

**UNIVERSIDAD NACIONAL  
TORIBIO RODRIGUEZ DE MENDOZA DE AMAZONAS**



**FACULTAD DE INGENIERÍA ZOOTECNISTA, AGRONEGOCIOS Y  
BIOTECNOLOGÍA**

**ESCUELA PROFESIONAL DE INGENIERÍA ZOOTECNISTA**

**TESIS PARA OBTENER  
EL TÍTULO PROFESIONAL DE  
INGENIERO ZOOTECNISTA**

**PREDICCIÓN DE COMPONENTES NUTRICIONALES DE *PASTOS*  
*ALTOANDINOS* MEDIANTE ALGORITMOS DE PROCESAMIENTO DE  
IMÁGENES RED-GREEN-BLUE, MULTIESPECTRALES Y TECNOLOGÍA  
DE INFRARROJO CERCANO**

**Autor:**

**Bach. Kevin Enrique Chamaya Muñoz**

**Asesores:**

**Dr. Héctor Vladimir Vásquez Pérez**

**Dr. Jonathan Alberto Campos Trigos**

**M.Sc. Leandro Valqui Valqui**

**Registro: (...)**

**CHACHAPOYAS – PERÚ**

**2024**

## **DEDICATORIA**

Dedico este trabajo de investigación principalmente a Dios, por darme la fortaleza necesaria para continuar en el proceso de alcanzar uno de mis más grandes deseos. A mis padres, por su amor, esfuerzo y sacrificio a lo largo de los años; gracias a ellos he logrado llegar hasta aquí y convertirme en quien soy. Ha sido un honor y un privilegio ser su hijo; son los mejores padres que podría tener. Agradezco también a todas las personas que me han brindado su apoyo y han contribuido al éxito de este trabajo, especialmente a aquellos que me ofrecieron su ayuda y compartieron sus conocimientos.

## **AGRADECIMIENTO**

A Dios, por cuidar de mi salud y guiarme en el camino correcto, a mis padres, Jacob Chamaya Tantalean y Eirene Muñoz Sánchez; y especialmente a mis abuelos Sinforoso, a mi papá Manuel y a mi querida mamá Mavila. Aunque algunos ya no están en este mundo, su apoyo fue fundamental para mí.

A mi pequeña familia, que es mi motor y razón para seguir adelante.

A mis asesores, por su apoyo desinteresado, paciencia y confianza, y a mis jurados, cuyas contribuciones me ayudaron a mejorar mis conocimientos y habilidades en el campo.

A mis docentes de la FIZAB-UNTRM; y a todas las personas que no mencioné, pero que han contribuido significativamente a alcanzar esta meta.

Al Instituto Nacional de Innovación Agraria (INIA), al Instituto de Investigación en Ganadería y Biotecnología (IGBI) de la Universidad Nacional Toribio Rodríguez de Mendoza de Amazonas, y al Programa Nacional de Investigación Científica y Estudios Avanzados (PROCIENCIA) por el financiamiento otorgado para el desarrollo de esta investigación a través del Proyecto de Investigación con contrato N°PE501080344-2022-PROCIENCIA.

**AUTORIDADES DE LA UNIVERSIDAD NACIONAL TORIBIO RODRÍGUEZ  
DE MENDOZA DE AMAZONAS**

**Ph. D. Jorge Luis Maicelo Quintana**

**Rector**

**Dr. Oscar Andrés Gamarra Torres**

**Vicerrector Académico**

**Dra. María Nelly Luján Espinoza**

**Vicerrectora de Investigación**

**Dr. Héctor Vladimir Vásquez Pérez**

**Decano(e) de la Facultad de Ingeniería Zootecnista, Agronegocios y  
Biotecnología**

## VISTO BUENO DEL ASESOR DE TESIS



### ANEXO 3-L

#### VISTO BUENO DEL ASESOR DE TESIS PARA OBTENER EL TÍTULO PROFESIONAL

El que suscribe el presente, docente de la UNTRM (  )/Profesional externo (  ), hace constar que ha asesorado la realización de la Tesis titulada "PREDICIÓN DE COMPONENTES NUTRICIONALES DE POSTOS AUTOMÁTICOS MEDIANTE ALGORITMOS DE PROCESAMIENTO DE IMÁGENES RGB-GREEN-BLUE, MULTIESPECTRALES Y TÉCNICA DE INTERPOLACIÓN CERCANO"; del egresado KEVIN ENRIQUE CHAMAYO MUÑOZ de la Facultad de INGENIERÍA TECNOLÓGICA, DE NEGOCIOS Y BIOTECNOLOGÍA Escuela Profesional de INGENIERÍA TECNOLÓGICA de esta Casa Superior de Estudios.

El suscrito da el Visto Bueno a la Tesis mencionada, dándole pase para que sea sometida a la revisión por el Jurado Evaluador, comprometiéndose a supervisar el levantamiento de observaciones que formulen en Acta en conjunto, y estar presente en la sustentación.



Chachapoyas, 10 de JUNIO de 24

A handwritten signature in blue ink is written over a horizontal line. The signature appears to be "Hector Umasma Ustareza Perez".

Firma y nombre completo del Asesor

HECTOR UMASMA USTAREZA PEREZ



**UNTRM**

**REGLAMENTO GENERAL**  
PARA EL OTORGAMIENTO DEL GRADO ACADÉMICO DE  
BACHILLER, MAESTRO O DOCTOR Y DEL TÍTULO PROFESIONAL

**ANEXO 3-L**

**VISTO BUENO DEL ASESOR DE TESIS PARA OBTENER EL TÍTULO PROFESIONAL**

El que suscribe el presente, docente de la UNTRM (  )/Profesional externo (  ), hace constar que ha asesorado la realización de la Tesis titulada "PREDICCIÓN DE COMPONENTES NUTRICIONALES DE PASTO ALTOANDINO MEDIANTE ALGORITMOS DE PROCESAMIENTO DE IMPÁGENES RED-GRUEN-BLUE Y MULTIESCALARES Y TÉCNICA DE INFRARROJO CERIANO"; del egresado KEVIN ENRIQUE CHANDYD MUÑOZ de la Facultad de INGENIERÍA ZOOTECNISTA, AGRONEGOCIO Y BIOTECNOLOGÍA Escuela Profesional de INGENIERÍA ZOOTECNISTA de esta Casa Superior de Estudios.



El suscrito da el Visto Bueno a la Tesis mencionada, dándole pase para que sea sometida a la revisión por el Jurado Evaluador, comprometiéndose a supervisar el levantamiento de observaciones que formulen en Acta en conjunto, y estar presente en la sustentación.

Chachapoyas, 10 de JUNIO de 24

Firma y nombre completo del Asesor

Jonathan Alberto Campos Trigos.



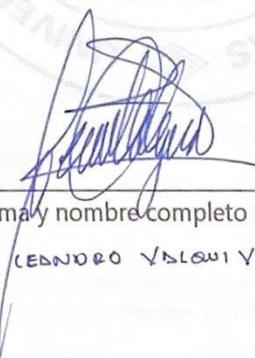
**ANEXO 3-L**

**VISTO BUENO DEL ASESOR DE TESIS PARA OBTENER EL TÍTULO PROFESIONAL**

El que suscribe el presente, docente de la UNTRM (  )/Profesional externo (  ), hace constar que ha asesorado la realización de la Tesis titulada "PREDICCIÓN DE COMPONENTES NUTRICIONALES DE PASTOS ALTODANDIJO MEDIANTE ALGORITMOS DE PROCESAMIENTO DE IMÓGENES RED-GREEN-BLUE, MULTISPECTRALES Y TECNOLOGÍA DE INFRAROJO CERCANO"; del egresado KEVIN ENRIQUE CHAMAYO MUÑOZ de la Facultad de INGENIERÍA ZOOTECNISTA, DORONOCOLDO Y BIOTECNOLOGÍA Escuela Profesional de INGENIERÍA ZOOTECNISTA de esta Casa Superior de Estudios.

El suscrito da el Visto Bueno a la Tesis mencionada, dándole pase para que sea sometida a la revisión por el Jurado Evaluador, comprometiéndose a supervisar el levantamiento de observaciones que formulen en Acta en conjunto, y estar presente en la sustentación.

Chachapoyas, 10 de JUNIO de 24

  
Firma y nombre completo del Asesor  
M.Sc. LEONORO VALDIVIA

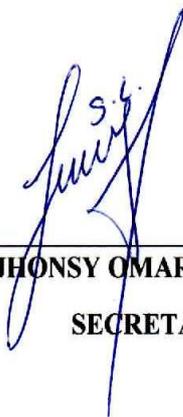
**JURADO EVALUADOR DE TESIS**



---

**M.Sc. CÉSAR AUGUSTO MARAVI CARMEN**

**PRESIDENTE**



---

**Mg. JHONSY OMAR SILVA LÓPEZ**

**SECRETARIO**



---

**M.Sc. LUIS HOMERO ZAGACETA LLANCA**

**VOCAL**

# CONSTANCIA DE ORIGINALIDAD DE LA TESIS



**UNTRM**

**REGLAMENTO GENERAL**  
PARA EL OTORGAMIENTO DEL GRADO ACADÉMICO DE  
BACHILLER, MAESTRO O DOCTOR Y DEL TÍTULO PROFESIONAL

## ANEXO 3-Q

### CONSTANCIA DE ORIGINALIDAD DE LA TESIS PARA OBTENER EL TÍTULO PROFESIONAL

Los suscritos, miembros del Jurado Evaluador de la Tesis titulada:

"PREDICCIÓN DE COMPONENTES NUTRICIONALES DE PASTOS AUTÓMATOS MEDIANTE ALGORITMOS DE  
PROCESAMIENTO DE IMÁGENES RED-GREEN-BLUE, MULTIESPECTRALES Y TECNOLOGÍA DE INFRAROJO CERCANO"

presentada por el estudiante ( )/egresado (x) BDCH. JEVIN C. CHAMPYA MENDOZA

de la Escuela Profesional de INGENIERÍA ZOOTECNISTA

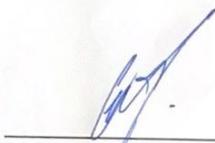
con correo electrónico institucional 7079591761@UNTRM.EDU.PE.

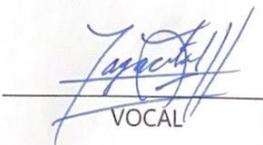
después de revisar con el software Turnitin el contenido de la citada Tesis, acordamos:

- La citada Tesis tiene 23 % de similitud, según el reporte del software Turnitin que se adjunta a la presente, el que es menor (x) / igual ( ) al 25% de similitud que es el máximo permitido en la UNTRM.
- La citada Tesis tiene \_\_\_\_\_ % de similitud, según el reporte del software Turnitin que se adjunta a la presente, el que es mayor al 25% de similitud que es el máximo permitido en la UNTRM, por lo que el aspirante debe revisar su Tesis para corregir la redacción de acuerdo al Informe Turnitin que se adjunta a la presente. Debe presentar al Presidente del Jurado Evaluador su Tesis corregida para nueva revisión con el software Turnitin.

Chachapoyas, 17 de JUNIO del 24

  
SECRETARIO

  
PRESIDENTE

  
VOCAL

OBSERVACIONES:

.....  
.....

## REPORTE TURNITIN

### PREDICCIÓN DE COMPONENTES NUTRICIONALES DE PASTOS ALTOANDINOS MEDIANTE ALGORITMOS DE PROCESAMIENTO DE IMÁGENES RED-GREEN-BLUE, MULTIESPECTRALES Y TECNOLOGÍA DE INFRARROJO CERCANO

#### INFORME DE ORIGINALIDAD

<b>23%</b>	<b>22%</b>	<b>9%</b>	<b>6%</b>
INDICE DE SIMILITUD	FUENTES DE INTERNET	PUBLICACIONES	TRABAJOS DEL ESTUDIANTE

#### FUENTES PRIMARIAS

<b>1</b>	<b>repositorio.untrm.edu.pe</b> Fuente de Internet	<b>5%</b>
<b>2</b>	<b>hdl.handle.net</b> Fuente de Internet	<b>3%</b>
<b>3</b>	<b>www.scielo.org.pe</b> Fuente de Internet	<b>2%</b>
<b>4</b>	<b>repository.udca.edu.co</b> Fuente de Internet	<b>2%</b>
<b>5</b>	<b>www.scielo.org.co</b> Fuente de Internet	<b>1%</b>
<b>6</b>	<b>purl.org</b> Fuente de Internet	<b>1%</b>
<b>7</b>	<b>revistasinvestigacion.unmsm.edu.pe</b> Fuente de Internet	<b>1%</b>
<b>8</b>	<b>cdn.www.gob.pe</b> Fuente de Internet	<b>&lt;1%</b>

*CÉSAR AUGUSTO RAMOS CARMEN*

# ACTA DE SUSTENTACIÓN DE LA TESIS



## ANEXO 3-5

### ACTA DE SUSTENTACIÓN DE TESIS PARA OBTENER EL TÍTULO PROFESIONAL

En la ciudad de Chachapoyas, el día 20 de Junio del año 2024, siendo las 15:40 horas, el aspirante: KEVIN ENRIQUE CHAMAYA MUÑOZ, asesorado por DA HECCON VADIMIR VÁSQUEZ PEREZ defiende en sesión pública presencial () / a distancia (  ) la Tesis titulada: PREVENCIÓN DE COMPONENTES NUTRICIONALES DE DATOS ALTO AERÍOS MEDIANTE ALGORITMOS DE PROCESAMIENTO DE IMÁGENES AIR-SAREN-BICE, MULTIESPECTRALES Y TECNOLOGÍA DE INFRARROJO CERCAÑO, para obtener el Título Profesional de INGENIERO ZOOTECNISTA, a ser otorgado por la Universidad Nacional Toribio Rodríguez de Mendoza de Amazonas; ante el Jurado Evaluador, constituido por:

Presidente: M.Sc. CESAR AUGUSTO MARAVI CARRERA

Secretario: Mg. JHONNY ONAR SILVA LÓPEZ

Vocal: M.Sc. LUIS HOMERO RAMÍREZ UANCA



Procedió el aspirante a hacer la exposición de la Introducción, Material y métodos, Resultados, Discusión y Conclusiones, haciendo especial mención de sus aportaciones originales. Terminada la defensa de la Tesis presentada, los miembros del Jurado Evaluador pasaron a exponer su opinión sobre la misma, formulando cuantas cuestiones y objeciones consideraron oportunas, las cuales fueron contestadas por el aspirante.

Tras la intervención de los miembros del Jurado Evaluador y las oportunas respuestas del aspirante, el Presidente abre un turno de intervenciones para los presentes en el acto de sustentación, para que formulen las cuestiones u objeciones que consideren pertinentes.

Seguidamente, a puerta cerrada, el Jurado Evaluador determinó la calificación global concedida a la sustentación de la Tesis para obtener el Título Profesional, en términos de:

Aprobado () por Unanimidad () / Mayoría (  ) Desaprobado (  )

Otorgada la calificación, el Secretario del Jurado Evaluador lee la presente Acta en esta misma sesión pública. A continuación se levanta la sesión.

Siendo las 16:25 horas del mismo día y fecha, el Jurado Evaluador concluye el acto de sustentación de la Tesis para obtener el Título Profesional.

[Signature]  
SECRETARIO

[Signature]  
VOCAL

[Signature]  
PRESIDENTE

OBSERVACIONES:  
.....

## ÍNDICE DE CONTENIDO

DEDICATORIA.....	ii
AGRADECIMIENTO.....	iii
AUTORIDADES DE LA UNIVERSIDAD NACIONAL TORIBIO RODRÍGUEZ DE MENDOZA DE AMAZONAS.....	iv
VISTO BUENO DEL ASESOR DE TESIS .....	v
JURADO EVALUADOR DE TESIS .....	viii
CONSTANCIA DE ORIGINALIDAD DE LA TESIS .....	ix
REPORTE TURNITIN .....	x
ACTA DE SUSTENTACIÓN DE LA TESIS .....	xi
ÍNDICE DE CONTENIDO .....	xii
ÍNDICE DE TABLAS .....	xiv
ÍNDICE DE FIGURAS .....	xv
RESUMEN:.....	xvi
ABSTRACT .....	xvii
<b>I. INTRODUCCIÓN:</b> .....	18
<b>II. MATERIALES Y METODOS:</b> .....	22
2.1. Ubicación del área de estudio .....	22
2.2. Instalación y manejo de parcelas de investigación .....	23
2.3. Parcelas instaladas .....	23
2.4. Análisis nutricional de pasturas .....	24
a) Proteína cruda (PC). .....	25
b) Fibra detergente neutra (FDN).....	25
c) Fibra detergente ácida (FDA).....	26
d) Energía bruta (EB).....	27
e) Digestibilidad in vitro (DIV).....	27
2.5. Recolección y preparación de muestras de pasturas.....	27
2.6. Adquisición de Imágenes RGB y Multiespectrales. ....	28
2.7. Procesamiento de imágenes RGB y Multiespectrales .....	28
2.8. Toma de Firmas espectrales .....	30
2.9. Análisis Proximal en laboratorio.....	31
2.10. Elaboración de base de datos.....	31
2.11. Construcción del modelo multivariado de predicción .....	31
2.12. Análisis de datos .....	32
<b>III. RESULTADOS</b> .....	32
3.1. Análisis Bromatológico de pastos altoandinos.....	32

3.2.	<b>Firmas espectrales para pastos altoandinos</b> .....	33
3.3.	<b>Longitudes de ondas relevantes en trébol</b> .....	33
3.4.	<b>Longitudes de ondas relevantes en rye Grass</b> .....	34
3.5.	<b>Modelos con PLSR y validación para trébol</b> .....	35
3.6.	<b>Modelos con PLSR y validación para Rye Grass</b> .....	36
3.7.	<b>Análisis de imágenes Red-Green-Blue y multiespectrales</b> .....	37
<b>IV.</b>	<b>DISCUSIÓN</b> .....	<b>41</b>
4.1.	<b>Análisis bromatológico de pastos</b> .....	41
4.2.	<b>Longitudes de ondas relevantes</b> .....	41
4.3.	<b>Modelos con PLSR y validación</b> .....	42
4.4.	<b>Modelos de NDVI y NDRE</b> .....	44
<b>V.</b>	<b>CONCLUSIONES</b> .....	<b>44</b>
<b>VI.</b>	<b>RECOMENDACIONES:</b> .....	<b>45</b>
<b>VII.</b>	<b>REFERENCIAS BIBLIOGRÁFICAS:</b> .....	<b>45</b>
<b>VIII.</b>	<b>ANEXOS:</b> .....	<b>48</b>

## ÍNDICE DE TABLAS

Tabla 1. Cuadro de tratamientos.....	24
Tabla 2. Índices de vegetación calculados a partir de imágenes Red Green Blue. (Rojo-Verde-Azul).....	29
Tabla 3. Fórmulas y bandas de los índices de vegetación obtenidos con imágenes espectrales.....	29
Tabla 4. Análisis bromatológico de pastos altoandinos (promedio y D.E). ....	32
Tabla 5. Estadísticos para modelos de predicción de la composición nutricional del pasto trébol blanco ( <i>Trifolium repens</i> ) en base seca, región Amazonas, Perú. ....	36
Tabla 6. Estadísticos para modelos de predicción de la composición nutricional del pasto rye grass ( <i>Lolium multiflorum</i> ) en base seca, región Amazonas, Perú. ....	36

## ÍNDICE DE FIGURAS

Figura 1. Ubicación del área de estudio .....	22
Figura 2. Perfil espectral de pastos altoandinos.. .....	33
Figura 3. Longitudes de onda relevantes de <i>Trifolium repens</i> . .....	34
Figura 4. Longitudes de onda relevantes de <i>Lolium multiflorum</i> . .....	35
Figura 5. Correlación entre valores nutricionales y firmas espectrales de <i>Lolium multiflorum</i> para (a) Proteína cruda (b) Fibra detergente neutra (c) Fibra detergente ácida (d) Digestibilidad in vitro (e) Cenizas. ....	37
Figura 6. Análisis de parcelas de <i>Lolium multiflorum</i> (NDVI) .....	39
Figura 7. Análisis de parcelas de <i>Lolium multiflorum</i> (NDRE) .....	39
Figura 8. Análisis de parcelas de <i>Trifolium repens</i> (NDVI).....	40
Figura 9. Análisis de parcelas de <i>Trifolium repens</i> (NDRE).....	40

## RESUMEN:

El objetivo de este estudio fue realizar la predicción de componentes nutricionales de pastos altoandinos mediante algoritmos de procesamiento de imágenes RGB, Multiespectrales y tecnología de infrarrojo cercano. Las calibraciones NIRS se obtuvieron para proteína cruda (PC), fibra detergente neutra (FDN), fibra detergente ácida (FDA) y digestibilidad in vitro (DIV). Para maximizar la variabilidad, el conjunto de muestras para el análisis se seleccionó de una parcela de campo instalada en la EEA Amazonas del INIA, cosechada durante tres frecuencias de corte y con dos diferentes dosis de fertilización. Las muestras se escanearon usando un NIR de sobremesa modelo SpectraStar 2500 XL con rango de 1100-2500 nm. Se utilizó un total de 90 muestras, 72 para calibrar y 18 para validar de forma cruzada las ecuaciones derivadas. Se utilizó un conjunto independiente separado (18 muestras) para probar las predicciones. Modelos de predicción completos y óptimos fueron generados utilizando la regresión por mínimos cuadrados parciales (PLSR). El  $R^2$  de los valores de validación para los modelos fueron  $>0.8$ , con un error de predicción (RPD) de 3.563 para PC, 3.756 para FDN, 3.16 para FDA, 3.3 para DIV y 3.841 para Ce. Los modelos NIR obtenidos de este estudio tienen el potencial de usarse en programas de mejoramiento para evaluar la calidad nutritiva de pastos altoandinos.

Palabras clave: Valor nutricional; NIR; PLSR; modelos predictivos; *pastos*

## **ABSTRACT**

The objective of this study was to predict the nutritional components of high Andean grasses using RGB, Multispectral image processing algorithms and near-infrared technology. NIRS calibrations were obtained for crude protein (CP), neutral detergent fiber (NDF), acid detergent fiber (ADF), and in vitro digestibility (IVD). To maximize variability, the set of samples for analysis was selected from a field plot installed in the Amazonas EEA of INIA, harvested during three cutting frequencies and with two different fertilization doses. Samples were scanned using a SpectraStar 2500 XL benchtop NIR model with 1100-2500 nm range. A total of 90 samples were used, 72 for calibration and 18 for cross-validation of the derived equations. A separate independent set (18 samples) was used to test the predictions. Complete and optimal prediction models were generated using partial least squares regression (PLSR). The R<sup>2</sup> of the validation values for the models were >0.8, with a prediction error (RPD) of 3.563 for CP, 3.756 for NDF, 3.16 for FDA, 3.3 for DIV and 3.841 for Ce. The NIR models obtained from this study have the potential to be used in breeding programs to evaluate the nutritional quality of high Andean grasses.

Keywords: Nutritional value; NIR; PLSR; predictive models; pastures.

## **I. INTRODUCCIÓN:**

La utilización de los algoritmos de procesamiento de imágenes RGB, Multiespectrales y la tecnología NIR en la predicción nutricional es una aplicación emergente que podría tener un impacto significativo en la agricultura, la producción de alimentos y la ganadería sostenible. Aquí hay los posibles escenarios de cómo se podría utilizar:

El mapeo y monitoreo de cultivos utilizando los VANT equipados con cámaras multiespectrales y sensores de imágenes pueden volar sobre los campos agrícolas para recopilar datos sobre el estado de los cultivos. Estos datos incluyen información sobre la salud de las plantas, la densidad de la vegetación, la humedad del suelo y otros factores relevantes para la nutrición de las plantas (Ríos-Hernández, 2021).

El análisis de datos, a través de la recopilación de información, utiliza algoritmos de análisis y aprendizaje automático para procesar la información y desarrollar modelos predictivos. Estos modelos pueden prever el estado nutricional de los cultivos, identificar deficiencias de nutrientes y sugerir estrategias de fertilización adaptadas a las particularidades de cada área del campo.

La aplicación de fertilizantes basándose en las predicciones generadas por los modelos, los agricultores pueden aplicar fertilizantes de manera más precisa y eficiente. En lugar de aplicar fertilizantes de manera uniforme en todo el campo, los agricultores pueden utilizar sistemas de aplicación de precisión, como drones rociadores o equipos terrestres controlados por GPS, para administrar los nutrientes exactamente donde y cuando sean necesarios (Ríos-Hernández, 2021).

El seguimiento continuo de los cultivos los VANT también pueden ser utilizados para monitorear la efectividad de las estrategias de fertilización y realizar ajustes en tiempo real según sea necesario (L.A. Hernández-Sánchez, 2023). Esto incluye la capacidad de realizar un seguimiento del crecimiento de los cultivos, detectar signos de estrés nutricional o enfermedades, y realizar evaluaciones periódicas para optimizar las prácticas de manejo agrícola.

En resumen, la integración de drones, análisis de datos y agricultura de precisión puede transformar radicalmente la gestión de la nutrición de los cultivos. Esto permite a los agricultores optimizar el uso de recursos y mejorar tanto la calidad como la cantidad de la producción alimentaria (L.A. Hernández-Sánchez, 2023).

Para la predicción nutricional de pasturas, se pueden emplear diversas tecnologías y métodos, tanto tradicionales como emergentes. Aquí hay algunas tecnologías que podrían utilizarse para este propósito:

La utilización de sensores remotos instalados en plataformas aéreas, como drones o satélites, permite la recolección de datos sobre la salud y el desarrollo de las pasturas. Estos sensores tienen la capacidad de capturar imágenes multiespectrales para evaluar la biomasa, la densidad de la vegetación y la composición de especies, proporcionando información valiosa sobre la calidad nutricional de las pasturas (Zamudio, B. Z., 2016).

El análisis espectral la espectroscopia de reflectancia cercana al infrarrojo (NIR) se utiliza para analizar muestras de pastura y predecir su contenido nutricional, como proteínas, fibra, minerales y otros nutrientes. Estos análisis proporcionan resultados rápidos y precisos sin necesidad de pruebas de laboratorio costosas y consumidoras de tiempo (Luis Alberto Sandoval-Mejía, 2008).

Los sistemas de información geográfica (SIG): se utilizan para integrar datos espaciales y de sensores remotos, como imágenes satelitales y datos topográficos, para modelar y predecir la calidad de la pastura en función de factores como el tipo de suelo, la topografía, las condiciones climáticas y entre otros criterios (Rodríguez, 2018).

Los modelos de predicción se utilizan modelos matemáticos y algoritmos de aprendizaje automático para predecir la calidad nutricional de la pastura en función de variables como el tipo de planta, la edad de la pastura, el clima y la gestión del suelo. Estos modelos pueden ayudar a los productores agropecuarios a tomar decisiones informadas sobre la alimentación del ganado y la gestión de la pastura.

Sistemas de monitoreo continuo los cuales se instalan sensores en el campo para monitorear continuamente la calidad nutricional de la pastura en tiempo real. Estos sistemas pueden proporcionar alertas tempranas sobre cambios en la calidad de la pastura y ayudar a los agricultores a ajustar su manejo de manera oportuna.

En Perú, el uso de tecnología en la predicción nutricional de pasturas está comenzando a ser explorado y adoptado por agricultores y ganaderos para mejorar la productividad y la sostenibilidad de sus operaciones. Pero cabe recalcar que tiene muy poco desde la introducción por lo cual no se encuentra muy desarrollada el uso de tecnología en la predicción nutricional de pasturas en Perú tiene el potencial de mejorar la productividad y la sostenibilidad de la ganadería, ayudando a los agricultores a tomar decisiones más informadas y eficientes en la gestión de sus recursos forrajeros.

Las plantas forrajeras forman la base de la dieta para los animales en pastoreo (Burns et al., 2017). Además, representan la alternativa más económica en términos de nutrientes y están especialmente adaptadas a las necesidades fisiológicas de los rumiantes. Es crucial que este tipo de alimento esté disponible en cantidades suficientes y con la calidad adecuada para que los rumiantes puedan alcanzar su máximo potencial genético en términos de producción.

La comprensión de la composición nutricional (calidad) de las pasturas es crucial para elaborar dietas que cubran las necesidades del animal y compensen los desequilibrios en la alimentación. Por ende, el análisis químico, combinado con una interpretación adecuada de los resultados, facilita una gestión eficaz de la alimentación, lo que contribuye a aumentar la productividad animal (Pérez, 2006).

Las metodologías para estimar los componentes bromatológicos de las pasturas permiten determinar su valor nutricional, lo que facilita la formulación de raciones equilibradas que satisfagan las necesidades nutricionales de los animales (Molano et al., 2016). Sin embargo, estas metodologías suelen tener altos costos debido a los reactivos químicos necesarios y su limitada disponibilidad en el mercado local (Asekova et al., 2016). Por ello, Oliva et al. (2015) subraya la importancia de contar con tecnologías alternativas más económicas que puedan ampliar el uso de estos análisis químicos.

Las evaluaciones de laboratorio (análisis químico) para determinar la calidad de los pastos y forrajes se remontan a más de 100 años hasta el sistema de análisis próximo (Bekewe et al, 2019; Asekova et al., 2016), y más recientemente a fibra detergente neutra (FDN) y fibra detergente ácido (FDA), técnicas (Van Soest et al 1991). Estas técnicas más los procedimientos químicos de laboratorio recientes son los estándares aceptados por la AOAC desde 1996, para poder estimar el potencial nutritivo de forrajes, pero los resultados obtenidos generalmente se basan en puntos; algunos de los procedimientos pueden producir desechos de laboratorio peligrosos, y la información resultante a menudo no está disponible en el momento oportuno, y problemas debido al tiempo necesario para recolectar, preparar y analizar las muestras.

Ante esta realidad es necesario poder implementar alternativas tecnológicas que permitan superar estos inconvenientes, y la espectroscopia de infrarrojo cercano (tanto de sobremesa como dispositivos portátiles) pueden tener el potencial para proporcionar datos oportunos sobre la calidad del forraje comparables a los procedimientos químicos tradicionales (Acosta et al., 2020; Mejia et al., 2019 y Estupiñan et al., 2017). Esta evaluación NIRS convencional de la calidad del forraje requiere que las ecuaciones de calibración para realizar un análisis nutritivo correcto, para ello, las muestras de forraje son recolectados del campo, secados, molidos a partículas de tamaño pequeño, y escaneadas utilizando un espectrofotómetro NIRS. Luego se realizará procedimientos que se utilizan para desarrollar y cuantificar las relaciones, entre los espectros de reflectancia NIR y la calidad del forraje a través de la comparación de estos con los resultados de las mediciones que se determinan mediante procedimientos químicos. Posteriormente se utilizará análisis estadísticos que permitirán construir y generar los modelos multivariado para cada parámetro nutricional a ser evaluado.

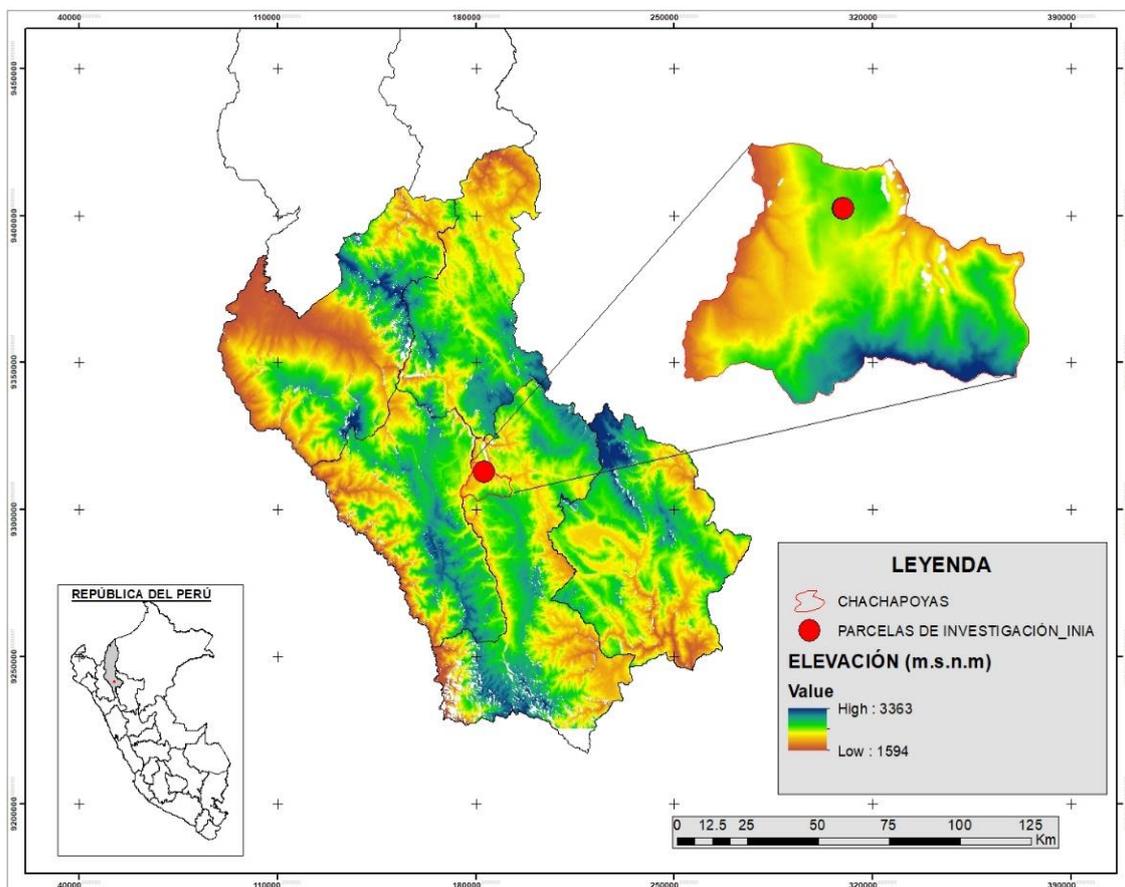
La metodología creada por Shenk y Westerhaus (1991) para definir la población, seleccionar muestras y desarrollar la calibración se ha adoptado ampliamente en el desarrollo de modelos NIR para el análisis de forrajes. Sin embargo, se ha observado que hay escasos estudios que comparen las predicciones del valor nutritivo del forraje cuando se utilizan diferentes dispositivos NIR para escanear la base de datos de muestras. El propósito de este estudio fue predecir los componentes nutricionales de

pastos altoandinos utilizando algoritmos de procesamiento de imágenes RGB, multiespectrales y tecnología de infrarrojo cercano.

## II. MATERIALES Y METODOS:

### 2.1. Ubicación del área de estudio

El estudio se llevó a cabo en el Centro Experimental San Juan de la Estación Experimental Agraria Amazonas del INIA, la estación está ubicada en el Distrito de Chachapoyas, Provincia de Chachapoyas, Departamento de Amazonas, ubicada a 2446 m.snm de altitud (Figura 1).



**Figura 1.** Ubicación del área de estudio

Para el procesamiento de las muestras de las pasturas altoandinas se realizó en el laboratorio de Nutrición y Bromatología de Alimentos de la Universidad Nacional Toribio Rodríguez de Mendoza (UNTRM); mientras que para el procesamiento de

las imágenes RGB y multiespectrales obtenidas por los sensores en el vehículo aéreo no tripulado (RPAS) se procesaron en el laboratorio de Cambio Climático del Instituto Nacional de Innovación Agraria (INIA) en la Sede Central

## **2.2. Instalación y manejo de parcelas de investigación**

Se instalaron dos parcelas de investigación, una para *Lolium multiflorum* con un área total de 269.04 m<sup>2</sup> con 32 unidades experimentales, y otra para *Trifolium repens* con un área total de 234.35 m<sup>2</sup> con 24 unidades experimentales; cada unidad experimental se conformó por 2m de ancho x 3m de largo, con distancia entre unidades experimentales de 0.3 m, y una calle de acceso de 1m por el perímetro del área experimental.

El área fue preparada mediante labores culturales y mecánicas, el sistema de riego fue por aspersión que fue usado a manera de riego complementario. En cuanto a la fertilización para la instalación de las parcelas se utilizará fertilización orgánica (gallinaza) a todas las parcelas en la misma proporción, el cual se realizará en base al análisis de suelo. Para la siembra se empleará semilla botánica, a través del método “al boleó”.

Después de realizar el primer corte a los 90 días para asegurar el enraizamiento de la pastura, se realizará la fertilización para gramíneas utilizando bases nitrogenadas y para leguminosas utilizando bases de fosforo y potasio, y se inició con el conteo del tiempo de corte a la semana 5 y 6 de instalados el experimento, esto se hará de forma manual con la ayuda de una hoz. Las actividades de deshierbo se realizarán después de cada corte.

## **2.3.Parcelas instaladas**

Parcela de investigación 1: La muestra de estudio estará conformado por el pasto Rye grass (*Lolium multiflorum*), planta completa, comprendida por el tallo y hojas. Las muestras se obtuvieron de un área de 1 m<sup>2</sup>, seleccionado aleatoriamente dentro de las parcelas de investigación instaladas. En la presente investigación se utilizaron parcelas con dimensiones de 2m de ancho x 3m de largo. Para cada parcela se obtuvo 04 muestras diferentes, 01 muestra para análisis nutricional, 03 muestras para toma de firmas espectrales, donde para cada muestra se realizó 03 lecturas con el

dispositivo NIR y 1 vuelo por semana con sistema de aeronave pilotada remotamente (RPAS) para obtener imágenes de sensores RGB y multiespectrales. Este procedimiento se replicó tres veces en el tiempo, haciendo un total de 96 unidades experimentales y 24 vuelos en toda la fase experimental.

Parcela de Investigación 2: La muestra de estudio estuvo conformada por el pasto Trébol blanco (*Trifolium repens*), planta completa, comprendida por el tallo y hojas. Las muestras se obtendrán de un área de 1 m<sup>2</sup>, seleccionado aleatoriamente dentro de las parcelas de investigación instaladas. Se utilizarán parcelas con dimensiones de 2m de ancho x 3m de largo. Para cada parcela se obtendrá 04 muestras diferentes, 01 muestra para análisis nutricional, 03 muestras para toma de firmas espectrales, donde para cada muestra se realizará 03 lecturas con el dispositivo NIR y se realizará 01 vuelo por semana con sistema de aeronave pilotada remotamente (RPAS) para obtener imágenes de sensores RGB y multiespectrales. Este procedimiento se replicó tres veces en el tiempo, haciendo un total de 72 unidades experimentales y 24 vuelos en toda la fase experimental.

El diseño constó de un DBCA con cuatro tratamientos (Tabla n°1) y 4 repeticiones.

**Tabla 1.** Cuadro de tratamientos.

Tratamientos	Descripción.
T1	Trébol con aplicación de fertilización
T2	Trébol sin fertilización
T3	Rye Grass con fertilización
T4	Rye Grass sin fertilización

**Fuente:** Elaboración propia

#### **2.4. Análisis nutricional de pasturas**

La metodología a utilizar fue la indicada por los protocolos validados de la AOAC (1990) para el análisis nutricional químico de materias, se realizó siguiendo el protocolo AOAC 976.05 para proteína cruda; para el análisis de la fibra detergente neutro y ácida, se utilizó el protocolo de Van Soest et al. (1991); para digestibilidad se realizó mediante la metodología ANKOM del incubador Daisy II y para Cenizas se utilizó el protocolo de la AOAC 75(6) 1016-1022.

**a) Proteína cruda (PC).**

La determinación de la proteína bruta se realizó según el Método 928.08 de la metodología AOAC (2012). El procedimiento constó de tres fases: en la primera, se llevó a cabo la digestión de la muestra, colocando un gramo de ésta en un tubo de digestión junto con 5 gramos de catalizador y 12 ml de ácido sulfúrico. Esta fase duró aproximadamente 3 a 4 horas, hasta que el líquido resultante se enfrió y adquirió un color que variaba entre azul claro, verde o amarillo, dependiendo del catalizador utilizado. En la segunda fase, se realizó la destilación, añadiendo 25 ml de agua destilada al tubo con la muestra enfriada y destilando 50 ml de hidróxido de sodio utilizando un equipo destilador de nitrógeno (TECNAL TE-304, Brasil). El destilado se recogió en un matraz con 50 ml de una solución de ácido bórico al 4% y 10 ml de un indicador mixto, obteniendo un volumen total de destilado de 100 ml. Finalmente, en la tercera fase, se realizó la titulación con una solución de ácido clorhídrico (HCl) al 0.25N, utilizando una bureta digital de 25M (marca, modelo, país) y añadiendo el HCl gradualmente hasta observar un cambio de color. El volumen (en mL) de HCl utilizado en esta titulación se empleó para determinar el contenido de proteína cruda, comenzando con el cálculo del nitrógeno presente en la muestra.

$$\text{Nitrogeno (mg)} = 14 * \text{volumen Hcl (ml)} * \text{Normalidad Hcl}$$

A partir del nitrógeno kjeldahl se calculó el % de proteína de la muestra:

$$\% \text{ Proteína} = \frac{\text{Nitrógeno (mg)}}{\text{Peso muestra (mg)}} * \text{Factor oprotenico (6.25)}$$

**b) Fibra detergente neutra (FDN).**

Se define como a la fracción insoluble en detergente neutro, formada básicamente por celulosa, hemicelulosa y lignina. (Official Methods of Analysis. A.O.A.C. 15th Edition 1990).

Se realizó la determinación de FDN con el uso del sistema de extractor de fibras bajo el Official Methods of análisis AOAC 15th, conforme a la norma INTE-ISO/IEC 17025:2005 requisitos generales para la competencia de laboratorios y ensayos y calibración. (Official Methods of Analysis. A.O.A.C. 15th Edition 1990).

**Cálculos y expresión de resultados:**

$$\%FDN \text{ exactamente} = \frac{w2 - w1}{w} * 100$$

$$\%FDN \text{ (base a MS)} = \frac{w2 - w1}{w} * 100 * MS$$

$$\%FDN \text{ (base MS de la MO)} = \frac{w2 - w1}{w} * 100$$

**Donde:**

**W1**= Peso crisol sin humedad y vacío.

**W2**= Peso de residuo secado en estufa más fibra

**W**= Cantidad de la muestra utilizada en el análisis correspondiente.

**W3**= Peso del crisol más la fibra digerida calcinada

**MS**= Materia seca

**MO**= Materia Orgánica

**c) Fibra detergente ácida (FDA).**

Se refiere a los componentes menos solubles de la pared celular, principalmente celulosa y lignina, que son insolubles en detergente ácido. La determinación de FDA se realizó utilizando el sistema de extracción de fibras del método ANKOM Technology ADF Method 5, conforme a la norma INTE-ISO/IEC 17025:2005, que establece los requisitos generales para la competencia de laboratorios de ensayos y calibración.

**Cálculos y expresión de resultados:**

$$\%FDN \text{ exactamente} = \frac{w2 - w1}{w} * 100$$

$$\%FDN \text{ (base a MS)} = \frac{w2 - w1}{w} * 100 * MS$$

$$\%FDN \text{ (base MS de la MO)} = \frac{w2 - w1}{w} * 100$$

Donde:

**W1**= Peso crisol sin humedad y vacío

**W2**= Peso de residuo secado en estufa más fibra

**W**= Cantidad de la muestra utilizada en el análisis correspondiente

**W3**= Peso del crisol más la fibra digerida calcinada

**MS**= Materia seca

**MO**= Materia Orgánica

**d) Energía bruta (EB).**

La determinación de la energía bruta se llevó a cabo utilizando la metodología propuesta con una bomba calorimétrica (Parr 6200 Calorimeter, USA). El proceso implicó la combustión completa de la muestra, y el reporte de la energía bruta se basó en la cantidad de calor generado.

**e) Digestibilidad in vitro (DIV).**

Para determinar la digestibilidad, se siguieron meticulosamente los pasos del protocolo del equipo Ankom Technology, específicamente la incubadora Daisy II D20.

**Cálculos y expression de resultados:**

$$\%IVT (Base recibido) = 100 = \frac{w3 - (w1 * c1)}{w3} * 100$$

$$\%IVT (DM básica) = 100 = \frac{w3 - (w1 * c1)}{w3 * DM} * 100$$

Donde

W1= Peso de bolsa tarada

W1= Peso de muestra

W3= peso de la bolsa final después in vitro y el tratamiento secuencial ND

C1= corrección de la bolsa en blanco  $\frac{\text{peso final secado en horno}}{\text{peso original de la bolsa en blanco}}$

**2.5.Recolección y preparación de muestras de pasturas**

Se realizó de acuerdo con la metodología indicada por Sandoval et al. (2008), se recolectaron muestras en un área de 1 m<sup>2</sup> por cada tratamiento, se utilizó una oz para cortar el forraje a una elevación de 5 cm del suelo, las muestras serán pesadas y transportadas para después ser secadas a 60 °C por 48 horas, hasta obtención de un peso constante, luego serán molidas, envasadas y selladas en bolsas homogeneizadoras Ziploc plásticas para después ser escaneadas por el dispositivo de espectroscopia de infrarrojo cercano y ser analizadas mediante los métodos químicos

referenciales de: proteína cruda (PC), fibra detergente neutra (FDN), fibra detergente ácida (FDA), energía bruta (EB) y Digestibilidad in vitro (DIV).

## **2.6. Adquisición de Imágenes RGB y Multiespectrales.**

Para facilitar esta investigación se utilizó un Dron DJI Matrice 300 con RTK, en el cual se incorporaron los sensores RGB y Multiespectrales Sensores RedEdge-MX y RedEdge-MX blue al integrar dos cámaras de cinco bandas, la RedEdge-MX y la nueva RedEdge-MX Blue, el Sistema de cámara dual permite las aplicaciones más avanzadas de teledetección e investigación de vegetación. Las imágenes aéreas se adquirieron entre las 11:00 a.m. y las 2:00 p.m. pero siendo mejor al medio día, en condiciones de cielo despejado (sin nubes), para esto se distribuyeron cinco puntos de control terrestres (GPC) de 0.50 m<sup>2</sup> en blanco y negro alrededor de las dos parcelas de estudio, así mismo cada punto de control cuenta con coordenadas UTM, usando un GPS diferencial, esto garantiza una calibración geométrica adecuada. La misión de vuelo del RPAS, se planificarán sobre las parcelas de estudio utilizando el aplicativo del control inteligente, el DJI Pilot 2, con un traslape de 85% tanto en la lateral como en la frontal y una velocidad más baja posible configurada en el menú de la misma aplicación, también el RPAS se mantendrá en el aire 1s para minimizará el efecto de la vibración. Antes del vuelo se tomará una fotografía de un panel de reflectancia calibrado. El vuelo se realizará a una altura de 30m de las parcelas experimentales con un GCP de 2.03cm/pixel.

## **2.7. Procesamiento de imágenes RGB y Multiespectrales**

El procesamiento de las imágenes RGB y Multiespectrales se realizó con los algoritmos de procesamiento de los softwares Pix4dmapper 4.8.4 y ArcGIS 10.8.2. “Se llevará un flujo de trabajo fotogramétrico para todo el conjunto de data con el objetivo de determinar los parámetros de orientación exterior de la imagen e interior de la cámara, así como la nube de puntos 3D y los ortomosaicos” (Olivera, 2020). Las imágenes RGB arrojados por el RPAS (dron) se sintetizaron utilizando los índices de vegetación de la Tabla 2, así como las imágenes multiespectrales se sintetizaron utilizando la Tabla 3. Los índices de vegetación seleccionados son considerados debido a la literatura existente, así como su capacidad de estos para cubrir los rangos espectrales completos.

**Tabla 2.** Índices de vegetación calculados a partir de imágenes Red Green Blue. (Rojo-Verde-Azul), cada capa se dividirá por el valor medio de todas las bandas.

ÍNDICE DE VEGETACIÓN	FORMULA
Índice de diferencia verde rojo (GRDI)	$\frac{G - R}{G + R}$
Índice de Vegetación Verde Rojo Modificado (MGRVI)	$\frac{G^2 - R^2}{G^2 + R^2}$
Índice de Vegetación Rojo Verde Azul (RGBVI)	$\frac{(R^2 - (B * R))}{(R^2 + (B * R))}$
Índice azul verde normalizado (NGBI) o índice de proporción de pigmento vegetal (PPR)	$\frac{(G - B)}{(G + B)}$
Índice azul rojo normalizado (NRBI)	$\frac{(R - B)}{(R + B)}$
Índice de resistencia atmosférica visible (VARI)	$\frac{(G - R)}{(G + R - B)}$

Las imágenes se procesaron con el software de fotogrametría de Pix4Dmapper con la configuración predeterminada y la corrección radiométrica basada en imágenes de panel de referencia. Los mapas de reflectancia resultantes se georreferenciaron con los puntos de control terrestres en las 2 parcelas de estudio. Así mismo se hizo el procesamiento para obtener las firmas espectrales utilizando el software de ArcGIS. Para lograr una mayor precisión en la estimación de los componentes nutricionales de las pasturas de interés en esta investigación se considerará la composición florística, dentro de esta las malezas que pueden ser competencias para los forrajes para su desarrollo, que serán analizados con el software ArcGIS.

**Tabla 3.** Fórmulas y bandas de los índices de vegetación obtenidos con imágenes espectrales.

ÍNDICE DE VEGETACIÓN	FORMULA
Índice de vegetación de la razón del infrarrojo cercano y el rojo (RVI)	$\frac{(NIR)}{(R)}$
Índice de vegetación de diferencia normalizada (NDVI)	$\frac{(NIR - R)}{(NIR + R)}$
Índice de vegetación de diferencia normalizada verde (GNDVI)	$\frac{(NIR - G)}{(NIR + G)}$
Índice de vegetación de diferencia normalizada borde del rojo (RNDVI)	$\frac{NIR - RE}{NIR + RE}$

Índice de vegetación de suelo ajustado (SAVI)	$\frac{(NIR - R)(1 + L)}{(NIR + R + L)}$
Índice de vegetación mejorado (EVI)	$\frac{2,5 * (NIR - R)}{(NIR + 6 * R - 7,5B + 1)}$
Índice verde de clorofila (Clg)	$\frac{NIR}{G} - 1$
Índice borde del rojo de clorofila (Clrg)	$\frac{NIR}{RE} - 1$
Índice reflectante de planta senescente (PSRI)	$\frac{R - G}{NIR}$
Índice de la razón de clorofila normalizado (NCPI)	$\frac{(R - B)}{(R + B)}$

Donde, NIR=banda infrarrojo cercano; R=banda del rojo; G=banda del verde; B=banda del azul; RE=banda del borde del rojo y L es igual a 0,5.

Los modelos matemáticos a utilizados para relacionar las características fisiológicas y de crecimiento de las muestras de las pasturas de investigación, calculadas a partir de las imágenes multiespectrales obtenidas, presentaran la siguiente estructura.

$$Y_{ij} = \beta_0 + s(Ni) + e_{ij} \dots EC (01)$$

$$Y_{ij} = \beta_0 + s(Ri) + e_{ij} \dots EC (02)$$

$$Y_{ij} = \beta_0 + s(Gi) + e_{ij} \dots EC (03)$$

$$Y_{ij} = \beta_0 + s(Ci) + e_{ij} \dots EC (04)$$

$$Z_{ij} = \beta_0 + s(RIi) + e_{ij} \dots EC (05)$$

$$Z_{ij} = \beta_0 + s(CLi) + e_{ij} \dots EC (06)$$

$$W_{ij} = \beta_0 + s(RIi) + e_{ij} \dots EC (07)$$

$$V_{ij} = \beta_0 + s(RIi) + e_{ij} \dots EC (08)$$

Donde,  $Y_{ij}$  es la biomasa verde en  $g/m^2$ ,  $Z_{ij}$  es la PB en  $g/kg$ ;  $W_{ij}$  es la FDN en  $g/kg$ , ;  $V_{ij}$  es la FDA en  $g/kg$ ;  $\beta_0$  es el intercepto, (s) es la función suavizada de una variable; (N) es el NDVI; (R) es el RVI, (G) es el GNDVI; C es el Clg; RI es el RNDVI; (CI) es el Clrg y (e) el efecto residual.

## 2.8. Toma de Firmas espectrales

Las firmas espectrales se obtuvieron siguiendo la metodología descrita por Acosta et al. (2020) y Mejía et al. (2019). Primero, en el laboratorio, se colocaron 15g de la muestra molida en una celda de 4cm de diámetro que utiliza el dispositivo SpectraStar 2500XL, luego se escaneará utilizando el dispositivo NIR de sobremesa (SpectraStar 2500xl, con rango espectral de 1100-2500nm, con 1400 longitudes de onda y con un intervalo de longitud de onda de 1).

## **2.9. Análisis Proximal en laboratorio**

La metodología que se utilizó fue la indicada por los protocolos validados de la AOAC (1990) para el análisis nutricional químico de materias y se realizaron en el Laboratorio de nutrición animal y bromatología de Alimentos de la UNTRM, se utilizará el protocolo AOAC 925.05 para humedad, AOAC 976.05 para proteína cruda y AOAC 920.39 para extracto etéreo; para el análisis de la fibra detergente neutro y ácida, se utilizó el protocolo de Van Soest *et al.* (1991); para energía bruta se utilizó la metodología por calorimetría y el protocolo recomendado por el fabricante para el incubador Daisy II para determinar la digestibilidad *in vitro*.

## **2.10. Elaboración de base de datos**

Fancello *et al.* (2016), describe el proceso para construir y generar la base de datos para realizar el modelado y la validación, utilizando tanto los valores nutritivos de la química húmeda como los perfiles espectrales. Primero se determinó cada tratamiento a utilizar, luego se obtendrán los valores nutricionales de la química húmeda para cada tratamiento, y se determinarán los perfiles espectrales de cada tratamiento. Para cada matriz de tratamiento obtenido con dimensiones (6x72), en una muestra de fila, las columnas obtienen un perfil espectral de absorbancia, de las cuales se utilizaron para modelar (80% de los datos) y para llevar a cabo la validación (20% de los datos). Finalmente, se emplearon los conjuntos de datos de cada tratamiento para la construcción, validación y comparación de los modelos desarrollados.

## **2.11. Construcción del modelo multivariado de predicción**

Para generar el modelo de predicción fue necesario comparar las relaciones entre las firmas espectrales de absorción, para lo cual se aplicaron herramientas quimiométricas, como los componentes principales - PCA, regresión multilineal - MLR, regresión de mínimos cuadrados parciales - PLSR y redes neuronales artificiales - ANN. Estos modelos serán implementados utilizando secuencias de comandos para procesamiento de datos escrita en el software estadístico R: R Core Team (2016), lo cual nos permitirá: (a) calcular el espectro de reflectancia medio de cada muestra para cada dispositivo, (b) transformar y detectar los valores atípicos y (c) entrenamiento del modelo, validación cruzada y predicción de nuevas observaciones; en todos los casos se va a utilizar un conjunto de datos para el proceso de calibración y otro para el proceso de validación.

## 2.12. Análisis de datos

Para el análisis y procesamiento de los datos se empleó el software R Studio 4.3.2. Se utilizaron herramientas de machine learning mediante modelos predictivos para determinar la composición nutricional a partir de las firmas espectrales y los resultados del análisis proximal. Para la calibración del NDVI, se aplicaron modelos de regresión, seleccionando aquellos con el menor valor de raíz del error cuadrático medio (RMSE) y el coeficiente de determinación (R<sup>2</sup>) más cercano a 1, basándose en el índice de concordancia. El mejor modelo predictivo se eligió en función de los mejores estimadores (RMSE y R<sup>2</sup>) (Núñez-Barriopedro, 2020). Se realizaron pruebas de regresión lineal (LR), análisis de componentes principales (PCA) y comparaciones de medias entre la química húmeda referencial, las imágenes RGB y multiespectrales, y las firmas espectrales NIR.

### III. RESULTADOS

#### 3.1. Análisis Bromatológico de pastos altoandinos

El análisis bromatológico de pastos mostró para el contenido de proteína el tratamiento 1 reportó los mejores valores (Trébol con fertilización) con 25 % de proteína. Para el caso de Cenizas el tratamiento con mayor contenido fue el T3(Rye Grass con fertilización) y el menor el T2 (Trébol sin fertilización). Para el caso de % de FDN se reportaron valores altos de este parámetro con el Tratamiento 2 con 4. 11 (Trébol sin fertilización). Para el caso de % de FDA se observaron diferencias estadísticamente significativas entre los tratamientos, destacándose el Tratamiento de Trébol con fertilización reportó el valor superior con 27.1 y finalmente en el % de digestibilidad se reportó diferencias entre tratamientos con el mayor valor del tratamiento 1 (Trébol con fertilización) Tabla 4:

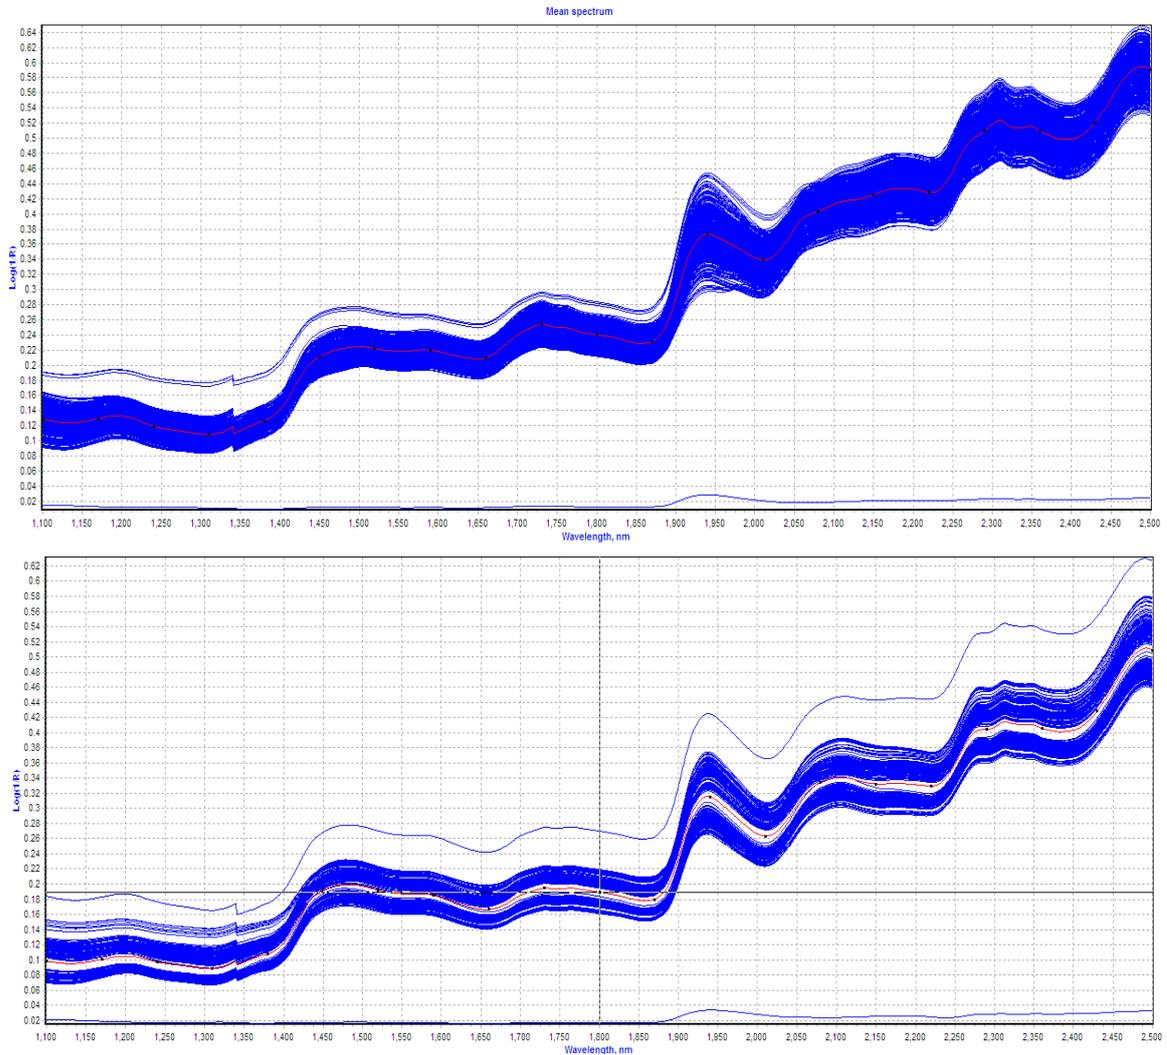
**Tabla 4.** Análisis bromatológico de pastos altoandinos (promedio y D.E).

T.	%PC p=0.0083	Ceniza p=0.5273	%FDN p=0.0079	%FDA p=0.4306	%DIV p=0.0086
T1	25.91 ± 1.21 c	8.33 ± 0.29 a	1.36 ± 1.36 ab	27.1 ± 2.32 a	80.35 ± 0.77 b
T2	25.47 ± 1.58 bc	7.99 ± 0.96 a	4.11 ± 4.11 a	24.61 ± 2.85 a	79.85 ± 0.13 b
T3	10.47 ± 1.26 ab	9.02 ± 0.87 a	1.61 ± 1.61 bc	24.96 ± 0.28 a	61.7 ± 1.92 a
T4	10.06 ± 1.42 a	8.98 ± 0.97 a	1.77 ± 1.77 c	26.73 ± 3.27 a	61.42 ± 1.48 a

D.E: Desviación estándar; T: tratamiento; letras diferentes en sentido vertical indican diferencias estadísticas significativas.

### 3.2. Firmas espectrales para pastos altoandinos

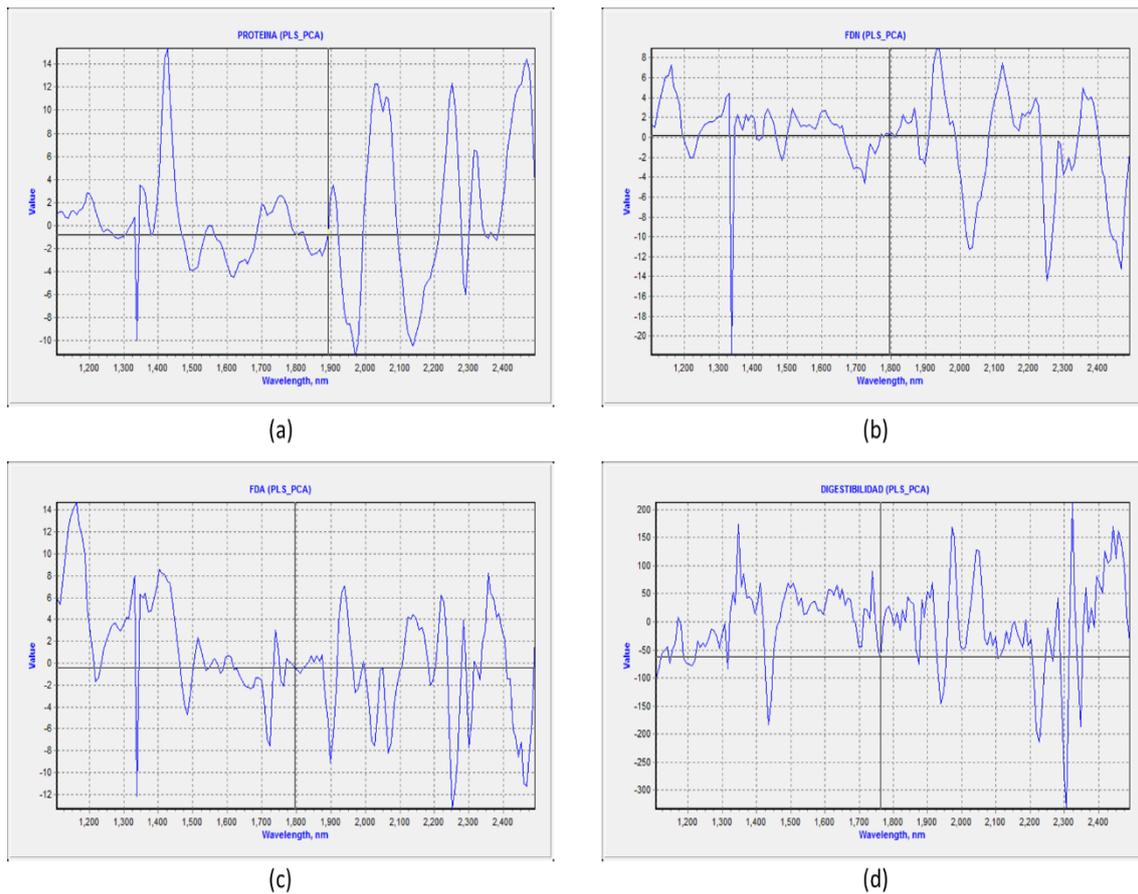
El perfil espectral construido con las firmas espectrales (absorbancia y longitud de onda) se encontró en el rango de 1100-2500 nm (Figura 2).



**Figura 2.** Perfil espectral de pastos altoandinos. Figura superior corresponde al cultivo de trébol y figura inferior corresponde al cultivo de Rye Grass.

### 3.3. Longitudes de ondas relevantes en trébol

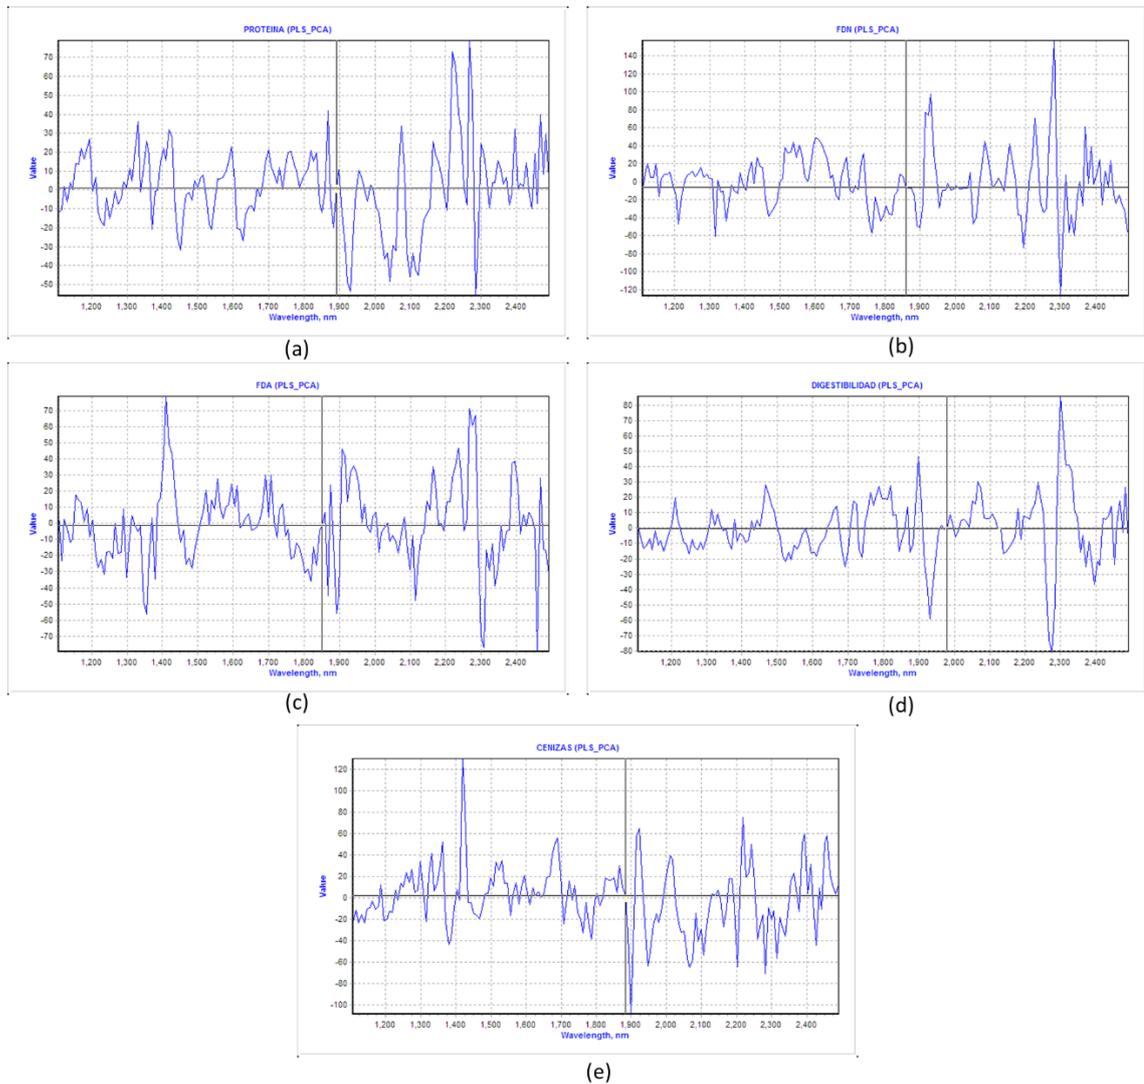
Para construir el modelo optimizado se distribuyeron las longitudes de onda relevantes a lo largo del rango evaluado (Figura 3). Se obtuvieron 20 longitudes de onda relevantes, estando para proteína cruda en el rango de 1425, 2025-2062, 2250, 2321 y 2470 nm, para fibra detergente neutra de 1168, 1330, 1925, 2125-2218 y 2357-2380 nm, para fibra detergente ácida de 1156, 1326-1402, 1928, 2124-2225 y 2353 nm, y para digestibilidad in vitro de 1350, 1975, 2045, 2324 y 2415-2455 nm.



**Figura 3.** Longitudes de onda relevantes de *Trifolium repens* para (a) Proteína cruda (b) Fibra detergente neutra (c) Fibra detergente ácida (d) Digestibilidad in vitro.

### 3.4. Longitudes de ondas relevantes en rye Grass

Para construir el modelo optimizado se distribuyeron las longitudes de onda relevantes a lo largo del rango evaluado (Figura 4). Se obtuvieron 23 longitudes de onda relevantes, estando para proteína cruda en el rango de 1328-1420, 1875, 2075, 2270-2223 y 2393-2468 nm, para fibra detergente neutra de 1416-1429, 1514-1600, 1910-1927, 2080-2275 y 2370-2386 nm, para fibra detergente ácida de 1416, 1905-1938, 2163-2280 y 2395 nm, para digestibilidad in vitro de 1900 y 2302 nm, y para cenizas de 1300-1358, 1420, 1687, 1925, 2014, 2215-2245y 2392-2453 nm.



**Figura 4.** Longitudes de onda relevantes de *Lolium multiflorum* para (a) Proteína cruda (b) Fibra detergente neutra (c) Fibra detergente ácida (d) Digestibilidad in vitro (e) Cenizas.

### 3.5. Modelos con PLSR y validación para trébol

Se generó un modelo de predicción, el cual fue validado, cuyos resultados se muestran en la Tabla 05. El modelo PLSR produjo resultados de característica aceptable con valores altos de  $R^2$ . En los valores nutricionales evaluados se obtuvo un  $R^2$  inferior a 0.90, pero mayor que 0.80, lo cual indica un  $R^2$  aceptable en el modelo PLSR. Los estadísticos, incluidos los errores estándar de calibración (SEC) y los valores de  $R^2$  para las ecuaciones de mejor ajuste obtenidas para cada uno de los constituyentes. Los valores de SEC oscilaron entre 1.013 para PC y 1.322 para DIV; los valores de  $R^2$  oscilaron entre 0.80 para FDN y 0.892 para DIV.

**Tabla 5.** Estadísticos para modelos de predicción de la composición nutricional del pasto trébol blanco (*Trifolium repens*) en base seca, región Amazonas, Perú.

Parámetro	PLSR					
	$R^2$	RMSE	SEC	RPD	RER	TM (a,b,c)
Proteína Cruda	0.854	0.075	1.013	2.348	14.008	1,5,5
Fibra Detergente Neutro	0.801	0.062	1.086	2.581	12.827	1,5,5
Fibra Detergente Ácida	0.825	0.017	1.032	2.560	12.684	1,5,5
Digestibilidad	0.892	0.063	1.322	5.498	16.293	1,5,5

PLSR: Partial Least Squares Regression;  $R^2$ : R-cuadrado; RMSE: Error cuadrático medio; RPD: Desviación residual predictiva; RER: Proporción de rango de datos con el error; TM: Tratamiento matemático; a: Derivada; b: Gap; c: Samooth Savitzky Golay

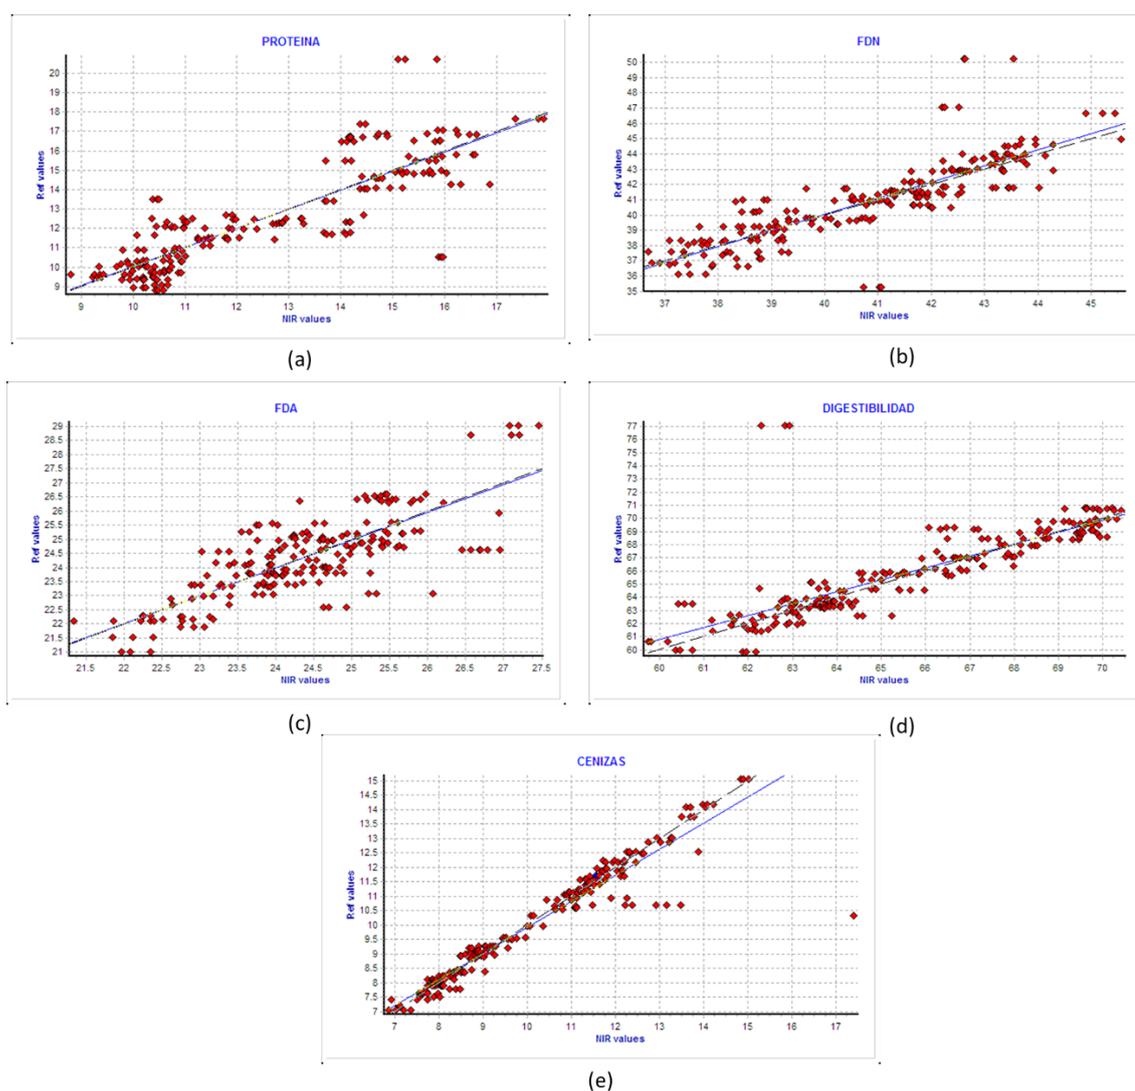
### 3.6. Modelos con PLSR y validación para Rye Grass

Se creó un modelo de predicción que fue validado, y cuyos resultados se presentan en la Tabla 06 y la Figura 5. El modelo PLSR generó resultados de calidad aceptable, con valores elevados de  $R^2$ . En DIV y Ce, se reportó un  $R^2$  superior a 0.90, mientras que para los demás valores nutricionales evaluados, el  $R^2$  fue inferior a 0.90 pero superior a 0.80, lo que sugiere un  $R^2$  aceptable en el modelo PLSR.

**Tabla 6.** Estadísticos para modelos de predicción de la composición nutricional del pasto rye grass (*Lolium multiflorum*) en base seca, región Amazonas, Perú.

Parámetro	PLSR				
	$R^2$	RMSE	RPD	RER	TM (a,b,c)
Proteína Cruda	0.804	0.023	3.563	12.254	1,8,8
Fibra Detergente Neutro	0.833	0.042	3.756	12.133	1,8,8
Fibra Detergente Ácida	0.854	0.026	3.160	14.263	1,8,8
Digestibilidad	0.922	0.037	3.300	12.129	1,8,8
Cenizas	0.985	0.055	3.841	15.374	1,8,8

PLSR: Partial Least Squares Regression;  $R^2$ : R-cuadrado; RMSE: Error cuadrático medio; RPD: Desviación residual predictiva; RER: Proporción de rango de datos con el error; TM: Tratamiento matemático; a: Derivada; b: Gap; c: Samooth Savitzky Golay



**Figura 5.** Correlación entre valores nutricionales y firmas espectrales de *Lolium multiflorum* para (a) Proteína cruda (b) Fibra detergente neutra (c) Fibra detergente ácida (d) Digestibilidad in vitro (e) Cenizas.

### 3.7. Análisis de imágenes Red-Green-Blue y multispectrales

Se realizó el análisis fotogramétrico de imágenes Red-Green-Blue y multispectral, permitiendo determinar índices vegetales que proveen información sobre el estado de los cultivos. En este estudio se utilizaron imágenes RGB e multispectrales de parcelas experimentales de pasto rye grass (*Lolium multiflorum*) y trébol blanco (*Trifolium repens*), tomadas con un RPAS y sensores instalados, para calcular los índices NDVI y NDRE.

El índice de vegetación de diferencia normalizada (NDVI, por sus siglas en inglés) es el más comúnmente empleado para evaluar la cantidad y el estado de la vegetación verde (Rouse et al., 1974). Se calcula utilizando las reflectancias en los canales del rojo y del infrarrojo cercano, de la siguiente manera:

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

Donde NIR es la reflectancia en el infrarrojo cercano y R en el rojo. Valores cercanos a 1 indican mucha vegetación verde, mientras que valores cercanos a 0 corresponden a suelos desnudos (Tucker, 1979).

Otro índice útil es el índice de erosión de diferencia normalizada (NDRE), el cual correlaciona positivamente con el contenido de clorofila y nitrógeno de la planta (Gitelson y Merzlyak, 1994). Se calcula de la siguiente forma:

$$\text{NDRE} = (\text{NIR} - \text{RedEdge}) / (\text{NIR} + \text{RedEdge})$$

Donde RedEdge es la reflectancia en el rojo lejano, entre 670-680 nm.

En este estudio, los valores de NDVI y NDRE obtenidos de las imágenes permitieron monitorear y evaluar el estado del cultivo a través de sus diferentes etapas fenológicas. Además, permitió comparar el desarrollo y estado nutricional del pasto rye grass y el trébol blanco a lo largo del tiempo desde su instalación, corte de homogenización y cortes anuales.

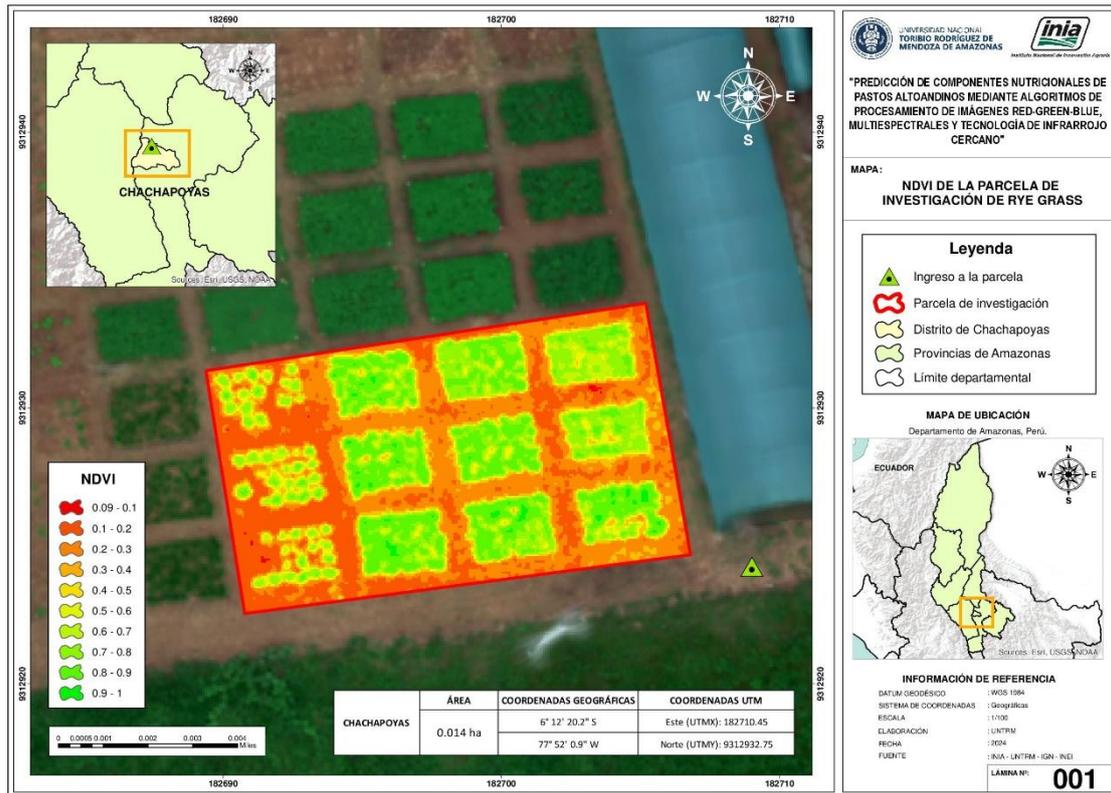


Figura 6. Análisis de parcelas de *Lolium multiflorum* para índices de vegetación NDVI.

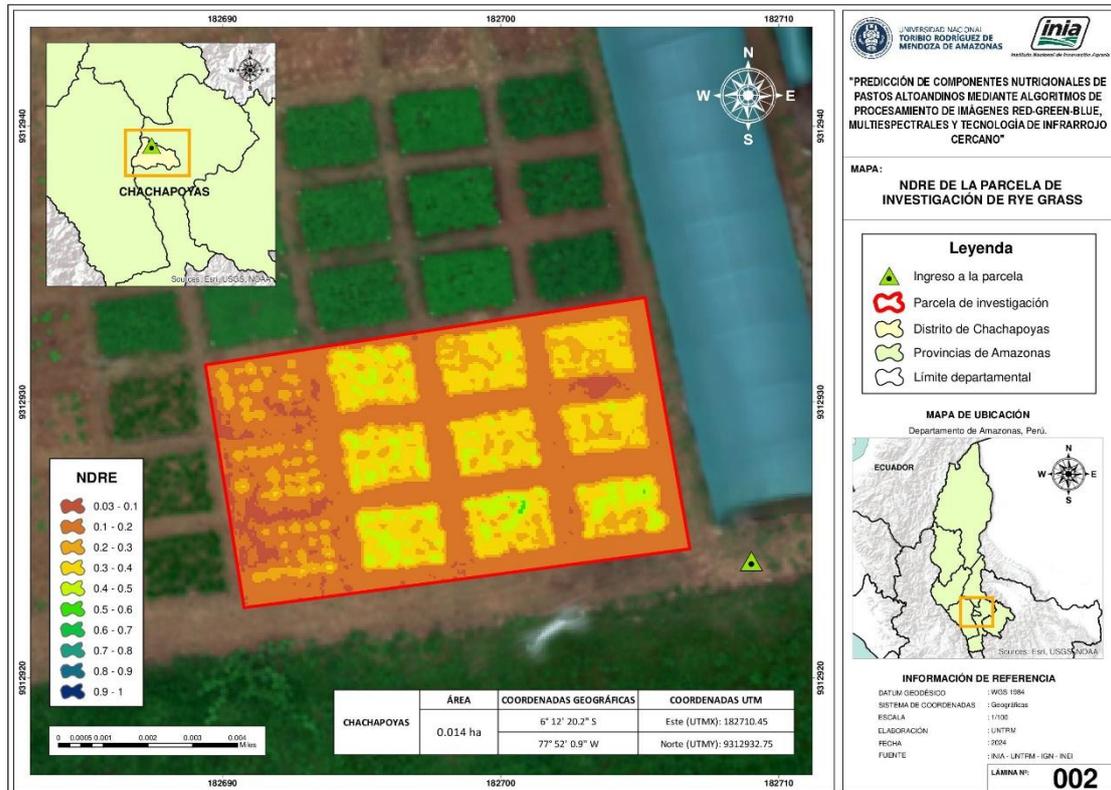


Figura 7. Análisis de parcelas de *Lolium multiflorum* para índices de vegetación NDRE.

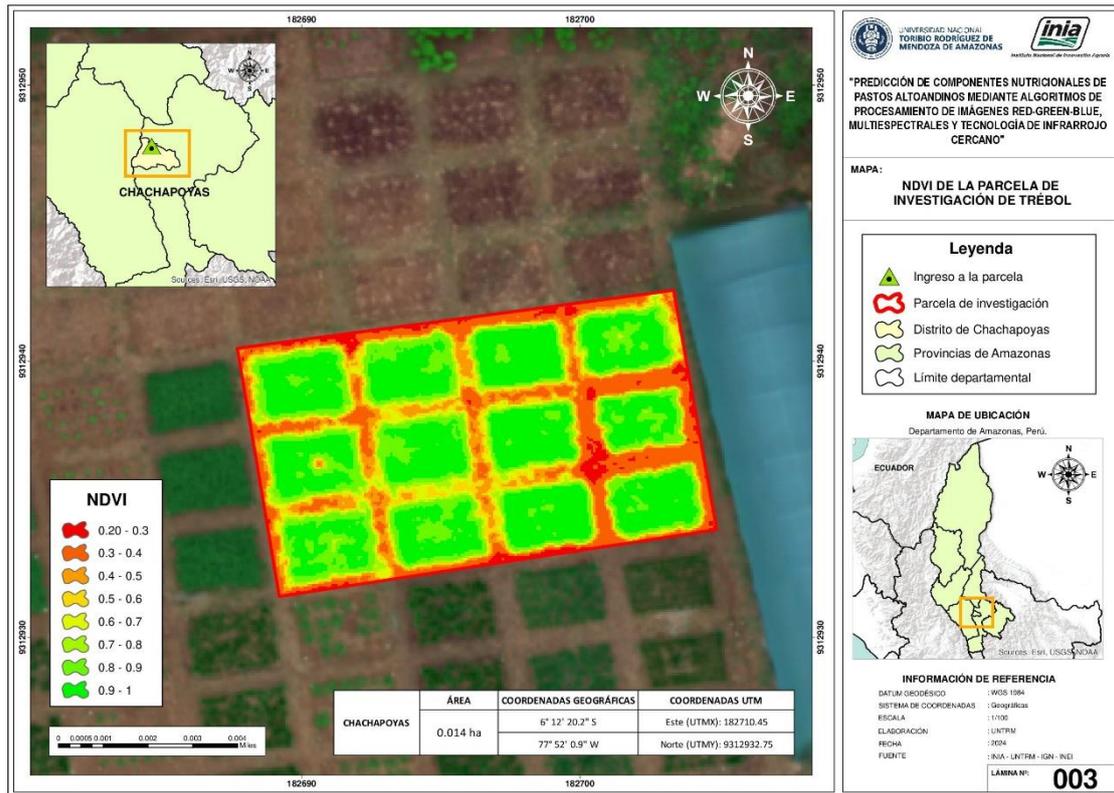


Figura 8. Análisis de parcelas de *Trifolium repens* para índices de vegetación NDVI.

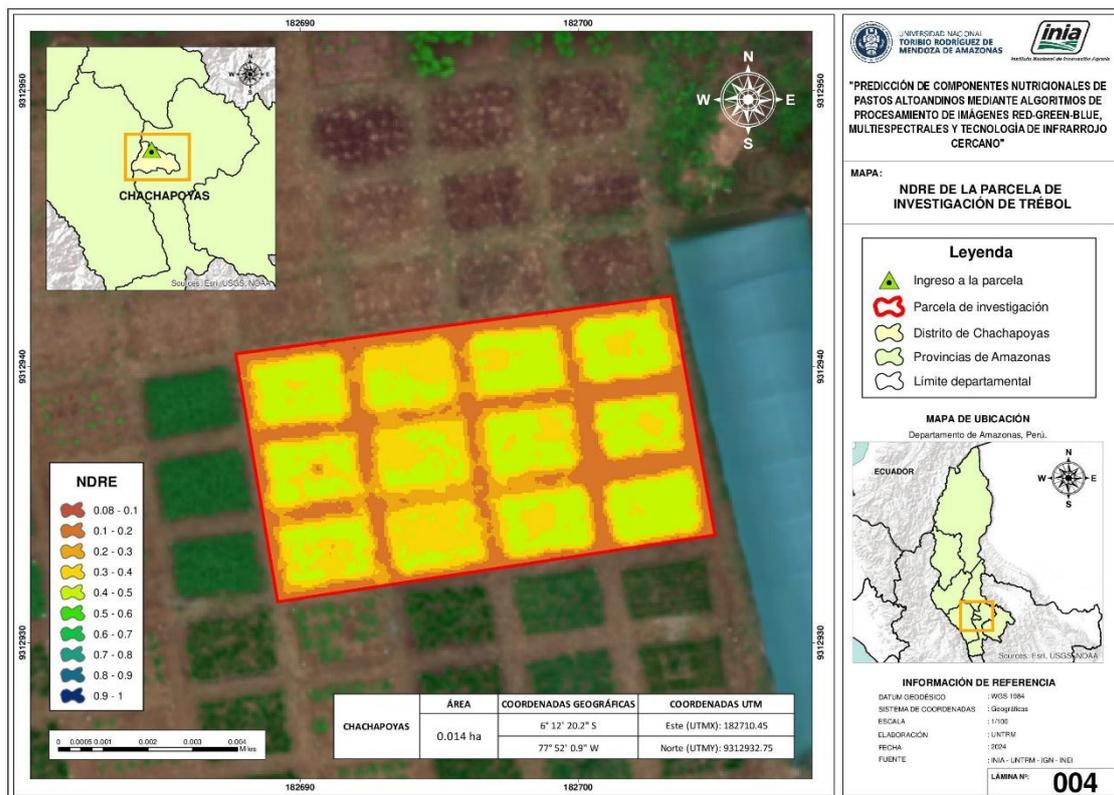


Figura 9. Análisis de parcelas de *Trifolium repens* para índices de vegetación NDRE.

## **IV. DISCUSIÓN**

### **4.1. Análisis bromatológico de pastos**

El análisis de componentes nutricionales reporta resultados con elevada variabilidad, debido al estado fenológico de las muestras colectadas en diferentes frecuencias de corte, lo que favoreció a la generación de los modelos de calibración NIR. El porcentaje de proteína obtenidos con trébol fueron superiores que los reportados por Estupiñan et al. (2021), Bojórquez et al. (2015) y Fernández (2002) con rangos de PC entre 15.28 a 22.70 %, Los valores obtenidos para rye Grass fueron inferiores que los reportados en los estudios de Bezada et al., 2017; Zamudio, 2016; Jaimes et al., 2015; Molano, 2012; Aguilar et al., 2009 y Soto et al. 2005, para valores de proteína con 19.02%, 15.87%, 19.04%, 16.03%, 20.6% y 17.8% respectivamente. Los valores de cenizas los valores obtenidos para ambos cultivos fueron inferiores a lo reportado en el trabajo de Bezada et al. (2017) con 12.41 y similares a lo reportado por Zamudio (2016) y Soto et al. (2005) con 10.84 y 10.0%, y superior a lo mencionado por encontrados por Jaimes et al. (2015) con 9.53%.

Con respecto a fibra detergente neutra para trébol y rye Grass los valores obtenidos fueron inferiores a lo obtenido por Nordheim et al. (2007); Estupiñan et al. (2021); Bezada et al. (2017) y Molano (2012) con 45.00%, 33.52%; 60.34% y 57.82% respectivamente.

Para la variable FDA para trébol y rye grass los resultados reportados son similares a lo reportado por Nordheim et al. (2007) con 25.31%, a los resultados de Berardo (1997) con 24.2% y Molano (2012) con 21.14%. Finalmente, el porcentaje de DIV los resultados obtenidos en la presente investigación fueron inferiores a lo mencionado por Oliva (2015) con 91.8% y Molano (2012) con 56.95%.

### **4.2. Longitudes de ondas relevantes**

Los resultados encontrados para trébol concuerdan con Estupiñan et al. (2021); Acosta et al. (2020); Nordheim et al. (2007) y Berardo (1997), que mencionan que para cada punto alto en la línea de onda va expresar la diferencia en los valores absorción y reflectancia, lo que va indicar un posible componente nutritivo dentro del perfil espectral.

Así mismo para las longitudes de onda encontrados para el cultivo de rye Grass concuerdan con Acosta et al. (2020), Bezada et al. (2017), Zamudio (2016), Sandoval et al. (2008) y Osborne (2006), quienes señalan que cada pico de longitud de onda corresponderá a una banda de absorción distinta, lo que sugiere la presencia de un componente nutricional diferente en el perfil espectral.

#### **4.3. Modelos con PLSR y validación**

Para el caso del trebol las pequeñas diferencias obtenidas utilizando el conjunto de datos de predicción indican que las medias previstas y reales no difieren sustancialmente, como sucede a veces incluso con valores aceptables de  $R^2$  y SEC. La precisión con la que NIRS predijo los análisis de laboratorio concuerda con los resultados obtenidos por otros autores como Estupiñan et al. (2021); Acosta et al. (2020); Nordheim et al. (2007) y Berardo (1997). La evaluación de las ecuaciones de calibración frente a un conjunto de muestras reveló valores de error estándar de predicción (SEC) que oscilaron entre 1.01 para proteína y 1.32 para digestibilidad. Estos fueron casi idénticos a los informados para el conjunto de calibración, pero inferiores a los encontrados por Estupiñan et al. (2021) y Berardo (1997). Los valores de  $R^2$  oscilaron entre 0,801 para FDN y 0.892 para DIV.

No se encontró un sesgo significativo con ninguno de los conjuntos de datos, ni las líneas de mejor ajuste fueron significativamente diferentes de la línea de acuerdo perfecto; estos datos se presentan de forma gráfica en la Figura 2, que sugiere que existen diferentes subpoblaciones dentro del conjunto de datos de validación para PC, FDN, FDA y DIV. Las otras subpoblaciones que se pueden identificar en los datos de concentraciones de PC, FDN, FDA y DIV podrían ser el resultado de las diferencias en la fecha de corte, los cultivares y las condiciones ambientales, así como las diferencias en las proporciones de las partes de la planta.

La composición media del *Trifolium repens* predicha por NIR arrojó resultados similares a los producidos por los análisis químicos para concentraciones de PC, FDN, FDA y DIV.

Los valores de SEP fueron similares o ligeramente mayores que los valores de SEL en este estudio. Esto es esperado, ya que cada valor de SEL es un componente del valor de SEP correspondiente. La estrecha concordancia entre el NIRS y los análisis químicos se debe probablemente sobre todo a la forma física homogénea de los

materiales utilizados en este estudio. Por ejemplo, se controló estrictamente el tamaño de partícula de las muestras, que puede tener un efecto importante en la estimación de la composición química y, por lo tanto, en los valores SEP.

Los valores de PC, FDN, FDA y DIV predichos por NIR estaban altamente correlacionados ( $R^2$  superiores a 0.8) con los valores proporcionados por los métodos AOAC. Esto demuestra que NIR se puede emplear como una herramienta para analizar un gran número de muestras. El éxito del análisis NIRS de forrajes depende casi por completo de la confiabilidad de los datos de calibración primarios. Aunque se observaron buenas predicciones para los resultados químicos para diferentes ubicaciones geográficas, es posible que sea necesario investigar más a fondo los efectos estacionales para evaluar la universalidad de las ecuaciones NIR (Berardo, 1997). Cuando se compara con los análisis de laboratorio convencionales, NIR parece ser una técnica alternativa atractiva debido a su rapidez, simplicidad, seguridad y bajos costos operativos. Esto es de particular importancia en los programas de nutrición y alimentación al pastoreo en los que se debe analizar el valor nutricional para formular raciones equilibradas.

Para el caso de rye Grass los resultados fueron parecidos a los generados por Acosta et al (2020), que analizaron muestras de pastos gramíneas en el rango que oscila entre los 1100 a 2500 nm y utilizando el modelo PLSR obteniendo un  $R^2$  de 0.99 para PC, 0.90 para FDN, 0.84 para FDA y 0.99 para DIV, con valores RPD y RER mayores a 3 y superiores a los obtenidos en el trabajo; Bezada et al. (2017), estudiaron el pasto rye grass mediante modelos PLSR usando NIR con rangos de onda de 400-2500 nm, con valores de  $R^2$  para PC, FDN y cenizas de 0.96, 0.90 y 0.90.

También Zamudio (2016) utilizó modelos PLSR para predecir valores nutricionales, con valores de  $R^2$  de 0.96 para Proteína, 0.90 para las fibras y 0.95 en cenizas. De la misma manera, Molano (2012) también utilizó modelos PLSR obteniendo índices de  $R^2$  para Proteína de 0.83, para FDN de 0.74, para FDA de 0.52 y para DIV de 0.85. Las diferencias de los valores obtenidos entre estudios, podrían ser a causa de los diferentes equipos utilizados para el escaneo de las muestras, así como al número de muestras utilizadas en cada análisis.

#### **4.4. Modelos de NDVI y NDRE**

Los resultados del análisis multiespectral de imágenes muestran diferencias en los valores de NDVI y NDRE entre las parcelas de pasto rye grass y trébol.

En las imágenes tomadas, el promedio de NDVI fue de 0.84 ( $\pm 0.05$ ) para la parcela de rye grass, indicando un buen desarrollo de biomasa verde. Por otro lado, el trébol registró un NDVI promedio de 0.78 ( $\pm 0.03$ ), lo cual sugiere una cantidad menor de clorofila activa (Gitelson & Merzlyak, 1994). Esta diferencia puede deberse a que el rye grass es una gramínea de ciclo otoño-invierno, por lo que se encuentra en pleno crecimiento a inicios de noviembre, mientras que el trébol es una leguminosa que entra en senescencia más temprano.

Los valores de NDRE también mostraron divergencias entre los cultivos, con un promedio de 0.73 ( $\pm 0.04$ ) para el rye grass y de 0.64 ( $\pm 0.03$ ) para el trébol. La mayor absorción en el infrarrojo cercano del pasto, indicada por mayores valores de NDRE, podría estar asociada a su contenido más elevado de clorofila, nitrógeno y proteína (Gitelson & Merzlyak, 1994; Clevers & Kooistra, 2012).

Los análisis espacio-temporales mediante índices vegetales como NDVI y NDRE permiten discriminar diferencias en la actividad fotosintética y estado nutricional de especies forrajeras. En este estudio, dichos índices calculados a partir de imágenes multiespectrales demostraron mayores niveles de biomasa verde y nutrición nitrogenada en parcelas de rye grass, en comparación con trébol, durante el período de muestreo.

#### **V. CONCLUSIONES**

En este estudio, se logró evaluar los componentes nutricionales. Se encontró que el tratamiento 1, que consistió en trébol con fertilización, mostró los mejores valores para el contenido de proteína, alcanzando un 25%. En cuanto al contenido de cenizas, el tratamiento con mayor concentración fue el T3 (Rye Grass con fertilización), mientras que el menor fue el T2 (Trébol sin fertilización). Para el porcentaje de fibra detergente neutro (% FDN), se observaron valores elevados en el Tratamiento 2, que incluyó trébol sin fertilización, alcanzando un 4.11%. Respecto al porcentaje de fibra detergente ácida (% FDA), se identificaron diferencias estadísticamente significativas

entre los tratamientos, destacándose el tratamiento con trébol y fertilización, que presentó un valor superior del 27.1%. Finalmente, en cuanto al porcentaje de digestibilidad, se observaron diferencias notables entre los tratamientos, destacando el tratamiento 1 (trébol con fertilización) el que mostró el mayor valor, superando el 80%.

En esta investigación, se utilizaron los índices NDVI y NDRE calculados a partir de imágenes RGB y multiespectrales para monitorear el progreso de los cultivos a través de distintas etapas fenológicas. Asimismo, se emplearon para comparar el crecimiento y estado nutricional del rye grass y el trébol blanco desde la siembra inicial hasta los cortes de homogenización y anuales.

El modelo NIR-PLSR generados en este estudio puede predecir la composición nutricional de proteína cruda, fibra detergente neutra y ácida y digestibilidad in vitro con valores de ajuste para correlación R<sup>2</sup> superiores al 0.80. La correlación que existe entre los valores PC, FDN, FDA, DIV y Ceniza calculados por espectroscopia del infrarrojo cercano, son altos.

## **VI. RECOMENDACIONES:**

Se sugiere para investigaciones futuras capturar imágenes aéreas preferiblemente al mediodía, en condiciones de cielo despejado sin presencia de precipitación y con un ángulo de visión de 90 grados. Es recomendable mantener un traslape del 85% tanto lateral como frontalmente y utilizar una velocidad adecuada para condiciones agrícolas. La altura promedio de captura de muestras debería ser de 30 metros, con un tamaño de píxel de 2 cm/píxel.

## **VII. REFERENCIAS BIBLIOGRÁFICAS:**

- [AOAC] Association of Official Analytical Chemists. 1990. Official Methods of Analysis. 15th ed. Vol 1. Washington, USA.
- Acosta, J.J., Castillo, M.S., & Hodge, G.R. (2020). Comparison of benchtop and handheld near-infrared spectroscopy devices to determine forage nutritive value. *Crop Science*. 2020;1–13. <https://doi.org/10.1002/csc2.20264>

- Aguilar OX, Moreno BM, Pabón ML, Carulla JE. 2009. Effect of kikuyo (*Pennisetum clandestinum*) or ryegrass (*Lolium hybridum*) intake on conjugated linoleic acid concentration and fatty acids composition of milk fat. *Livestock Res Rural Develop* 21(4). [Internet]. Disponible en: <http://www.lrrd.org/lrrd21/4/agu21049.htm>
- Asekova S, Han SI, Choi HJ, Park SJ, Shin DH, Kwon CH, Lee JD. 2016. Determination of forage quality by near-infrared reflectance spectroscopy in soybean. *Turk J Agric For* 40: 45-52. doi: 10.3906/tar-1407-33.
- Bekewe, P.E., Castillo, M.S., Acosta, J.J., & Rivera, R. (2019). Defoliation management effects on nutritive value of 'Performer' switchgrass. *Crop Science*, 60, 1682–1689. <https://doi.org/10.1002/csc2.20036>
- Berardo, N. (1997). Prediction of the chemical composition of white clover by near-infrared reflectance spectroscopy. Instituto Sperimentale Colture Foraggere, Bergamo, Italy.
- Bezada, S., Arbaiza, T., Carcelén, F., San Martín, F., López, C., Rojas, J., . . . Veléz, V. (Julio de 2017). Predicción de la Composición Química y Fibra Detergente Neutro de Rye Grass Italiano (*Lolium multiflorum* Lam) mediante Espectroscopía de Reflectancia en Infrarrojo Cercano (NIRS). *Revista de Investigaciones Veterinarias del Perú*. Obtenido de <http://dx.doi.org/10.15381/rivep.v28i3.13357>
- Bojórquez C, Rojas J, Ordóñez J. 2015. Pastos cultivados en el valle del Mantaro. Lima, Perú: Fondo Editorial UNMSM. 147 p.
- Burns, J. C., Fisher, D. S., & Rottinghaus, G. E. (2006). Grazing influences on mass, nutritive value, and persistence of stockpiled Jesup tall fescue without and with novel and wild-type fungal endophytes. *Crop Science*, 46, 1898–1912. <https://doi.org/10.2135/cropsci2005.09-0327>
- Clevers, J. G., & Kooistra, L. (2012). Using hyperspectral remote sensing data for retrieving canopy chlorophyll and nitrogen content. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 5(2), 574-583.
- Estupiñam, C., Carcelén, F., Hidalgo, V., Rojas, D., Vera, O., López, S., & Bezada, S. (2021). Aplicación de la espectroscopía del infrarrojo cercano – NIRS – para determinar el valor nutritivo de variedades de alfalfa (*Medicago sativo* L) y trebol rojo (*Trifolium pratense* L). *Rev Inv Vet Perú* 2021; 32(1): e19491. Obtenido de <http://dx.doi.org/10.15381/rivep.v32i1.19491>
- Fancello F., Petretto G.L., Zara S., Sanna M.L., Addis R., Maldini M., Foddai, M., Rourke J.P., Chessa M. and Pintore, G. (2016). Chemical characterization, antioxidant capacity and antimicrobial activity against food related microorganisms of Citrus limon var. pompia leaf essential oil. *LWT - Food Sci Technol.*, 69, (2016) 579–585.

- Fernández H. 2002. Composición de alimentos para rumiantes. Argentina: EEA INTA Balcarce. 300 p.
- Gitelson, A. A., & Merzlyak, M. N. (1994). Spectral reflectance changes associated with autumn senescence of *Aesculus hippocastanum* L. and *Acer platanoides* L. leaves. Spectral features and relation to chlorophyll estimation. *Journal of Plant Physiology*, 143(3), 286-292.
- Jaimés LJ, Cerón JM, Correa HJ. 2015. Efecto de la época del año y la etapa de lactancia sobre el consumo alimenticio de vacas Holstein pastoreando kikuyo (*Cenchrus clandestinus*) en Colombia. *Livestock Res Rural Develop* 27(12). [Internet]. Disponible en: <http://www.lrrd.org/lrrd27/12/jaim27244.html>
- L.A. Hernández-Sánchez, G. O.-T.-V.-M. (2023). *Uso de Vehículos Aéreos no Tripulados para aplicaciones de Agricultura de Precisión*. Guadalajara, México, 2023: AMAT EDITORIAL.
- Luis Alberto Sandoval-Mejía, F. J.-U.-N. (2008). *PREDICCIÓN NUTRICIONAL PARA PASTOS TROPICALES POR ESPECTROSCOPÍA DE REFLECTANCIA EN EL INFRARROJO CERCANO*. Morazán, Honduras.: Escuela Agrícola Panamericana.
- Mejía, F., Yoplac, I., Bernal, W., & Castro, W. (2019). Evaluación de modelos de predicción de composición química y energía bruta de kikuyo (*Pennisetum clandestinum*) usando espectroscopía en infrarrojo cercano (NIRS). *Rev Inv Vet Perú* 2019; 30(3): 1068-1076. Obtenido de <http://dx.doi.org/10.15381/rivep.v30i3.16598>
- Molano ML, Cortés ML, Ávila P, Martens SD, Muñoz S. 2016. Ecuaciones de calibración en espectroscopía de reflectancia en el infrarrojo cercano (NIRS) para predicción de parámetros nutritivos en forrajes tropicales. *Forrajes Tropicales* 4: 139-145. doi: 10.17138/TGFT(4)139-145.
- Nordheim H, Volden H, Fystro G, Lunnan T. 2007. Prediction of in situ degradation characteristics of neutral detergent fibre (aNDF) in temperate grasses and red clover using nearinfrared reflectance spectroscopy (NIRS). *Anim Feed Sci Tech* 139: 92- 108. doi: 10.1016/j.anifeedsci.2006.11.024.
- Núñez-Barriopedro, E., Sanz-Gómez, Y. y Ravina-Ripoll, R. (2020). Los videojuegos en la educación: beneficios y perjuicios. *Revista Electrónica Educare*, vol. 24, núm. 2. <https://www.redalyc.org/jatsRepo/1941/194163269012/index.html>
- Oliva M, Rojas D, Morales A, Oliva C, Oliva M. 2015. Contenido nutricional, digestibilidad y rendimiento de biomasa de pastos nativos que predominan en las cuencas ganaderas de Molinopampa, Pomacochas y Leymebamba, Amazonas, Perú. *Scientia Agropec* 6: 211-215. doi: 10.17268/sci.agropecu.2015.03.07
- Olivera, J. K. (2020). *Machine Learning Estimators For The Quantity And Quality Of Grass Swards Used For Silage Production Using Drone-Based Imaging*

Spectrometry And Photogrammetry. Finland: Finnish Geospatial Research Intitute In National Land Survey Of Finland (Fgi).

Osborne BG. 2006. Near-infrared spectroscopy in food analysis. In: Encyclopedia of analytical chemistry. John Wiley & Sons. p 1-14. doi: 10.1002/9780470027318.a1018

Pérez, Z. (2006). Importancia de conocer la calidad de los pastos. CETAPAR. Sección Producción Animal. Colombia.

R Core Team. (2016). R: A language and environment for statistical computing. Vienna, Austria: R Foundation for Statistical Comput-ing. Obtenido de [www.R-project.org/](http://www.R-project.org/)

Rouse, J. W., Haas, R. H., Schell, J. A., & Deering, D. W. (1974). Monitoring vegetation systems in the Great Plains with ERTS. NASA special publication, 351, 309.

Rodríguez, D. C. (2018). Use of free geographical information systems for the protection of the environment. Case study: raster map management with climate data. Ecuador: Universidad y Sociedad de Ecuador.

Sandoval LA, Bueso FJ, Vélez M. 2008. Predicción nutricional para pastos tropicales por espectroscopía de reflectancia en el infrarrojo cercano. *Agronomía Mesoamericana* 19: 221-225. doi: 10.15517/AM.V19I2.5003

Shenk, J. S., & Westerhaus, M. O. (1991). Population definition, sample selection, and calibration procedures for near infrared reflectance spectroscopy. *Crop Science*,31,469\_474.https://doi.org/10.2135/cropsci1991.0011183x003100020049x

Tucker, C. J. (1979). Red and photographic infrared linear combinations for monitoring vegetation. *Remote sensing of Environment*, 8(2), 127-150.

Van Soest, P.J.; Robertson J.B. and Lewis B.A. (1991). Methos for dietary fiber, neutral detergent fiber, and nonstarch polysaccharides in relation to animal nutrition. *Dayri Science*. Cornell University, Department of Animal Science and Division of Nutritional Sciences, Ithaca, NY.

Zamudio, B. Z. (2016). Predicción de la composición química de Rye grass mediante el uso de espectroscopia de reflectancia en el infrarrojo cercano (NIRS). Universidad Nacional Mayor de San Marcos. Lima: E.A.P. de Medicina Veterinaria.

## **VIII. ANEXOS:**

**ANEXO 01**

**PARCELA DEMOSTRATIVA RAY GRASS**



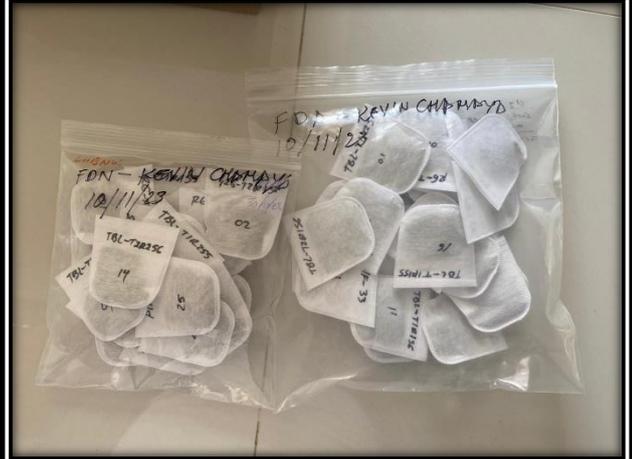
**ANEXO 02**

**PARCELA DEMOSTRATIVA DE TREBOL.**



## ANEXO 03

### PREPARACIÓN DE LAS MUESTRAS



## ANEXO 04

### ANÁLISIS BROMATOLÓGICO DE PASTOS ALTOANDINOS



## ANEXO 05

### ANÁLISIS NIR DE PASTOS ALTOANDINOS

