



CLÁUSULA DE CESIÓN DE DERECHO DE PUBLICACIÓN DE TESIS

Yo Víctor Eduardo Tacuri Espinoza

autor/a de la tesis titulada:

**BIOMASA FORRAJERA EN ÁREAS DE PASTOREO, MEDIANTE UN SISTEMA AÉREO OPERADO REMOTAMENTE (RPAS)
ESTUDIO DE CASO: GRANJA NERO CANTÓN CUENCA, PROVINCIA DEL AZUAY
– ECUADOR**

mediante el presente documento, declaro que la obra mencionada es de mi exclusiva autoría y producción. Esta tesis ha sido elaborada como uno de los requisitos previos para la obtención del título de: **“Magíster en Teledetección y Sistemas de Información Geográfica”** en la Universidad Andina Simón Bolívar, Sede Central Sucre.

Cesión de Derechos:

1. **Derechos Cedidos:** A partir de la fecha de la defensa de grado, cedo a la Universidad Andina Simón Bolívar, Sede Central Sucre, los derechos exclusivos de reproducción, comunicación pública, distribución y divulgación de la obra. La Universidad está autorizada a utilizar esta obra por cualquier medio, actualmente conocido o que se desarrolle en el futuro, siempre y cuando dicha utilización no se realice con fines de lucro. Esta cesión incluye la reproducción total o parcial en formatos virtual, electrónico, digital, u óptico, así como su uso en red local e Internet.
2. **Responsabilidades del Autor:** Declaro que, en caso de presentarse cualquier reclamación o demanda por parte de terceros respecto de los derechos de autor de la obra mencionada, asumiré toda la responsabilidad legal frente a dichos terceros y frente a la Universidad, incluyendo, sin limitación, la defensa de tales reclamaciones y el mantenimiento de la Universidad indemne frente a las mismas.
3. **Entrega de Ejemplares:** En esta fecha, entrego a la biblioteca de la Universidad un ejemplar de la obra y sus anexos, en formatos impreso y digital o electrónico.

Fecha: 18 de noviembre de 2024

Firma:



UNIVERSIDAD ANDINA SIMÓN BOLÍVAR
SEDE CENTRAL
Sucre – Bolivia

**MAESTRÍA EN TELEDETECCIÓN Y SISTEMAS DE
INFORMACIÓN GEOGRÁFICA**

**BIOMASA FORRAJERA EN ÁREAS DE PASTOREO, MEDIANTE
UN SISTEMA AÉREO OPERADO REMOTAMENTE (RPAS)**

**ESTUDIO DE CASO: GRANJA NERO CANTÓN CUENCA, PROVINCIA DEL
AZUAY - ECUADOR**

**Tesis presentada para optar al Grado
Académico de Magíster en Teledetección
y Sistemas de Información Geográfica**

MAESTRANTE: EDUARDO TACURI ESPINOZA

Cuenca – Ecuador

2024



UNIVERSIDAD ANDINA SIMÓN BOLÍVAR
SEDE CENTRAL
Sucre – Bolivia

**MAESTRÍA EN TELEDETECCIÓN Y SISTEMAS DE
INFORMACIÓN GEOGRÁFICA**

**BIOMASA FORRAJERA EN ÁREAS DE PASTOREO, MEDIANTE
UN SISTEMA AÉREO OPERADO REMOTAMENTE (RPAS)**

**ESTUDIO DE CASO: GRANJA NERO CANTÓN CUENCA, PROVINCIA DEL
AZUAY - ECUADOR**

**Tesis presentada para optar al Grado
Académico de Magíster en Teledetección
y Sistemas de Información Geográfica**

MAESTRANTE: EDUARDO TACURI ESPINOZA

TUTOR: LUCIA LUPERCIO NOVILLO

Cuenca – Ecuador

2024

DEDICATORIA

A Dios por darme la fortaleza para seguir y no desistir, a mi esposa Fabiola y a mis hijas Doménica, Paulina y Karen, quienes han sido mis compañeras y apoyo constante durante todo este proceso. Gracias por ser mi motivación y por estar siempre presentes en mi vida.

AGRADECIMIENTOS

Mi sincero agradecimiento a Dios por brindarme la fortaleza para alcanzar esta meta. A mi tutora de tesis, Ing. Lucía Lupercio P.hD., por su guía, paciencia y valiosas sugerencias que permitieron mejorar mi trabajo de manera significativa. Agradezco al Ing. Alberto Macancela y al Ing. Mateo López MSc., del Laboratorio de GEOMATICA de la Facultad de Ciencias Agropecuarias por su apoyo y sus valiosos aportes en la elaboración de esta tesis. Al Decanato de la Facultad de Ciencias Agropecuarias y a la Dirección Académica y Administrativa de la Granja Nero de la Universidad de Cuenca, por permitirme trabajar en sus predios para desarrollar esta Investigación. Finalmente, agradezco a la Universidad Andina Simón Bolívar – sede central Sucre - Bolivia, y a sus Docentes, por brindarme la oportunidad de llevar a cabo este proyecto académico y por su compromiso con la educación de excelencia.

RESUMEN

En los últimos años, el avance de las nuevas tecnologías ha abierto oportunidades para la investigación y desarrollo de métodos indirectos destinados a la determinación de biomasa. Específicamente, se ha explorado el uso de vehículos aéreos operados remotamente (RPAS) equipados con cámaras RGB. Sin embargo, en el área de pastos o forrajes, hay escasa de información disponible. Esta brecha en el conocimiento es lo que impulsa el desarrollo de la presente investigación, cuyo objetivo principal es determinar el volumen de biomasa sobre el suelo en zonas de pastoreo rotacional en la granja "Nero", situada en la provincia del Azuay, Ecuador.

En este estudio se empleó fotografía aérea capturada mediante un sistema aéreo operado remotamente, fotografía que fue procesada utilizando software especializado para obtener el Modelo Digital de Superficie (MDS), que para nuestro caso corresponde el modelo digital de cultivo (MDC) de las áreas de muestreo. Paralelamente, se realizó un levantamiento topográfico para obtener el Modelo Digital de Terreno (MDT), lo que permitió identificar las variaciones de altura y posteriormente calcular el volumen digital en cada unidad de muestreo.

Además, se llevó a cabo el aforo de pastos utilizando el método tradicional, seleccionando aleatoriamente 44 sitios de muestreo con marcos de medición de 1m², aquí se midió altura del pasto, luego se procedió a cortar y pesar la producción obtenida, lo que proporcionó los datos necesarios para calcular el peso de la biomasa fresca y determinar el volumen real. Posteriormente, al secar las muestras en una estufa, permitió obtener el peso de la biomasa seca.

Con el análisis de correlación de los datos obtenidos, se obtuvo la relación entre volúmenes cercano a 1, al igual que con la altura de pasto y la relación entre la biomasa digital y real. Las relaciones entre volumen digital y altura digital con biomasa fresca obtuvieron un coeficiente de correlación por encima de 0.90 indicándonos la existencia de una correlación fuerte. En cuanto al p valor los resultados demuestran que se cumple con la condición de ser inferior al nivel de significancia impuesto ($p < 0.05$).

Posteriormente se generó modelos de entrenamiento y prueba para ser validados con el uso de la validación cruzada k-fold. El modelo de altura alcanzó un $R^2 = 0.955$ con la siguiente ecuación resultante: $y = 1.008x - 0.0039$. Para volumen de pasto se obtuvo un $R^2 = 0.985$ con la siguiente ecuación $y = 0.127x - 0.044$ y la biomasa con un $R^2 = 0.985$, generando la siguiente ecuación resultante $y = 0.970x + 99.702$.

Estos resultados evidencian que el uso del sistema aéreo operado a distancia es un método confiable para determinar la altura, volumen y biomasa de pasto, mediante el modelado 3D de fotografía aérea.

ÍNDICE GENERAL

| | |
|---|----------|
| CAPÍTULO I. INTRODUCCIÓN..... | 1 |
| 1.1 Justificación..... | 2 |
| 1.2 Planteamiento del problema | 4 |
| 1.2.1 Situación problemática | 4 |
| 1.2.2 Formulación del problema | 5 |
| 1.3 Delimitación..... | 6 |
| 1.3.1 Objeto de estudio | 6 |
| 1.3.2 Campo de acción..... | 6 |
| 1.4 Objetivos | 6 |
| 1.4.1 Objetivo general | 6 |
| 1.4.2 Objetivos específicos..... | 6 |
| 1.5 Hipótesis..... | 7 |
| 1.5.1 Identificación de variables | 7 |
| 1.5.2 Análisis de indicadores | 7 |
| 1.5.3 Operativización de las variables | 7 |
| 1.6 Metodología de la investigación..... | 8 |
| 1.6.1 Aforo tradicional por muestreo en pastizales | 8 |
| 1.6.2 Generación de geo información mediante sensor operado remotamente11 | |
| 1.6.2.1 Planificación de vuelo | 12 |
| 1.6.3 Ubicación de puntos de apoyo fotogramétrico (PAF)..... | 13 |
| 1.6.4 Ejecución del vuelo..... | 14 |
| 1.6.5 Obtención de topografía | 17 |
| 1.6.6 Determinación del volumen digital de biomasa..... | 21 |

| | | |
|--|--|-----------|
| 1.6.7 | Análisis estadístico | 23 |
| CAPÍTULO II. MARCO TEÓRICO..... | | 25 |
| 2.1 | Biomasa forrajera | 25 |
| 2.2 | Determinación de Biomasa..... | 26 |
| 2.3 | Sistemas aéreos operados remotamente | 28 |
| 2.3.1 | Tipos de RPAS de acuerdo a su estructura | 28 |
| 2.3.2 | RPAS Autel Evo II | 28 |
| 2.3.3 | Uso de RPAS en la agricultura | 29 |
| 2.4 | Proceso fotogramétrico..... | 30 |
| 2.5 | La validación cruzada | 32 |
| CAPÍTULO III. MARCO CONTEXTUAL..... | | 34 |
| 3.1 | Ubicación del área en estudio..... | 34 |
| 3.2 | Caracterización Geomorfológica y Topográfica | 35 |
| 3.3 | Caracterización Edafológica | 38 |
| 3.4 | Caracterización Climática | 40 |
| 3.4.1 | Precipitación..... | 40 |
| 3.4.2 | Temperatura | 42 |
| 3.5 | Cobertura y uso del suelo..... | 44 |
| CAPÍTULO IV. RESULTADOS..... | | 49 |
| 4.1 | Obtención de imágenes..... | 49 |
| 4.1.1 | Nube de puntos densa..... | 50 |
| 4.1.2 | Levantamiento topográfico de cada área de muestreo | 51 |
| 4.1.3 | Volumen de biomasa | 52 |
| 4.1.3.1 | Volumen real..... | 52 |
| 4.1.3.2 | Volumen con modelación digital..... | 54 |

| | | |
|-------|--------------------------------|-----------|
| 4.1.4 | Relación entre variables | 55 |
| 4.1.5 | Modelos de regresión | 57 |
| 4.1.6 | Determinación de biomasa | 62 |
| 4.2 | Discusión..... | 64 |
| 4.3 | Conclusiones | 66 |
| 4.4 | Recomendaciones..... | 67 |
| | BIBLIOGRAFÍA..... | 69 |
| | ANEXOS | 77 |

ÍNDICE DE FIGURAS

| | |
|---|----|
| Figura 1. Áreas de toma de datos al interior de un potrero | 9 |
| Figura 2. Planificación de vuelo en el software Autel explorer | 13 |
| Figura 3. Lonas o dianas utilizadas para levantamiento de puntos de apoyo... .. | 14 |
| Figura 4. Aeronave Autel Evo II RTK | 15 |
| Figura 5. Flujo de trabajo en Agisoft Metashape Professional | 16 |
| Figura 6. Nube de puntos – MDS, polígono 13 ^a | 17 |
| Figura 7. Nube de puntos en levantamiento topográfico | 20 |
| Figura 8. Modelo digital de terreno | 21 |
| Figura 9. Análisis estadístico | 24 |
| Figura 10. Diagrama del procesamiento 3D de imágenes con SFM | 31 |
| Figura 11. Proceso de cross-validation para k=5 | 33 |
| Figura 12. Ubicación del área de estudio a nivel nacional, provincial y cantonal | 34 |
| Figura 13. Ubicación del área de estudio en la granja Nero - potreros..... | 35 |
| Figura 14. Unidades geomorfológicas..... | 36 |
| Figura 15. Pendientes de la granja Nero..... | 37 |
| Figura 16. Suelos de la granja Nero | 39 |
| Figura 17. Distribución espacial de la precipitación en mm..... | 42 |
| Figura 18. Distribución espacial de la temperatura en °C | 44 |
| Figura 19. Orto imagen granja Nero | 45 |
| Figura 20. Ortofoto área de pastos | 46 |
| Figura 21. Uso – cobertura vegetal..... | 47 |
| Figura 22. Pares estereoscópicos..... | 49 |
| Figura 23. Nube de puntos para el área de muestreo 41 ^a | 51 |
| Figura 24. Modelo digital de terreno del área de muestreo 41 ^a | 52 |

ÍNDICE DE TABLAS

| | |
|---|----|
| Tabla 1: Operacionalización de las variables | 7 |
| Tabla 2. Coordenadas de la estación utilizada en metros | 18 |
| Tabla 3. Coordenadas de puntos base WGS84 Z17S-EGM2008 | 19 |
| Tabla 4. Clasificación de pendientes en rangos..... | 38 |
| Tabla 5. Tipo de suelos | 39 |
| Tabla 6. Estaciones pluviométricas..... | 41 |
| Tabla 7. Estaciones climatológicas | 43 |
| Tabla 8. Uso – cobertura vegetal | 48 |
| Tabla 9. Volumen real en cada parcela de muestreo de pasto. | 53 |
| Tabla 10. Volumen aparente con modelación digital en cada parcela de muestreo de pasto..... | 54 |
| Tabla 11. Resultados de correlaciones mediante el coeficiente de Pearson.... | 55 |
| Tabla 12. Medidas de tendencia central en la obtención de volumen y altura de pasto..... | 57 |
| Tabla 13. Medidas de tendencia central en la obtención de biomasa de pasto. | 58 |
| Tabla 14. Valores de RMSE, MAE y R ² de los modelos generados a partir de volumen, altura y biomasa digital..... | 59 |
| Tabla 15. Áreas de cada potrero, biomasa y factor de densidad (FD) por potrero | 63 |

ÍNDICE DE GRÁFICOS

| | |
|--|----|
| Gráfico 1. Ajuste de temperaturas | 43 |
| Gráfico 2. Correlación de Pearson | 55 |
| Gráfico 3. Representación gráfica de la regresión lineal entre altura digital con altura real y Volumen digital con volumen real | 61 |
| Gráfico 4. Regresión lineal de altura digital, biomasa fresca y biomasa seca .. | 62 |
| Gráfico 5. Regresión entre volumen digital, biomasa fresca y seca | 62 |
| Gráfico 6. Regresión lineal entre biomasa | 63 |

ÍNDICE DE FOTOGRAFÍAS

| | |
|--|----|
| Fotografía 1. Cuadro de medición..... | 10 |
| Fotografía 2. Corte de materia verde | 10 |
| Fotografía 3. Secado de pasto en la estufa | 11 |
| Fotografía 4. Levantamiento aerofotogramétrico | 15 |
| Fotografía 5. Georreferenciación de puntos base utilizando el equipo GNSS T300 plus..... | 18 |
| Fotografía 6. Relieve – Granja Nero | 35 |
| Fotografía 7. Fotos aéreas obtenidas | 50 |

ÍNDICE DE ANEXOS

| | |
|--|-----|
| Anexo 1. Planes de vuelo | 77 |
| Anexo 2. Base de información | 80 |
| Anexo 3. Ejemplo de extracción de alturas a partir de modelos digitales en R. 82 | |
| Anexo 4. Análisis estadístico | 86 |
| Anexo 5. Comportamiento de los residuales de cada modelo..... | 100 |

CAPÍTULO I. INTRODUCCIÓN

El sector agropecuario con sus áreas de pastizales en el Ecuador es una base muy importante de desarrollo social y económico, ya que satisface las demandas de la población en alimentos tan esenciales como la carne y leche, y es fuente esencial de generación de mano de obra e ingresos (Benalcázar et al., 2021).

En Ecuador, la extensión dedicada a pastizales supera la de cualquier otro tipo de cultivo. Según los datos de la Encuesta de Superficie y Producción Agropecuaria Continua (ESPAC) del Instituto Nacional de Estadística y Censos (INEC), la superficie total utilizada para actividades agropecuarias abarcó 5133969 hectáreas. Dentro de esta categoría, los pastos cultivados representaron el 45.3%, mientras que los pastos naturales comprendieron el 12% (INEC, 2023).

En el contexto de estas superficies agropecuarias, se sitúan diversas fincas, granjas y parcelas de tierra designadas para el cultivo tanto de pastizales naturales como de especies introducidas. La determinación precisa del aforo o la productividad en estas áreas destinadas a la cría de ganado reviste una importancia crucial, ya que nos brinda la capacidad de cuantificar en kilogramos la totalidad del pasto generado, es decir, la biomasa forrajera completa producida en un área específica de terreno, destinada a la alimentación del ganado.

Tradicionalmente, la determinación de biomasa forrajera y por consiguiente la productividad primaria neta aérea (PPNA), se ha calculado utilizando métodos denominados directos a partir de cortes periódicos de la vegetación, como sostienen (Ramos & Martínez, 2020) en su estudio en donde plantean un diseño de unidades de muestreo para estudio de la vegetación y determinación de la biomasa en cuadros de 2 x 2 m (120m² por pastizal) distribuyéndolos al azar. La biomasa aérea en cada una de las áreas de muestreo se obtiene del corte a ras del suelo, para luego registrar su peso en fresco y seco mediante el secado en el horno (Ramos & Martínez, 2020).

Por otra parte, las nuevas tecnologías en los últimos años brindan oportunidades para la investigación y el desarrollo de métodos indirectos en la determinación de biomasa ya sea de pastos en monocultivo o de mezclas forrajeras, utilizando

por ejemplo el Índice de Vegetación de Diferencia Normalizada (NDVI) obtenido mediante instrumentos como el *GreenSeeker* cuya interpretación contribuye inclusive al diagnóstico rápido y dirigido de las condiciones nutricionales del cultivo. Otro método indirecto es la utilización del plato medidor que permite, de acuerdo a las mediciones y la determinación de la ecuación de calibración, estimar la dinámica de crecimiento de la pradera en las distintas épocas del año (Méndez, 2021).

Los sistemas pastoriles se han visto favorecidos también con la utilización de técnicas que usan sensores remotos desde plataformas satelitales, para estimar la oferta de forraje; por ejemplo, se pueden utilizar imágenes Landsat 8 y Sentinel 2^a para obtener los índices de vegetación NDVI, SAVI, EVI y GNDVI, calculados a partir de las bandas azul, verde, rojo e infrarrojo cercano. Los resultados luego de ser analizados concluyen que para las condiciones del estudio el EVI (para Landsat 8) y el NDVI (para Sentinel 2A) son índices apropiados para predecir la oferta forrajera del pasto Llanero (*Gramínea estolonífera perenne de crecimiento semierecto a postrado y denso originario de África*) (Díaz Giraldo et al., 2021).

El uso de sistemas de aeronaves operadas remotamente o a distancia (Remotely Piloted Aircraft System - RPAS) y equipadas con cámaras RGB y multiespectrales, no han sido la excepción en la determinación de la biomasa de un cultivo en función del Índice de Vegetación de Diferencia Normalizada (NDVI), ecuaciones lineales y potenciales generadas, presentan niveles altos de ajuste y significancia con un R^2 arriba de 0.80 y errores estándar aceptables (Allen Asensio, 2019).

(Botello-Aguillón, Gavi-Reyes, et al., 2019) realizó la estimación de biomasa forrajera en especies de invierno como la Avena (*Avena sativa*) y Alfalfa (*Medicago sativa*), utilizando una cámara digital acoplada a un "RPAS", obteniendo imágenes antes de la cosecha de los cultivos con lo que estimaron el volumen de biomasa luego del procesamiento con software SIG y CAD.

1.1 Justificación

El objetivo de una granja o finca ganadera es la obtención de utilidad económica luego de realizada su inversión; para cumplir con este objetivo, el ganadero tiene

que concentrar su esfuerzo en la producción de forraje en calidad y cantidad durante todo el año y en la utilización eficiente del forraje producido. Este factor se controla por medio de una adecuada planificación y manejo del pastoreo, en donde el conocer el aforo del forraje que se produce es un factor sumamente importante. Una determinación incorrecta de la disponibilidad de pasto puede propiciar un uso incorrecto de la pastura, ya sea por subpastoreo o sobrepastoreo. La primera puede impulsar al ganadero a cambiar la cobertura de suelo de bosques a pastizales por su errónea conclusión de que el área que posee en ese momento no será suficiente para abastecer la demanda alimenticia de su ganado. La segunda puede acelerar la degradación de la pastura, debido a la compactación del suelo y la intensidad de defoliación que sufre el pasto (Allen Asensio, 2019).

La correcta planificación del pastoreo implica el conocer datos básicos, pero a la vez importantes como es el aforo de un pastizal en una finca o terreno. Mediante la determinación del aforo de una pradera, es decir, la producción global estimada y proyectada de pasto durante un ciclo específico de crecimiento y desarrollo, podemos calcular la cantidad total de pasto disponible por cosecha y así determinar la carga animal máxima de ganado de manera precisa; sin embargo, la metodología tradicional de aforo de biomasa en campo puede presentar diversas desventajas para el productor. Una de ellas es el margen de error entre la determinación y la real disponibilidad de pasto en el potrero. Además, el costo de oportunidad que se genera al designar mano de obra a esta tarea es alto (Gaillard & Pece, 2014).

Hoy en día, la fotogrametría se ha convertido en un método común y económico para documentación y presentación de imágenes por parte de la comunidad científica. El análisis computacional de imágenes digitales para la determinación de la cobertura vegetal presenta un potencial importante por ser una técnica confiable (Mitsikostas, 2017).

Además, ciertas características agronómicas de un cultivo, tales como altura de la planta y su cobertura, pueden estimarse con base en un modelo digital de superficie (MDS) o un modelo digital de elevación (MDE) y también por el análisis

de clasificación de imágenes tomadas desde RPAS. Así mismo, conociendo la altura se puede estimar la producción de biomasa aplicando modelos de regresión (Hassnain et al., 2023).

En relación a la disponibilidad de información sobre la determinación de biomasa de forrajes mediante el uso de cámaras digitales montadas en RPAS, no es abundante, quizá por ser un tema poco estudiado, lo cual puede llegar a ser una opción cuando no se cuenta con imágenes multi espectrales o tecnología LIDAR, ya que actualmente tanto el RPAS como las cámaras digitales, son usados por ser equipos económicamente accesibles (Botello-Aguillón, Gavi-Reyes, et al., 2019).

Lo anteriormente citado motiva al desarrollo de la presente investigación, junto con el interés en contribuir con el desarrollo de técnicas que permitan fortalecer el conocimiento de la determinación de la biomasa aérea forrajera en sistemas de pastoreo rotacional mediante un RPAS, información que permitirá a los administradores de granjas: plantear a futuro una optimización de estrategias de mejoramiento de pastizales; prevenir la degradación del ecosistema, elevar la condición de los pastizales, incrementando su productividad y capacidad de carga, ya que es completamente pertinente.

1.2 Planteamiento del problema

1.2.1 Situación problemática

El aforo tradicional de pastizales es una técnica utilizada para determinar la cantidad de biomasa disponible en un área determinada de pasto. Esta técnica se basa en la toma de muestras de la vegetación, generalmente utilizando un cuadrante de muestreo, y su posterior pesaje para determinar la cantidad de forraje disponible. Se utilizan también otros métodos denominados directos como, por ejemplo, el aforo en cruz, el aforo en zigzag, aforo por doble muestreo, debiendo tomarse varias muestras con las que se llegará a tener un promedio aritmético o media aritmética en Kg/m^2 , valor que se conoce como aforo promedio (León et al., 2018).

La obtención de la muestra se realiza cortando todo el pasto que se encuentra al interior de los límites de un marco de medición, por un número de repeticiones

establecidas en el aforo. Consecuentemente se da la destrucción del material vegetal y si sumamos a esto que la técnica es precisa solo a nivel del sitio de muestreo, además de consumir tiempo y recursos que en varias ocasiones son restrictivos, generarían limitaciones al momento de extrapolar los resultados a superficies más grandes (Mónaco et al., 2017).

Ante situaciones similares, se están optando por métodos indirectos como por ejemplo el monitoreo con imágenes satelitales de alta temporalidad realizando estimaciones mediante la fracción de absorción fotosintética (Gómez-Giráldez et al., 2019); sin embargo, hay situaciones específicas como las condiciones climáticas, el tamaño de los predios, la resolución espacial de la información, aspectos que limitan de momento su aplicación masiva.

1.2.2 Formulación del problema

La problemática del aforo tradicional de biomasa forrajera disponible en potreros, radica en que esta metodología genera la destrucción del material vegetal, pudiendo ser costoso, requerir mucho tiempo y no ser representativo de la realidad del potrero en su totalidad. Además, que este no toma en cuenta la variabilidad espacial y temporal de la vegetación ya que puede crecer de manera heterogénea, con áreas con mayor densidad de plantas y otras con menor densidad, lo que puede llevar a una sobre o subestimación del aforo de forraje (Mónaco et al., 2017).

En este sentido, la implementación de tecnologías de teledetección y modelos de predicción basados en datos de vegetación pueden ser alternativas precisas y eficientes para el aforo de biomasa de forraje disponible en potreros. Estas tecnologías permiten una evaluación más detallada de la vegetación, la calidad y su disponibilidad para el ganado, lo que permitiría mejorar la toma de decisiones de manejo y aumentar la productividad ganadera. Es por esto que la presente investigación plantea la utilización de imágenes digitales, para la determinación de biomasa aérea forrajera en sistemas de pastoreo rotacional.

1.3 Delimitación

1.3.1 Objeto de estudio

La presente investigación tiene como objeto de estudio la determinación de **biomasa forrajera** en zonas de pastoreo rotacional en una granja pecuaria situada en la zona austral ecuatoriana.

1.3.2 Campo de acción

a investigación plantea el uso de un sistema aéreo operado remotamente como alternativa a los aforos tradicionales sin la destrucción de la materia verde. Se obtendrá el volumen aparente (digital) de biomasa expresado en m^3 , obtenido a partir de la modelación 3D de las fotografías aéreas levantadas en campo; el volumen aparente (real) expresado en m^3 y obtenido por la medición de la altura de las plantas en campo con la ayuda del marco de medición. El porcentaje de materia verde y seca obtenida por el corte del forraje en campo con la ayuda del marco de medición, pesado y secado en laboratorio y los análisis estadísticos entre las variables que permitan determinar el grado de significancia.

1.4 Objetivos

1.4.1 Objetivo general

Determinar la biomasa forrajera aérea en zonas de pastoreo rotacional mediante la utilización de imágenes digitales obtenidas por un sistema aéreo operado remotamente (RPAS), en la granja Nero, cantón Cuenca, provincia del Azuay - Ecuador

1.4.2 Objetivos específicos

- Establecer la producción forrajera mediante aforo tradicional por muestreo en pastizales.
- Determinar el volumen de biomasa mediante técnicas fotogramétricas aplicadas sobre fotografía aérea digital captada desde un RPAS.
- Realizar el análisis comparativo de la biomasa medida por el método tradicional de corte y pesado, con la calculada a partir del empleo de fotogrametría digital aérea.

1.5 Hipótesis

La altura, volumen, y biomasa forrajera se determinan mediante la utilización de imágenes digitales con un sistema aéreo operado remotamente como alternativa al método tradicional de aforo.

1.5.1 Identificación de variables

En esta investigación para la obtención de resultados a través del uso de modelos estadísticos para cumplir los objetivos planteados se consideran seis variables entre dependientes e independientes.

Las variables independientes se obtuvieron a través de metodologías convencionales o en campo y de manera digital, estas fueron: Volumen real y digital (m³), altura real y digital (m) y factor de densidad (kg/m²).

La variable dependiente considerada en este estudio fue la biomasa digital (kg/ha), la cual fue obtenida a través de la toma de imágenes aéreas y su procesamiento.

1.5.2 Análisis de indicadores

Tanto el volumen real como el digital se miden en metros cúbicos; mientras que, la altura obtenida por las dos metodologías en metros y el indicador de la biomasa en kilogramos por hectárea. Finalmente, la biomasa fresca y biomasa seca se cuantifica a través de kilogramos por metro cuadrado. Se usó estadística descriptiva e inferencial. La primera para la obtención de medidas de tendencia central y la estadística inferencial generando modelos de correlaciones y regresiones para los datos obtenidos por las dos metodologías.

1.5.3 Operativización de las variables

Tabla 1: Operacionalización de las variables

| Pregunta de investigación | Objetivo general | Variables | Dimensión | Indicadores | Instrumento |
|--|---|-------------------------|-----------|-----------------------------|--------------------------------|
| ¿La utilización de imágenes digitales captadas | Determinar la biomasa forrajera en zonas de | la Var. Independientes: | | -Espacio que ocupa el pasto | Toma de fotografías aéreas con |

| | | | | | |
|--|--|--|---|--|--|
| desde un pastoreo sistema aéreo operado remotamente, permite determinar con precisión la biomasa aérea forrajera en sistemas de pastoreo rotacional? | pastoreo rotacional mediante utilización de imágenes digitales obtenidas por un sistema aéreo operado remotamente (RPAS) como alternativa al método tradicional de aforo en la granja Nero, cantón Cuenca, provincia del Azuay - Ecuador | -Volumen digital y real -Altura digital y real -Factor de densidad (FD) Var. Dependiente: -Biomasa digital | m ³ m kg/m ³ kg/ha | -Distancia del pasto desde la base del suelo -Peso en un volumen determinado -Materia vegetal en 10000m ² | RPAS y procesamiento en software de SIG. Aforamiento de pasto en campo Toma de fotografías aéreas con RPAS y procesamiento en software de SIG. |
|--|--|--|---|--|--|

1.6 Metodología de la investigación

Metodológicamente se trabajó con investigación inferencial y descriptiva a partir de un estudio de caso en la granja Nero, de propiedad de la Universidad de Cuenca - Ecuador. Aquí, la determinación del volumen de biomasa implicó la utilización de dos métodos prácticos siendo el primero la utilización del aforo tradicional por muestreo en pastizales, que corresponde al empleo de un cuadro de medición propuesto por Botello-Aguillón et al., (2019) técnica sistemática y manual que permite evaluar la cantidad de forraje disponible en un área determinada y la altura promedio del pasto para determinar el volumen. Y el segundo método denominado obtención de geo información mediante sensor operado remotamente, para lo cual se utilizó un vehículo aéreo equipado con una cámara incorporada de 8k con una alta resolución de 8000px * 6000px. A continuación, se describe cada uno de los métodos empleados.

1.6.1 Aforo tradicional por muestreo en pastizales

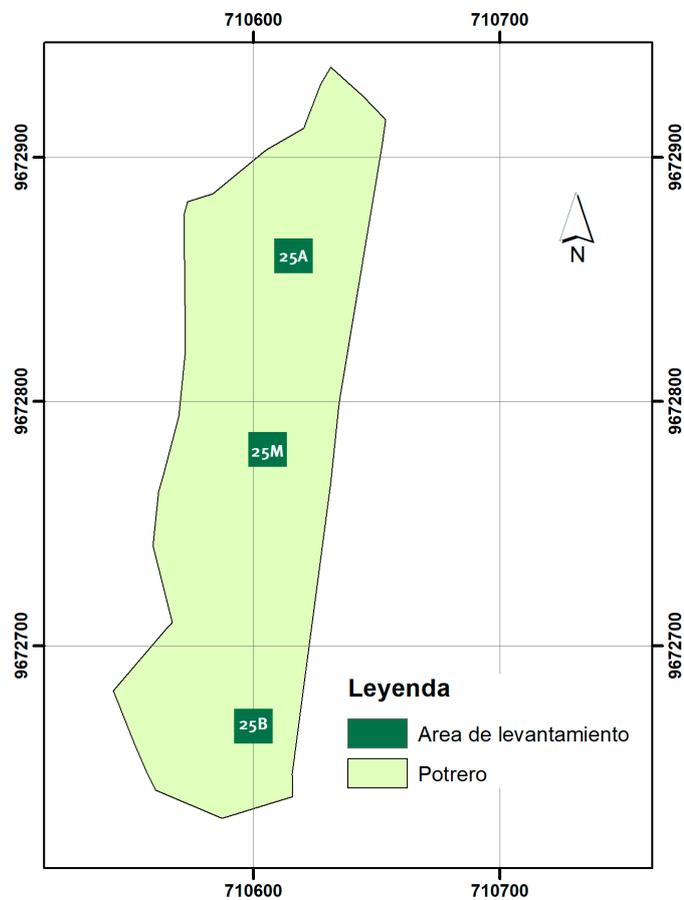
El proceso consiste en seleccionar zonas representativas para muestreo al interior del área destinada a la producción de pastos en la granja. Se eligieron

áreas en sus partes alta, media y baja de cada potrero a evaluar (ver figura 1), mediante la selección aleatoria con la utilización de un marco cuadrado de madera de 1m^2 (ver fotografía 1).

El área de potreros de la granja corresponde a zonas cultivo con una mezcla forrajera de Ray Grass inglés (*Lolium perenne*), Ray Grass italiano (*Lolium multiflorum*) y Trébol blanco (*Trifolium repens*).

Una vez ubicados en la parte alta, media o baja de cada potrero seleccionado, se lanzó el marco de medición y se procedió a recolectar datos de altura del pasto, se obtuvo el promedio de estos datos y se multiplicó por su área para finalmente obtener el volumen promedio por cada zona de muestreo.

Figura 1. Áreas de toma de datos al interior de un potrero



Fotografía 1. Cuadro de medición



Luego de la medición de la altura del pasto, se procedió con el cortado del pasto para obtener peso de materia verde o biomasa fresca (ver fotografía 2). Posteriormente, en laboratorio utilizando una estufa se secó el pasto a 70°C durante 60 horas para obtener la biomasa seca, tomando como referencia a (Muler 2016).

Fotografía 2. Corte de materia verde



Fotografía 3. Secado de pasto en la estufa



Para la presente investigación la biomasa denominada fresca, considera el peso de la totalidad de pasto cortado en campo de cada parcela de muestreo expresado en kg/m^2 .

La biomasa real considera el peso de la totalidad de pasto expresado en kg/ha .

La biomasa seca considera el peso de la totalidad de pasto extraído de la parcela de muestreo sometido 60°C durante 72 horas expresado en kg/m^2

1.6.2 Generación de geo información mediante sensor operado remotamente

Las herramientas de análisis espacial abren nuevas posibilidades para estudiar el territorio, el uso de vehículos operados remotamente permite la obtención de fotografías aéreas de alta resolución. El sistema de vehículos operados remotamente está estructurado por segmentos tanto para tierra como para el vuelo.

El segmento tierra lo constituye la estación de control la cual recibe información de la aeronave relacionado con los indicadores de vuelo y envía información planificada para la ejecución de planes de vuelo.

El segmento vuelo consta de la aeronave no tripulada equipada con la cámara fotográfica, el control de vuelo con sus indicadores como altitud, velocidad, la

integración del GNSS en la plataforma de vuelo, el sistema de despegue, aterrizaje y comunicaciones.

1.6.2.1 Planificación de vuelo

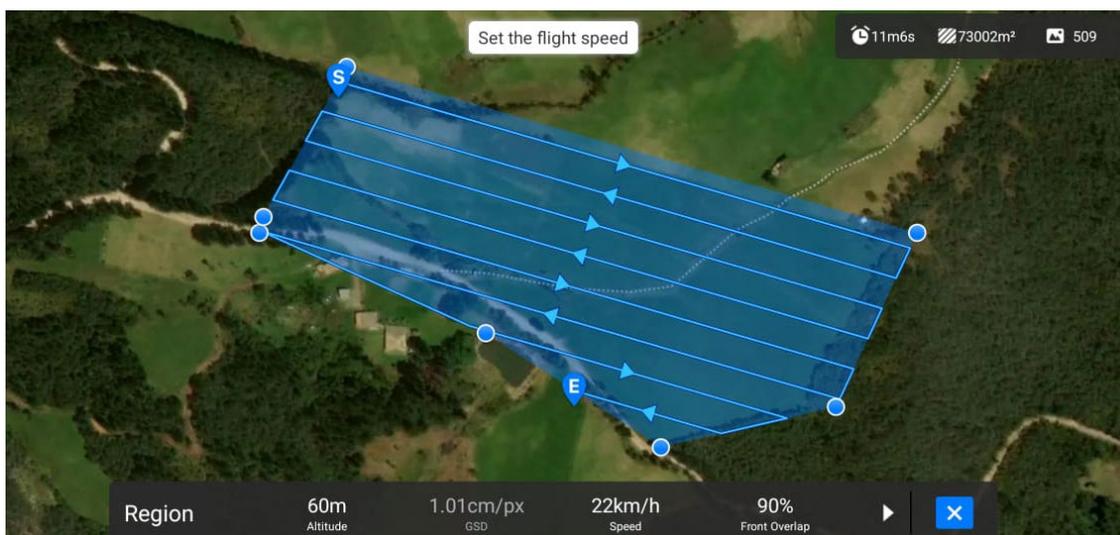
La planificación del vuelo fotogramétrico para un vehículo aéreo operado remotamente, implica una serie de pasos que garantice un despliegue seguro y eficiente. Principalmente consiste en parametrizar altura, número de pasadas, orientación de la cámara y solapamiento entre imágenes para lo cual es necesario, conocer los parámetros técnicos básicos de la óptica de la aeronave – cámara como la distancia focal o el tamaño de las imágenes.

Elegidos los parámetros de altura y solapes, se calcula el número de pasadas que tiene que hacer la aeronave para el correcto recubrimiento en base a la distancia a recorrer, el tiempo de vuelo, número de imágenes necesarias, el tamaño del píxel, la huella de la imagen y la velocidad de disparo de la cámara (Santana, 2017).

Haciendo uso del software Autel explorer, se calcula el número de pasadas que tiene que hacer la aeronave, para el correcto recubrimiento del área en base a los siguientes elementos: distancia que debe recorrer, tiempo de vuelo, número de fotos, tamaño del píxel y velocidad.

Como ejemplo de lo actuado, se presenta solo una planificación del total de vuelos realizados entre febrero y julio de 2022 (Anexo 1), en donde vemos los siguientes aspectos técnicos considerados: área de levantamiento 73002 m², tiempo de vuelo 11 minutos, número de fotografías 509, altitud del vuelo 60 m, tamaño del gsd 1.01 cm, velocidad 22 km/h, traslape frontal 90 %, traslape lateral 76% y la inclinación del estabilizador al 90% (Ver figura 2). Cabe destacar que con el uso de RPAS y equipos GNSS se levantó un área bastante más extensa (14.04 ha), que posteriormente a nivel de imagen digital y modelos digitales de superficie o cultivo fue recortado y contrastado con el 100% del área muestreada.

Figura 2. Planificación de vuelo en el software Autel explorer



1.6.3 Ubicación de puntos de apoyo fotogramétrico (PAF)

La correcta georreferenciación de la cartografía digital a obtener del vuelo fotogramétrico, implica la obtención de posiciones precisas de determinados puntos sobre el terreno, los mismos que servirán para transformar el modelo fotogramétrico en modelo de terreno. Estos puntos denominados de apoyo fotogramétrico deben ser foto identificables para poder establecer una correcta correlación, por lo que se colocan marcas en el piso mediante lonas o dianas que contrasten con la vegetación existente (ver figura 3), sobre superficies planas cuidando que no queden ocultas durante el vuelo de la aeronave.

Los puntos de apoyo fotogramétrico fueron repartidos estratégicamente en toda la zona de levantamiento a fin de poder resolver la orientación externa y la georreferenciación del levantamiento.

Figura 3. Lonas o dianas utilizadas para levantamiento de puntos de apoyo



Ubicados los puntos de apoyo fotogramétrico se procedió a su posicionamiento mediante la utilización de equipos GNSS que admiten la corrección diferencial. El equipo utilizado como base fue el receptor GNSS T300 plus para levantamiento estático (ComNav Technology Ltd., 2018), realizando la corrección con la estación de monitoreo continuo del Instituto Geográfico Militar de código CUEC, nombre Cuenca código IERS 42009M001 que se encuentra a 15 km del área de levantamiento. El levantamiento de puntos de apoyo fue con el GNSS EMLID Reach RS2 como equipo móvil (EMLID 2022).

1.6.4 Ejecución del vuelo

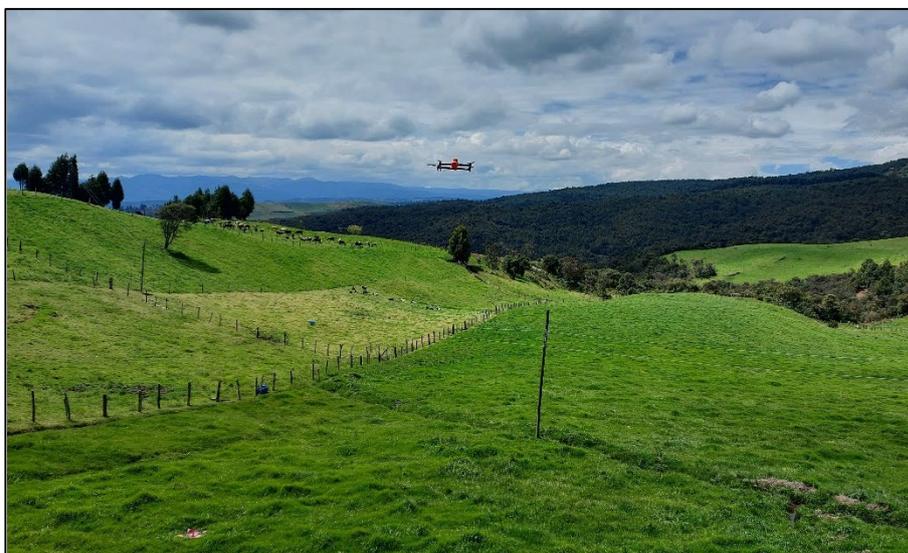
Para la obtención de las fotos aéreas se utilizó el sistema Autel Evo II RTK (ver figura 4), para lo cual se realizó la planificación de vuelo para cada una de las áreas destinadas al monitoreo que corresponden a los potreros de la granja Nero. Los aspectos técnicos considerados fueron que los vuelos deben ser estables y constantes para obtener elementos de la foto anterior, posterior y laterales, con una cantidad adecuada de solapamiento entre ellas.

Figura 4. Aeronave Autel Evo II RTK



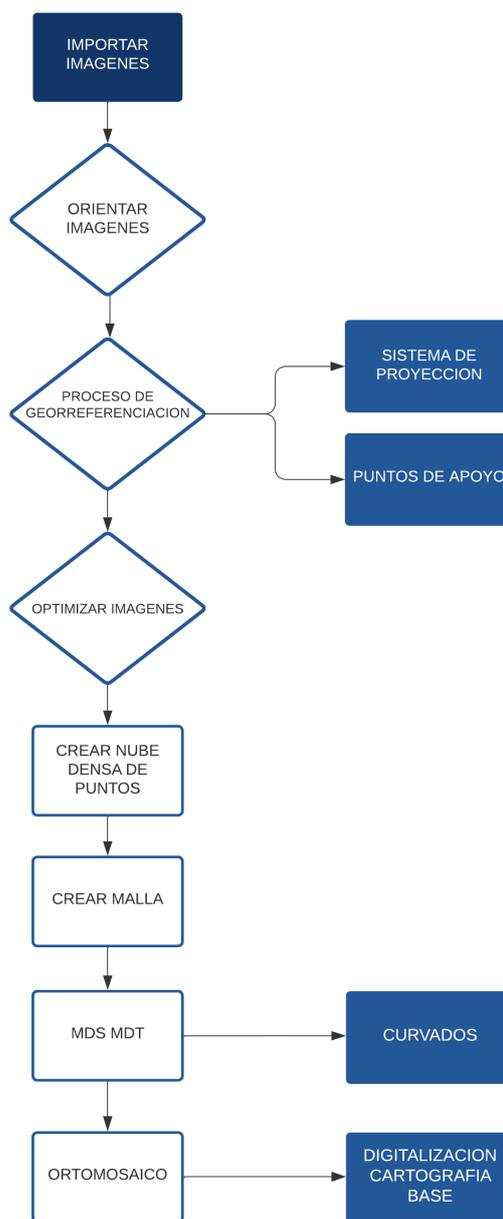
Ingresa la planificación de vuelo en el sistema, la aeronave ejecuta la misión (ver fotografía 4), del levantamiento, en base en base a los parámetros ingresados.

Fotografía 4. Levantamiento aerofotogramétrico



Finalmente, el postproceso se realizó en el programa *Agisoft Metashape Professional* generando productos como el modelo digital de superficie (MDS) que para nuestro caso corresponde al modelo de cultivo (MDC) y, el mosaico orto rectificado en base al flujo de trabajo que se presenta a continuación:

Figura 5. Flujo de trabajo en Agisoft Metashape Professional

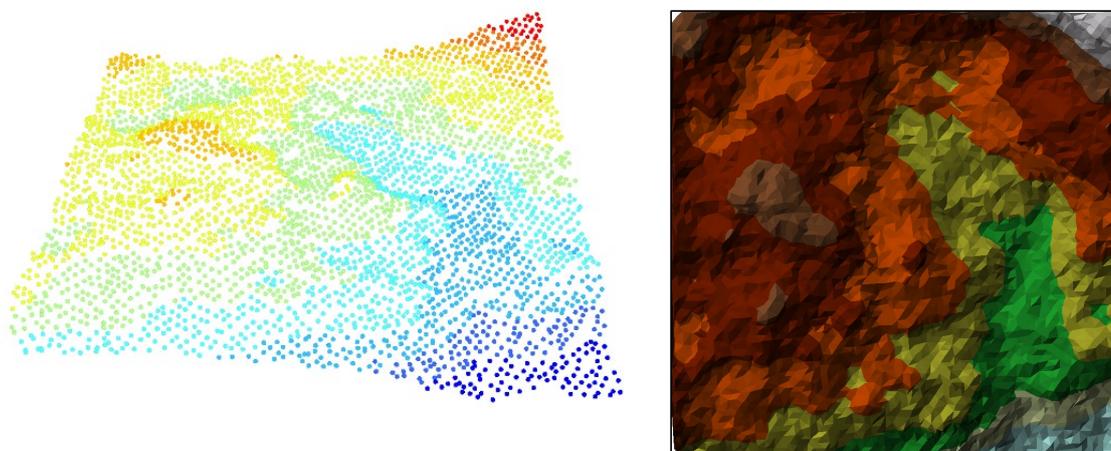


En Agisoft Metashape se genera un modelo digital de superficie a partir de un conjunto de fotografías levantadas en campo, estas se importan y se procesan para crear un conjunto de puntos de referencia y una nube de puntos 3D. El software utiliza los puntos de referencia para alinear las fotos y crear una sola vista 3D de la escena.

El software genera una malla poligonal a partir de la nube de puntos para crear una representación visual del área, finalmente el software Agisoft Metashape u

otro software SIG genera el modelo digital de superficie (MDS), para cada polígono, como se observa en la figura 6, utilizando la malla poligonal y la textura de las imágenes originales para crear una representación realista y detallada.

Figura 6. Nube de puntos – MDS, polígono 13^a



1.6.5 Obtención de topografía

A más de las fotografías aéreas que permiten entre otros productos la obtención del modelo digital de superficie (MDS), fue necesario obtener la topografía que permita la generación del modelo digital de terreno (MDT) de cada área de levantamiento, en total 44 sitios de muestreo. Esto nos servirá posteriormente para obtener la diferencia de altura con el MDS y determinar el volumen.

Según la metodología planteada se usa un marco de medición para el aforo de biomasa fresca, de estas áreas se obtuvo la topografía utilizando el equipo GNSS T300 plus, para generar las coordenadas de puntos bases y la estación total FOCUS 2 de Spectra Precisión para el levantamiento topográfico propiamente dicho. Este equipo de alta precisión permitió obtener datos detallados del terreno, con el objetivo de elaborar un modelo digital del terreno (MDT).

Para la corrección diferencial en el postproceso se utilizó los datos de la estación permanente REGME del Instituto Geográfico Militar (IGM) de código CUEC, localizada en el tanque reservorio de agua ETAPA, sector Cristo Rey en la Ciudad de Cuenca.

Tabla 2. Coordenadas de la estación utilizada en metros

| Estación | Valor Este | Valor Norte | Elevación |
|----------|------------|-------------|-----------|
| CUEC | 722037.612 | 9681111.691 | 2605.6170 |

Fotografía 5. Georreferenciación de puntos base utilizando el equipo GNSS T300 plus



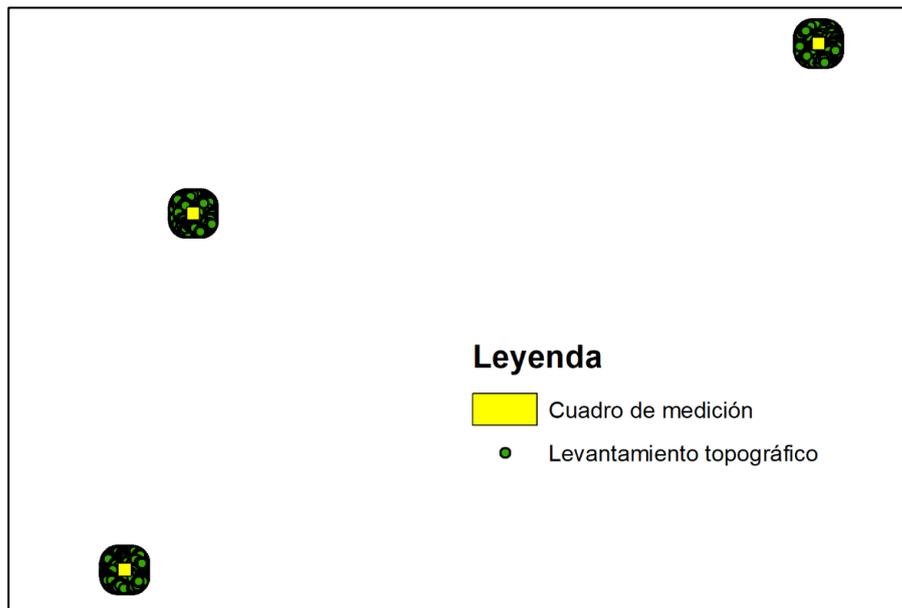
Tabla 3. Coordenadas de puntos base WGS84 Z17S-EGM2008

| "A" Establo | Valor (m) | Precisión (m) |
|--------------------|-----------|---------------|
| Este | 710810.19 | 0.007 |
| Norte | 9672741.3 | |
| Elevación | 3138.2706 | 0.029 |

| "B" Lirio | Valor (m) | Precisión (m) |
|------------------|-----------|---------------|
| Este | 710478.49 | 0.009 |
| Norte | 9672998.2 | |
| Elevación | 3185.2794 | 0.03 |

| "C" Borregos | Valor (m) | Precisión (m) |
|---------------------|-----------|---------------|
| Este | 710182.01 | 0.01 |
| Norte | 9672618.8 | |
| Elevación | 3180.4918 | 0.022 |

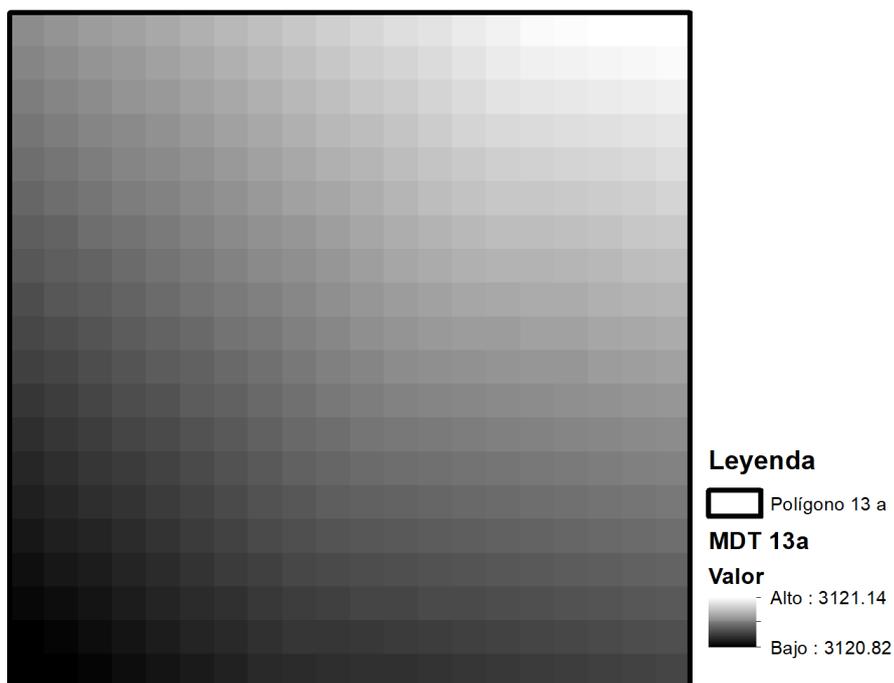
Figura 7. Nube de puntos en levantamiento topográfico



El tipo de interpolación utilizada para generar el modelo digital del terreno a partir de la nube de puntos obtenida en campo fue tipo TIN (Triangulated Irregular Network). Esta realiza una triangulación de los puntos de elevación levantados, conectando los puntos vecinos entre sí para formar una red de triángulos que cubre toda el área de estudio.

Para cada triángulo en la red, se calcula la altura interpolada en los vértices del triángulo, una vez calculada las alturas de los vértices de los triángulos, el algoritmo interpola los valores de elevación para los puntos dentro de cada triángulo. Finalmente genera el modelo digital del terreno convirtiendo los datos interpolados en una representación digital de la elevación, como un raster o una malla regular (ver figura 8).

Figura 8. Modelo digital de terreno



1.6.6 Determinación del volumen digital de biomasa

El **volumen digital** se obtuvo calculado el modelo digital de superficie (MDS) denominado también para nuestro caso modelo de cultivo (MDC) a partir de la fotografía aérea, es decir se generó representaciones digitales tridimensionales del área de levantamiento, sin la aplicación de ningún tipo de filtrado, con el objeto de tener las alturas de la vegetación de todo el marco de medición. Para esto, mediante Agisoft metashape, software de fotogrametría basado en la técnica de Structure from Motion (SFM), se crearon modelos 3D a partir de imágenes 2D. SFM reconstruye la geometría tridimensional de una escena a partir de una serie de imágenes, calculando la posición y orientación de las imágenes en un espacio tridimensional común, luego, a partir de estas estimaciones, el software genera un modelo digital de superficie mediante la triangulación de los puntos correspondientes en las imágenes (Nyimbili et al., 2016). Adicionalmente fue necesario modelar la topografía de cada sitio de muestreo con la cual se generó el modelo digital de terreno (MDT). Finalmente, con el modelo digital de superficie y el modelo digital del terreno, se calculó el volumen de cada una de las áreas muestreadas mediante el comando medir

volumen entre superficies del software Global Mapper. Lo que hace el software es medir el volumen entre superficies dividiendo el área de interés en pequeñas piezas rectangulares y luego calculando el volumen de la suma de los pequeños rectángulos 3D entre los dos modelos, MDS y MDT (Blue Marble, 2019).

El cálculo para la obtención de la biomasa digital es obtenido entre el modelo digital de superficie (MDS) y el modelo digital de terreno (MDT) de cada parcela experimental, multiplicando este resultado por el factor de densidad de cada parcela (Sinde-González et al., 2021).

La fórmula utilizada es la siguiente:

$$B= V.FD$$

Dónde:

B: Biomasa seca del área de muestreo convertido en Kg/ha.

V: Volumen por superficie de crecimiento. Diferencia de superficies del MDT inicial con el MDS después del crecimiento del cultivo en m³

FD: Factor de densidad

Como mencionan Gil-Docampo et al. (2020) el factor de densidad es una constante que resulta de la cantidad de biomasa seca (peso seco real) por volumen que se encuentre en cada parcela de muestreo para poder generalizar biomasa en un área más extensa. En total se calcularon 44 factores de densidad que es el número de parcelas estudiadas en base a la siguiente fórmula:

La biomasa es el peso seco de pasto obtenido en el laboratorio, mientras que el volumen se obtiene con la superficie del marco de medición y la altura del pasto en campo.

La obtención de la **altura digital** se llevó a cabo mediante la extracción de alturas a partir de los modelos digitales de superficie y terreno. Para este propósito, se creó un script (Anexo 3) en el software Rstudio específicamente diseñado para cada parcela de muestreo.

1.6.7 Análisis estadístico

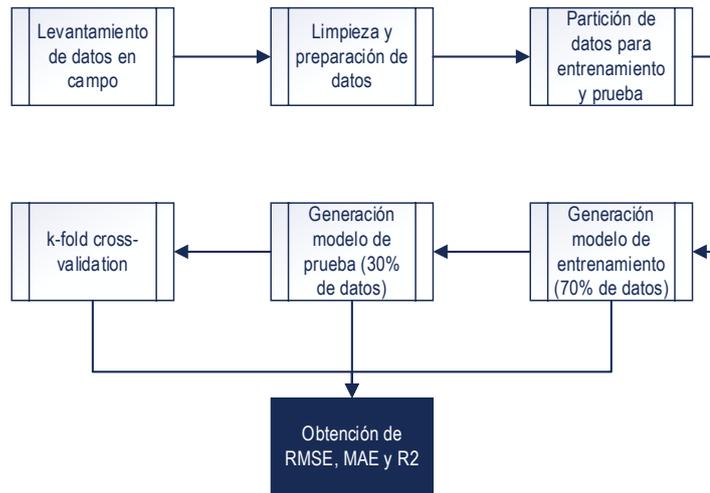
Se realizaron correlaciones entre las variables volumen digital vs. volumen real, altura digital vs. altura real, biomasa digital vs biomasa real, volumen digital vs. biomasa fresca, volumen digital vs. biomasa seca, altura vs. biomasa fresca y altura vs. biomasa seca, para conocer si existe relación, evaluar la confiabilidad de las mediciones digitales en comparación con las reales, e identificar qué variables se pueden usar para predecir o estimar los valores de otras variables de interés.

Al haber relación se procedió con el análisis estadístico que corresponde a la generación de regresiones lineales entre las metodologías de obtención de volumen y las metodologías de altura. Además de la biomasa fresca y biomasa seca con volumen y altura obtenida a partir de imágenes aéreas. Asimismo, se estimó la biomasa de pasto a partir de imágenes aéreas. Se particionó la base de datos en 70% para entrenamiento y 30% para prueba (Álvarez-Mendoza et al., 2022). Luego de esto fue necesario aplicar validación cruzada k-fold para garantizar que los resultados son independientes de las particiones. Para este último paso el número de folders utilizado fue de 5. Esto significa que el conjunto de datos original se divide aleatoriamente en 5 subconjuntos o "pliegues" (folds) de igual tamaño.

Para el entrenamiento, prueba y validación cruzada se estimó los coeficientes de RMSE (root mean squared error), MAE (mean absolute error) y R^2 (Allgaier & Pryss, 2024). El proceso para la generación y descripción de los siete análisis se ilustra en la figura 9. También se realizaron cuadros con medidas de tendencia central y dispersión por metodología de volúmenes, alturas y biomasa.

Los modelos y gráficas fueron generados en el IDE de R studio (Wickham et al., 2023).

Figura 9. Análisis estadístico



CAPÍTULO II. MARCO TEÓRICO

2.1 Biomasa forrajera

La biomasa forrajera se refiere a la materia vegetal que se utiliza como alimento para animales, incluyendo pastos y cultivos específicos (León Ramiro, Bonifaz Nancy, 2018). Otros investigadores señalan que la biomasa como concepto abarca la suma completa de materia orgánica renovable, como plantas y residuos agrícolas, en un punto específico de tiempo y en una superficie determinada, o en uno de los niveles tróficos, siendo cuantificado en gramos de carbono o calorías por unidad de área. Las pirámides de biomasa resultan valiosas como herramientas para visualizar la distribución de materia vegetal en los diferentes niveles tróficos (Martínez Romero & Leyva Galán, 2014).

Una especie forrajera que se desarrolla mayormente de forma natural en potreros andinos es el kikuyo (*Pennisetum clandestinum*) (Portillo-López et al., 2021), esta es una gramínea que se ve limitada cuando en zonas de montaña las temperaturas bajas interrumpen su crecimiento, lo que a su vez es contraproducente para el desarrollo del ganado, debido a que sus tejidos son de baja digestibilidad (Vargas- Martínez et al., 2018). Por lo que es de suma importancia el uso de distintas especies de pastos y realizar mezclas entre estos.

De acuerdo a (Grünwaldt et al., 2015) el realizar mezclas forrajeras entre gramíneas y leguminosas brinda mayor valor nutritivo y genera mayor cantidad de materia seca, lo cual resulta ser más económico que las dietas balanceadas para el ganado. Asimismo, las leguminosas fijan el nitrógeno atmosférico al suelo, lo cual ayuda a una mayor producción de biomasa (Guzmán & Montero, 2021), por ende, se evita el uso excesivo de fertilizantes de síntesis química.

El Rye Grass italiano (*Lolium multiflorum*) es una especie gramínea forrajera de importancia a nivel mundial, debido a sus bondades nutritivas y de fácil digestión (Walia & Dick, 2016). Esta depende de las condiciones del suelo, aunque tiene una gran adaptabilidad a sitios con distintas condiciones climáticas (CIAT, 2021). La masa seca que genera este pasto en condiciones experimentales se encuentra entre 6.66 t. ha⁻¹ y 9.37 t. ha⁻¹; además, presenta un alto porcentaje de nutrientes digestibles (60.8%) (Yavuz et al., 2017), por lo cual, lo hace idóneo

como alimento para el ganado vacuno. Asimismo, el pasto Rye Grass inglés (*Lolium perenne*) es un pasto con características muy similares al Rye Grass italiano, se ha registrado porcentajes altos de nutrientes digestibles de 68% cuando está en estado maduro y produce cantidades altas de materia seca ($15\text{t}\cdot\text{ha}^{-1}$) (Silva et al., 2019).

Otro pasto de alto valor nutricional es el trébol blanco (*Trifolium repens*), esta especie al ser una leguminosa posee nódulos en sus raíces que permiten fijar nitrógeno atmosférico al suelo al interactuar con bacterias (Shah et al., 2021). Para manejarla en sistemas de pastoreo, es necesario conocer la estación del año en la que es cultivada (Moreno-Carrillo et al., 2015). De acuerdo a registros de estudios esta produce $2.9\text{ t}\cdot\text{ha}^{-1}$ de materia seca en condiciones experimentales y se caracteriza por su alta digestibilidad, la cual ronda el 92% (Huerta et al., 2018) (Oliva et al., 2015).

2.2 Determinación de Biomasa

En la actualidad, la cantidad de biomasa de un cultivo puede ser obtenida a través de metodologías directas e indirectas. De la misma manera, el volumen de biomasa también puede ser estimado con métodos directos e indirectos.

El método directo es obtenido al aforar el pasto dentro de un cuadrante de un área conocida, el corte se lo debe realizar a nivel del suelo, seguido de esto, el material vegetal es almacenado y llevado al laboratorio, en donde es pesado la biomasa fresca, para luego ser secado de acuerdo a algún protocolo previo, el cual indica el tiempo y temperatura que se debe someter al pasto, para finalmente registrar el peso luego de haber sido secada la muestra (Boyda et al., 2015).

Entre los métodos indirectos se encuentran el uso de sondas que cuentan con procesadores electrónicos que permiten conocer la biomasa de un potrero. De acuerdo al modelo de instrumento utilizado, dependerá la cantidad de datos que puedan ser almacenados y la exactitud del mismo, un ejemplo de estos es el medidor GrassMaster II ® el cual permite guardar 200 potreros y en cada potrero hasta 250 lecturas (Serrano et al., 2020).

Otro método indirecto es el plato medidor, esta técnica consiste en dejar caer un plato al pasto, este registrará un valor. Este cuenta con una ecuación que ha sido desarrollada de acuerdo a las condiciones de pasto de Nueva Zelanda, por lo que cada registro de biomasa permite calibrar esta ecuación con datos propios de los potreros en los cuales se hace el levantamiento de información. Es recomendable hacer entre 30 y 40 lecturas por cada 5000m² (Cárdenas et al., 2020).

La metodología de rendimiento comparativo de Haydock y Shaw, es una técnica que se necesita pesar cinco muestras que serán guías o patrones, luego en el potrero se observa otros puntos que también serán muestreados y se les dará un valor entre 15 y 50 de acuerdo a los patrones, por lo que es importante que la persona que haga el muestreo visualice y toque con su mano el pasto. Este proceso se lo realiza al menos en 15 cuadrantes (Paletto & Bouno, 2020).

Otro estimador de biomasa es el NDVI el cual permite considerar rasgos morfológicos propios de una especie y generar un modelo con un ajuste importante de la ecuación resultante (Zhang et al., 2022).

También la determinación de biomasa a través de imágenes aéreas es posible al conocer un factor de densidad (FD), para ello es necesario tener conocimiento del volumen (V) el cual ha sido calculado mediante el procesamiento de imágenes aéreas, luego es necesario despejar la biomasa (B) de la ecuación $FD = B/V$ (Sinde-González et al., 2021).

De igual manera como la biomasa es calculada de manera directa e indirecta, el volumen de pasto también puede ser obtenido de la misma manera. La metodología directa es aforar el pasto y a través del principio de Arquímedes, se sumerge la muestra en un contenedor con agua, el aumento de volumen del agua en el contenedor será el volumen de la muestra de pasto. Asimismo, con el uso de programas de SIG puede obtenerse este valor al tener imágenes aéreas y aplicar algoritmos de modelamiento de una nube de puntos o imágenes en 3D (Botello-Aguillón, Gavi-Reyes, et al., 2019).

2.3 Sistemas aéreos operados remotamente

Los RPAS, son aeronaves que tienen la facilidad de ser monitoreadas a través de un mando a distancia. Estas tienen como finalidad realizar misiones que son difíciles o imposibles para naves tripuladas. Se usan en misiones que tienen una duración considerable, también donde haya de por medio contaminantes químicos o gases nocivos y en ocasiones en donde el piloto o la tripulación puede estar en peligro (Andújar, 2017), (Noor et al., 2018), (Montoya & Vásquez, 2019).

Uno de los sistemas más utilizados en la actualidad son los RPAS. Esta tecnología ha evolucionado constantemente, por lo que ha habido mejoría tanto en su desempeño, rendimiento y funcionalidad. Esto ha permitido que abarque otros campos de aplicación y su costo sea relativamente bajo (FAO, 2018).

2.3.1 Tipos de RPAS de acuerdo a su estructura

Los RPAS pueden clasificarse de acuerdo a su estructura, Sistemas de ala fija y sistemas de ala rotativa. Los primeros hacen referencia a naves que por su forma permiten aprovecharse de la aerodinámica y volar, estos se mantienen en vuelo un largo periodo y cuentan con una gran estabilidad, aunque el lanzamiento tiene que ser realizado por quien lo monitorea. Suelen usarse cuando se hace levantamiento de extensiones grandes de terreno (Hassnain et al., 2023).

Por otro lado, tenemos a los de ala rotativa que cuentan con distintos motores, los mismos que hacen girar a sus alas. Estos son más comunes por su versatilidad, maniobrabilidad y precio, también presenta una gran estabilidad y puede ser programado su vuelo. La desventaja que cuenta este tipo de drones es la autonomía de la batería, suele ser de un periodo pequeño, es por ello que, si se lo usa en un levantamiento topográfico, es necesario realizar una planificación de acuerdo a los recursos de la batería, por lo que podrá sobrevolar una extensión de espacio menor al de ala fija (Vergouv et al., 2016).

2.3.2 RPAS Autel Evo II

En el mercado existe una cantidad grande de marcas de RPAS, una de estas marcas se encuentra en la empresa Autel robotics. Uno de sus modelos, el Autel Evo 2 es un sistema que, por sus características es usado para misiones de

rescate y topografía. Una de sus principales características es que presenta una batería con autonomía de hasta 40 minutos, esto se debe a que su batería cuenta con 7100mAh, lo cual la hace muy duradera. La velocidad de vuelo es relativamente alta, este alcanza hasta los 72 km/h y tiene un alcance de transmisión de 9 kilómetros, por lo que es usado en misiones de rescate y levantamiento topográfico, asimismo, la altura máxima de despegue es de hasta los 6 kilómetros m s.n.m. Igualmente, cuenta con la opción de vuelos programables y una cámara incorporada de 8k con una alta resolución de 8000px * 6000px (Autel Robotics, 2022).

2.3.3 Uso de RPAS en la agricultura

En la actualidad, el uso de RPAS en la agricultura inteligente está en auge, estos sistemas han permitido levantar información que ayuda a vigilar y monitorear distintos procesos de un cultivo. El uso de estos equipos principalmente se debe a que la demanda de alimentos es mayor y por ende la de producción de alimentos, es así como crece el área cultivable y el cuidado del cultivo conlleva a solicitar una cantidad grande de mano de obra; sin embargo, con el empleo de RPAS, evita utilizar un extenso personal y a la vez el trabajo puede realizarse en menor tiempo (Pino V., 2019) (González et al., 2016).

El procesamiento de imágenes aéreas tomadas con RPAS permite realizar distintas operaciones como la gestión hídrica, fertilización, detección de enfermedades, por ende, nos permite conocer la sanidad del cultivo. El resultado de estas funciones es a lo que se llama mapas agronómicos, y representan los problemas y desarrollo del cultivo. Para ello los técnicos validan a través de índices de vegetación permitiendo conocer el estado en el cual se encuentra el cultivo, un ejemplo de estos índices es el NDVI (Índice de Vegetación de Diferencia Normalizada), este es ampliamente utilizado, debido a que la interferencia de la iluminación en el momento de la toma de la imagen, la pendiente y orientación no son factores que influyen en las imágenes resultantes (González et al., 2016), (FAO, 2018).

En materia de riego es idóneo conocer cuánto y cuándo regar la plantación, esto es oportuno porque evita que haya un estrés hídrico en el cultivo, es por ello que

el uso de RPAS permite lograr mayor eficiencia en el uso del recurso hídrico al sectorizar las necesidades hídricas del cultivo, es decir, regar la cantidad exacta que demande el cultivo espacialmente (Hassan-Esfahani et al., 2015).

De igual manera, en una finca convencional la fertilización lo hace el personal a la par con la maquinaria que prepara el terreno o avionetas tripuladas; por lo que, económicamente no es conveniente aplicar fertilizantes de esta manera. Al utilizar RPAS, el estado nutricional del cultivo se lo evalúa en el momento al estar equipado con distintas cámaras especializadas o con filtros específicos que permiten conocer los nutrientes que necesita la plantación y liberar la cantidad exacta de fertilizante para el cultivo (Torres-Rua et al., 2018). Así se puede ahorrar tiempo, mano de obra y fertilizante.

El procesamiento de las imágenes aéreas en software de SIG permite obtener información que en campo tomaría recursos y tiempo, por lo que ha sido necesario generar distintos algoritmos que ayudan a obtener resultados muy cercanos a la realidad. Un ejemplo de esto es la obtención de alturas de árboles en bosques, estos procesos son usados principalmente en ecología (Rueda-Ayala et al., 2019).

2.4 Proceso fotogramétrico

El propósito fundamental de un proceso fotogramétrico clásico radica en la creación de un modelo aproximado de un objeto real con el fin de extraer su información. Este proceso se estructura en tres etapas secuenciales:

En primer lugar, se realiza la adquisición de imágenes o patrones de energía emitida por el objeto bajo estudio. Posteriormente, se emplea un sistema de medición para identificar los puntos de unión entre las imágenes, utilizando características como la orientación de la fotografía, de manera análoga a lo realizado en la aerotriangulación.

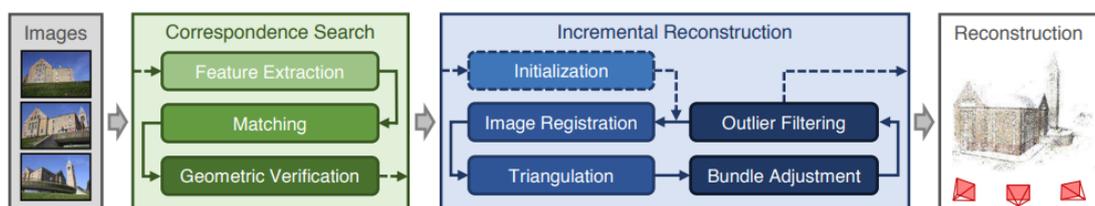
Finalmente, se lleva a cabo la etapa de reconstrucción del objeto en tres dimensiones, utilizando un algoritmo que opera en base a diferentes perspectivas. Los enfoques más comunes para esta tarea son el Structure from motion (SFM) y el Scale Invariant Feature Transform (SIFT) (Cordero, 2018).

SFM es un proceso que permite la reconstrucción de una estructura en 3D a partir de su proyección en imágenes tomadas desde distintos puntos de vista o ángulos sobre un lapso de tiempo. Tiene como entrada imágenes que generan una nube de puntos en 3D, la posición desde donde fue tomada la foto y un parámetro óptico propio de las cámaras (Torres et al., 2012).

El proceso es descrito como una tubería que procesa las imágenes de manera secuencial, este proceso inicia con una extracción y reconoce caracteres que coinciden entre todas las imágenes, seguido de esto, realiza una verificación geométrica, en este proceso se obtendrá un gráfico base que sirve para la etapa de reconstrucción, el cual establece el modelo seleccionado con una reconstrucción de dos vistas, antes de registrar nuevas imágenes, triangula y filtra valores atípicos que ayudan a refinar la reconstrucción, como se indica en la figura 9 (Schonberger & Frahm, 2016).

De acuerdo a Eltner & Sofia (2020) el uso de SFM es recomendado, porque es una metodología estable y hay estudios que lo demuestran, aunque se espera que en el campo de la georreferenciación permita mejorar la resolución a escala temporal y pueda manejarse la estimación del error para mejorar los modelos. La figura 10 sintetiza mediante un diagrama, el procesamiento 3D de imágenes con SFM.

Figura 10. Diagrama del procesamiento 3D de imágenes con SFM



Nota: (Schonberger & Frahm, 2016)

SIFT es un descriptor que se utiliza como herramienta para la generación de imágenes 3D, este algoritmo permite transformar los datos de la imagen en coordenadas. El descriptor SIFT es invariable a las rotaciones, traslaciones, transformaciones de escala y de luminosidad. Además, las propiedades son distintivas, es decir que puede emparejar o coincidir con imágenes con las

mismas propiedades que han sido guardadas en una base de datos, para ello, cada propiedad extraída se comparado con propiedades de otras imágenes (Gbash, Ekhlas & Saleh, Suha Mohammed, 2017).

El procedimiento para este algoritmo es el siguiente: detectan los extremos en una escala espacial, se localizan los puntos clave, se asigna orientación y se extrae descriptores de puntos clave. Para el primer proceso se usa diferencia Gaussiana para identificar puntos clave, la imagen de entrada producirá una cantidad de imágenes denominada octava. En el siguiente proceso los puntos clave se ubican con precisión en píxeles alternos al ajustar una función de expansión de Taylor a los valores de píxeles locales. En la tercera etapa, se asigna una orientación a cada punto clave y finalmente para cada punto clave se genera un histograma y el descriptor resultante es un vector de 128 elementos (Sima & Buckley, 2013).

Se ha podido demostrar que el descriptor SIFT es de utilidad para el emparejamiento de imágenes (coincidencia de imágenes); asimismo, permite reconocer objetos de luz visible y ha presentado buenos resultados en alineamiento de imágenes, por lo que se está trabajando en mejorar el algoritmo y usar imágenes (Chen et al., 2021).

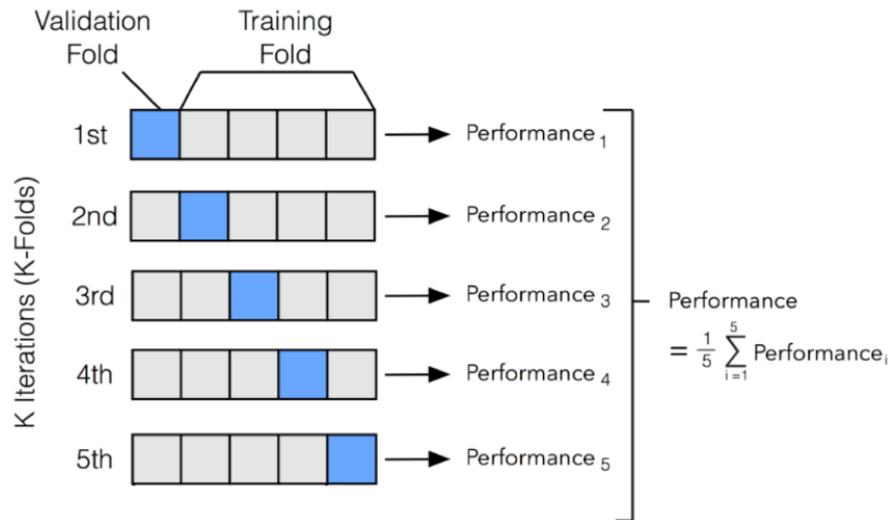
2.5 La validación cruzada

La validación cruzada es una técnica estadística fundamental en el campo del aprendizaje automático y la modelización predictiva, que se utiliza para evaluar la capacidad de generalización de un modelo (Ochoa, 2019). La validación cruzada es particularmente útil para evitar el sobreajuste, asegurando estimar la solidez y el rendimiento del modelo, permitiendo predecir con precisión como se desempeñará en un entorno real de aplicación (Allgaier & Pryss, 2024).

La validación cruzada de “k” particiones o **k-fold cross-validation**, consiste en dividir de todos los datos originales en “k” subconjuntos y, al momento de realizar el entrenamiento, se toma cada “k” subconjunto como conjunto de prueba del modelo, mientras que el resto de subconjuntos (k-1) se tomará como conjunto de entrenamiento. El proceso de validación cruzada se repetirá k veces, y en cada iteración se tomará un conjunto de prueba diferente, siendo el resto de

datos el conjunto de entrenamiento. Al finalizar las k iteraciones, se calcula el promedio de los resultados de precisión y error obtenidos (Ochoa, 2019).

Figura 11. Proceso de cross-validation para k=5



El algoritmo de validación cruzada de K iteraciones (K-fold cross-validation) opera bajo un proceso sistemático para evaluar la eficacia de un modelo de aprendizaje automático. Parte primero dividiendo aleatoriamente el conjunto de datos en 'K' subconjuntos o grupos de tamaño aproximadamente igual. Para el entrenamiento y validación, en cada iteración, uno de los "K" subconjuntos se utiliza como conjunto de validación (o prueba), y los "K-1" subconjuntos restantes se utilizan como conjunto de entrenamiento. Para la evaluación del modelo, este se entrena con los "K-1" grupos y luego se evalúa con el pliegue de validación. Se calcula la precisión del modelo, como el error cuadrático medio en el caso de regresión, sobre las observaciones en el subconjunto de validación (Kuhn, 2023).

CAPÍTULO III. MARCO CONTEXTUAL

3.1 Ubicación del área en estudio

La investigación en este estudio de caso se desarrolló en la granja Nero de la Universidad de Cuenca – Ecuador, ubicada en la parroquia Baños, cantón Cuenca, provincia del Azuay a 3100 metros de altura sobre el nivel del mar, con un área total de 297.8 ha de las cuales aproximadamente el 17.1 % ha están destinadas a pastos, área que se ubica en las coordenadas X mínima 709801.7, X máxima 711302.2, Y mínimo 9672084.7, Y máximo 9673143.8 en el sistema de proyección y coordenadas Universal Transversal de Mercator (UTM 17S WGS84) (ver figura 12 y 13).

Figura 12. Ubicación del área de estudio a nivel nacional, provincial y cantonal

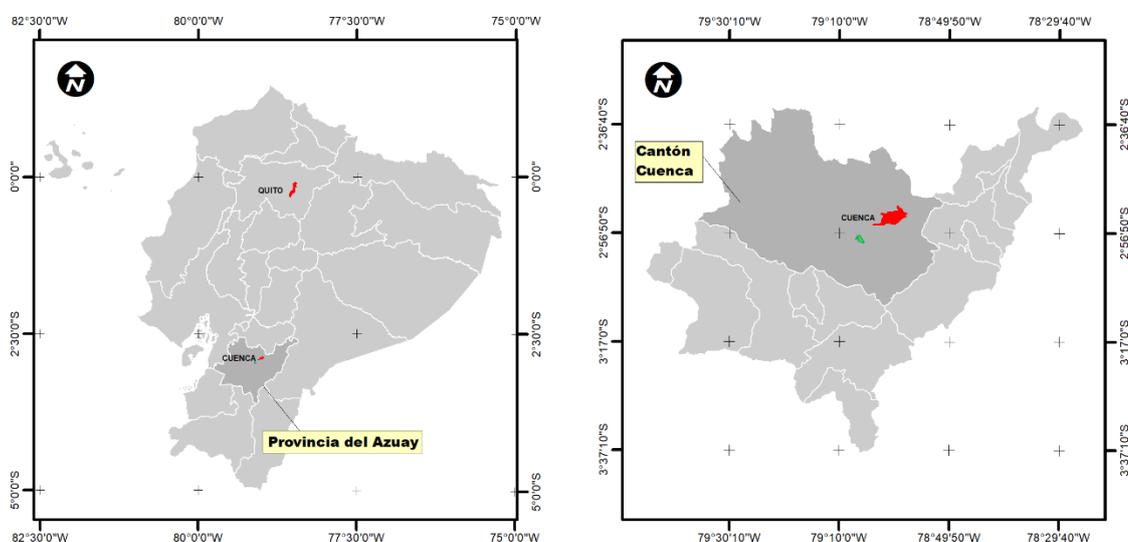
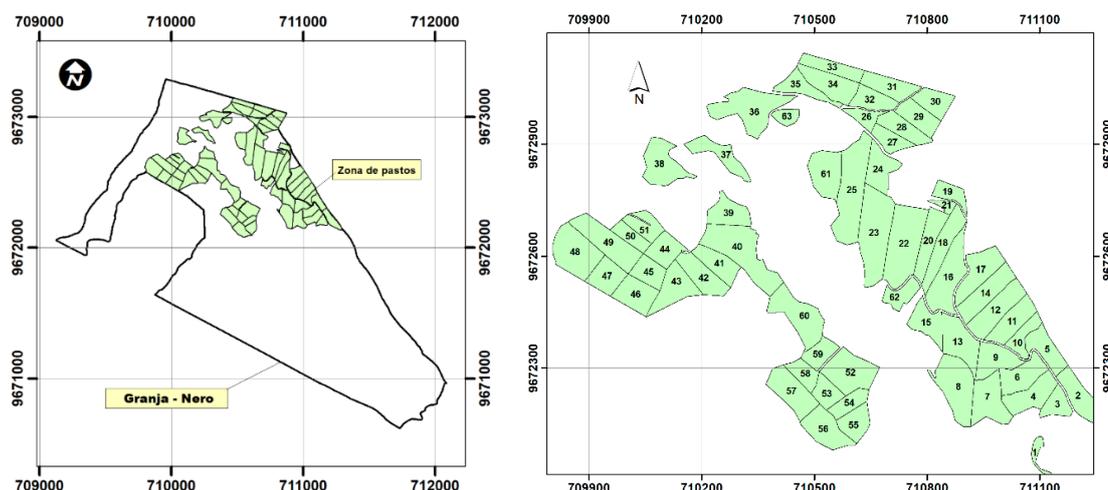


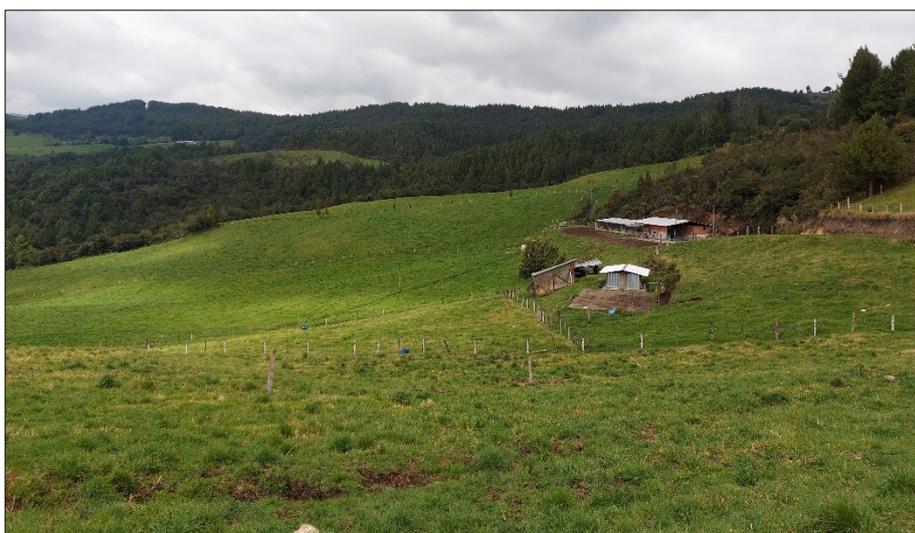
Figura 13. Ubicación del área de estudio en la granja Nero - potreros



3.2 Caracterización Geomorfológica y Topográfica

La granja Nero presenta una geomorfología variada, encontrándose zonas de cimas redondeadas típicamente ubicadas entre valles, con colinas de cimas suavemente curvadas, superficies inclinadas disectadas con paisajes que muestran signos de degradación del suelo en áreas con pendientes altas (ver fotografía 6).

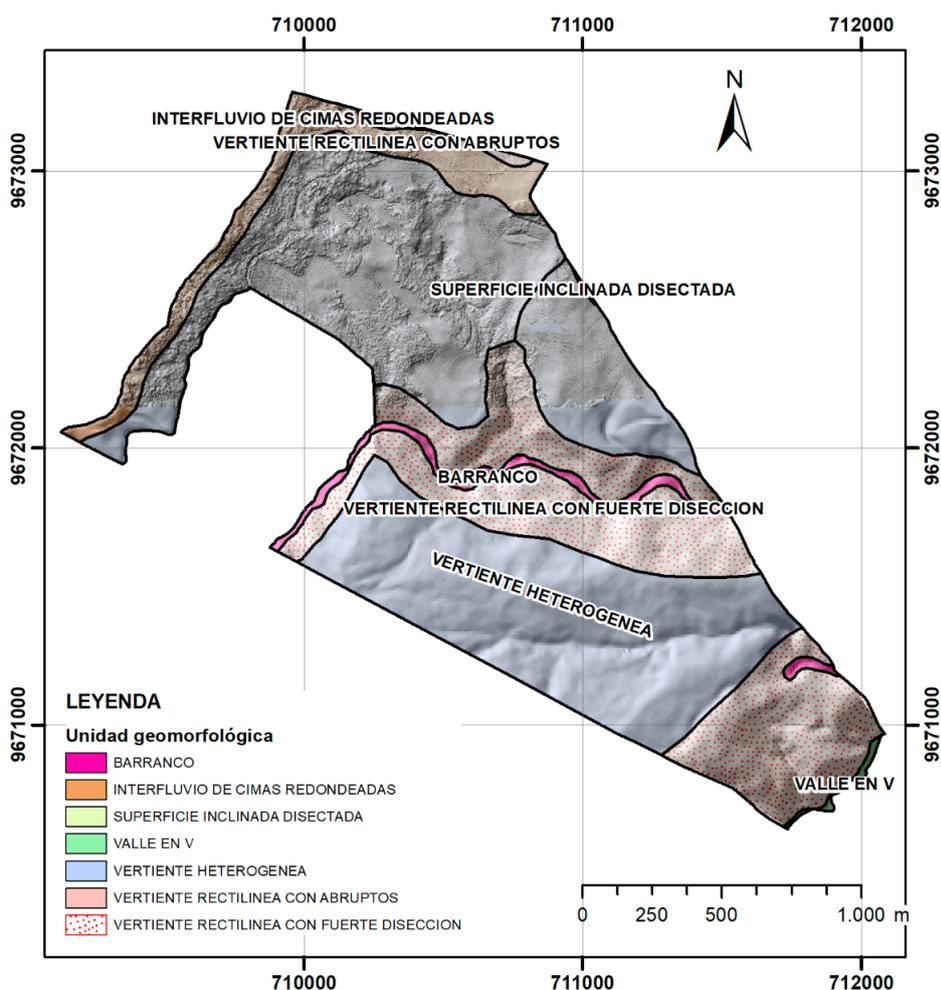
Fotografía 6. Relieve – Granja Nero



La mayor superficie de la granja se caracteriza por ser una vertiente heterogénea, es decir se da la presencia de laderas que muestran una variación sustancial en sus características topográficas, geológicas, vegetativas u otros

atributos a medida que se desciende o asciende por ella. También se observa una vertiente rectilínea abrupta, es decir una forma lineal o recta en el perfil longitudinal y la presencia de cambios bruscos o empinados en la topografía del terreno. Al Sureste de la granja se encuentra el valle en “V”, con lados inclinados o empinados que convergen hacia el centro del valle. Finalmente encontramos una formación encañonada en forma de hendidura que caracteriza a un barranco en zonas de altura. Las unidades geomorfológicas descritas lo podemos observar en la figura 14.

Figura 14. Unidades geomorfológicas



Topográficamente la granja presenta una elevación mínima de 2760.78 m s.n.m. y máxima de 3299.93 m s.n.m., con un desnivel de 539.14 m. Se generó un mapa de pendientes a partir del modelo digital del terreno realizado por el Sistema Nacional de Información y Gestión de Tierras Rurales e Infraestructura

Tecnológica "SIGTIERRAS", con una resolución de tamaño de pixel de 3 m x 3 m (ver figura 15); y se reclasificaron las pendientes en porcentajes como se describe en la tabla 2.

Figura 15. Pendientes de la granja Nero

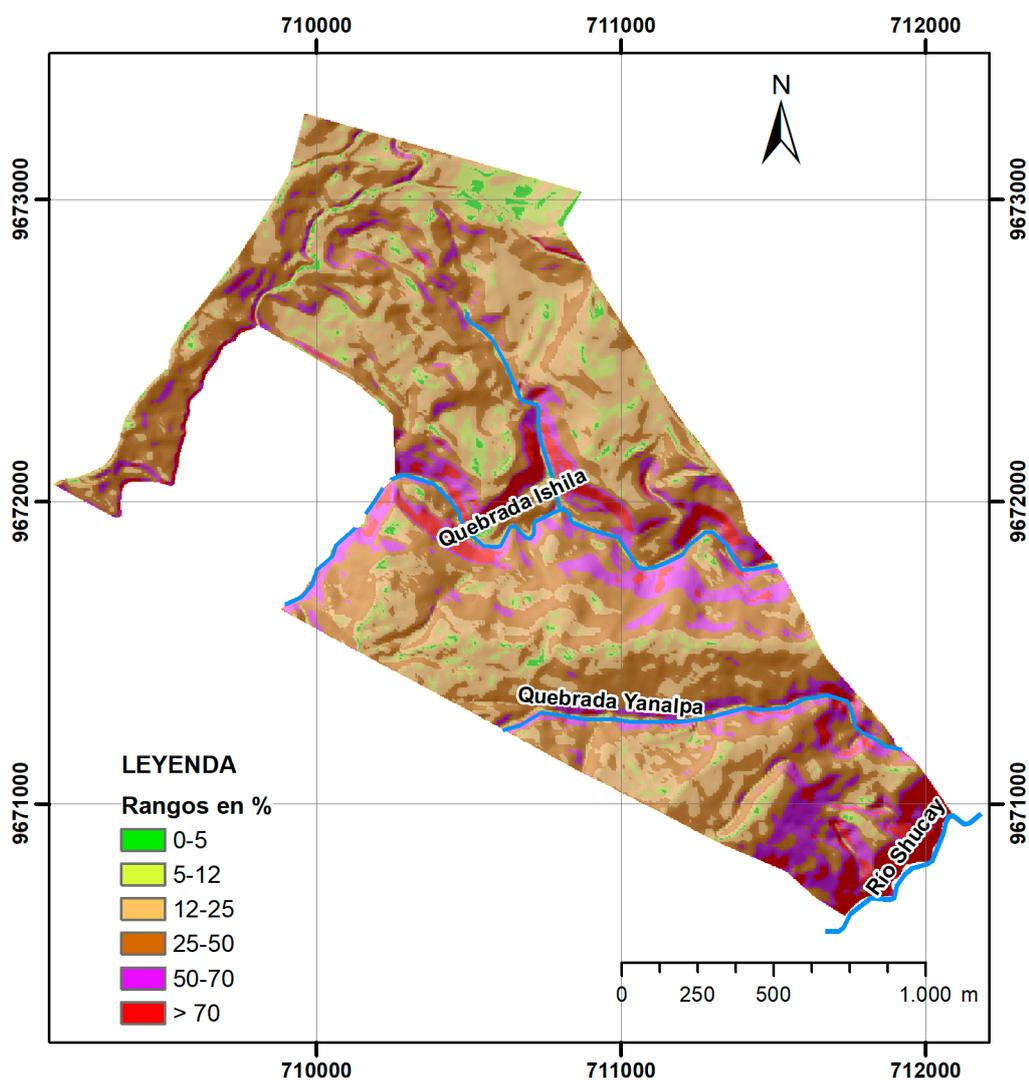


Tabla 4. Clasificación de pendientes en rangos

| Clase | Rango % | Forma del relieve | Ha | % |
|-------|---------|---|--------|-------|
| 1 | 0 - 5 | Pendiente débil, plano o casi plano | 3.69 | 1.25 |
| 2 | 5 - 12 | Pendiente con inclinación regular, suave o ligeramente ondulada | 22.71 | 7.70 |
| 3 | 12 - 25 | Pendiente irregular, ondulación moderada | 85.59 | 29.00 |
| 4 | 25 - 50 | Pendientes fuertes, colinado | 126.30 | 42.80 |
| 5 | 50 - 70 | Pendientes muy fuertes, escarpado | 37.89 | 12.84 |
| 6 | > 70 | Pendientes abruptas, montañoso | 18.93 | 6.41 |

La figura y tabla presentada nos brinda información sobre la distribución del terreno en diferentes categorías en función de la pendiente y la forma del relieve. En términos generales el rango de 25% a 50% de pendiente correspondiente al relieve de pendientes fuertes o colinado, que es lo que mayormente encontramos en la granja, seguido del rango de 12% a 25% y otras en menor porcentaje, nos indica que puede ser adecuado para ciertos propósitos, pero se deben considerar cuidadosamente los desafíos y las soluciones requeridas para aprovechar al máximo el terreno de manera sostenible y segura.

3.3 Caracterización Edafológica

Tomando como fuente de información la capa geopedológica a escala 1:25000 en formato vector, generado dentro del proyecto Generación de Geoinformación para la Gestión del Territorio a Nivel Nacional, se elaboró el mapa geopedológico para la Granja Nero (ver figura 16 y tabla 3). Este contiene información edafológica en base a unidades geomorfológicas previamente interpretadas. El nivel de clasificación de suelos corresponde hasta subgrupo de acuerdo a la Soil Taxonomy (Usda, 2014).

Figura 16. Suelos de la granja Nero

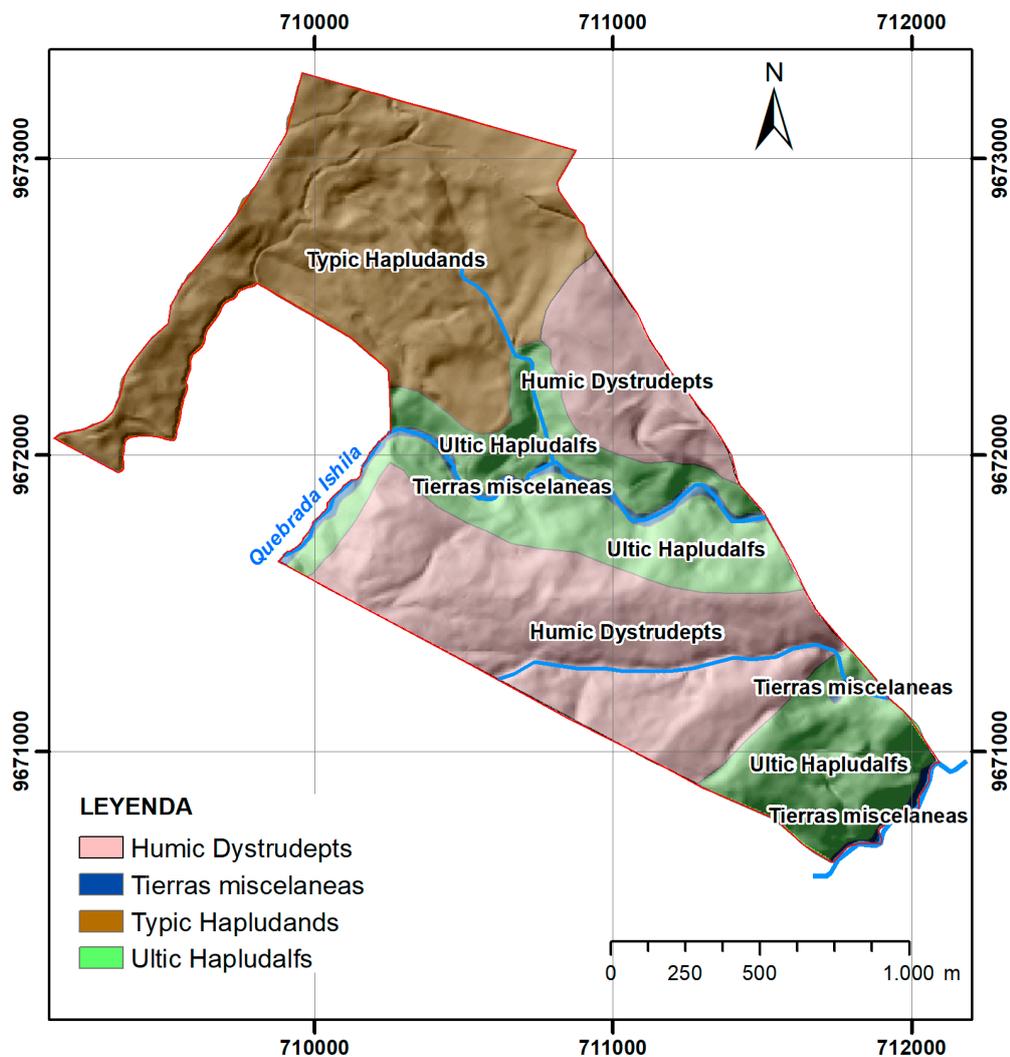


Tabla 5. Tipo de suelos

| Tipo de suelo | Área ha | % |
|--------------------------|---------|------|
| Humic Dystrudepts (KGEU) | 105.8 | 35.6 |
| Typic Hapludands (DHFU) | 103.0 | 34.7 |
| Ultic Hapludalfs (JEJZb) | 81.0 | 27.3 |
| Tierras misceláneas | 7.2 | 2.4 |

En el mapa generado en base al sistema de clasificación propuesto por el Departamento de Agricultura de los Estados Unidos (Usda, 2014), predomina el

tipo de suelos Humic Dystrudepts (35.6 %), estos tienen un alto contenido de materia orgánica descompuesta que proviene de la acumulación de material vegetal y orgánico a lo largo del tiempo. Suelos ricos en nutrientes que tienden a ser ácidos debido a la descomposición de la materia orgánica. Este pH ácido puede afectar la disponibilidad de ciertos nutrientes para las plantas por lo que es indispensable el ajuste en el pH y nutrientes para optimizar su uso agrícola.

El siguiente tipo de suelos se los conoce como Typic Hapludands (34.7 %), estos se encuentran en la zona norte de la Granja y específicamente en la zona de pastos, poseen horizontes del suelo bien desarrollados, incluyendo el horizonte O (orgánico), el horizonte A (superficial), el horizonte E (lixiviación de minerales), y el horizonte B (acumulación de minerales). Estos horizontes son típicos de suelos maduros y bien desarrollados. Poseen una textura que va desde arenosa a arcillosa, lo que significa que pueden retener cierta cantidad de agua, pero permiten un buen drenaje. Su pH tiende a ser neutro o ligeramente ácido, lo que es beneficioso para el desarrollo de cultivos. En cuanto a su composición mineral se da la presencia de arcilla, limo y arena en proporciones diversas.

El siguiente grupo de suelos presente es Ultic Hapludalfs (27.3 %), son suelos bien desarrollados con horizontes típicos de suelos maduros y bien formados. Poseen una textura correspondiente a la mezcla de arena, limo y arcilla con capacidad moderada para retener agua.

El pH de estos suelos corresponde a ligeramente ácido o neutro, con minerales diversos, como arcilla, limo y arena, en diferentes proporciones.

Finalmente encontramos tierras misceláneas en un porcentaje del 2.4% del total de la granja.

3.4 Caracterización Climática

3.4.1 Precipitación

Uno de los parámetros climáticos más importante es la precipitación, a partir de la lluvia se puede conocer de manera aproximada, el volumen de agua esperado en los ríos luego del escurrimiento producido por la presencia de precipitaciones.

Alrededor de la Granja existe un número importante de estaciones de medición de precipitación, las mismas que presentan información de varios años, con registros diarios y mensuales. La fuente de esta información corresponde a las siguientes instituciones: INAMHI, ETAPA y PROMAS-Universidad de Cuenca. A continuación, se indica en la Tabla 6 las estaciones pluviométricas consideradas para la elaboración de la distribución espacial de la precipitación. En la última columna se presenta la cantidad media anual de precipitación registrada en las estaciones.

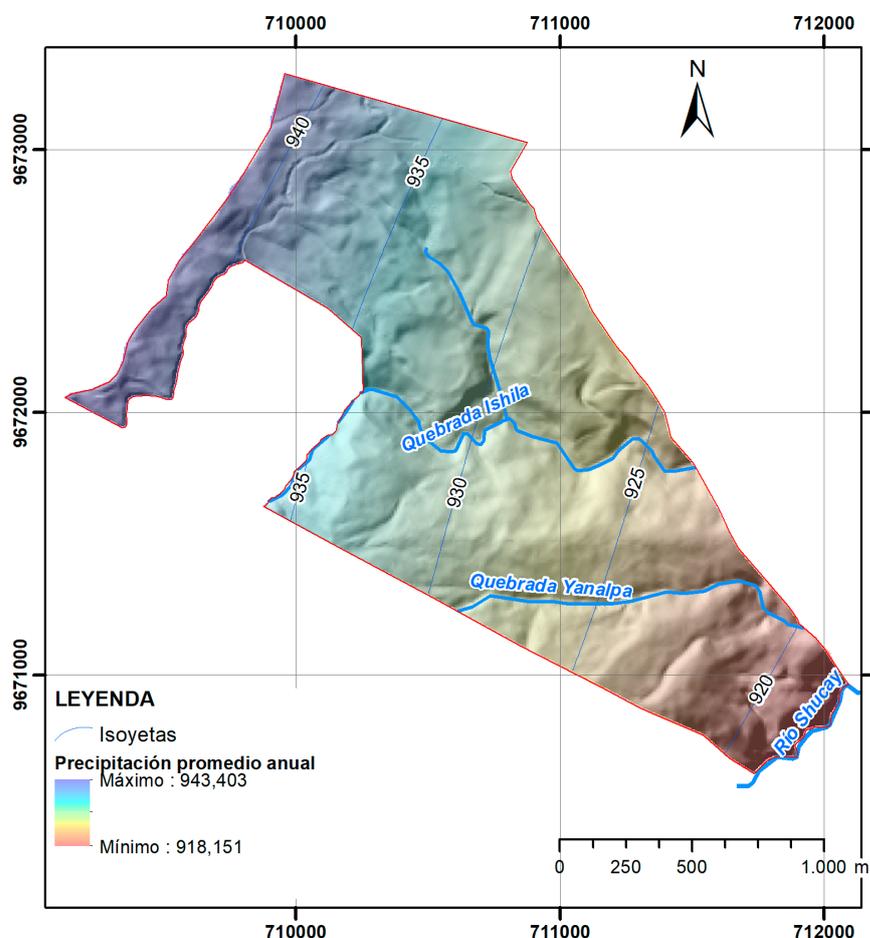
Tabla 6. Estaciones pluviométricas

| Estación | UTM X | UTM Y | Elevación | Promedio mm/año |
|-----------------------|-----------|------------|-----------|-----------------|
| Piscícola Chirimichay | 705194.66 | 9689463.09 | 3350 | 1330.69 |
| Cumbe | 720764.44 | 9658680.01 | 2715 | 637.50 |
| Cochabamba | 730198.48 | 9666779.94 | 2710 | 1017.40 |
| Matadero | 714501.60 | 9681917.03 | 2720 | 993.50 |
| Tarqui DJ Cumbe | 718459.47 | 9663817.02 | 2622 | 829.55 |
| Yanuncay en Pucán | 703249.55 | 9674135.11 | 3000 | 951.54 |
| Cancán | 689498.58 | 9675885.20 | 3680 | 873.01 |
| Portete | 712748.42 | 9654635.06 | 3080 | 1105.98 |
| Cuenca Aeropuerto | 723740.58 | 9680429.97 | 2516 | 865.30 |
| Cochapamba Quingeo | 730198.48 | 9666779.94 | 2710 | 934.40 |
| Gima | 727012.32 | 9640876.98 | 2770 | 955.80 |
| Marianza | 708638.62 | 9684240.07 | 3454 | 1113.85 |
| Baños | 714110.54 | 9673632.04 | 2600 | 917.35 |
| Bermejos | 696612.51 | 9667128.16 | 3712 | 991.03 |
| Universidad Cuenca | 721218.57 | 9679184.99 | 2610 | 883.15 |
| Esmeralda | 730219.38 | 9651115.95 | 2638 | 726.32 |

Con la información georreferenciada de la precipitación promedio anual se procedió a realizar una interpolación utilizando el método Inversa distancia

ponderada "IDW", para estimar valores de precipitación en lugares donde no hay estaciones. Este resultado lo presentamos en el siguiente mapa temático.

Figura 17. Distribución espacial de la precipitación en mm.



El comportamiento de las precipitaciones en la granja se da de manera regular con una precipitación promedio anual mínima de 918.15 mm en la zona sureste y máxima de 943.4 mm en la zona noroeste.

3.4.2 Temperatura

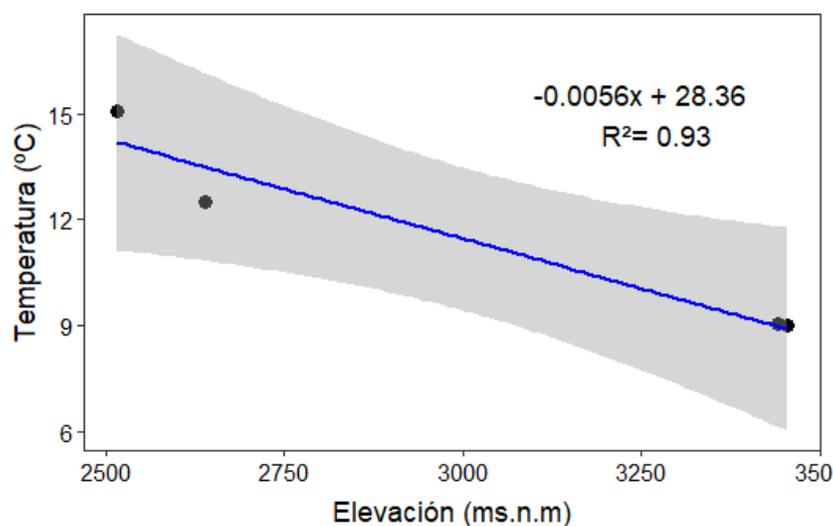
La temperatura es otro de los factores importantes en la caracterización climática ya que influye de manera significativa en la vegetación, la vida animal y la vida humana. Con la información de temperaturas obtenida en las estaciones climatológicas operadas por el INAMHI, y PROMAS-Universidad de Cuenca, se determinó la temperatura media alrededor de la granja mediante un análisis de correlación determinado por una ecuación de ajuste entre temperatura y altitud.

Los datos de temperatura que se presentan en la Tabla 7, se obtuvieron de estaciones ubicadas en las zonas más cercanas a la granja, la temperatura media anual registrada va desde los 8.99°C hasta los 15,06°C.

Tabla 7. Estaciones climatológicas

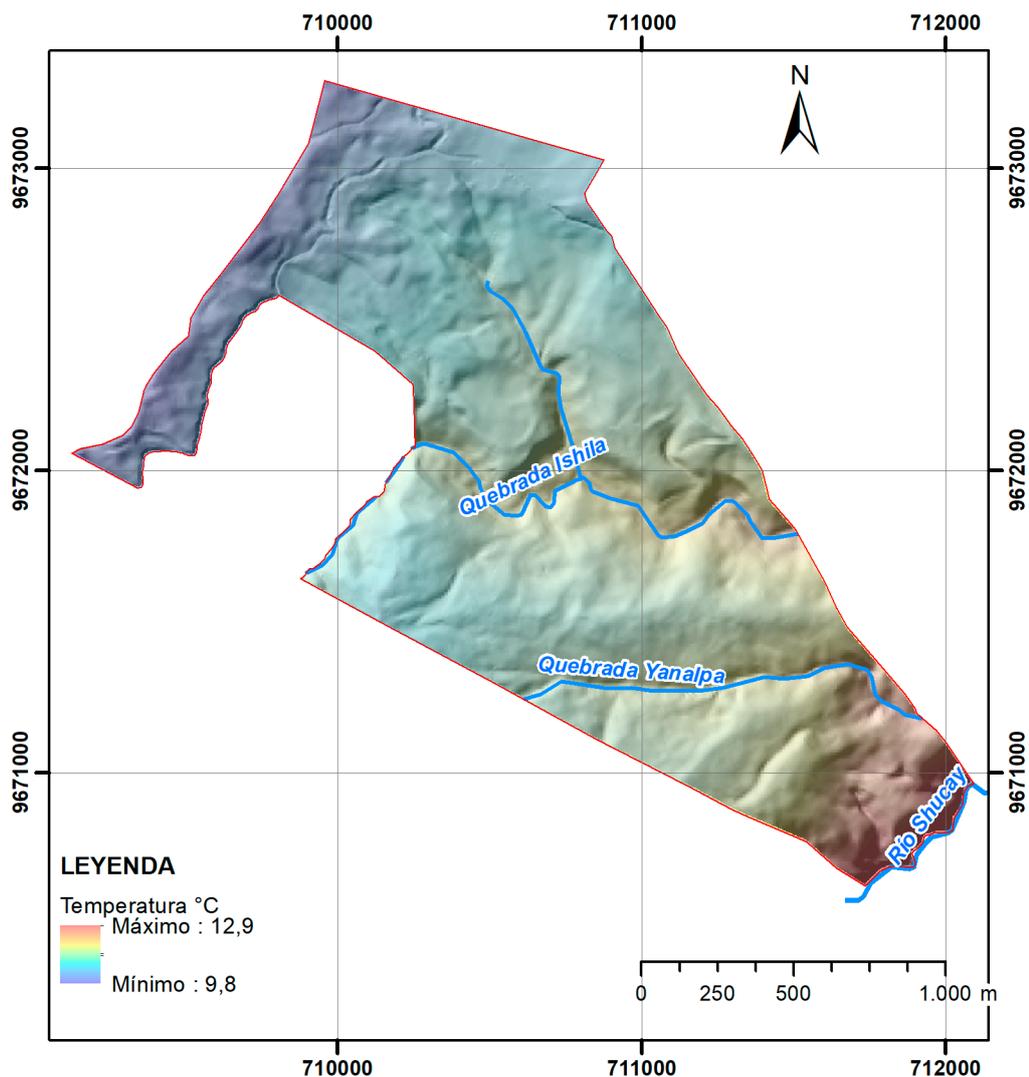
| Estación | XCoord | YCoord | Elevación | Promedio °C |
|-------------------|-----------|------------|-----------|-------------|
| Marianza | 708638.62 | 9684240.07 | 3454 | 8.99 |
| Esmeralda | 730219.38 | 9651115.95 | 2638 | 12.50 |
| Labrado | 714194.71 | 9698109.02 | 3440 | 9.03 |
| Cuenca Aeropuerto | 723740.58 | 9680429.97 | 2516 | 15.06 |

Gráfico 1. Ajuste de temperaturas



En el Gráfico 1 y la figura 18 se indica el ajuste lineal realizado para obtener la función de temperaturas relacionadas con la altitud, y la distribución espacial de la temperatura en la granja, se puede mencionar que la temperatura varía desde los 9.8° C en las zonas altas hasta 12.9 ° C en las zonas bajas con un promedio de 11.05°C.

Figura 18. Distribución espacial de la temperatura en °C



3.5 Cobertura y uso del suelo

Para generar el mapa de la cobertura y uso del suelo, se hizo uso de la orto imagen Pléiades del 12 de junio de 2020, de una resolución de 0.5m (figura 19); de la ortofoto correspondiente a la zona de pastos de la granja Nero de enero de 2023, con una resolución de 0.10 m (figura 20), y utilizando el módulo de ArcMap 10.8 y sus funciones de delimitación se procedió a digitalizar en pantalla y llenar los atributos en las bases de datos alfanuméricas de las diferentes coberturas.

Figura 19. Orto imagen granja Nero

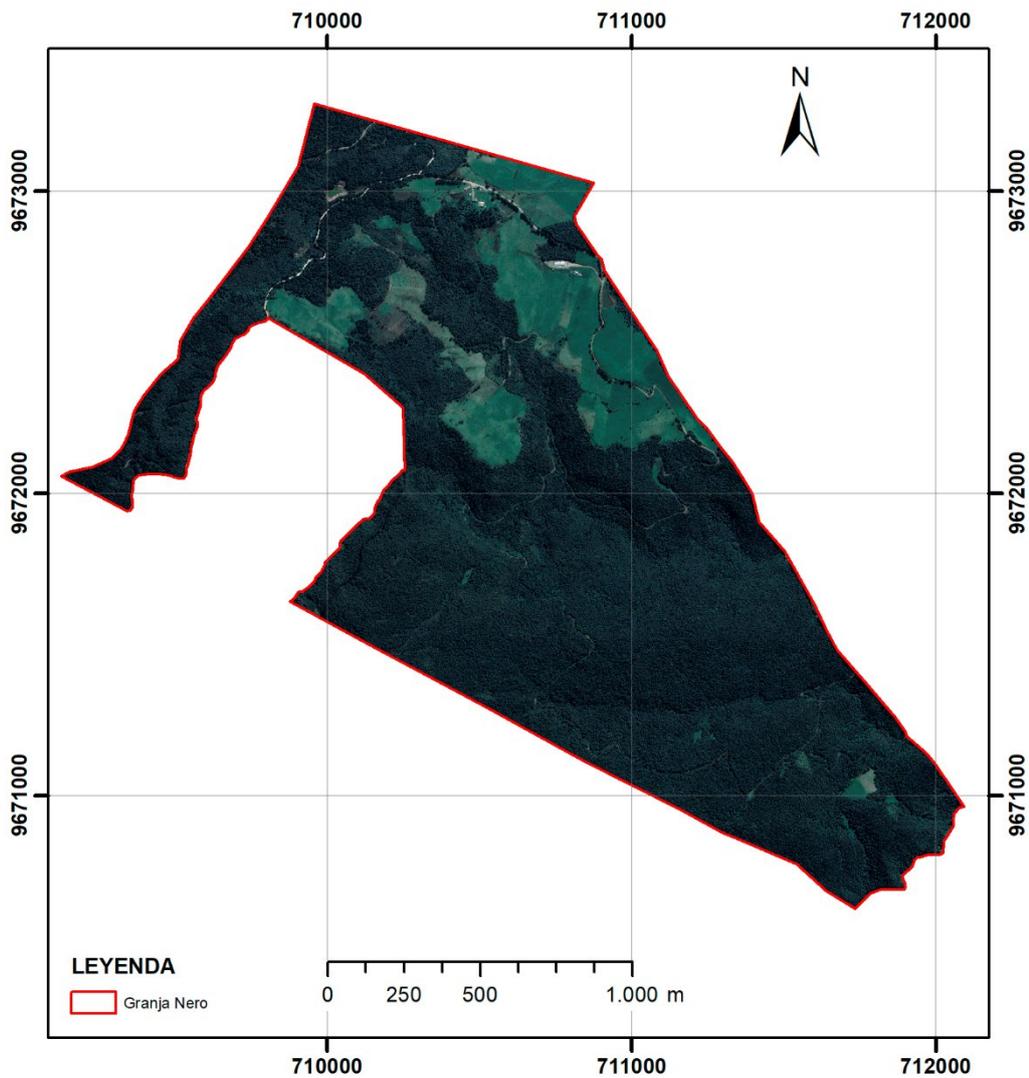
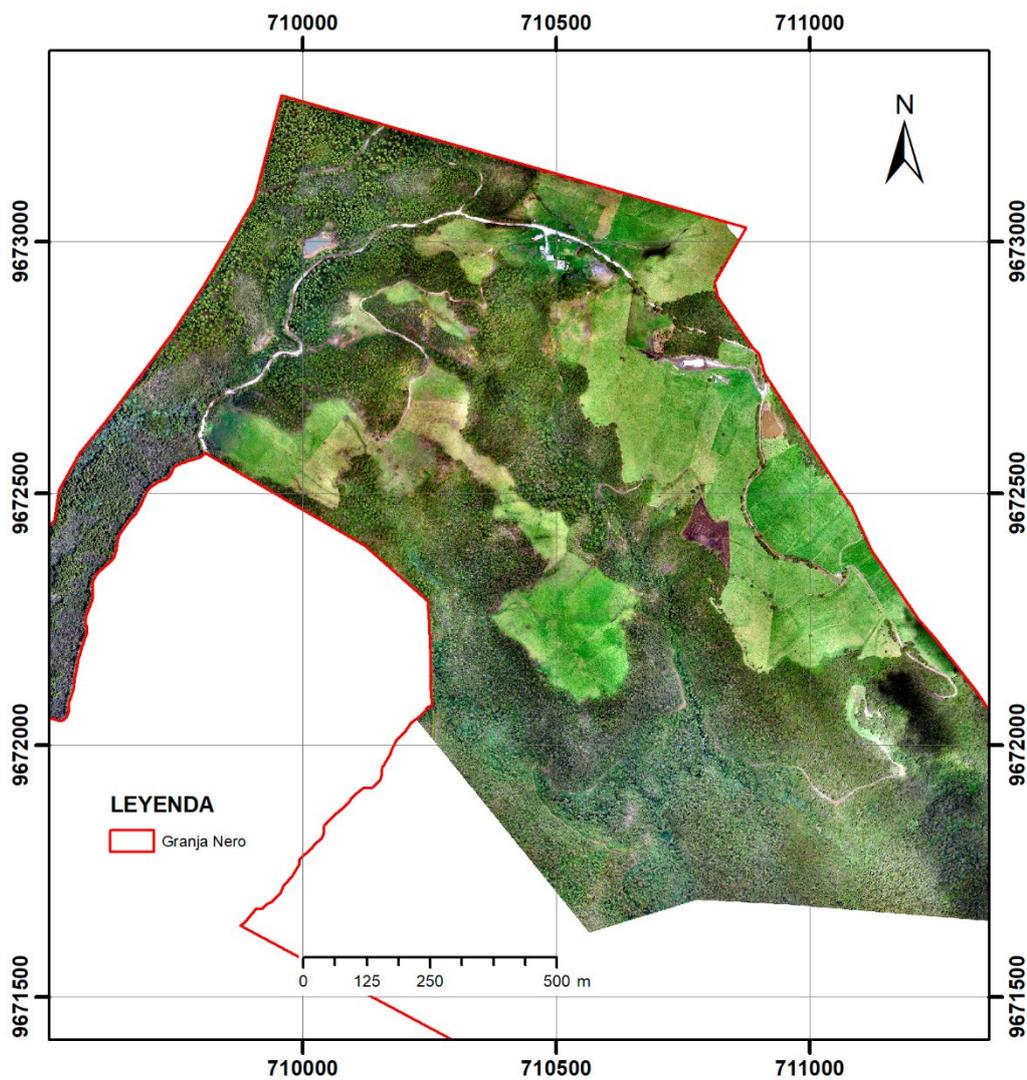


Figura 20. Ortofoto área de pastos



Los polígonos digitalizados corresponden a las siguientes coberturas y usos de suelo:

- Área de apicultura
- Áreas de reservorio
- Bosque húmedo medianamente alterado
- Casa de hacienda
- Establo
- Pasto cultivado
- Pino
- Red vial

- Reservoir

The result generated can be visualized in figure 21 and table 8.

Figura 21. Uso – cobertura vegetal

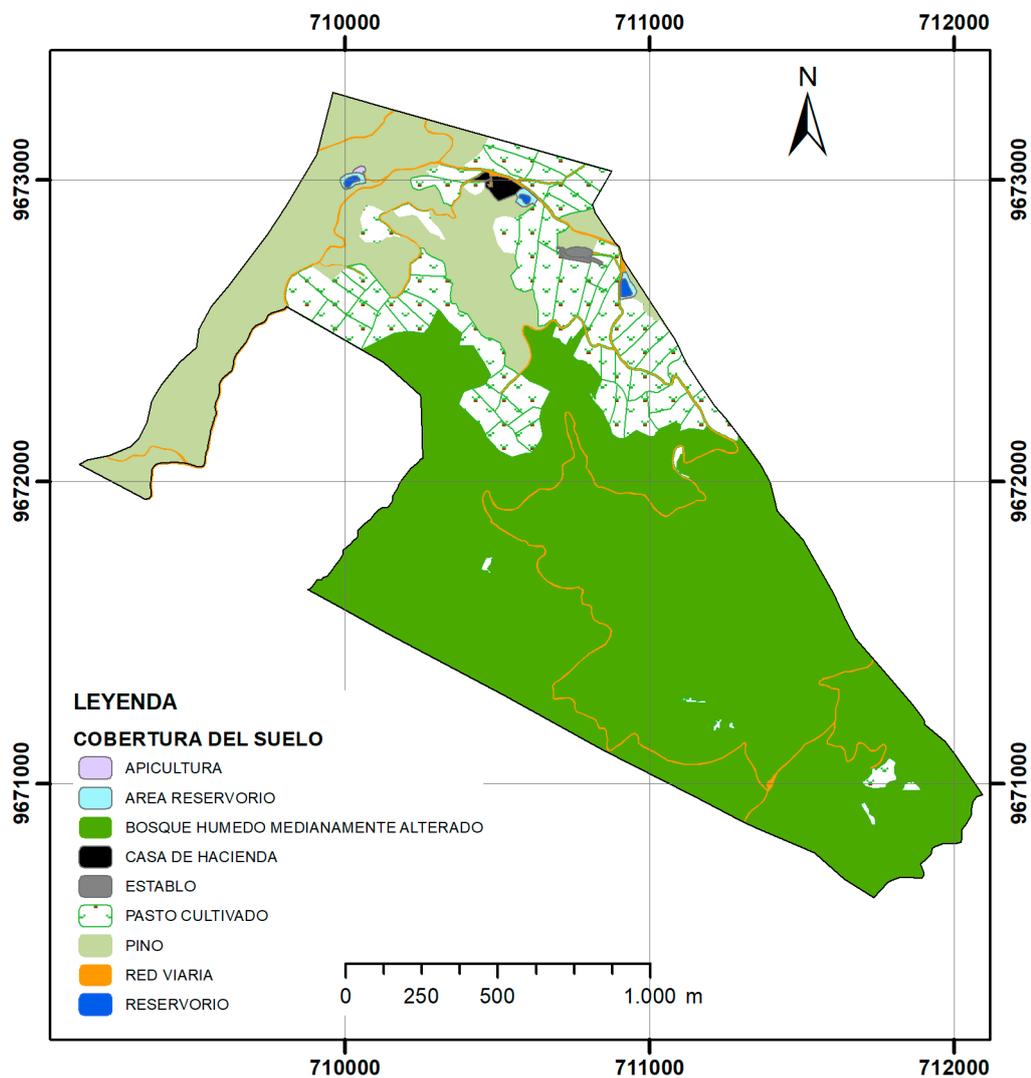


Tabla 8. Uso – cobertura vegetal

| Uso - cobertura | Área m2 | Área ha | % |
|-------------------------------------|------------|---------|-------|
| Apicultura | 754,28 | 0,08 | 0,03 |
| Área reservorio | 5979,63 | 0,60 | 0,20 |
| Bosque húmedo medianamente alterado | 1863319,43 | 186,33 | 62,45 |
| Casa de hacienda | 6996,05 | 0,70 | 0,23 |
| Establo | 4753,32 | 0,48 | 0,16 |
| Pasto cultivado | 511823,91 | 51,18 | 17,15 |
| Pino | 523721,57 | 52,37 | 17,55 |
| Red viaria | 62839,69 | 6,28 | 2,11 |
| Reservorio | 3384,77 | 0,34 | 0,11 |

Al realizar un breve análisis de la tabla 8 de los 9 tipos de cobertura vegetal y uso del suelo de la granja Nero, se puede afirmar que el porcentaje más alto (62,45%) corresponde al Bosque húmedo medianamente alterado; seguido de la plantación de pino ocupando un 17.55% del total de la granja; pasto cultivado el 17.15% y las demás coberturas se encuentran bajo estos porcentajes.

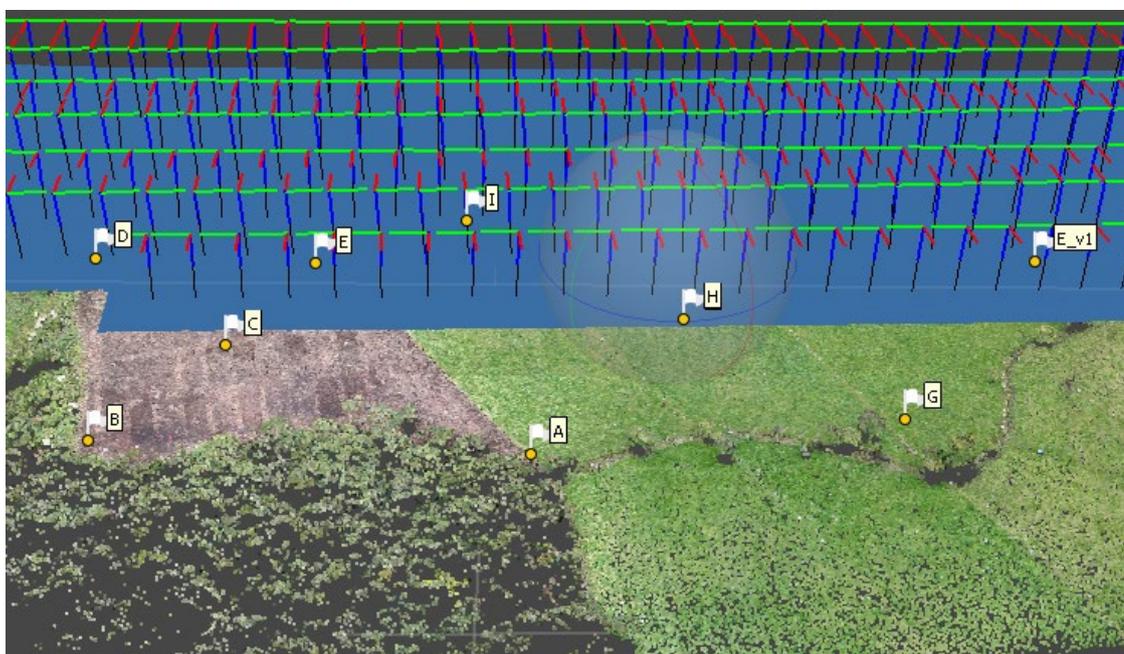
En relación al área de pastos de la granja, objeto de estudio de esta investigación está constituida por una mezcla forrajera de Ray Grass inglés (*Lolium perenne*), Ray Grass italiano (*Lolium multiflorum*) y Trébol blanco (*Trifolium repens*), en un sistema de pastoreo rotacional para lo cual el área está dividido en varias secciones o potreros más pequeños y la rotación del ganado entre ellos. El objetivo de este sistema en la granja es permitir que el ganado pastoree una sección de pasto durante un período de tiempo limitado, permitiendo que la hierba se recupere y crezca antes de que el ganado retorne a esta área; Sin embargo, lo observado es una variabilidad grande en el tiempo que permanece el ganado en cada sección debido a que el alimento forrajero se termina rápidamente, observando que en algunos casos permanecen algunos días y en otros solamente un día y en superficies más o menos homogéneas.

CAPÍTULO IV. RESULTADOS

4.1 Obtención de imágenes

La función del vehículo aéreo operado remotamente en la generación de geo información, es el adquirir datos de campo mediante la toma georreferenciada de fotos aéreas consecutivas y homogéneas con el traslape adecuado con el objeto de crear pares estereoscópicos (ver figura 22). Con los vuelos realizados en las áreas de monitoreo correspondiente a pasto de la mezcla forrajera de Ray Grass inglés (*Lolium perenne*), Ray Grass italiano (*Lolium multiflorum*) y Trébol blanco (*Trifolium repens*), se obtuvieron 1171 fotos a una altura de 60m del terreno con un tamaño de pixel promedio de 0.014 m (ver figura 22 y fotografía 7).

Figura 22. Pares estereoscópicos



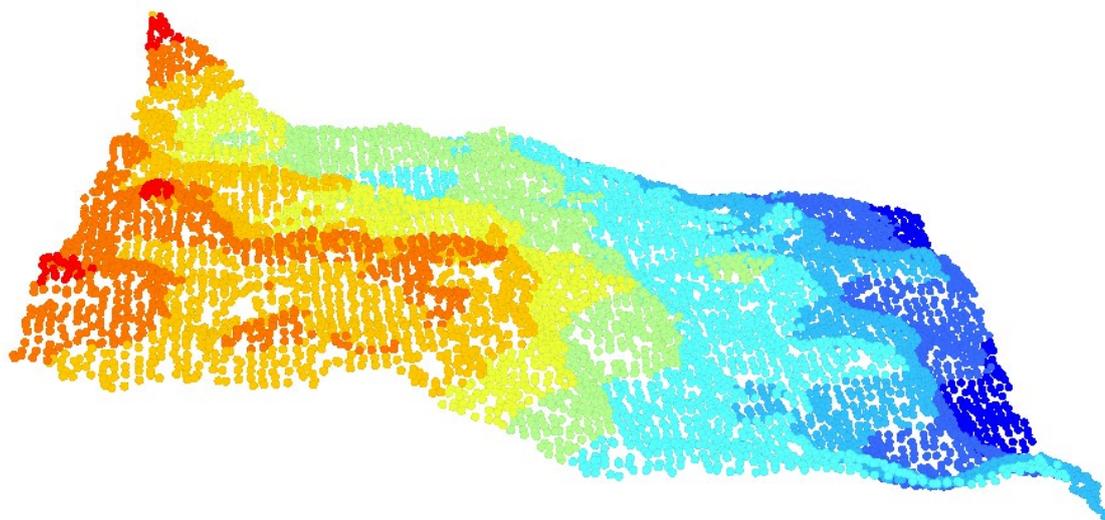
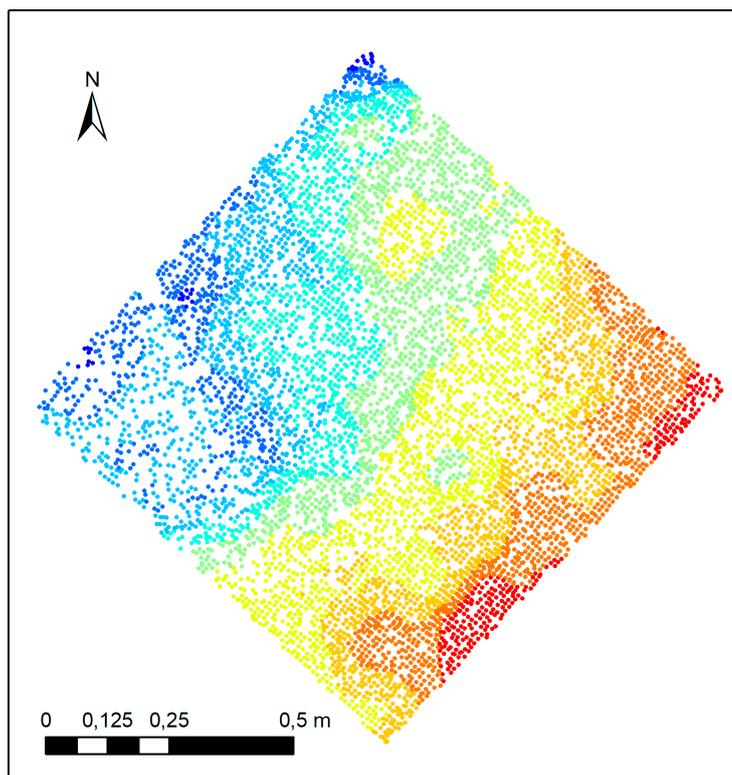
Fotografía 7. Fotos aéreas obtenidas



4.1.1 Nube de puntos densa

Utilizando el flujo de trabajo establecido en la metodología, haciendo uso del software Agisoft Metashape, se crea la nube puntos densa con una calidad extra alta para todas las áreas levantadas. Luego, utilizando la delimitación de las áreas de muestro establecidas, se extrae los puntos y se los exporta a archivos con la extensión .las, como resultado se obtiene nubes de puntos para cada una de las áreas de muestreo (ver figura 23).

Figura 23. Nube de puntos para el área de muestreo 41^a

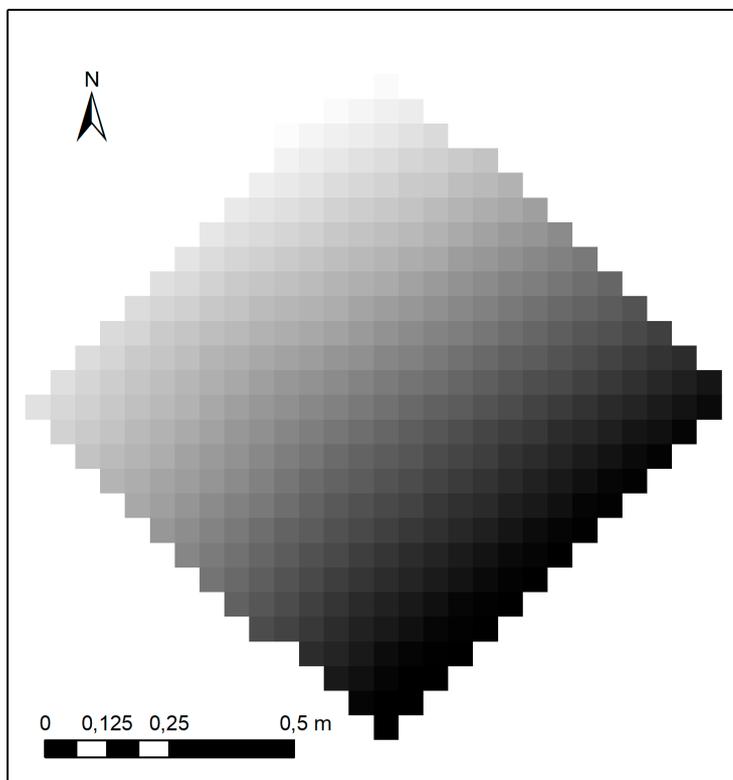


4.1.2 Levantamiento topográfico de cada área de muestreo

Aplicando la metodología establecida se realizó el levantamiento topográfico para cada área de muestro. El resultado fue la obtención de puntos con

coordenadas tridimensionales precisas, las mismas que utilizando software de sistemas de información geográfica, se realizó la interpolación tipo TIN (Triangulated Irregular Network) para llegar a obtener el modelo digital de terreno, para cada área de muestreo (ver figura 24).

Figura 24. Modelo digital de terreno del área de muestreo 41^a



4.1.3 Volumen de biomasa

4.1.3.1 Volumen real

Calculado a partir de las alturas del cultivo por el área muestreada se presenta en la siguiente tabla:

Tabla 9. Volumen real en cada parcela de muestreo de pasto.

| Pm | m3 | Pm | m3 |
|-----------|-----------|-----------|-----------|
| 13A_A | 0.37 | 35_B | 0.4 |
| 13A_B | 0.28 | 41_A | 0.15 |
| 13A_M | 0.27 | 41_B | 0.16 |
| 13B_A | 0.22 | 41_C | 0.14 |
| 13B_B | 0.28 | 41_D | 0.15 |
| 13B_M | 0.19 | 6_A | 0.23 |
| 22_A | 0.26 | 6_B | 0.15 |
| 22_B | 0.37 | 6_M | 0.22 |
| 22_M | 0.23 | 7_A | 0.15 |
| 23_A | 0.38 | 7_B | 0.21 |
| 23_B | 0.23 | 7_M | 0.25 |
| 23_M | 0.33 | 8_A | 0.21 |
| 25_A | 0.47 | 8_B | 0.24 |
| 25_B | 0.21 | 8_M | 0.24 |
| 25_M | 0.17 | 8B_A | 0.26 |
| 31_A | 0.21 | 8B_M | 0.34 |
| 31_B | 0.21 | 8B_B | 0.3 |
| 32_A | 0.25 | 9_A | 0.19 |
| 32_B | 0.22 | 9_B | 0.16 |
| 33_A | 0.18 | 9_C | 0.14 |
| 33_B | 0.15 | 9A_8B | 0.19 |
| 34_A | 0.21 | 9B_8B | 0.16 |
| 34_B | 0.18 | 9C_8B | 0.14 |
| 35_A | 0.29 | | |

4.1.3.2 Volumen con modelación digital

Generado con el procesamiento de la fotografía aérea obtenida mediante el RPAS se presenta en la siguiente tabla:

Tabla 10. Volumen aparente con modelación digital en cada parcela de muestreo de pasto.

| Pm | m3 | Pm | m3 |
|-----------|-----------|-----------|-----------|
| 13A_A | 0.366 | 35_B | 0.403 |
| 13A_B | 0.280 | 41_A | 0.149 |
| 13A_M | 0.294 | 41_B | 0.148 |
| 13B_A | 0.219 | 41_C | 0.151 |
| 13B_B | 0.284 | 41_D | 0.142 |
| 13B_M | 0.203 | 6_A | 0.233 |
| 22_A | 0.267 | 6_B | 0.153 |
| 22_B | 0.365 | 6_M | 0.204 |
| 22_M | 0.230 | 7_A | 0.159 |
| 23_A | 0.384 | 7_B | 0.179 |
| 23_B | 0.244 | 7_M | 0.249 |
| 23_M | 0.331 | 8_A | 0.198 |
| 25_A | 0.466 | 8_B | 0.236 |
| 25_B | 0.214 | 8_M | 0.231 |
| 25_M | 0.168 | 8B_A | 0.181 |
| 31_A | 0.189 | 8B_M | 0.162 |
| 31_B | 0.207 | 8B_B | 0.137 |
| 32_A | 0.237 | 9_A | 0.273 |
| 32_B | 0.224 | 9_B | 0.343 |
| 33_A | 0.179 | 9_C | 0.294 |
| 33_B | 0.145 | 9A_8B | 0.181 |
| 34_A | 0.206 | 9B_8B | 0.162 |

| | | | |
|------|-------|-------|-------|
| 34_B | 0.172 | 9C_8B | 0.137 |
| 35_A | 0.299 | | |

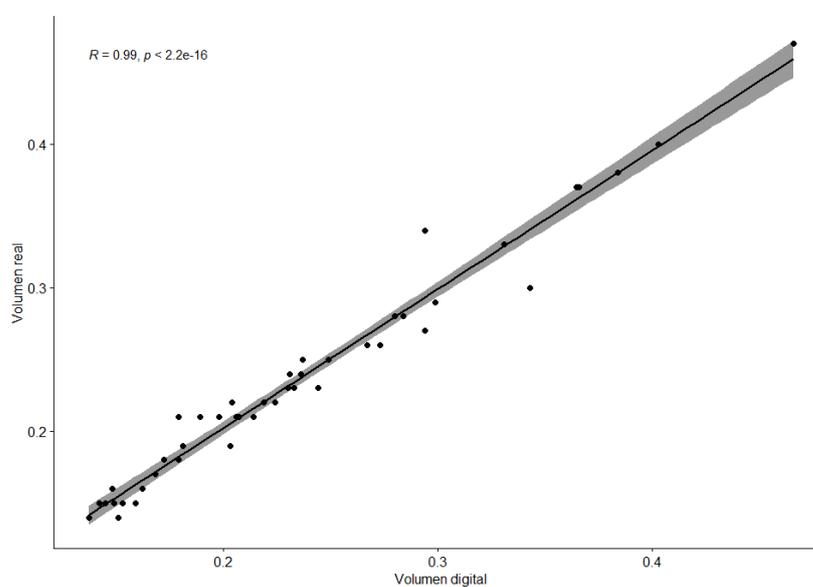
4.1.4 Relación entre variables

Los análisis de correlación desarrollados con el propósito de evaluar la idoneidad de los datos generados para la construcción de modelos estadísticos se pueden observar en la siguiente tabla y gráfico.

Tabla 11. Resultados de correlaciones mediante el coeficiente de Pearson

| Correlaciones | P-valor | Coeficiente (r) |
|---|---------|-----------------|
| Volumen Digital (m3) - Volumen real (m3) | < 0 | 0.993 |
| Altura Digital (m) - Altura real (m) | < 0 | 0.985 |
| Biomasa Digital (kg) - Biomasa real (kg) | < 0 | 0.918 |
| Volumen Digital (m3) - Biomasa fresca (kg/m2) | < 0 | 0.915 |
| Volumen Digital (m3) - Biomasa seca (kg/m2) | <0.0001 | 0.652 |
| Altura Digital (m) - Biomasa fresca (kg/m2) | < 0 | 0.920 |
| Altura Digital (m) - Biomasa seca (kg/m2) | <0.0001 | 0.634 |

Gráfico 2. Correlación de Pearson



Como podemos observar los resultados de la correlación volumen digital (m³) - volumen real (m³), indica que existe una correlación positiva muy fuerte (0.993) y que esta correlación es estadísticamente muy significativa (p-valor < 0.0).

La correlación altura digital (m) – altura real (m), al igual que en el caso anterior, se observa una correlación positiva muy fuerte (0.985), siendo también estadísticamente muy significativa (p-valor < 0.0).

La correlación positiva biomasa digital (kg) - Biomasa real kg es también muy fuerte (0.918) y estadísticamente muy significativa (p-valor < 0.0).

La correlación volumen digital (m³) - biomasa fresca (kg/m²) es positiva muy fuerte (0.915) siendo también estadísticamente muy significativa (p-valor < 0.0).

La correlación volumen digital (m³) - biomasa seca (kg/m²) es positiva, aunque moderadamente fuerte (0.652), esto indica que, si bien hay una relación lineal entre estas variables, no es tan estrecha como en el caso de otras correlaciones reportadas. Dándonos a entender que el volumen digital no es el único factor que determina la biomasa seca, y que posiblemente existan otras variables que influyen en esta relación de manera más significativa.

La correlación altura digital (m) - biomasa fresca (kg/m²) es positiva y muy fuerte (0.920), estadísticamente muy significativa (p-valor < 0.0).

La correlación altura digital (m) – Biomasa seca (kg/m²) al igual que con el volumen digital, la correlación positiva, aunque moderada ($r = 0.634$) indica que, si bien a medida que aumenta la altura digital también tiende a aumentar la biomasa seca, esta relación no es tan estrecha o proporcional como en los casos de correlaciones más altas. Puede deberse a que existen otros factores, además de la altura, que influyen en la determinación de la biomasa seca de una manera más significativa.

En términos generales, los resultados muestran correlaciones positivas muy fuertes y estadísticamente significativas entre las variables digitales y sus correspondientes variables reales, con la excepción de las correlaciones con la biomasa seca, que son más débiles, pero aun así significativas. En relación al p valor conocido como nivel de significancia, los resultados demuestran que

cumplen con la condición de ser menor que un nivel de significancia impuesto ($p < 0.05$), por lo que consideramos que lo obtenido es estadísticamente significativo.

4.1.5 Modelos de regresión

La obtención de resultados correspondientes al volumen y altura, hizo uso de los datos obtenidos en el aforo tradicional y digital. El volumen y altura obtenidos en campo (volumen-altura real) y el volumen y altura a partir de imágenes de RPAS (volumen-altura digital).

Las Tablas 12 y 13 describen las medidas de tendencia central para cada variable de volumen, altura y biomasa, en esta se puede observar que, cuando obtenemos el volumen la media, la mediana y la varianza son muy similares. Así mismo, se divisa el mismo comportamiento con los valores máximos y mínimos. El coeficiente de variación señala que la dispersión del volumen digital fue del 33%, mientras que, del volumen real fue del 32 %, valores muy próximos.

Tabla 12. Medidas de tendencia central en la obtención de volumen y altura de pasto

| Variable | Media | Mediana | Máximo | Mínimo | Varianza | Coef. var |
|-----------------------------|-------|---------|--------|--------|----------|-----------|
| Vol. Digital m ³ | 0.235 | 0.221 | 0.466 | 0.137 | 0.0061 | 0.33 |
| Vol. Real m ³ | 0.237 | 0.220 | 0.471 | 0.135 | 0.0060 | 0.32 |
| Alt. Digital m | 0.236 | 0.222 | 0.466 | 0.137 | 0.006 | 0.33 |
| Alt. Real m | 0.238 | 0.220 | 0.470 | 0.140 | 0.006 | 0.32 |

Las medias y medianas de las variables digitales y reales son muy similares, lo que indica que los valores tienden a estar agrupados alrededor de la media.

Los valores máximos y mínimos también son cercanos entre las variables digitales y reales, lo que refuerza la alta correlación observada anteriormente.

Los coeficientes de variación son relativamente bajos (alrededor de 0.32-0.33), lo que sugiere que la dispersión de los datos en torno a la media no es muy alta.

En síntesis, las medidas de tendencia central (media, mediana) y de dispersión (varianza, coeficiente de variación) muestran que los valores de las variables digitales y reales son muy similares, lo que coincide con los altos coeficientes de correlación reportados anteriormente.

Tabla 13. Medidas de tendencia central en la obtención de biomasa de pasto.

| Variable | Media | Mediana | Máximo | Mínimo | Varianza | Coef. var |
|---------------------|---------|---------|---------|--------|----------|-----------|
| Biom. Digital kg/ha | 2902.93 | 2883.10 | 4771.02 | 628.65 | 1453329 | 0.415 |
| Biom. Real kg/ ha | 2906.18 | 2915.5 | 4884 | 646 | 1380367 | 0.404 |

Realizando un análisis de estos resultados, podemos observar semejanza entre variables, por ejemplo, los valores de media, mediana, máximo y mínimo son muy similares entre la biomasa digital y la biomasa real. Esto indica una alta correlación entre ambas variables. Las medias y medianas son bastante cercanas, indicando que los datos están agrupados alrededor de un valor central. Esto se ve reforzado por los bajos coeficientes de variación. Los valores de varianza y coeficiente de variación son también muy similares entre ambas variables, esto significa que la dispersión de los datos en torno a la media es relativamente baja. Finalmente, los valores máximos y mínimos sugieren que puede haber algunos datos atípicos ya que hay diferencias significativas entre el valor máximo y mínimo.

En la tabla 14 se muestra los coeficientes de los modelos de entrenamiento, prueba y validación cruzada de los modelos generados.

- El modelo de altura digital y real presenta un R² de 0.955 en entrenamiento, 0.981 en prueba y 0.958 en validación cruzada. Los errores (RMSE y MAE) son muy bajos, lo que indica una predicción muy precisa de la altura real a partir de la altura digital.
- El modelo volumen digital y real tiene un excelente ajuste, con un R² superior a 0.98 en las tres métricas. Los errores (RMSE y MAE) son mínimos, lo que demuestra una predicción muy precisa del volumen real a partir del volumen digital.

- El modelo altura digital y biomasa fresca tiene un buen ajuste en entrenamiento ($R^2 = 0.914$) y validación cruzada ($R^2 = 0.910$); sin embargo, en la prueba el ajuste disminuye ($R^2 = 0.827$), lo que sugiere cierta falta de generalización del modelo. Los errores (RMSE y MAE) son un poco más altos que en los casos anteriores, pero siguen siendo aceptables.
- El modelo altura y biomasa seca su ajuste es moderado con R^2 de 0.686 en entrenamiento, 0.587 en prueba y 0.738 en validación cruzada. Los errores (RMSE y MAE) son más altos que en los modelos anteriores, lo que indica una predicción menos precisa de la biomasa seca a partir de la altura.
- El modelo volumen digital y biomasa fresca tiene un buen ajuste, con R^2 entre 0.732 y 0.808. Los errores (RMSE y MAE) son bajos y relativamente constantes en las tres métricas.
- El modelo volumen digital y biomasa seca tiene un R^2 de 0.566 en entrenamiento, 0.161 en prueba y 0.713 en validación cruzada. Los errores (RMSE y MAE) son los más altos de todos los modelos, lo que indica una predicción poco precisa de la biomasa seca a partir del volumen.
- El modelo biomasa digital y biomasa real tiene un excelente ajuste con R^2 de 0.985 en entrenamiento, 0.990 en prueba y 0.990 en validación cruzada. Los errores (RMSE y MAE) son relativamente bajos, lo que demuestra una predicción muy precisa de la biomasa real a partir de la biomasa digital.

Tabla 14. Valores de RMSE, MAE y R^2 de los modelos generados a partir de volumen, altura y biomasa digital

| Modelo | | R^2 | RMSE | MAE |
|-------------------------------------|--------------------|-------|-------|-------|
| Altura digital y altura real (n=44) | Entrenamiento | 0.955 | 0.016 | 0.011 |
| | Prueba | 0.981 | 0.009 | 0.007 |
| | Validación cruzada | 0.958 | 0.013 | 0.010 |

| | | | | |
|--|--------------------|-------|--------|--------|
| Volumen digital y volumen real (n=44) | Entrenamiento | 0.985 | 0.009 | 0.007 |
| | Prueba | 0.984 | 0.008 | 0.006 |
| | Validación cruzada | 0.986 | 0.009 | 0.007 |
| Biomasa digital y biomasa real (n= 44) | Entrenamiento | 0.985 | 143.22 | 104.44 |
| | Prueba | 0.990 | 142.92 | 105.87 |
| | Validación cruzada | 0.990 | 139.06 | 108.45 |
| Altura digital y BMF (n=25) | Entrenamiento | 0.914 | 0.016 | 0.014 |
| | Prueba | 0.827 | 0.045 | 0.035 |
| | Validación cruzada | 0.910 | 0.017 | 0.015 |
| Altura digital y BMS (n=25) | Entrenamiento | 0.686 | 0.032 | 0.027 |
| | Prueba | 0.587 | 0.071 | 0.055 |
| | Validación cruzada | 0.738 | 0.026 | 0.022 |
| Volumen digital y BMF (n= 25) | Entrenamiento | 0.808 | 0.019 | 0.017 |
| | Prueba | 0.766 | 0.021 | 0.017 |
| | Validación cruzada | 0.732 | 0.017 | 0.016 |
| Volumen digital y BMS (n= 25) | Entrenamiento | 0.566 | 0.031 | 0.026 |
| | Prueba | 0.161 | 0.046 | 0.039 |
| | Validación cruzada | 0.713 | 0.027 | 0.023 |

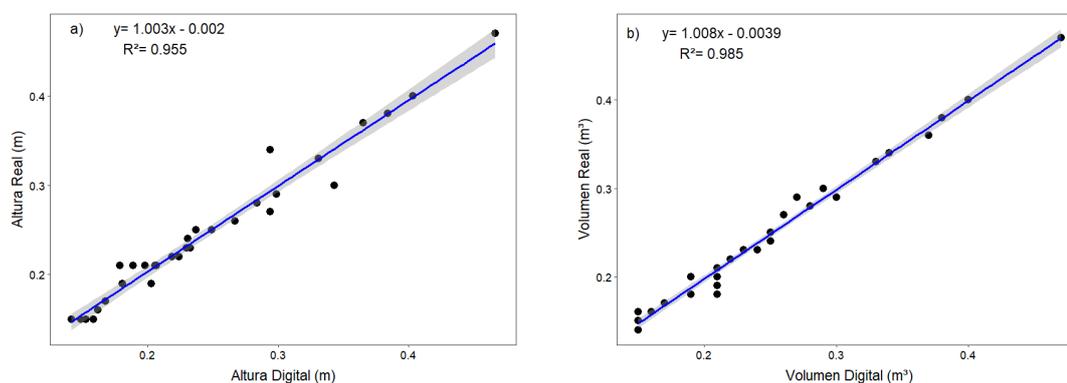
BMF: Biomasa Fresca; BMS: Biomasa seca; n= Individuos analizados para el modelo

El modelo generado por la comparación de alturas demuestra que la altura medida a través de fotografía aérea es válida puesto que el R^2 alcanzó el 0.955, lo cual es un buen indicador para su aplicación. La ecuación resultante es: $y=$

$1.003x - 0.002$, indica que la pendiente será multiplicada por el valor a sustituir (ver gráfico 3a).

La predicción del volumen de pasto a partir de fotos aéreas puede usarse para determinar esta variable, en vista de que los resultados del modelo de regresión demuestran que el R^2 resultante fue del 98.5%. La ecuación resultante fue $y = 1.008x - 0.0039$, en donde, y es el volumen real a obtener, la pendiente es 1.008, el intercepto -0.0039 x representa el valor a sustituir (ver gráfico 3b).

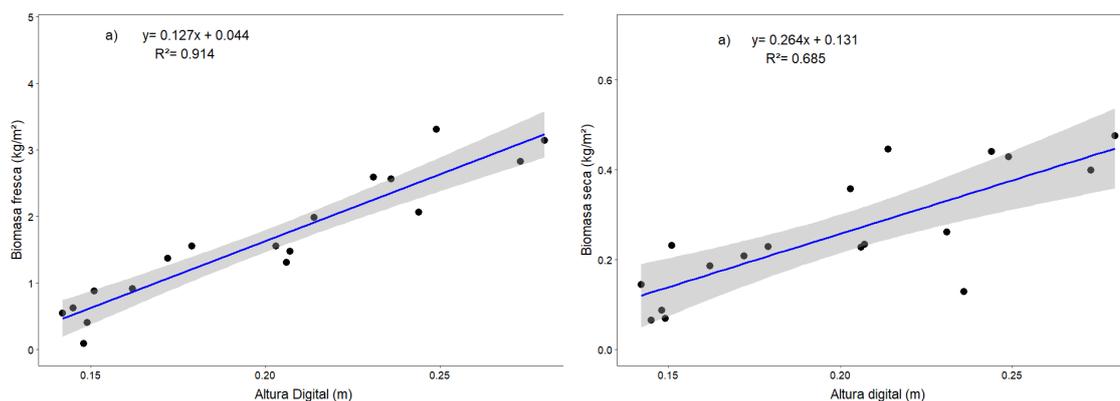
Gráfico 3. Representación gráfica de la regresión lineal entre altura digital con altura real y Volumen digital con volumen real



La regresión lineal obtenida entre altura digital y biomasa fresca de pasto generó un ajuste del 91.4%, la ecuación que la describe es: $y = 0.127x + 0.044$ (ver gráfico 4a).

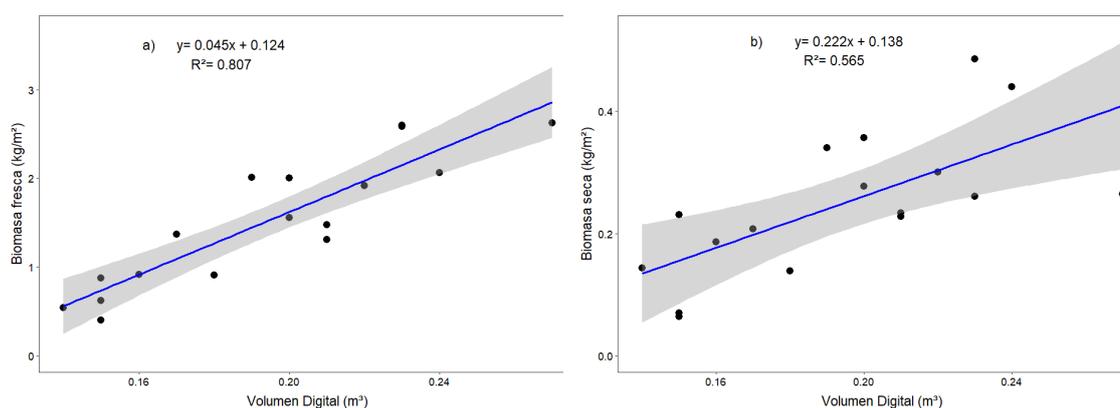
El gráfico 4b muestra los resultados del modelo de regresión entre altura digital y biomasa seca, alcanzando una variabilidad de sus datos de 68.5%, demostrando un ajuste moderado. La ecuación obtenida fue $y = 0.264x + 0.131$.

Gráfico 4. Regresión lineal de altura digital, biomasa fresca y biomasa seca



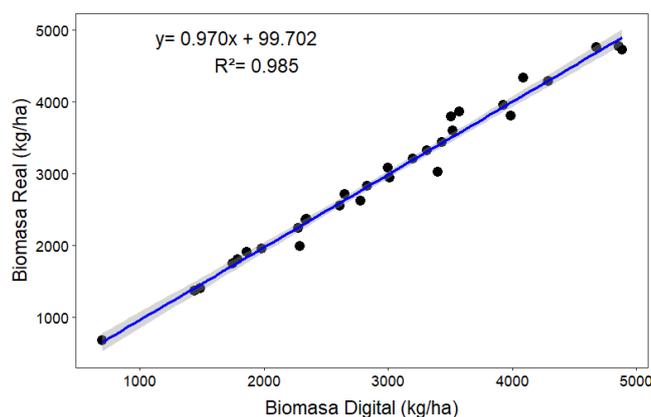
El gráfico 5a refleja los resultados del modelo obtenido entre volumen digital con biomasa fresca, se observa un ajuste del 80.7% y la ecuación que lo describe es: $y = 0.045x + 0.124$. La regresión lineal de volumen digital y biomasa seca demuestran que su ajuste fue inferior al del resto de modelos, debido a que su R^2 es apenas del 56.5%. La ecuación que describe este modelo es $y = 0.222x + 0.138$ (ver gráfico 5b).

Gráfico 5. Regresión entre volumen digital, biomasa fresca y seca



4.1.6 Determinación de biomasa

La regresión lineal entre las dos biomosas indica un ajuste alto, alcanzó el 98.5%, la ecuación que describe a este modelo es $y = 0.970x + 99.702$.

Gráfico 6. Regresión lineal entre biomasa

En la Tabla 15 se puede observar la producción de biomasa digital y real por potrero y por hectárea. La diferencia máxima entre los valores de biomasa por hectárea es de 150.9 kg/ha en el potrero 31, y la diferencia mínima de 0.1 kg/ha, en el potrero 22. En la mayoría de los potreros la diferencia es menor a 50 kg/ha, lo que indica una excelente correspondencia entre los datos con un R^2 de 0.98, demostrando una relación lineal muy fuerte.

Tabla 15. Áreas de cada potrero, biomasa y factor de densidad (FD) por potrero

| Potrero | Área m ² | Biomasa digital kg. | Biomasa real kg. | Biomasa Digital kg/ha | Biomasa Real kg/ha | FD kg/ m ³ |
|---------|---------------------|---------------------|------------------|-----------------------|--------------------|-----------------------|
| 13A | 4841.9 | 1983.0 | 1949.4 | 4095.4 | 4026.1 | 1.31 |
| 13B | 4484.3 | 1362.0 | 1340.7 | 3037.2 | 2989.8 | 1.29 |
| 22 | 17817.9 | 6078.9 | 6079.1 | 3411.7 | 3411.8 | 1.19 |
| 23 | 19223.9 | 7295.7 | 7140.3 | 3795.1 | 3714.3 | 1.19 |
| 25 | 18274.6 | 9151.7 | 9271.8 | 5007.9 | 5073.6 | 1.77 |
| 31 | 6747.5 | 1827.5 | 1929.4 | 2708.5 | 2859.4 | 1.37 |
| 32 | 5965.8 | 1351.7 | 1375.8 | 2265.8 | 2306.1 | 0.98 |
| 33 | 5640.5 | 549.7 | 559.6 | 974.5 | 992.2 | 0.60 |
| 34 | 8512.6 | 1806.5 | 1856.7 | 2122.1 | 2181.2 | 1.12 |
| 35 | 5417.1 | 2264.8 | 2223.4 | 4180.8 | 4104.5 | 1.19 |
| 41 | 4395.1 | 593.7 | 601.4 | 1350.7 | 1368.4 | 0.92 |

| | | | | | | |
|----|---------|--------|--------|--------|--------|------|
| 6 | 7816.8 | 2955.0 | 3002.7 | 3780.4 | 3841.4 | 1.92 |
| 7 | 10165.7 | 3688.7 | 3798.1 | 3628.6 | 3736.2 | 1.85 |
| 8A | 6666.9 | 1464.5 | 1504.4 | 2196.6 | 2256.6 | 0.99 |
| 8B | 6770.9 | 2131.8 | 2085.2 | 3148.5 | 3079.6 | 1.04 |
| 9 | 7724.3 | 2427.6 | 2498.4 | 3142.8 | 3234.5 | 1.96 |

4.2 Discusión

En la actualidad el uso de sistemas de aeronaves pilotadas de forma remota en la agricultura, está solucionando problemáticas que normalmente requieren metodologías, que toman tiempo, personal, que son destructivas y de altos costos (Debangshi, 2021). Obtener la altura de pasto es muy difícil, debido a que difiere mucho entre hojas, por lo que el uso de imágenes aéreas de alta resolución puede llegar a solucionarlo (Rueda-Ayala et al., 2019).

Según los resultados presentados, el uso de fotografía aérea para obtener el volumen de pasto se muestra como una alternativa viable. Esta metodología logra estimar la biomasa, volumen y altura del pasto, y a su vez evitaría realizar cortes innecesarios en el pasto como metodología de aforo invasivas y destructivas. Además, modelos generados a partir de imágenes aéreas y biomasa de pastos con el uso de Machine Learning y Deep Learning con distintos algoritmos han demostrado rendimientos altos para sus modelos, asimismo, los ajustes de estos están por encima del 70%, incluso sobrepasan el 90% (Vahidi et al., 2023).

El uso de modelamiento 3D a partir de imágenes aéreas ha demostrado ser muy potente cuando se busca obtener alturas de cobertura vegetal como pastizales en distintos ecosistemas (Gillan et al., 2019), lo cual indica que al hacer uso de estas metodologías para medición de altura y de volumen de vegetación, se obtienen valores cercanos a la realidad. Asimismo, a partir de imágenes aéreas se ha obtenido biomasa de la vegetación como pasturas, cultivos y matorral (Varela et al., 2017).

Varios estudios demuestran que el uso RPAS para obtener altura de la vegetación han sido exitosos (Han et al., 2018a); (Rueda-Ayala et al., 2019);(Varela et al., 2017). Por ejemplo Rueda-Ayala et al. (2019), enfatiza que los modelos lineales generados obtienen ajustes del 98% al comparar la altura de pasto obtenida a partir de imágenes aéreas y al aforar mediante cuadrante. Asimismo Han et al. (2018), en su estudio, informan que los modelos generados con alturas de plantas de maíz medidas en campo e imágenes aéreas obtenidas con ala delta, alcanzaron R^2 por encima del 80% y RMSE por debajo de 1.

Asimismo, Geipel et al. (2014) con la ayuda de imágenes aéreas y modelado en 3D ha desarrollado regresiones lineales de la altura y cobertura de plantaciones de algodón con datos levantados en campo, en sus resultados se indica que los mejores modelos se ajustan hasta un 74%, mientras que los de menor ajuste fue de 55%. Al igual, los RMSE obtenidos están por debajo de 1. Resultados muy similares se obtuvo en nuestra investigación, puesto que los ajustes son similares e incluso superiores en algunos casos. El mismo comportamiento sucede con los RMSE obtenidos.

Los modelos generados entre biomasa fresca con altura y volumen digital, pueden ser usados para su estimación a partir de la altura y volumen de pasto obtenidos a partir de imágenes aéreas, pues estos al igual que los modelos anteriores también alcanzaron R^2 cercanos y sobre el 80%. En estudios previos se ha podido constatar que la generación de modelos de biomasa a partir de imágenes aéreas muestra resultados muy confiables (Tang et al., 2022).

Resultados similares se pudo evidenciar en investigaciones de Botello-Aguillón, Gavi-Reyes, et al. (2019) quienes encontraron una alta relación entre volumen obtenido a partir de imágenes aéreas y biomasa fresca; asimismo, Rueda-Ayala et al. (2019) demostró en su investigación ajustes del 54% en los modelos generados para estimar la biomasa y volumen de la vegetación.

La biomasa fresca en el presente estudio alcanzó ajustes mayores al 80% y biomasa seca menores al 60%, al igual, los RMSE de todos los modelos mostraron ser bajos. Tendencia muy similar a los resultados presentados por Botello-Aguillón, Gavi-Reyes, et al. (2019), en este se reportaron R^2 cercanos al

70% de biomasa fresca y menores al 40% en biomasa seca, de igual manera, el error calculado es bajo. Otro estudio como el de Castillo et al. (2017), mostraron ajustes del 90% mediante el uso de índices de vegetación y clasificación supervisada para estimar la biomasa fresca de la cobertura vegetal. Los resultados entre nuestro estudio y el citado anteriormente varían levemente, puesto que las metodologías son distintas al igual que los algoritmos para la obtención de resultados.

Finalmente, el modelo para biomasa obtenido a partir de las imágenes aéreas y de muestras de campo, indican que su ajuste es alto (95.9%), resultados similares obtenidos por Sinda-González et al. (2021) sugieren que esta metodología es ideal para obtener biomasa. Asimismo, estas tecnologías han permitido que se evite intervención en el cultivo, tan solo el obtener alturas es suficiente como para conocer la biomasa de una planta (Batistoti et al. 2019).

4.3 Conclusiones

Se generaron siete modelos de regresión, pero luego de su validación se evidencia que los modelos que relacionan las variables digitales (altura, volumen, biomasa) con sus correspondientes variables reales presentan un ajuste y una precisión muy alta. Por otro lado, los modelos que relacionan las variables digitales con la biomasa seca tienen un ajuste y precisión moderados.

Al comparar el Error Medio Cuadrático (RMSE) de los modelos generados, se observó que el ajuste es preciso indicando que existe una excelente capacidad predictiva, por ejemplo, en el caso del volumen digital en comparación con la biomasa fresca. De manera similar, el modelo que relaciona el volumen digital con el real, exhibe un coeficiente casi perfecto, lo que indica un ajuste altamente significativo.

Se llegó a resultados que muestran que la regresión lineal entre biomasa fresca con altura digital indica que el modelo obtenido es confiable, debido, a que sus valores de R^2 están por encima del 91%, la misma variable con volumen obtuvo ajuste del 80%. Es decir, se puede hacer uso de los modelos de altura y volumen obtenidos a través de imágenes aéreas para calcular biomasa del pasto. Con el

mismo comportamiento se registró al modelo de biomasa real y digital, la cual presentó un ajuste cercano al 100% de la variabilidad de los datos.

Se determinó que la biomasa seca a partir de la altura y volumen para la mezcla forrajera no es confiable, debido a que los modelos lineales generados no mostraron ajustes altos y su uso llevaría a resultados poco confiables.

4.4 Recomendaciones

A partir de los resultados obtenidos en esta investigación se podría recomendar utilizar los modelos (altura real/altura digital - volumen real / volumen digital, y biomasa real vs biomasa digital) debido a su excelente ajuste y capacidad predictiva. También podría considerarse el modelo de biomasa fresca vs volumen digital, si fuese relevante para los objetivos de la granja en estudio.

Los modelos lineales que relacionan la altura y el volumen digital con la biomasa seca no han mostrado un ajuste satisfactorio, lo que conlleva a resultados poco confiables. Esto sugiere la necesidad de explorar enfoques de modelado alternativos o de analizar más a fondo las características específicas de esta mezcla forrajera para encontrar la mejor manera de estimar su biomasa seca a partir de las variables digitales.

En la presente investigación se realizó el levantamiento de información topográfica mediante el uso de estación total; sin embargo, sería de mucha utilidad realizar investigaciones probando algoritmos o filtrado en software, para obtener un modelo digital de terreno preciso y confiable a partir del vuelo fotogramétrico, quizá mediante la utilización de técnicas de segmentación y/o clasificación de imágenes, que permitan identificar y separar el pasto del terreno subyacente.

Se recomienda seguir entrenando los modelos de regresión analizados, puesto que es mucho más confiable cuanto mayor sea la cantidad de datos para entrenar, testear y validar.

Sería importante el usar la metodología actual desarrollada en otras coberturas de pastizales, con el fin de generar una ecuación global para pasturas, en la zona austral ecuatoriana.

Se recomienda usar otras metodologías para la región como por ejemplo el uso de índices de vegetación y LIDAR, que permitan obtener volumen de pasto de manera precisa en campo y comparar con el volumen obtenido con el uso de fotografía aérea, para de esta forma tener puntos de comparación que permitan validar una vez más los resultados obtenidos.

BIBLIOGRAFÍA

- Allen Asensio, H. J. (2019). *Estimación de productividad de Pannicum máximo cv. Mombasa mediante sensores remotos en la unidad de Ganado de Carne de Zamorano*. <https://bdigital.zamorano.edu/items/f23c63f0-6200-418d-860f-7c934293c3e4>
- Allgaier, J., & Pryss, R. (2024). Cross-Validation Visualized: A Narrative Guide to Advanced Methods. *Machine Learning and Knowledge Extraction*, 6(2), 1378-1388. <https://doi.org/10.3390/make6020065>
- Alvarez-Mendoza, C. I., Guzman, D., Casas, J., Bastidas, M., Polanco, J., Valencia-Ortiz, M., Montenegro, F., Arango, J., Ishitani, M., & Selvaraj, M. G. (2022). Predictive Modeling of Above-Ground Biomass in Brachiaria Pastures from Satellite and UAV Imagery Using Machine Learning Approaches. *Remote Sensing*, 14(22). <https://doi.org/10.3390/rs14225870>
- Andújar, J. M. (2017). *Sistemas Aéreos Pilotados de forma Remota (RPAS): Historia, Sistemas y Operaciones*. 22.
- Autel Robotics. (2022). *Autel Drones EVO II*. auteldrones. <https://auteldrones.com/pages/evo-ii-detail>
- Batistoti, J., Marcato, J., Ítavo, L., Matsubara, E., Gomes, E., Oliveira, B., Souza, M., Siqueira, H., Filho, G. S., Akiyama, T., Gonçalves, W., Liesenberg, V., Li, J., & Dias, A. (2019). Estimating pasture biomass and canopy height in Brazilian Savanna using UAV photogrammetry. *Remote Sensing*, 11(20), 1-12. <https://doi.org/10.3390/rs11202447>
- Benalcázar, B., López, V., Gutiérrez, F., & Alvarado, S. (2021). Efecto de la fertilización nitrogenada en el crecimiento de cinco pastos perennes en Ecuador. *Pastos y Forrajes*, 44, 1-9.
- Blue Marble. (2019). *Global Mapper: getting started guide*.
- Botello-Aguillón, C., Gavi-Reyes, F., Tijerina-Chávez, L., Galvis-Spíndola, A., & Roblero-Hidalgo, R. (2019). Estimación de biomasa aérea de forrajes de invierno bajo riego a través de un dron. *Agro Productividad*, 12(4). <https://doi.org/10.32854/agrop.v0i0.354>

- Boyda, E. D., Butler, J. L., & Xu, L. (2015). Estimating Herbaceous Biomass of Grassland Vegetation Using the Reference Unit Method. *The Prairie Naturalist*, 47, 73-83.
- Cárdenas, J., Balocchi, O., & Calvache, I. (2020). Calibration of the rising plate meter for mixed pastures of ryegrass (*Lolium perenne* L.) and kikuyo (*Cenchrus clandestinus*). *Chilean Journal of Agricultural and Animal Sciences*, 36(3), 216-223. <https://doi.org/10.29393/CHJAAS36-20CRJC30020>
- Castillo, E. C., Pellat, F. P., & Bolaños González, M. A. (2017). *Estimación de biomasa y cobertura aérea usando radiometría e imágenes digitales a nivel de campo en pastizales y matorrales Estimation of biomass and aerial cover using radiometry and field level digital imaging of grasslands and scrublands.*
- Chen, S., Zhong, S., Xue, B., Li, X., Zhao, L., & Chang, C.-I. (2021). Iterative Scale-Invariant Feature Transform for Remote Sensing Image Registration. *IEEE Transactions on Geoscience and Remote Sensing*, 59(4), 3244-3265. <https://doi.org/10.1109/TGRS.2020.3008609>
- CIAT. (2021). *Tropical grassland* (Vol. 9, Número 3).
- ComNav Technology Ltd. (2018). *T300 Plus GNSS Receiver*. www.comnavtech.com
- Cordero, Q. J. A. (2018). *Diseño de un sistema de cuantificación automática de biomasa basado en procesamiento de imágenes y fotogrametría con vehículos aéreos no tripulados*. 91.
- Debangshi, U. (2021). *Drones - Applications in Agriculture*. October. <https://doi.org/10.5281/zenodo.5554734>
- Díaz Giraldo, R. A., Álvarez de León, M., & Pérez López, O. (2021). Uso de sensores remotos en la determinación del forraje disponible de *Urochloa humidicola* cv. Llanero bajo pastoreo en la Altillanura colombiana. *Tropical Grasslands-Forrajes Tropicales*, 9(3), 376-382. [https://doi.org/10.17138/tgft\(9\)376-382](https://doi.org/10.17138/tgft(9)376-382)
- Eltner, A., & Sofia, G. (2020). Structure from motion photogrammetric technique. En *Developments in Earth Surface Processes* (Vol. 23, Número June, pp. 1-24). <https://doi.org/10.1016/B978-0-444-64177-9.00001-1>

- EMLID. (2022). *REACH RS2+*. <https://files.emlid.com/docs/Datasheet-RS2%2B-ENG-web.pdf>
- Emmanuel, E., Cruz, S., & Moreno Ortiz, R. (2017). *Propuesta de sistema multi-UAV para aplicaciones de cobertura de área*.
- FAO. (2018). *E-agriculture in Action: Drones for Agriculture*. <https://openknowledge.fao.org/server/api/core/bitstreams/5d85a726-91df-47f2-b986-9970261a1ed4/content>
- Gaillard, C., & Pece, M. G. (2014). *Muestreo y Técnicas de Evaluación en Vegetación y Fauna*.
- Gbash; Ekhlash, & Saleh; Suha Mohammed. (2017). Scale-Invariant Feature Transform Algorithm with Fast Approximate Nearest Neighbor. *Baghdad Science Journal*, 14(3), 0651. <https://doi.org/10.21123/bsj.2017.14.3.0651>
- Geipel, J., Link, J., & Claupein, W. (2014). Combined spectral and spatial modeling of corn yield based on aerial images and crop surface models acquired with an unmanned aircraft system. *Remote Sensing*, 6(11), 10335-10355. <https://doi.org/10.3390/rs61110335>
- Gil-Docampo, M. L., Arza-García, M., Ortiz-Sanz, J., Martínez-Rodríguez, S., Marcos-Robles, J. L., & Sánchez-Sastre, L. F. (2020). Above-ground biomass estimation of arable crops using UAV-based SfM photogrammetry. *Geocarto International*, 35(7), 687-699. <https://doi.org/10.1080/10106049.2018.1552322>
- Gillan, J. K., McClaran, M. P., Swetnam, T. L., & Heilman, P. (2019). Estimating forage utilization with drone-based photogrammetric point clouds. *Rangeland Ecology and Management*, 72(4), 575-585. <https://doi.org/10.1016/j.rama.2019.02.009>
- Gómez-Giráldez, P. J., Aguilar, C., Caño, A. B., García-Moreno, A., & González-Dugo, M. P. (2019). Remote sensing estimation of net primary production as monitoring indicator of holm oak savanna management. *Ecological Indicators*, 106(June 2018), 105526. <https://doi.org/10.1016/j.ecolind.2019.105526>
- González, A., Amarillo, G., Amarillo, M., & Sarmiento, F. (2016). Drones Aplicados a la Agricultura de Precisión. *Publicaciones e Investigación*, 10, 23. <https://doi.org/10.22490/25394088.1585>

- Grünwaldt, J. M., Guevara, J. C., Grünwaldt, E. G., & Carretero, E. M. (2015). Cactus (Opuntia sp.) como forraje en las tierras secas de Argentina. En *Revista de la Facultad de Ciencias Agrarias* (Vol. 47, Número 1, pp. 263-282).
- Guzmán, D., & Montero, J. (2021). Interaction of bacteria and plants in nitrogen fixation. *Revista de Investigación e Innovación Agropecuaria y de Recursos Naturales*, 8(2), 2518-6868.
- Han, X., Thomasson, J. A., Bagnall, G. C., Pugh, N. A., Horne, D. W., Rooney, W. L., Jung, J., Chang, A., Malambo, L., Popescu, S. C., Gates, I. T., & Cope, D. A. (2018a). Measurement and Calibration of Plant-Height from Fixed-Wing UAV Images. *Sensors (Basel, Switzerland)*, 18(12). <https://doi.org/10.3390/s18124092>
- Hassan-Esfahani, L., Torres-Rua, A., & McKee, M. (2015). Assessment of optimal irrigation water allocation for pressurized irrigation system using water balance approach, learning machines, and remotely sensed data. *Agricultural Water Management*, 153, 42-50. <https://doi.org/https://doi.org/10.1016/j.agwat.2015.02.005>
- Hassnain, S. A., Othman, N., Li, Y., Alsharif, M., & Khan, M. (2023). Unmanned aerial vehicles (UAVs): practical aspects, applications, open challenges, security issues, and future trends. *Intelligent Service Robotics*. <https://doi.org/10.1007/s11370-022-00452-4>
- Huerta, H. V., Zaragoza, J. L., & Arenas, D. G. (2018). Análisis de crecimiento estacional de Trébol blanco (*Trifolium repens* L.). *Agro Productividad*, August.
- INEC. (2023). Encuesta de superficie y producción agropecuaria continua. En *Instituto Nacional de Estadísticas y Censos*.
- Kuhn, M. (2023). *Package «caret» Title Classification and Regression Training*. <https://github.com/topepo/caret/>
- León, R., Bonifaz, N., & Gutiérrez, F. (2018). Pastos y forrajes del Ecuador: siembra y producción de pasturas. En Universidad Politécnica Salesiana (Ed.), *News.Ge* (Editorial). <http://dspace.ups.edu.ec/handle/123456789/19019>

- Martínez Romero, A., & Leyva Galán, A. (2014). Revisión bibliográfica LA BIOMASA DE LOS CULTIVOS EN EL AGROECOSISTEMA. SUS BENEFICIOS AGROECOLÓGICOS. *Cultivos Tropicales*, 35(1), 11-20.
- Méndez, D. (2021). *Evaluar diferentes métodos de determinación de biomasa de mezclas forrajeras*. Universidad Central del Ecuador.
- Mitsikostas, E. (2017). *Monitorización y Optimización de Tierras con Drones y Fotogrametría Aérea para Aplicaciones de Precisión en Agricultura*. 19-29.
- Mónaco, N., Santa, V., Rosa, M. J., & Autran, V. (2017). Evaluación de métodos indirectos para estimar biomasa en un pastizal natural del sur de Córdoba (Argentina Central). *European Scientific Journal, ESJ*, 13(36), 59. <https://doi.org/10.19044/esj.2017.v13n36p59>
- Montoya, P., & Vásquez, R. (2019). *Empleo de los UAV, en operaciones de seguridad y vigilancia en las áreas estratégicas en el Ecuador*.
- Moreno-Carrillo, M. A., Hernández-Garay, A., Vaquera-Huerta, H., Trejo-López, C., Escalante-Estrada, J. A., Zaragoza-Ramírez, J. L., & Joaquín-Torres, B. M. (2015). Forage yield of seven association and two pure swards of grasses and legumes under grazing conditions. *Revista Fitotecnia Mexicana*, 38(1), 101-108.
- Muler, A. L. (2016). *Identifying plant functional traits to assist ecological intervention in a drying landscape Edith Cowan University*.
- Noor, N., Abdullah, A., & Mazlan, H. (2018). Remote sensing UAV/drones and its applications for urban areas: A review. *IOP Conference Series: Earth and Environmental Science*, 169(1), 0-8. <https://doi.org/10.1088/1755-1315/169/1/012003>
- Nyimbili, P. H., Demirel, H., Seker, D. Z., & Erden, T. (2016). Structure from Motion (SfM) - Approaches and Applications. *International Scientific Conference on Applied Sciences, September*, 27-30.
- Ochoa, L. (2019, julio). *Evaluación de Algoritmos de Clasificación utilizando Validación Cruzada*. <https://doi.org/10.18687/LACCEI2019.1.1.471>

- Oliva, M., Rojas, D., Morales, A., Oliva, C., & A. Oliva, M. (2015). Nutritional content, digestibility and performance of native grasses biomass that dominate livestock Molinopampa, Pomacochas and Leymebamba basins, Amazonas, Peru. *Scientia agropecuaria*, 6(3), 211-215. <https://doi.org/10.17268/sci.agropecu.2015.03.07>
- Paletto, V. B., & Bouno, G. (2020). *Métodos de evaluación de pastizales en Patagonia Sur*.
- Pino V., E. (2019). Los drones una herramienta para una agricultura eficiente: un futuro de alta tecnología. *Idesia (Arica), ahead*, 0-0. <https://doi.org/10.4067/s0718-34292019005000402>
- Portillo-López, P. A., Meneses-Buitrago, D. H., Lagos-Burbano, E., Duter-Nisivoccia, M. E., & Castro-Rincón, E. (2021). Nutritive value of forage mixtures in the dry and rainy seasons in Nariño, Colombia. *Agronomía Mesoamericana*, 32(2), 556-572. <https://doi.org/10.15517/am.v32i2.43207>
- Ramos, E., & Martínez, J. L. (2020). Almacenes de biomasa y carbono aéreo y radicular en pastizales de *Urochloa decumbens* y *Paspalum notatum* (Poaceae) en el sureste de México. *Revista de Biología Tropical*, 68(2), 440-451. <https://doi.org/10.15517/rbt.v68i2.37395>
- Rueda-Ayala, V. P., Peña, J. M., Höglind, M., Bengochea-Guevara, J. M., & Andújar, D. (2019). Comparing UAV-based technologies and RGB-D reconstruction methods for plant height and biomass monitoring on grass ley. *Sensors (Switzerland)*, 19(3). <https://doi.org/10.3390/s19030535>
- Santana, E. E. (2017). *Propuesta de sistema multi-UAV para aplicaciones de cobertura de área*.
- Schonberger, J. L., & Frahm, J. M. (2016). Structure-from-Motion Revisited. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 2016-Decem, 4104-4113. <https://doi.org/10.1109/CVPR.2016.445>
- Serrano, J., Shahidian, S., Moral, F., Carvajal-Ramirez, F., & da Silva, J. M. (2020). Estimation of Productivity in Dryland Mediterranean Pastures: Long-Term Field

- Tests to Calibration and Validation of the Grassmaster II Probe. *AgriEngineering*, 2(2), 240-255. <https://doi.org/10.3390/agriengineering2020015>
- Shah, A. S., Wakelin, S. A., Moot, D. J., Blond, C., Laugraud, A., & Ridgway, H. J. (2021). *Trifolium repens* and *T. subterraneum* modify their nodule microbiome in response to soil pH. *Journal of Applied Microbiology*, 131(4), 1858-1869. <https://doi.org/10.1111/jam.15050>
- Silva, D., Velarde, A., Gallardo, P., Freire, M., Molina, T., Tayupanta, S., Acosta, P., & Marcheco, C. (2019). Forages quality of *Cenchrus clandestinum* and *Lolium perenne* forages in the form of hay at different regrowth ages. Calidad de los forrajes *Cenchrus clandestinum* y *Lolium perenne* en forma de heno a diferentes edades de rebrote. *Cuban Journal of Agricultural Science*, 53(3), 299-306.
- Sima, A. A., & Buckley, S. J. (2013). Optimizing SIFT for matching of short wave infrared and visible wavelength images. *Remote Sensing*, 5(5), 2037-2056. <https://doi.org/10.3390/rs5052037>
- Sinde-González, I., Gil-Docampo, M., Arza-García, M., Grefa-Sánchez, J., Yáñez-Simba, D., Pérez-Guerrero, P., & Abril-Porras, V. (2021). Biomass estimation of pasture plots with multitemporal UAV-based photogrammetric surveys. *International Journal of Applied Earth Observation and Geoinformation*, 101(April). <https://doi.org/10.1016/j.jag.2021.102355>
- Tang, Z., Xia, X., Huang, Y., Lu, Y., & Guo, Z. (2022). Estimation of National Forest Aboveground Biomass from Multi-Source Remotely Sensed Dataset with Machine Learning Algorithms in China. *Remote Sensing*, 14(21). <https://doi.org/10.3390/rs14215487>
- Torres, J., Arroyo, G., Romo, C., & Haro, J. De. (2012). 3D Digitization using Structure from Motion. *academia.edu*, October 2014.
- Torres-Rua, A., Nieto, H., Parry, C., Elarab, M., Collatz, W., Coopmans, C., McKee, L., McKee, M., & Kustas, W. (2018). Inter-comparison of thermal measurements using ground-based sensors, UAV thermal cameras, and eddy covariance radiometers. En J. A. Thomasson, M. McKee, & R. J. Moorhead (Eds.), *Autonomous Air and Ground Sensing Systems for Agricultural Optimization and*

Phenotyping III (Vol. 10664, p. 106640E). SPIE.
<https://doi.org/10.1117/12.2305832>

Usda. (2014). *Claves para la Taxonomía de Suelos Décima segunda Edición, 2014 Servicio de Conservación de Recursos Naturales.*

Vahidi, M., Shafian, S., Thomas, S., & Maguire, R. (2023). Pasture Biomass Estimation Using Ultra-High-Resolution RGB UAVs Images and Deep Learning. *Remote Sensing*, 15(24). <https://doi.org/10.3390/rs15245714>

Varela, S., Assefa, Y., Vara Prasad, P. V., Peralta, N. R., Griffin, T. W., Sharda, A., Ferguson, A., & Ciampitti, I. A. (2017). Spatio-temporal evaluation of plant height in corn via unmanned aerial systems. *Journal of Applied Remote Sensing*, 11(03), 1. <https://doi.org/10.1117/1.jrs.11.036013>

Vargas- Martínez, J. D. J., Sierra-Alarcón, A., Benavidez-Cruz, J., Avellaneda-Avellaneda, Y., & Ariza-Nieto, C. (2018). Establecimiento y producción de raigrás y tréboles en dos regiones del trópico alto colombiano. *Agronomía Mesoamericana*, 29(1), 177. <https://doi.org/10.15517/ma.v29i1.28077>

Vergouv, B., Nagel, H., Geert, B., & Bart, C. (2016). Metadata of the chapter that will be visualized in Online. *Springer Nature Singapor, August*, 1-8.

Walia, M. K., & Dick, W. A. (2016). Soil chemistry and nutrient concentrations in perennial ryegrass as influenced by gypsum and carbon amendments. *Journal of Soil Science and Plant Nutrition*, 16(3), 832-847. <https://doi.org/10.4067/s0718-95162016005000059>

Wickham, H., Rundel, M. C., & Golemund, G. (2023). *R for Data Science* (O'Reilly Media, Ed.; 2.^a ed.).

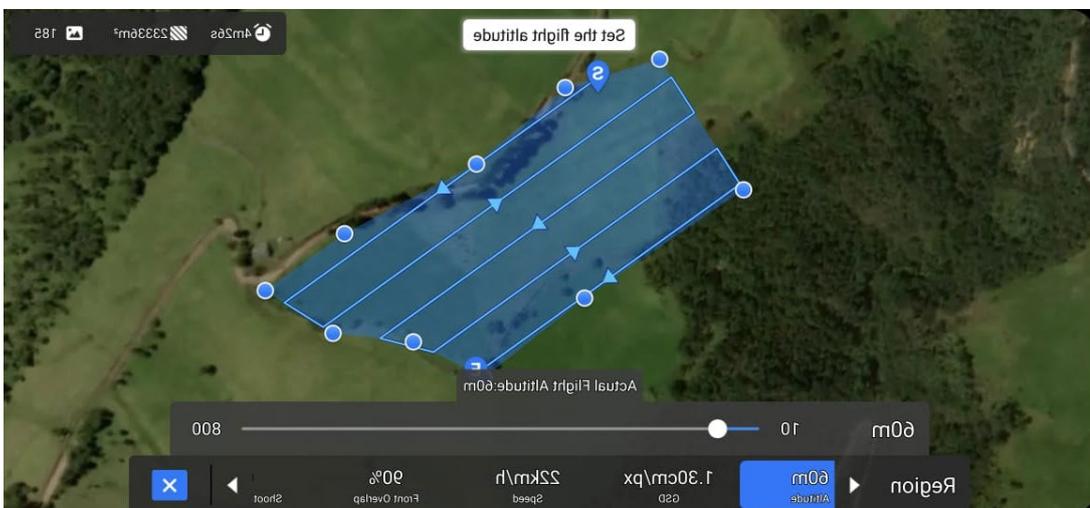
Yavuz, T., Sürmen, M., Albayrak, S., & Çankaya, N. (2017). Determination of forage yield and quality characteristics of annual ryegrass (*Lolium multiflorum* lam.) lines. *Tarım Bilimleri Dergisi-journal of Agricultural Sciences*, 23(2), 234-241.

Zhang, Y., Huang, J., Huang, H., Li, X., Jin, Y., Guo, H., Feng, Q., & Zhao, Y. (2022). Grassland Aboveground Biomass Estimation through Assimilating Remote Sensing Data into a Grass Simulation Model. *Remote Sensing*, 14(13). <https://doi.org/10.3390/rs14133194>

ANEXOS

Anexo 1. Planes de vuelo

Vuelo 1



Vuelo 2



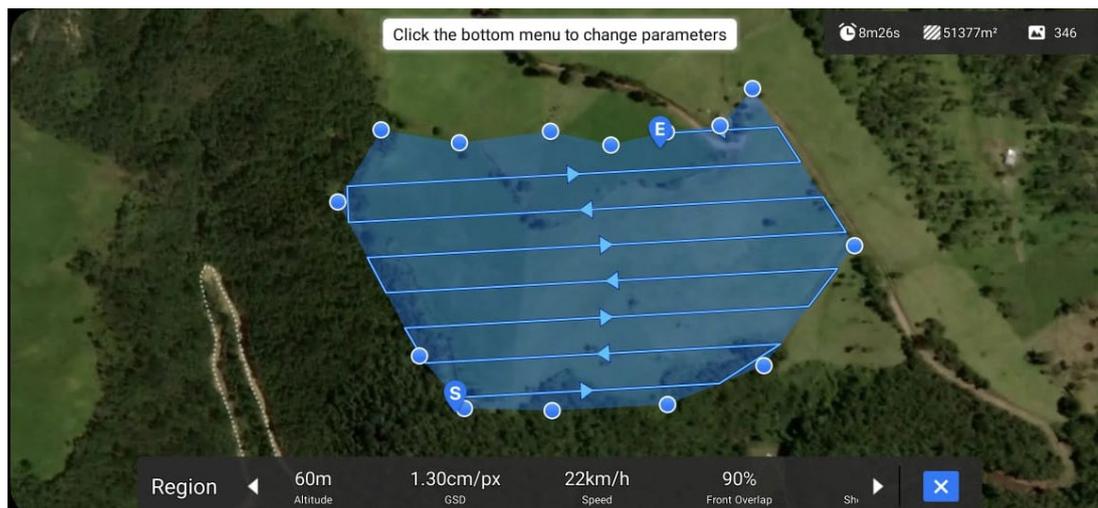
Vuelo 3



Vuelo 4



Vuelo 5



Anexo 2. Base de información

| CODE | Vuelo | DIG | REAL | | | | Peso humedo | Peso seco | | |
|-------|-------|-------|-------|-------|-------|-------|-------------|-----------|-------|-------|
| 13A_A | 1 | 0.366 | 0.370 | 0.313 | 0.308 | 0.308 | 3.2 | 0.4 | 3.070 | 0.392 |
| 13A_B | 1 | 0.280 | 0.282 | | | | 3.1 | 0.5 | | |
| 13A_M | 1 | 0.294 | 0.272 | | | | 2.9 | 0.4 | | |
| 13B_A | 1 | 0.219 | 0.224 | 0.235 | 0.231 | | 1.9 | 0.3 | 1.481 | 0.279 |
| 13B_B | 1 | 0.284 | 0.282 | | | | 1.0 | 0.2 | | |
| 13B_M | 1 | 0.203 | 0.188 | | | | 1.6 | 0.4 | | |
| 22_A | 2 | 0.267 | 0.261 | 0.287 | 0.287 | | 2.6 | 0.3 | 2.090 | 0.308 |
| 22_B | 2 | 0.365 | 0.366 | | | | 1.1 | 0.2 | | |
| 22_M | 2 | 0.230 | 0.234 | | | | 2.6 | 0.5 | | |
| 23_A | 2 | 0.384 | 0.381 | 0.319 | 0.313 | | 1.1 | 0.2 | 3.315 | 0.335 |
| 23_B | 2 | 0.244 | 0.226 | | | | 2.1 | 0.4 | | |
| 23_M | 2 | 0.331 | 0.331 | | | | 6.8 | 0.3 | | |
| 25_A | 2 | 0.466 | 0.472 | 0.283 | 0.287 | | 0.9 | 0.2 | 1.678 | 0.377 |
| 25_B | 2 | 0.214 | 0.214 | | | | 2.0 | 0.4 | | |
| 25_M | 2 | 0.168 | 0.174 | | | | 2.2 | 0.5 | | |
| 31_A | 3 | 0.189 | 0.213 | 0.198 | 0.209 | | 2.0 | 0.3 | 1.743 | 0.241 |
| 31_B | 3 | 0.207 | 0.205 | | | | 1.5 | 0.2 | | |
| 32_A | 3 | 0.237 | 0.251 | 0.230 | 0.234 | | 1.5 | 0.1 | 1.369 | 0.196 |
| 32_B | 3 | 0.224 | 0.218 | | | | 1.3 | 0.3 | | |
| 33_A | 3 | 0.179 | 0.181 | 0.162 | 0.165 | | 0.9 | 0.1 | 0.767 | 0.144 |
| 33_B | 3 | 0.145 | 0.149 | | | | 0.6 | 0.1 | | |
| 34_A | 3 | 0.206 | 0.209 | 0.189 | 0.194 | | 1.3 | 0.2 | 1.340 | 0.262 |
| 34_B | 3 | 0.172 | 0.179 | | | | 1.4 | 0.2 | | |
| 35_A | 3 | 0.299 | 0.293 | 0.351 | 0.345 | | 1.9 | 0.4 | 2.298 | 0.296 |
| 35_B | 3 | 0.403 | 0.396 | | | | 2.7 | 0.5 | | |
| 41_A | 4 | 0.149 | 0.152 | 0.148 | 0.149 | | 0.4 | 0.1 | 0.477 | 0.129 |
| 41_B | 4 | 0.148 | 0.161 | | | | 0.1 | 0.1 | | |
| 41_C | 4 | 0.151 | 0.136 | | | | 0.9 | 0.2 | | |
| 41_D | 4 | 0.142 | 0.149 | | | | 0.5 | 0.1 | | |
| 6_A | 5 | 0.233 | 0.233 | 0.197 | 0.200 | | 2.9 | 0.3 | 2.488 | 0.367 |
| 6_B | 5 | 0.153 | 0.152 | | | | 2.0 | 0.4 | | |
| 6_M | 5 | 0.204 | 0.215 | | | | 2.5 | 0.4 | | |
| 7_A | 5 | 0.159 | 0.150 | 0.196 | 0.202 | | 2.3 | 0.4 | 2.380 | 0.355 |
| 7_B | 5 | 0.179 | 0.206 | | | | 1.6 | 0.2 | | |
| 7_M | 5 | 0.249 | 0.249 | | | | 3.3 | 0.4 | | |
| 8_A | 5 | 0.198 | 0.210 | 0.222 | 0.228 | | 2.0 | 0.3 | 2.389 | 0.223 |
| 8_B | 5 | 0.236 | 0.237 | | | | 2.6 | 0.1 | | |
| 8_M | 5 | 0.231 | 0.237 | | | | 2.6 | 0.3 | | |
| 9A | 1 | 0.273 | 0.260 | 0.303 | 0.297 | | 2.8 | 0.4 | 2.571 | 0.326 |
| 9B | 1 | 0.343 | 0.335 | | | | 3.1 | 0.3 | | |
| 9M | 1 | 0.294 | 0.295 | | | | 1.7 | 0.3 | | |
| 9A_8B | 5 | 0.181 | 0.190 | 0.160 | 0.164 | | 2.9 | 0.4 | 2.048 | 0.295 |
| 9B_8B | 5 | 0.162 | 0.162 | | | | 0.9 | 0.2 | | |
| 9C_8B | 5 | 0.137 | 0.142 | | | | 2.3 | 0.3 | | |

| VUELO | PARCEA | PARTE | CODE | VoID/par | VolR/par | MAX | MIN | Área | VolR/ha | Área (b*1) | Peso humed | Peso seco | so seco/ft | Altura | tura real | (tura dig | (rturas (cm | FD |
|-------|--------|-------|-------|----------|----------|-------|-------|---------|---------|------------|------------|-----------|------------|--------|-----------|-----------|-------------|------|
| 1 | 13A | A | 13A_A | 0.366 | 0.370 | 0.538 | 0.252 | 4841.9 | 0.755 | 1 | 3.2 | 0.35 | 0.72 | 0.37 | 0.37 | 0.366 | 36.6 | 0.95 |
| 1 | 13A | B | 13A_B | 0.280 | 0.28 | 0.361 | 0.232 | 4841.9 | 0.578 | 1 | 3.1 | 0.48 | 0.98 | 0.28 | 0.28 | 0.280 | 28 | 1.70 |
| 1 | 13A | M | 13A_M | 0.294 | 0.29 | 0.408 | 0.186 | 4841.9 | 0.608 | 1 | 2.9 | 0.35 | 0.72 | 0.27 | 0.27 | 0.294 | 29.4 | 1.21 |
| 1 | 13B | A | 13B_A | 0.219 | 0.22 | 0.285 | 0.148 | 4484.3 | 0.488 | 1 | 1.9 | 0.30 | 0.67 | 0.22 | 0.22 | 0.219 | 21.9 | 1.37 |
| 1 | 13B | B | 13B_B | 0.284 | 0.28 | 0.413 | 0.186 | 4484.3 | 0.633 | 1 | 1.0 | 0.18 | 0.40 | 0.28 | 0.28 | 0.284 | 28.4 | 0.64 |
| 1 | 13B | M | 13B_M | 0.203 | 0.20 | 0.333 | 0.143 | 4484.3 | 0.452 | 1 | 1.6 | 0.36 | 0.80 | 0.19 | 0.19 | 0.203 | 20.3 | 1.79 |
| 2 | 22 | A | 22_A | 0.267 | 0.27 | 0.43 | 0.162 | 17817.9 | 0.150 | 1 | 2.6 | 0.26 | 0.15 | 0.26 | 0.26 | 0.267 | 26.7 | 0.98 |
| 2 | 22 | B | 22_B | 0.365 | 0.36 | 0.364 | 0.226 | 17817.9 | 0.205 | 1 | 1.1 | 0.17 | 0.10 | 0.37 | 0.37 | 0.365 | 36.5 | 0.49 |
| 2 | 22 | M | 22_M | 0.230 | 0.23 | 0.315 | 0.084 | 17817.9 | 0.129 | 1 | 2.6 | 0.49 | 0.27 | 0.23 | 0.23 | 0.230 | 23 | 2.11 |
| 2 | 23 | A | 23_A | 0.384 | 0.38 | 0.48 | 0.332 | 19223.9 | 0.200 | 1 | 1.1 | 0.23 | 0.12 | 0.38 | 0.38 | 0.384 | 38.4 | 0.62 |
| 2 | 23 | B | 23_B | 0.244 | 0.24 | 0.32 | 0.177 | 19223.9 | 0.127 | 1 | 2.1 | 0.44 | 0.23 | 0.23 | 0.23 | 0.244 | 24.4 | 1.83 |
| 2 | 23 | M | 23_M | 0.331 | 0.33 | 0.463 | 0.259 | 19223.9 | 0.172 | 1 | 6.8 | 0.33 | 0.17 | 0.33 | 0.33 | 0.331 | 33.1 | 1.00 |
| 2 | 24 | A | 25_A | 0.466 | 0.47 | 0.867 | 0.248 | 18274.6 | 0.255 | 1 | 0.9 | 0.20 | 0.11 | 0.47 | 0.47 | 0.466 | 46.6 | 0.42 |
| 2 | 24 | B | 25_B | 0.214 | 0.21 | 0.275 | 0.167 | 18274.6 | 0.117 | 1 | 2.0 | 0.45 | 0.24 | 0.21 | 0.21 | 0.214 | 21.4 | 2.12 |
| 2 | 24 | M | 25_M | 0.168 | 0.17 | 0.273 | 0.069 | 18274.6 | 0.092 | 1 | 2.2 | 0.49 | 0.27 | 0.17 | 0.17 | 0.168 | 16.8 | 2.87 |
| 3 | 31 | A | 31_A | 0.189 | 0.19 | 0.328 | 0.094 | 6747.5 | 0.280 | 1 | 2.0 | 0.34 | 0.50 | 0.21 | 0.21 | 0.189 | 18.9 | 1.79 |
| 3 | 31 | B | 31_B | 0.207 | 0.21 | 0.277 | 0.166 | 6747.5 | 0.306 | 1 | 1.5 | 0.23 | 0.35 | 0.21 | 0.21 | 0.207 | 20.7 | 1.11 |
| 3 | 32 | A | 32_A | 0.237 | 0.24 | 0.297 | 0.199 | 5965.8 | 0.397 | 1 | 1.5 | 0.15 | 0.25 | 0.25 | 0.25 | 0.237 | 23.7 | 0.62 |
| 3 | 32 | B | 32_B | 0.224 | 0.22 | 0.302 | 0.167 | 5965.8 | 0.376 | 1 | 1.3 | 0.30 | 0.50 | 0.22 | 0.22 | 0.224 | 22.4 | 1.36 |
| 3 | 33 | A | 33_A | 0.179 | 0.18 | 0.288 | 0.117 | 5640.5 | 0.317 | 1 | 0.9 | 0.14 | 0.25 | 0.18 | 0.18 | 0.179 | 17.9 | 0.77 |
| 3 | 33 | B | 33_B | 0.145 | 0.15 | 0.199 | 0.099 | 5640.5 | 0.258 | 1 | 0.6 | 0.06 | 0.11 | 0.15 | 0.15 | 0.145 | 14.5 | 0.43 |
| 3 | 34 | A | 34_A | 0.206 | 0.21 | 0.317 | 0.141 | 8512.6 | 0.242 | 1 | 1.3 | 0.23 | 0.27 | 0.21 | 0.21 | 0.206 | 20.6 | 1.08 |
| 3 | 34 | B | 34_B | 0.172 | 0.17 | 0.316 | 0.099 | 8512.6 | 0.202 | 1 | 1.4 | 0.21 | 0.24 | 0.18 | 0.18 | 0.172 | 17.2 | 1.22 |
| 3 | 35 | A | 35_A | 0.299 | 0.30 | 0.452 | 0.161 | 5417.1 | 0.552 | 1 | 1.9 | 0.35 | 0.65 | 0.29 | 0.29 | 0.299 | 29.9 | 1.17 |
| 3 | 35 | B | 35_B | 0.403 | 0.40 | 0.515 | 0.328 | 5417.1 | 0.743 | 1 | 2.7 | 0.47 | 0.86 | 0.4 | 0.4 | 0.403 | 40.3 | 1.17 |
| 4 | 41 | A | 41_A | 0.149 | 0.15 | 0.232 | 0.07 | 4395.1 | 0.338 | 1 | 0.4 | 0.07 | 0.16 | 0.15 | 0.15 | 0.149 | 14.9 | 0.46 |
| 4 | 41 | B | 41_B | 0.148 | 0.15 | 0.252 | 0.067 | 4395.1 | 0.337 | 1 | 0.1 | 0.09 | 0.20 | 0.16 | 0.16 | 0.148 | 14.8 | 0.58 |
| 4 | 41 | C | 41_C | 0.151 | 0.15 | 0.237 | 0.097 | 4395.1 | 0.344 | 1 | 0.9 | 0.23 | 0.52 | 0.14 | 0.14 | 0.151 | 15.1 | 1.54 |
| 4 | 41 | D | 41_D | 0.142 | 0.14 | 0.266 | 0.034 | 4395.1 | 0.324 | 1 | 0.5 | 0.14 | 0.33 | 0.15 | 0.15 | 0.142 | 14.2 | 1.03 |
| 5 | 6 | A | 6_A | 0.233 | 0.23 | 0.32 | 0.083 | 7816.8 | 0.298 | 1 | 2.9 | 0.34 | 0.44 | 0.23 | 0.23 | 0.233 | 23.3 | 1.49 |
| 5 | 6 | B | 6_B | 0.153 | 0.15 | 0.255 | 0.042 | 7816.8 | 0.196 | 1 | 2.0 | 0.39 | 0.50 | 0.15 | 0.15 | 0.153 | 15.3 | 2.62 |
| 5 | 6 | M | 6_M | 0.204 | 0.20 | 0.359 | 0.086 | 7816.8 | 0.261 | 1 | 2.5 | 0.37 | 0.47 | 0.22 | 0.22 | 0.204 | 20.4 | 1.83 |
| 5 | 7 | A | 7_A | 0.159 | 0.16 | 0.259 | 0.074 | 10165.7 | 0.157 | 1 | 2.3 | 0.41 | 0.40 | 0.15 | 0.15 | 0.159 | 15.9 | 2.55 |
| 5 | 7 | B | 7_B | 0.179 | 0.18 | 0.274 | 0.116 | 10165.7 | 0.176 | 1 | 1.6 | 0.23 | 0.23 | 0.21 | 0.21 | 0.179 | 17.9 | 1.27 |
| 5 | 7 | M | 7_M | 0.249 | 0.25 | 0.369 | 0.148 | 10165.7 | 0.245 | 1 | 3.3 | 0.43 | 0.42 | 0.25 | 0.25 | 0.249 | 24.9 | 1.71 |
| 5 | 8 | A | 8_A | 0.198 | 0.20 | 0.37 | 0.113 | 6666.9 | 0.297 | 1 | 2.0 | 0.28 | 0.42 | 0.21 | 0.21 | 0.198 | 19.8 | 1.39 |
| 5 | 8 | B | 8_B | 0.236 | 0.24 | 0.352 | 0.163 | 6666.9 | 0.354 | 1 | 2.6 | 0.13 | 0.19 | 0.24 | 0.24 | 0.236 | 23.6 | 0.54 |
| 5 | 8 | M | 8_M | 0.231 | 0.23 | 0.357 | 0.093 | 6666.9 | 0.347 | 1 | 2.6 | 0.26 | 0.39 | 0.24 | 0.24 | 0.231 | 23.1 | 1.14 |
| 1 | 9 | A | 9A | 0.181 | 0.19 | 0.359 | 0.201 | 7724.3 | 0.234 | 1 | 2.8 | 0.40 | 0.52 | 0.26 | 0.26 | 0.273 | 27.3 | 2.10 |
| 1 | 9 | B | 9B | 0.162 | 0.16 | 0.439 | 0.239 | 7724.3 | 0.210 | 1 | 3.1 | 0.32 | 0.41 | 0.34 | 0.34 | 0.294 | 29.4 | 1.98 |
| 1 | 9 | M | 9M | 0.137 | 0.14 | 0.372 | 0.211 | 7724.3 | 0.177 | 1 | 1.7 | 0.26 | 0.33 | 0.3 | 0.3 | 0.343 | 34.3 | 1.82 |
| 5 | 9_8 | A | 9A_8B | 0.273 | 0.26 | 0.262 | 0.084 | 6770.9 | 0.403 | 1 | 2.9 | 0.42 | 0.61 | 0.19 | 0.19 | 0.181 | 18.1 | 1.60 |
| 5 | 9_8 | B | 9B_8B | 0.343 | 0.34 | 0.257 | 0.093 | 6770.9 | 0.507 | 1 | 0.9 | 0.19 | 0.27 | 0.16 | 0.16 | 0.162 | 16.2 | 0.56 |
| 5 | 9_8 | M | 9C_8B | 0.294 | 0.30 | 0.249 | 0.072 | 6770.9 | 0.434 | 1 | 2.3 | 0.28 | 0.42 | 0.14 | 0.14 | 0.137 | 13.7 | 0.96 |

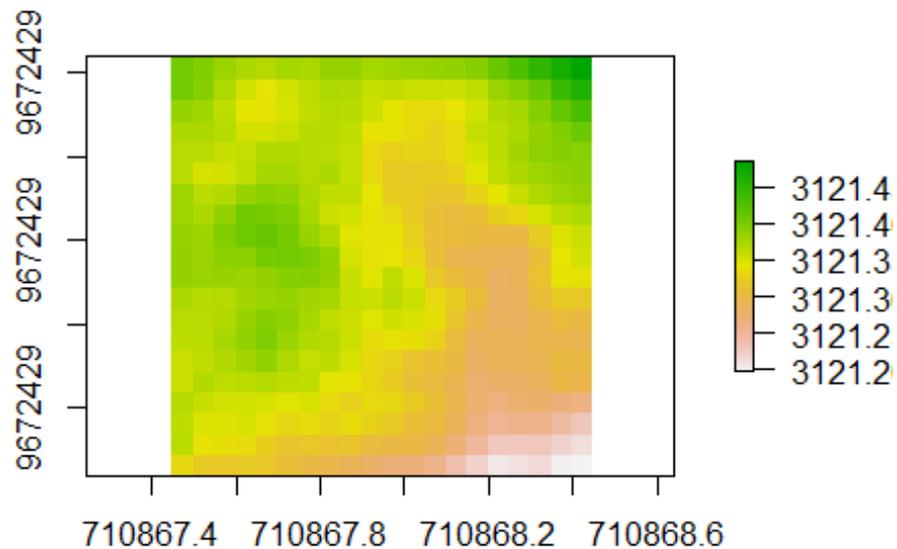
Anexo 3. Ejemplo de extracción de alturas a partir de modelos digitales en R.

Selecciono el raster a cargar

```
raster("13A_A.tif")->MDS
```

Gráfico el raster con el nombre "MDS"

```
plot(MDS)
```



Chequeo el sistema de proyecciones

```
projection(MDS)
```

```
## [1] "+proj=utm +zone=17 +south +datum=WGS84 +units=m +no_defs"
```

Transformo a dataframe los valores de las alturas de cada pixel

```
as.data.frame(MDS)->base
```

Chequeo la base

```
head(base)
```

```
##      X13A_A
## 1 3121.403
## 2 3121.396
## 3 3121.381
```

```
## 4 3121.372
## 5 3121.367
## 6 3121.375
```

Realizo sumatoria de valores NA

```
sum(is.na(base))
## [1] 0
```

Reviso la estructura del dataframe "base"

```
str(base)
## 'data.frame': 400 obs. of 1 variable:
## $ X13A_A: num 3121 3121 3121 3121 3121 ...
```

Realizo la media de las alturas del MDS de la parcela 13A

```
a=mean (base$X13A_A, na.rm=TRUE)
```

Imprimo el valor "a"

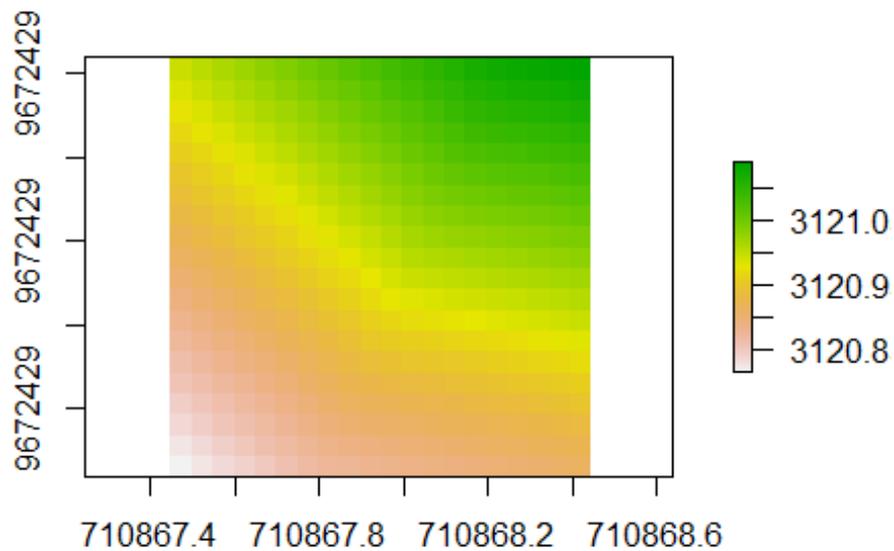
```
a
## [1] 3121.342
```

Selecciono el raster a cargar

```
raster("1roV_mde_microtopo_13A_A.tif")->MDT
```

Grafico el raster con el nombre "MDT"

```
plot(MDT)
```



Chequeo el sistema de proyecciones

```
projection(MDT)
```

```
## [1] "+proj=utm +zone=17 +south +datum=WGS84 +units=m +no_defs"
```

Transformo a dataframe los valores de las alturas de cada pixel

```
as.data.frame(MDT)->base2
```

Chequeo la base2#

```
head(base2)
```

```
## X1roV_mde_microtopo_13A_A
## 1 3120.995
## 2 3121.003
## 3 3121.012
## 4 3121.021
## 5 3121.030
## 6 3121.039
```

Realizo sumatoria de valores NA

```
sum(is.na(base2))
```

```
## [1] 0
```

Reviso la estructura del dataframe "base"

```
str(base)
## 'data.frame': 400 obs. of 1 variable:
## $ X13A_A: num 3121 3121 3121 3121 3121 ...
```

Realizo la media de las alturas de la microtopografía de la parcela 13A

```
b=mean(base2$X1roV_mde_microtopo_13A_A, na.rm=TRUE)
```

Imprimo el valor "b"

```
b
## [1] 3120.977
```

Realizo la diferencia entre la altura "a" y altura "b"

```
altura=(a-b)
```

Imprimo el valor de la altura

```
altura
## [1] 0.365459
```

Anexo 4. Análisis estadístico

```
library(readr)
library(dplyr)
library(readxl)
library("Metrics")
library(caret)
library(ggplot2)
library(tensorflow)
library(car)
library(lmtest)
library(nortest)
#library(keras)
#library(MASS)

###
####
#####
#####
#####

base <- read_excel("C:/Nero/val/Base_modelos.xlsx")
base0 <- read_excel("C:/Nero/val/Base_modelos.xlsx", sheet="Sheet3")
base1 <- read_excel("C:/Nero/val/Base_modelos.xlsx", sheet="Sheet4")
base3 <- read_excel("C:/Nero/val/Base_modelos.xlsx", sheet="Sheet9")
```

```

set.seed(1000)

base2=sample(1:nrow(base), round(0.70*nrow(base),0), replace=FALSE)

tra=base[base2,]
tes=base[-base2,]

###GENERO EL MODELO CON DATOS DE ENTRENAMIENTO

#m1=lm(tra$Vdig~tra$Vreal)

#plot(m1)

m1=caret::train(Vdig~Vreal, data = tra ,method = 'lm')

m1$results

summary(m1)

#mean(m1$residuals^2)

#sqrt(mean(m1$residuals^2))

#mae(tra$Vreal, predict(m1))

#BIC(m1)

#AIC(m1)

### ### ### ### ###

par(mfrow = c(2, 2))

m1.1=lm(tra$Vdig~tra$Vreal)

plot(m1.1)

shapiro.test(m1$trainingData$.outcome-m1$trainingData$Vreal)

dwtest(lm(tra$Vdig~tra$Vreal))

ncvTest(lm(tra$Vdig~tra$Vreal))

### ### ### ### ###

```

```

pred <- predict(m1, tes)
postResample(pred, tes$Vdig)

###VALIDO EL MODELO ANTERIOR A TRAVES DE K FOLD
set.seed(1000)
control <- trainControl(method = "cv", number = 5)
mod1<- caret::train(Vdig~Vreal, data = tra, method = "lm", trControl = control)
print(mod1)
mod1$finalModel
mod1$resample

plot<-ggplot(tra, aes(x=(Vreal), y=(Vdig))) + geom_point(size=3) +
  geom_smooth(method=lm, se=TRUE, color="blue")+ theme_test()+
  ggtitle(" ")+theme(plot.title = element_text(size=14, hjust = 0.5))+
  ylab("Volumen Real (m³)") +theme(axis.title.y = element_text(vjust=1.5,
colour="black", size=rel(1.25)))+
  theme(axis.text.x = element_text(colour="black", size=rel(1.25)))+
  xlab("Volumen Digital (m³)")+theme(axis.title.x = element_text(vjust=-0.5,
colour="black", size=rel(1.25)))+
  theme(axis.text.y = element_text(colour="black", size=rel(1.25)))
text<-("b) y= 1.008x - 0.0039
R²= 0.985")
plot+annotate("text", x = 0.2, y = 0.465, label=text, size=4.8)

#####

```

```
#####
```

```
###GENERO EL MODELO CON DATOS DE ENTRENAMIENTO
```

```
#m2=lm(tra$Adig~tra$Areal)
```

```
m2=caret::train(Adig~Areal, data = tra ,method = 'lm')
```

```
m2$results
```

```
summary(m2)
```

```
###
```

```
par(mfrow = c(2, 2))
```

```
m2.1=lm(tra$Adig~tra$Areal)
```

```
plot(m2.1)
```

```
shapiro.test(m2$trainingData$.outcome-m2$trainingData$Areal)
```

```
dwtest(lm(Adig~Areal, data = tra))
```

```
ncvTest(lm(Adig~Areal, data = tra))
```

```
###
```

```
pred1 <- predict(m2, tes)
```

```
postResample(pred1, tes$Adig)
```

```
###VALIDO EL MODELO ANTERIOR A TRAVES DE K FOLD
```

```
set.seed(1000)
```

```
control <- trainControl(method = "cv", number = 5)
```

```
mod2<- caret::train(Adig~Areal, data = tra, method = "lm", trControl = control)
```

```
print(mod2)
```

```
mod2$finalModel
```

```
mod2$resample
```

```
plot<-ggplot(tra, aes(x=Adig, y=Areal)) + geom_point(size=3) +
  geom_smooth(method=lm, se=TRUE, color="blue")+ theme_test()+
  ggtitle(" ")+theme(plot.title = element_text(size=14, hjust = 0.5))+
  ylab("Altura Real (m)") +theme(axis.title.y = element_text(vjust=1.5,
  colour="black", size=rel(1.25)))+
  theme(axis.text.x = element_text(colour="black", size=rel(1.25)))+
  xlab("Altura Digital (m)")+theme(axis.title.x = element_text(vjust=-0.5,
  colour="black", size=rel(1.25)))+
  theme(axis.text.y = element_text(colour="black", size=rel(1.25)))
text<-("a      y= 1.003x - 0.002
      R2= 0.955")
plot+annotate("text", x = 0.2, y = 0.465, label=text, size=4.8)
```

```
#####
```

```
#####
```

```
set.seed(1000)
```

```
base2.2=sample(1:nrow(base0), round(0.70*nrow(base0),0), replace=FALSE)
```

```
tra1=base0[base2.2,]
```

```
tes1=base0[-base2.2,]
```

```
###GENERO EL MODELO CON DATOS DE ENTRENAMIENTO
```

```
#m3=lm(tra1$Altura~tra1$Fresco)
```

```

m3=caret::train(Altura~Fresco, data = tra1 ,method = 'lm')
m3$results
summary(m3)

### ### ### ### ###
par(mfrow = c(2, 2))
m3.1=lm(tra1$Altura~tra1$Fresco)
plot(m3.1)
shapiro.test(m3$trainingData$.outcome-m3$trainingData$Fresco)
dwtest(lm(Altura~Fresco, data = tra1))
ncvTest(lm(Altura~Fresco, data = tra1))
### ### ### ### ###

pred2 <- predict(m3, tes1)
postResample(pred2, tes1$Altura)

###VALIDO EL MODELO ANTERIOR A TRAVES DE K FOLD
set.seed(1000)
control <- trainControl(method = "cv", number = 5)
mod3<- caret::train(Altura~Fresco, data = tra1, method = "lm", trControl = control)
print(mod3)
mod3$finalModel
mod3$resample

plot<-ggplot(tra1, aes(x=Altura, y=Fresco)) + geom_point(size=3) +

```

```

geom_smooth(method=lm, se=TRUE, color="blue")+ theme_test()+
ggtitle(" ")+theme(plot.title = element_text(size=14, hjust = 0.5))+
ylab("Biomasa fresca (kg/m²)") +theme(axis.title.y = element_text(vjust=1.5,
colour="black", size=rel(1.25)))+
theme(axis.text.x = element_text(colour="black", size=rel(1.25)))+
xlab("Altura Digital (m)")+theme(axis.title.x = element_text(vjust=-0.5,
colour="black", size=rel(1.25)))+
theme(axis.text.y = element_text(colour="black", size=rel(1.25)))+ylim(0,4.8)
text<-("a    y= 0.127x + 0.044
R²= 0.914")
plot+annotate("text", x = 0.175, y = 4.6, label=text, size=4.8)

```

```

#####
#####

```

```
###GENERO EL MODELO CON DATOS DE ENTRENAMIENTO
```

```
#m4=lm(tra1$Altura~tra1$Seco)
```

```
m4=caret::train(Altura~Seco, data = tra1 ,method = 'lm')
```

```
m4$results
```

```
summary(m4)
```

```
### ### ### ### ###
```

```
par(mfrow = c(2, 2))
```

```
m4.1=lm(tra1$Altura~tra1$Seco)
```

```
plot(m4.1)
```

```
shapiro.test(m4$trainingData$.outcome-m4$trainingData$Seco)
```

```

dwtest(lm(Altura~Seco, data = tra1))
ncvTest(lm(Altura~Seco, data = tra1))

### ### ### ### ###

pred3 <- predict(m4, tes1)
postResample(pred3, tes1$Altura)

###VALIDO EL MODELO ANTERIOR A TRAVES DE K FOLD

set.seed(1000)

control <- trainControl(method = "cv", number = 5)
mod4<- caret::train(Altura~Seco, data = tra1, method = "lm", trControl = control)
print(mod4)
mod4$finalModel
mod4$resample

plot<-ggplot(tra1, aes(x=Altura, y=Seco)) + geom_point(size=3) +
  geom_smooth(method=lm, se=TRUE, color="blue")+ theme_test()+
  ggtitle("")+theme(plot.title = element_text(size=14, hjust = 0.5))+
  ylab("Biomasa seca (kg/m²)") +theme(axis.title.y = element_text(vjust=1.5,
colour="black", size=rel(1.25)))+
  theme(axis.text.x = element_text(colour="black", size=rel(1.25)))+
  xlab("Altura digital (m)")+theme(axis.title.x = element_text(vjust=-0.5,
colour="black", size=rel(1.25)))+
  theme(axis.text.y = element_text(colour="black", size=rel(1.25)))+ylim(0,0.71)
text<-("a    y= 0.264x + 0.131

R²= 0.685")

```

```
plot+annotate("text", x = 0.185, y = 0.67, label=text, size=4.8)
```

```
#####
```

```
#####
```

```
set.seed(1000)
```

```
base2.3=sample(1:nrow(base1), round(0.70*nrow(base1),0), replace=FALSE)
```

```
tra2=base1[base2.3,]
```

```
tes2=base1[-base2.3,]
```

```
###GENERO EL MODELO CON DATOS DE ENTRENAMIENTO
```

```
#m5=lm(tra2$Vol~tra2$Fresco)
```

```
m5=caret::train(Vol~Fresco, data = tra2 ,method = 'lm')
```

```
m5$results
```

```
summary(m5)
```

```
###
```

```
par(mfrow = c(2, 2))
```

```
m5.1=lm(tra2$Vol~tra2$Fresco)
```

```
plot(m5.1)
```

```
shapiro.test(m5$trainingData$.outcome-m5$trainingData$Fresco)
```

```
dwtest(lm(Vol~Fresco, data = tra2))
```

```
ncvTest(lm(Vol~Fresco, data = tra2))
```

```
###
```

```
pred4 <- predict(m5, tes2)
postResample(pred4, tes2$Vol)
```

###VALIDO EL MODELO ANTERIOR A TRAVES DE K FOLD

```
set.seed(1000)
control <- trainControl(method = "cv", number = 5)
mod5<- caret::train( Vol~Fresco, data = tra2, method = "lm", trControl = control)
print(mod5)
mod5$finalModel
mod5$resample
```

```
plot<-ggplot(tra2, aes(x=Vol, y=Fresco)) + geom_point(size=3) +
  geom_smooth(method=lm, se=TRUE, color="blue")+ theme_test()+
  ggtitle(" ") +theme(plot.title = element_text(size=14, hjust = 0.5))+
  ylab("Biomasa fresca (kg/m²)") +theme(axis.title.y = element_text(vjust=1.5,
  colour="black", size=rel(1.25)))+
  theme(axis.text.x = element_text(colour="black", size=rel(1.25)))+
  xlab("Volumen Digital (m³)") +theme(axis.title.x = element_text(vjust=-0.5,
  colour="black", size=rel(1.25)))+
  theme(axis.text.y = element_text(colour="black", size=rel(1.25)))+ylim(0, 3.65)
text<-("a    y= 0.045x + 0.124
      R²= 0.807")
plot+annotate("text", x = 0.18, y = 3.4, label=text, size=4.8)
```

```
#####
```

```
#####
```

```
###GENERO EL MODELO CON DATOS DE ENTRENAMIENTO
```

```
#m6=lm(tra2$Vol~tra2$Seco)
```

```
m6=caret::train(Vol~Seco, data = tra2 ,method = 'lm')
```

```
m6$results
```

```
summary(m6)
```

```
###
```

```
par(mfrow = c(2, 2))
```

```
m6.1=lm(tra2$Vol~tra2$Seco)
```

```
plot(m6.1)
```

```
shapiro.test(m6$trainingData$.outcome-m6$trainingData$Seco)
```

```
dwtest(lm(Vol~Seco, data = tra2))
```

```
ncvTest(lm(Vol~Seco, data = tra2))
```

```
###
```

```
pred5 <- predict(m6, tes2)
```

```
postResample(pred5, tes2$Vol)
```

```
###VALIDO EL MODELO ANTERIOR A TRAVES DE K FOLD
```

```
set.seed(1000)
```

```
control <- trainControl(method = "cv", number = 5)
```

```
mod6<- caret::train( Vol~Seco, data = tra2, method = "lm", trControl = control)
```

```

print(mod6)

mod6$finalModel

mod6$resample

plot<-ggplot(tra2, aes(x=Vol, y=Seco)) + geom_point(size=3) +
  geom_smooth(method=lm, se=TRUE, color="blue")+ theme_test()+
  ggtitle(" ") + theme(plot.title = element_text(size=14, hjust = 0.5)) +
  ylab("Biomasa seca (kg/m²)") + theme(axis.title.y = element_text(vjust=1.5,
  colour="black", size=rel(1.25))) +
  theme(axis.text.x = element_text(colour="black", size=rel(1.25))) +
  xlab("Volumen Digital (m³)") + theme(axis.title.x = element_text(vjust=-0.5,
  colour="black", size=rel(1.25))) +
  theme(axis.text.y = element_text(colour="black", size=rel(1.25))) + ylim(0, 0.53)
text<-("b      y= 0.222x + 0.138
      R²= 0.565")
plot+annotate("text", x = 0.19, y = 0.50, label=text, size=4.8)

#####
#####

set.seed(1000)

base2.4=sample(1:nrow(base3), round(0.70*nrow(base3),0), replace=FALSE)
tra3=base3[base2.4,]
tes3=base3[-base2.4,]

```

```
###GENERO EL MODELO CON DATOS DE ENTRENAMIENTO
```

```
#m7=lm(tra3$breal~tra3$bdig)
```

```
m7=caret::train(Bmreal~Bmdig, data = tra3 ,method = 'lm')
```

```
m7$results
```

```
summary(m7)
```

```
### ### ### ### ###
```

```
par(mfrow = c(2, 2))
```

```
m7.1=lm(tra3$Bmreal~tra3$Bmdig)
```

```
plot(m7.1)
```

```
shapiro.test(m7$trainingData$.outcome-m7$trainingData$Bmdig)
```

```
dwtest(lm(Bmreal~Bmdig, data = tra3))
```

```
ncvTest(lm(Bmreal~Bmdig, data = tra3))
```

```
### ### ### ### ###
```

```
pred6 <- predict(m7, tes3)
```

```
postResample(pred6, tes3$Bmreal)
```

```
set.seed(1000)
```

```
control <- trainControl(method = "cv", number = 5)
```

```
mod7<- caret::train(Bmreal~Bmdig, data = tra3, method = "lm", trControl =  
control)
```

```
print(mod7)
```

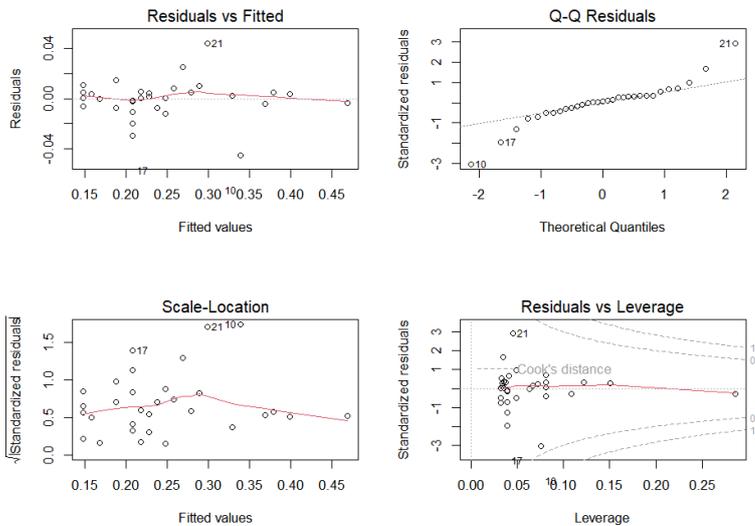
```
mod7$finalModel
```

```
mod7$resample
```

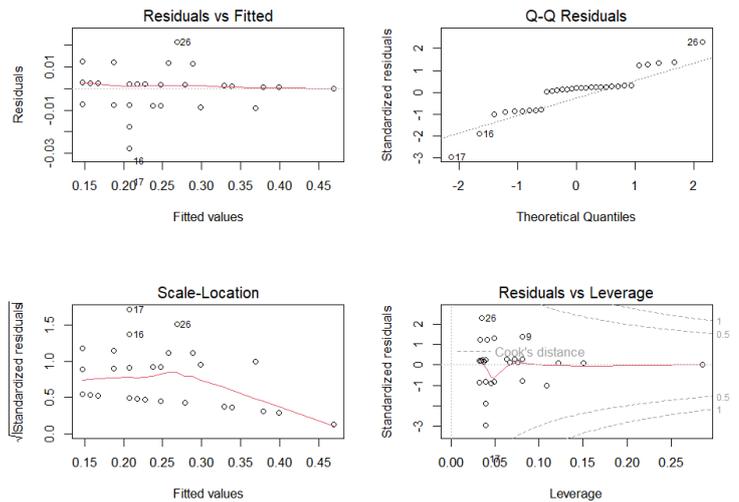
```
plot<-ggplot(tra3, aes(x=Bmreal, y=Bmdig)) + geom_point(size=3) +  
  geom_smooth(method=lm, se=TRUE, color="blue")+ theme_test()+  
  ggtitle(" ")+theme(plot.title = element_text(size=14, hjust = 0.5))+  
  ylab("Biomasa Real (kg/ha)") +theme(axis.title.y = element_text(vjust=1.5,  
colour="black", size=rel(1.25)))+  
  theme(axis.text.x = element_text(colour="black", size=rel(1.25)))+  
  xlab("Biomasa Digital (kg/ha)")+theme(axis.title.x = element_text(vjust=-0.5,  
colour="black", size=rel(1.25)))+  
  theme(axis.text.y = element_text(colour="black", size=rel(1.25)))  
text<-("y= 0.970x + 99.702  
  R2= 0.985")  
plot+annotate("text", x = 1800, y=4700, label=text, size=4.8)
```

Anexo 5. Comportamiento de los residuales de cada modelo

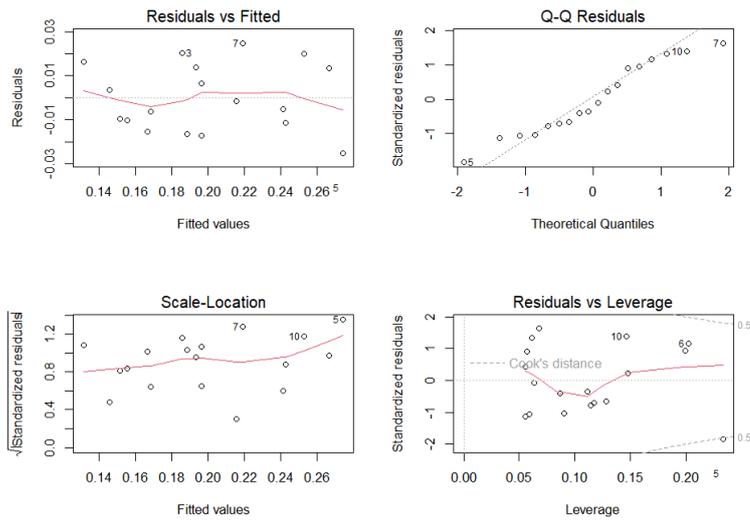
Altura digital y real



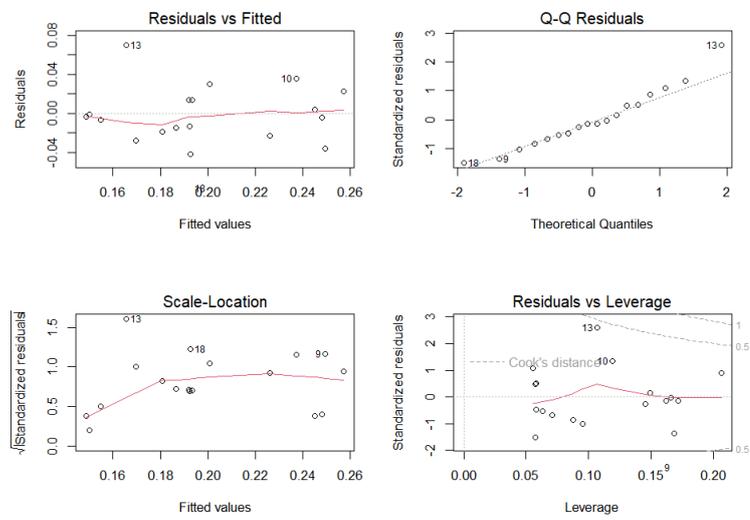
Volumen digital y real



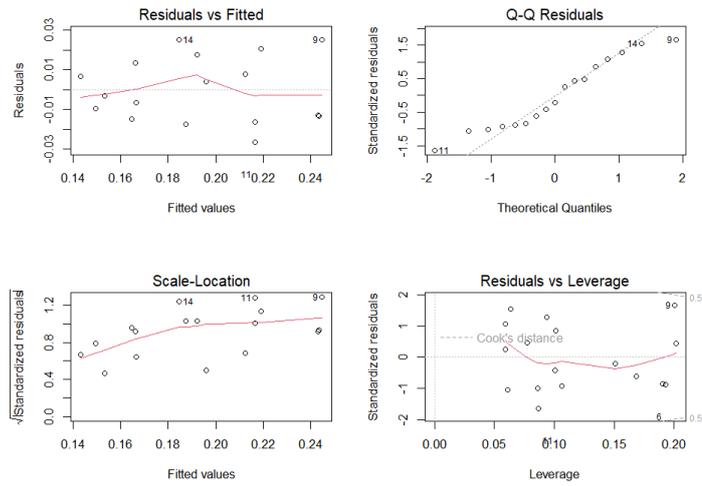
Altura digital y biomasa fresca



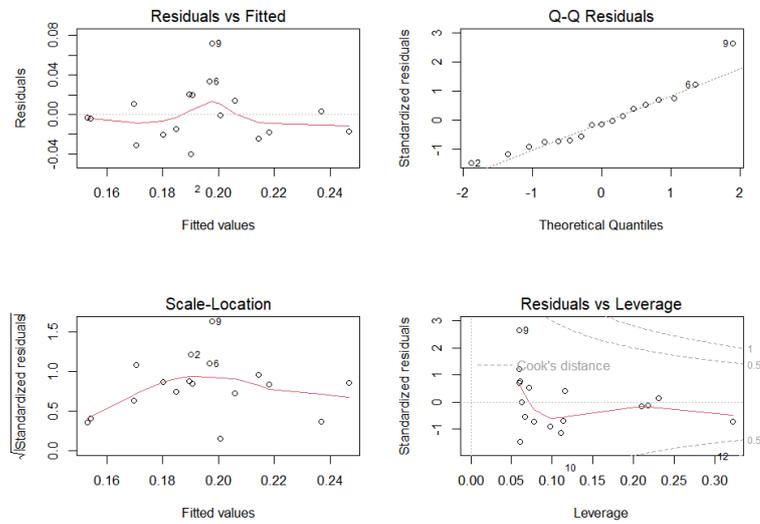
Altura digital y biomasa seca



Volumen y biomasa fresca



Volumen y biomasa seca



Biomasa digital y biomasa real

