae). Libro de resúmenes. XII Reunión Científica del Instituto de Investigación de Ciencias Biológicas “Antonio Raimondi” – Facultad de Ciencias Biológicas – UNMSM. Lima, Perú.
- Morin, D., Planells, M., Guyon, D., Villard, L., Mermoz, S., Bouvet, A., Thevenon, H., Dejoux, J. F., Le Toan, T., & Dedieu, G. (2019). Estimation and mapping of forest structure parameters from open access satellite images: Development of a generic method with a study case on coniferous plantation. *Remote Sensing*, 11(11). Obtenido de <https://doi.org/10.3390/rs11111275>
- Municipalidad Provincial de Vilcas Huamán. (s.f). Plan de Desarrollo Concertado Local de la Provincia de Vilcas Huamán (2009 - 2021).
- Nagendra, H. (2001). Using remote sensing to assess biodiversity. *International Journal Remote Sensing*, 22, 2377–2400.
- Nicholson, C. (2018). Fitogeografía General (Geografía Física). *Editorial Sociedad Geográfica de Lima*, 1, 11-12.
- Odemakinde, E. (2021). Mask R-CNN: A beginner's guide. (10 de noviembre 2021). Obtenido de <https://www.viso.ai/deep-learning/maskr-cnn/>.

- Olofsson, P., Foody, G. M., Herold, M., Stehman, S. V., Woodcock, C. E., & Wulder, M. A. (2014). Good practices for estimating area and assessing accuracy of land change. *Remote Sensing of Environment*, 148, 42–57. Obtenido de <https://doi.org/10.1016/j.rse.2014.02.015>
- Olofsson, P., Foody, G. M., Stehman, S. V., & Woodcock, C. E. (2013). Making better use of accuracy data in land change studies: Estimating accuracy and area and quantifying uncertainty using stratified estimation. *Remote Sensing of Environment*, 129, 122-131.
- Ostendorf, B. (2011). Overview: spatial information and indicators for sustainable management of natural resources. *Ecological Indicators*, 11(1), 97–102.
- Paredes, H. B., & Tamayo, A. N. (2022). *Determinación del índice de electrificación mediante el procesamiento de imágenes satelitales para la zona rural del área de concesión de la Empresa Eléctrica Regional Centro Sur. C.A.* [Tesis de pregrado, Universidad de Cuenca]. Ecuador. Obtenido de <http://dspace.ucuenca.edu.ec/handle/123456789/38476>
- Parente, L., Taquary, E., Silva, A. P., Souza, C., & Ferreira, L. (2019). Next generation mapping: Combining deep learning, cloud computing, and big remote sensing data. *Remote Sensing*, 11(23). Obtenido de <https://doi.org/10.3390/rs11232881>
- Pascual, G., Suni, M., & Vadillo, E. (2003). Avances en el estudio del sistema reproductivo de *Puya raimondii* Harms (Bromeliaceae). Laboratorio de Fisiología Vegetal de la Universidad Nacional Mayor de San Marcos, Perú. Parque Nacional del Huascarán, Ancash – Perú.
- Pepe, M., Costantino, D., Alfio, V. S., Voza, G., & Cartellino, E. (2021). A novel method based on deep learning, gis and geomatics software for building a 3d city model from vhr satellite stereo imagery. *ISPRS International Journal of Geo-Information*, 10(10). Obtenido de <https://doi.org/10.3390/ijgi10100697>
- Perona, P., & Malik, J. (1990). Scale-space and edge detection using anisotropic diffusion. *IEEE Transactions on pattern analysis and machine intelligence*, 12(7), 629-639.
- Pešek, O. (2018). *Mask R-CNN in GRASS GIS* [Master's Thesis, Czech Technical University in Prague]. Obtenido de <http://hdl.handle.net/10467/77344>
- Pettorelli, N., Safi, K., & Turner, W. (2014). Satellite remote sensing, biodiversity research and conservation of the future. *Philosophical transactions of the Royal Society of London. Series B, Biological sciences*, 369(1643), 20130190. Obtenido de <https://doi.org/10.1098/rstb.2013.0190>

- Pineda, J. (2017). *Modelo de optimización del consumo energético en trenes mediante el diseño geométrico vertical sinusoidal y su impacto en el coste de la construcción de la infraestructura* [Tesis de doctorado, Universitat Politècnica de València]. España. Obtenido de <https://doi.org/10.4995/Thesis/10251/90546>
- Prado-Aliaga, G.E., J.C. Salcedo-Aliaga, W.W. Vicuña-Zevallos, M.L. Suni-Ninataype. (2021). Las poblaciones de *Puya raimondii* de la provincia de Chupaca, Junín, Perú: propuesta de un método de delimitación espacial y evaluación del estado actual. *Chloris Chilensis*, 24(1), 94-118.
- Prasad, N., Semwal, M., & Roy, P.S. (2015). *Remote sensing and GIS for Biodiversity Conservation*. En: Upreti, D., Divakar, P., Shukla, V., Bajpai, R. (eds) *Recent Advances in Lichenology*. Springer, 151–179. Obtenido de [https://doi.org/10.1007/978-81-322-2181-4\\_7](https://doi.org/10.1007/978-81-322-2181-4_7)
- Pulgar Vidal, J. (1981). *Geografía del Perú: las ocho regiones naturales del Perú*. Editorial Universo.
- Pullin, A. S. (2002). *Conservation Biology*. Cambridge University Press. Obtenido de <http://doi.org/10.1017/CBO9781139051927>
- Radoux, J., & Bogaert, P. (2017). Good Practices for Object-Based Accuracy Assessment. *Remote Sensing*, 9, 646. Obtenido de <https://doi.org/10.3390/rs9070646>
- Riley, S.J., DeGloria, S.D. & Elliott, R. (1999). A terrain ruggedness index that quantifies topographic heterogeneity. *Intermountain Journal of Science*, 5, 23–27.
- Rivera, C.A. (1985). *Puya raimondii* Harms. *Boletín de Lima*, 7: 85-91.
- Rodríguez, E., Briceño, J., Leiva, S., Pollack, L., Alvítez, E., & Gutiérrez, J. (2020). Nuevos registros de localidades para *Puya raimondii* Harms (Bromeliaceae) en la región La Libertad, Perú. *Sagasteguiana*, 8(1), 23-42.
- Ronneberger, O., Fischer, P., & Brox, T. (2015). U-Net: Convolutional Networks for Biomedical Image Segmentation. *En Lecture Notes in Computer Science (pp. 234–241)*. Springer Obtenido de [https://doi.org/10.1007/978-3-319-24574-4\\_28](https://doi.org/10.1007/978-3-319-24574-4_28)
- Rouse, J.W., Haas, R.W., Schell, J.A., Deering, D.H., & Harían, J.C. (1974). Monitoring vegetation systems in the great plains with ERTS. In: *Third ERTS Symposium*, 10–14 December 1974, Washington, USA, (1), 48–62.
- Rozzi, S., & Nazionale, P. (2015). Una experiencia de gestión en áreas protegidas a través del deporte, para la promoción del desarrollo alternativo sostenible. *Perfil de Proyecto Para El Fortalecimiento de Capacidades Locales Dirigidas Al*

*Logro de Las Eco-Sostenibilidad Del A.C.R. Rodal de Puya raimondii – “Titankayocc”, 46.*

- Russakovsky, O., Deng, J., Su, H., Krause, J., Satheesh, S., Ma, S., Huang, Z., Karpathy, A., Khosla, A., Bernstein, M., & Berg, A. C. (2015). ImageNet Large Scale Visual Recognition Challenge. *International Journal of Computer Vision*, 211–252. Obtenido de <https://doi.org/10.1007/s11263-015-0816-y>
- Salazar, J., Cáceres, F., Poma, I., & Raimundo, F.M. (2010). Diagnóstico del estado actual de conservación de Puya raimondii en Arequipa (Perú). *Quaderni di Botanica Ambientale e Applicata*, 21, 85-93.
- Salinas, L., Arana, C., & Suni, M. (2007). El néctar de especies de Puya como recurso para picaflores Altoandinos de Ancash, Perú. *Revista Peruana de Biología*, 14(1), 129–134. Obtenido de <https://doi.org/10.15381/rpb.v14i1.2166>
- Sanchez, E., Quinteros, Z., & Tori, W. (1998). Estado actual y tendencia de una población de Puya raimondii del Parque Nacional Huascarán, Ancash, Perú. *Libro de Resúmenes del IV Congreso Latinoamericano de Ecología*, 3-3.
- Schiewe, J. (2002). Segmentation of high-resolution remotely sensed data-concepts, applications and problems. *International Archives of Photogrammetry Remote Sensing and Spatial Information Sciences*, 34(4), 380-385.
- Secretaría del Convenio de Diversidad Biológica, & Comisión Holandesa para Evaluación Ambiental. (2006). *Cuaderno Técnico CDB No. 26 la diversidad biológica en las evaluaciones de impacto*. Documento de antecedentes de la Decisión VII/28 del Convenio sobre la Diversidad Biológica. Obtenido de <http://www.eia.nl/ncea/pdfs/biodiversityeaisea.pdf>
- SERNANP. (2011). Servicio Nacional de Áreas Naturales Protegidas por el Estado.
- Sgorbati, S., Labra, M., Grugni, E., Barcaccia, G., Galasso, G., Boni, U., Mucciarelli, M., Citterio, S., Benavides Iramátegui, A., Venero Gonzales, L., & Scannerini, S. (2004). A Survey of Genetic Diversity and Reproductive Biology of *Puya raimondii* (Bromeliaceae), the Endangered Queen of the Andes. *Plant Biology*, 6, 222-230. Obtenido de <https://doi.org/10.1055/s-2004-817802>
- Shiu, Y. S., Lee, R. Y., & Chang, Y. C. (2023). Pineapples' Detection and Segmentation Based on Faster and Mask R-CNN in UAV Imagery. *Remote Sensing*, 15(3). Obtenido de <https://doi.org/10.3390/rs15030814>

- Silverio Torres, W. C., & Jaquet, J. (2003). "Cartographie provisoire de la couverture du sol du Parc national Huascarán (Perou), à l'aide des images TM de Landasat -5" *Teledetection*, 3(1), 69-83.
- Silverio Torres, W. C., & Jaquet, J. (2009). Prototype land-cover mapping of the Huascarán Biosphere Reserve (Peru) using a digital elevation model, NDSI and NDVI indices. *Journal of Applied Remote Sensing*, 3(033516). Obtenido de <https://doi.org/10.1117/1.3106599>
- Skidmore, A. K., Pettorelli, N., Coops, N. C., Geller, G. N., Hansen, M., Lucas, R., Múcher, S., O'Connor, B., Paganini, M., Pereira, H. M., Schaepman, M. E., Turner, W., Wang, T., & Wegmann, M. (2015). Environmental science: Agree on biodiversity metrics to track from space. *Nature*, 523(7561), 403-405. Obtenido de <https://doi.org/10.1038/523403a>
- Slaughter, D. C., Giles, D. K., & Downey, D. (2008). Autonomous robotic weed control systems: A review. *Computers and electronics in agriculture*, 61(1), 63-78.
- Song, C. (2005). Spectral mixture analysis for subpixel vegetation fractions in the urban environment: How to incorporate endmember variability? *Remote Sensing of Environment*. 95, 248-263. Obtenido de <https://doi.org/10.1016/j.rse.2005.01.002>.
- Stehman, S. V., & Czaplewski, R. L. (1998). Design and analysis for thematic map accuracy assessment: fundamental principles. *Remote sensing of environment*, 64(3), 331-344.
- Stehman, S. V., & Foody, G. M. (2019). Key issues in rigorous accuracy assessment of land cover products. *Remote Sensing of Environment*, 231(5), 111199. Obtenido de <https://doi.org/10.1016/j.rse.2019.05.018>
- Sze, V., Chen, Y. H., Yang, T. J., & Emer, J. S. (2017). Efficient Processing of Deep Neural Networks: A Tutorial and Survey. *Proceedings of the IEEE*, 105(12), 2295–2329. Obtenido de <https://doi.org/10.1109/JPROC.2017.2761740>
- Szykalski, J., Quijano, E. B., Krajewska, K., & Mikocik, Ł. (2016). Most Recent Results Of American Studies / Avances Recientes En La Americanística Mundial. *Tambo. Boletín de Arqueología*, 3, 255-282.
- Tscharntke, T., Klein, A.M., Kruess, A., Steffan-Dewenter, I. & Thies, C. (2005), Landscape perspectives on agricultural intensification and biodiversity – ecosystem service management. *Ecology Letters*, 8, 857-874. Obtenido de <https://doi.org/10.1111/j.1461-0248.2005.00782.x>

- Tumi Calisaya, M. L. (2021). *Estructura y Diversidad Genética de Puya raimondii Harms "El gigante de los Andes Peruanos"* [Tesis de maestría, Universidad Ricardo Palma]. Perú. Obtenido de <https://repositorio.urp.edu.pe/handle/URP/4020>
- Turner, W., Spector, S., Gardiner, N., Fladeland, M., Sterling, E., & Steininger, M. (2003). Remote sensing for biodiversity science and conservation. *Trends in Ecology & Evolution*, 18, 306–314.
- Vadillo, G., Suni, M., & Cano, A. (2004). Viabilidad y germinación de semillas de *Puya raimondii* Harms (Bromeliaceae). *Revista Peruana de Biología*, 11, 71- 78.
- Vadillo, G., Suni, M., & Roca W. (2007). *Evaluación de la diversidad genética y morfológica de Puya raimondii*. Serie de publicaciones de Flora y Fauna silvestre. Instituto Nacional de Recursos Naturales, 1-13.
- Vásquez Tineo, M. (2018). *Mejoramiento de la productividad del palto y tara a través de fortalecimiento de capacidades de los productores en comunidades del distrito de Vischongo, Vilcashuamán - Ayacucho* [Tesis de pregrado, Universidad Nacional San Cristóbal de Huamanga]. Perú. Obtenido de <http://repositorio.unsch.edu.pe/handle/UNSCH/3098>
- Vega, L. A., Hirata, Y., Santos, L. C. V., & Torobeo, N. S. (2018). Natural forest mapping in the Andes (Peru): A comparison of the performance of machine-learning algorithms. *Remote Sensing*, 10(5). Obtenido de <https://doi.org/10.3390/rs10050782>
- Venero, J.L. (1984). El Rodal de *Puya raimondii* en Lares - Calca. *Boletín de Lima*, 6, 65-69.
- Vetrivel, A., Gerke, M., Kerle, N., Nex, F., & Vosselman, G. (2018). Disaster damage detection through synergistic use of deep learning and 3D point cloud features derived from very high resolution oblique aerial images, and multiple-kernel-learning. *ISPRS Journal of Photogrammetry and Remote Sensing: Official Publication of the International Society for Photogrammetry and Remote Sensing (ISPRS)*, 140, 45–59. Obtenido de <https://doi.org/10.1016/j.isprsjprs.2017.03.001>
- Villiger, F. (1981). Rodales de *Puya raimondii* y su protección. *Boletín de Lima*, 10, 84-91.
- Wei X. (2017). *Design of college English classroom activities based on the theory of multiple intelligences*. *Boletín Técnico/Technical Bulletin*, 55(16), 579-584.

- Whittaker, R.J., Araujo, M.B., Jepson, P., Ladle, R.J., Watson, J.E.M., & Willis, K.J. (2005). Conservation biogeography: assessment and prospect. *Diversity and Distributions*, 11, 3–23
- Woolf, T. (2018). *Deep Convolutional Neural Networks for Remote Sensing Investigation of Looting of the Archeological Site of Al-Lisht, Egypt* [Master's Thesis, University of Southern California]. United States. Obtenido de <https://spatial.usc.edu/wp-content/uploads/formidable/12/Timberlynn-Woolf.pdf>.
- Yao, X., & Liu, Y. (2005). Search Methodologies. *Springer*. chapter Machine Learning, 341–373pp.
- Yekeen, S. T., Balogun, A. L., & Yusof, K. B. W. (2020). A novel deep learning instance segmentation model for automated marine oil spill detection. *ISPRS Journal of Photogrammetry and Remote Sensing*, 167, 190-200.
- Yuan, Q., Shen, H., Li, T., Li, Z., Li, S., Jiang, Y., Xu, H., Tan, W., Yang, Q., Wang, J., Gao, J., & Zhang, L. (2020). Deep learning in environmental remote sensing: Achievements and challenges. *Remote Sensing of Environment*, 24, 111716. Obtenido de <https://doi.org/10.1016/j.rse.2020.111716>
- Zavaleta, E.H. (2017). *Puya raimondii* Harms del Santuario Nacional de Calipuy. *Revista de Glaciares y Ecosistemas de Montaña*, 3, 113-119. Obtenido de <https://doi.org/10.36580/rgem.i3.113-119>
- Zeiler, M. D., & Fergus, R. (2014). Visualizing and understanding convolutional networks. En: *European conference on computer vision (ECCV)*, 818-833. Obtenido de [https://doi.org/10.1007/978-3-319-10590-1\\_53](https://doi.org/10.1007/978-3-319-10590-1_53)
- Zhang, L., Zhang, L., & Kumar, V. (2016). Deep learning for Remote Sensing Data. *IEEE Geoscience and Remote Sensing Magazine*, 4(2), 22–40.
- Zhang, X., Xiao, P., Feng, X., & Yuan, M. (2017). Separate segmentation of multi-temporal high-resolution remote sensing images for object-based change detection in urban area. *Remote Sensing of Environment*, 201, 243-255.
- Zuschlag, S.F. (2014). *Puya raimondii: A study in the National Sanctuary of Calipuy in the Andes Mountains of northern Peru* [Master's Thesis, Oregon State University]. United States. Obtenido de <https://www.rufford.org/projects/shannon-fletcher-zuschlag/assessing-the-status-of-the-endangered-puya-raimondii-population-in-the-national-sanctuary-of-calipuy/>

# ANEXOS

## Anexo 1

Cuadro de densidad por grilla de la *P. raimondii*.

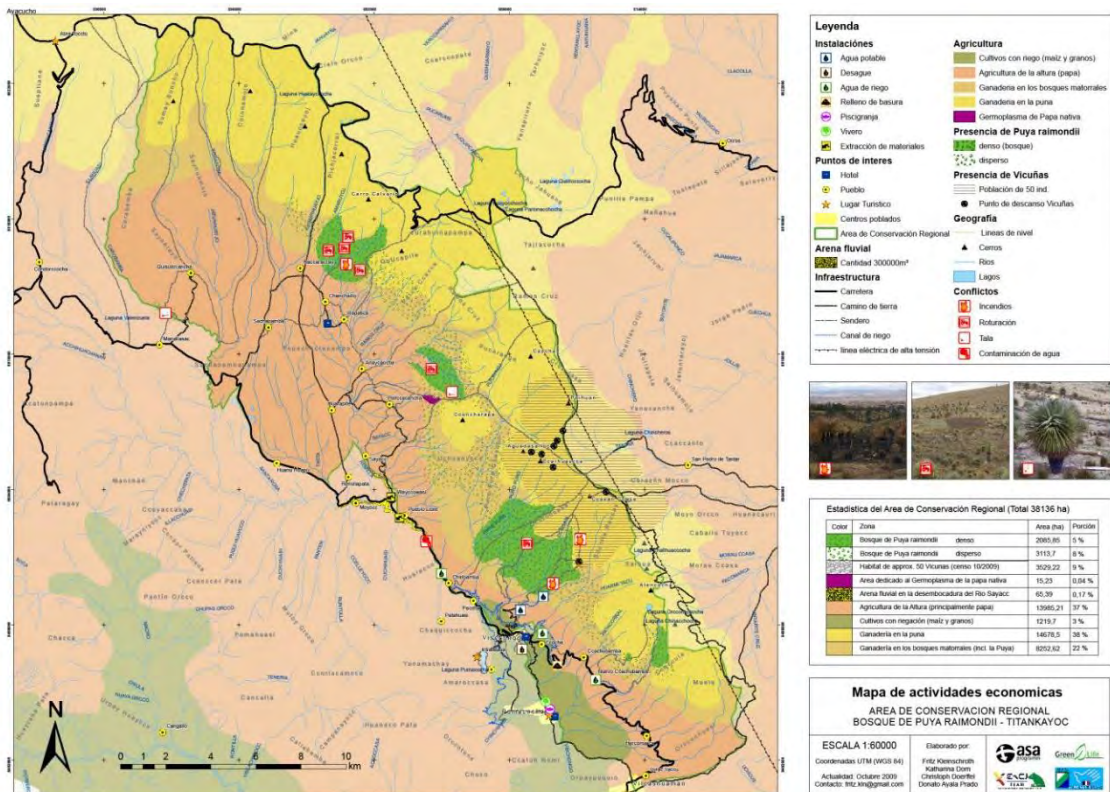
N° Cuadrícula	Perímetro de Cuadrícula (m)	Área de Cuadrícula (Ha)	N° Puyas	Biomasa aérea (Ha)	Promedio de NDVI	Área foliar (Ha)
0	3515.13	76.28	7	0.01	0.239	0.0001
1	3923.05	98.76	1645	2.50	0.241	0.0253
2	4000.00	100.00	2322	3.68	0.222	0.0368
3	4000.00	100.00	1181	1.89	0.241	0.0189
4	4000.00	100.00	684	1.05	0.245	0.0105
5	4000.00	100.00	497	0.79	0.235	0.0079
6	4000.00	100.00	940	1.53	0.177	0.0153
7	4000.00	100.00	307	0.49	0.174	0.0049
8	4000.00	100.00	275	0.48	0.200	0.0048
9	4000.00	100.00	2255	3.24	0.231	0.0324
10	4000.00	100.00	2159	3.22	0.231	0.0322
11	4000.00	100.00	4178	5.84	0.226	0.0584
12	4000.00	100.00	1076	1.64	0.265	0.0164
13	4000.00	100.00	42	0.07	0.247	0.0007
14	4000.00	100.00	341	0.57	0.196	0.0057
15	4000.00	100.00	251	0.44	0.163	0.0044
16	4000.00	100.00	1078	1.66	0.220	0.0166
17	4000.00	100.00	1333	2.07	0.207	0.0207
18	4000.00	100.00	4108	5.53	0.214	0.0553
19	4000.00	100.00	3537	4.87	0.235	0.0487
20	4000.00	100.00	349	0.55	0.292	0.0055
21	4000.00	100.00	1137	1.72	0.237	0.0172
22	4000.00	100.00	5781	7.70	0.253	0.0770
23	4000.00	100.00	3513	4.52	0.253	0.0452
24	4000.00	100.00	487	0.69	0.259	0.0069
25	4000.00	100.00	112	0.19	0.244	0.0019
26	4000.00	98.38	754	1.42	0.235	0.0144
27	4000.00	100.00	1264	2.13	0.222	0.0213
28	4000.00	100.00	1078	1.51	0.229	0.0151
29	4000.00	100.00	1521	2.12	0.262	0.0212
30	4000.00	100.00	1029	1.67	0.243	0.0167
31	3726.83	85.03	373	0.66	0.224	0.0078
32	4362.27	94.09	601	1.11	0.214	0.0118
33	4000.00	100.00	1024	1.83	0.208	0.0183
34	4000.00	100.00	1843	2.64	0.227	0.0264
35	4000.00	100.00	1168	1.92	0.242	0.0192
36	4000.00	100.00	92	0.17	0.287	0.0017
37	3889.52	93.98	16	0.02	0.301	0.0002

38	5121.51	87.35	447	0.79	0.188	0.0090
39	4000.00	100.00	830	1.28	0.197	0.0128
40	4000.00	100.00	981	1.74	0.212	0.0174
41	4000.00	100.00	610	1.08	0.249	0.0108
42	4000.00	100.00	308	0.48	0.216	0.0048
43	3183.89	51.66	233	0.31	0.270	0.0060
44	3965.11	95.95	184	0.30	0.203	0.0031
45	5533.33	117.71	28	0.05	0.229	0.0004
46	3698.06	60.11	27	0.05	0.193	0.0009
47	3781.64	68.59	582	0.93	0.187	0.0135
48	5272.20	102.40	692	1.15	0.202	0.0112
49	4557.94	116.61	18	0.03	0.282	0.0002
50	5146.79	105.73	93	0.15	0.229	0.0014
51	8051.55	89.20	518	0.86	0.228	0.0096
52	5062.08	95.04	22	0.04	0.249	0.0004
53	5219.78	103.32	16	0.02	0.201	0.0002
54	5740.11	110.65	93	0.15	0.237	0.0014
55	4892.64	75.50	5	0.01	0.315	0.0001
56	3905.49	90.55	338	0.46	0.225	0.0051
57	4342.59	115.74	193	0.28	0.205	0.0025
58	5385.86	114.73	189	0.31	0.183	0.0027
59	5057.64	116.73	989	1.44	0.221	0.0123
60	6009.66	84.79	69	0.12	0.189	0.0014
61	4428.61	121.43	523	0.87	0.177	0.0072
62	4261.99	111.82	214	0.36	0.185	0.0032
63	5284.57	90.23	46	0.08	0.149	0.0009

*Fuente: Elaboración propia.*

## Anexo 2

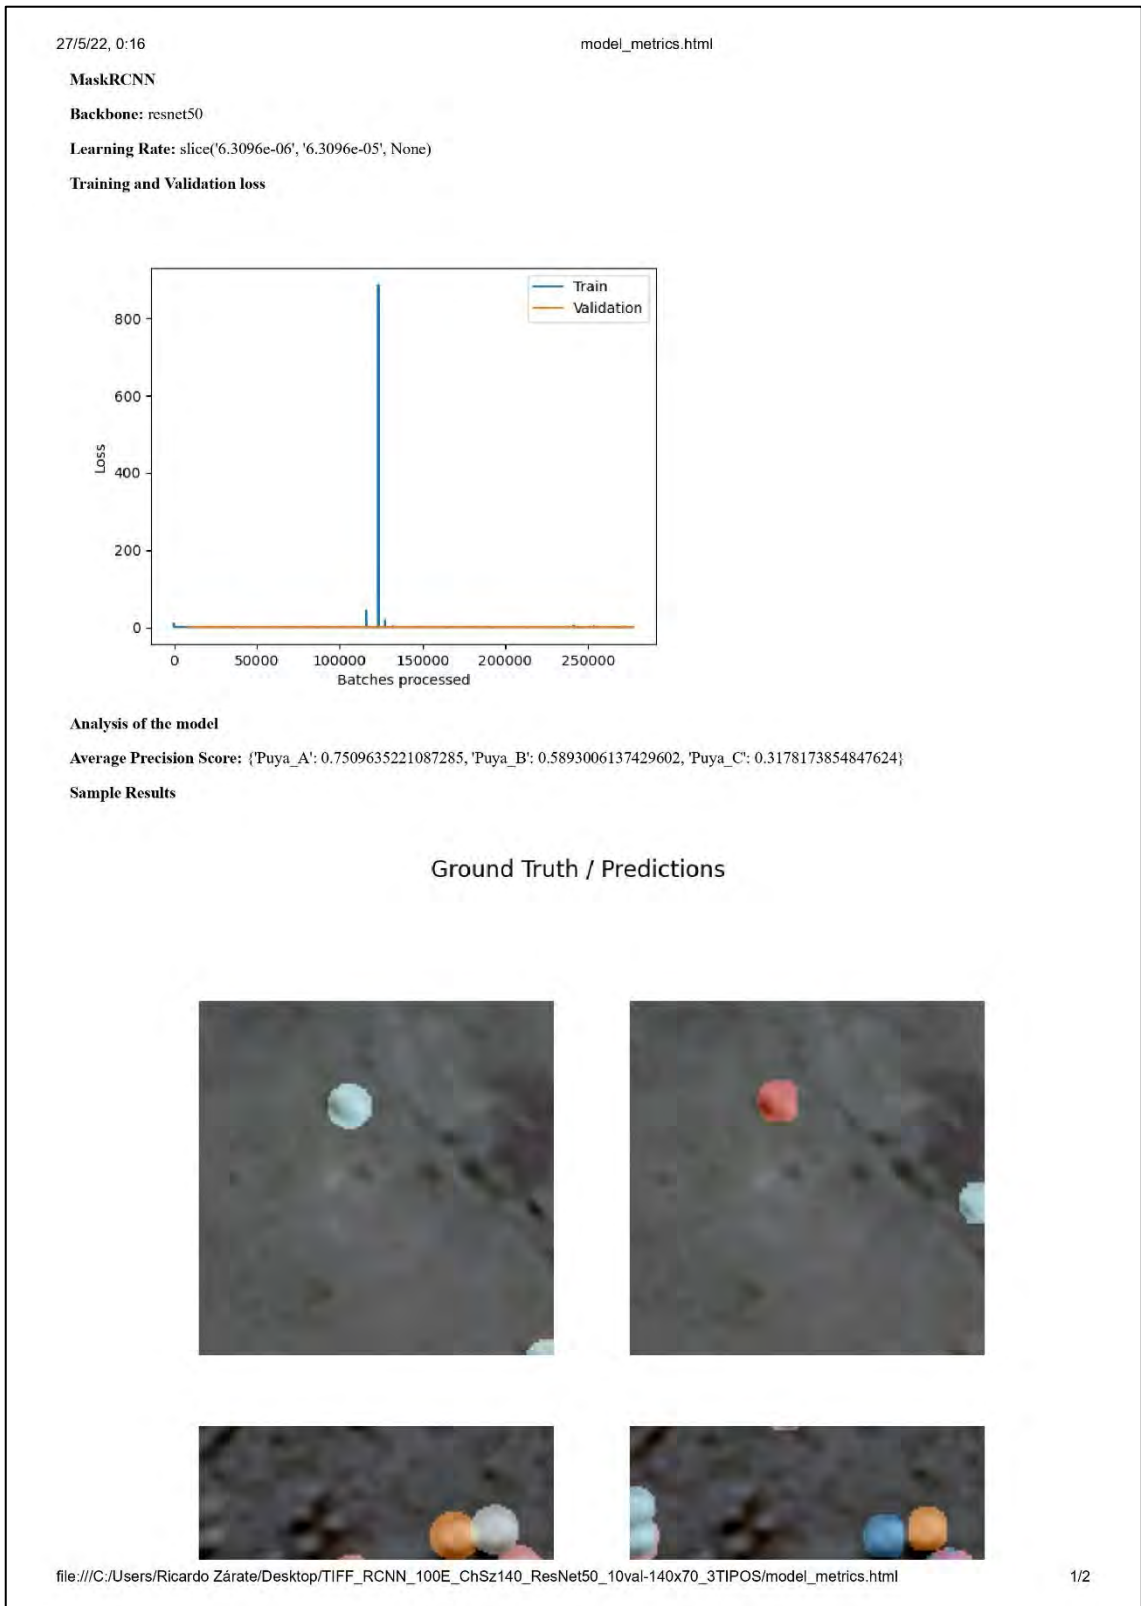
### Mapa de actividades económicas Proyecto MARSINCA 2008.



Fuente: Rozzi y Nazionale, 2015.





### Anexo 3

Reporte de métricas del modelo *Deep Learning* para la detección de *P. raimondii*.



27/5/22, 0:16

model\_metrics.html



file:///C:/Users/Ricardo Zárata/Desktop/TIFF\_RCNN\_100E\_ChSz140\_ResNet50\_10val-140x70\_3TIPOS/model\_metrics.html

2/2

*Fuente: Elaboración propia.*