

Universidad de Costa Rica  
Facultad de Ingeniería  
Escuela de Ingeniería de Biosistemas

Generación de modelos de composición bromatológica para el forraje  
Estrella Africana (*Cynodon nlemfuensis*) ubicado en la Estación  
Experimental Alfredo Volio Mata (EEAVM) de la Universidad de Costa  
Rica, por medio de espectroscopía de campo

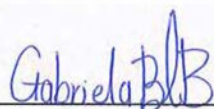
Trabajo Final de Graduación para optar por el grado académico de  
Licenciatura en Ingeniería Agrícola y de Biosistemas

María Gabriela Blanco Barrientos

Ciudad Universitaria Rodrigo Facio  
San José, Costa Rica  
Febrero, 2024

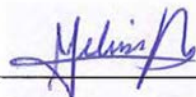
## Aprobación

Trabajo Final de Graduación bajo modalidad de tesis, sometido a revisión por la Comisión de Trabajos Finales de Graduación de la Escuela de Ingeniería Agrícola y de Biosistemas de la Facultad de Ingeniería de la Universidad de Costa Rica, como requisito para optar por el grado de Licenciatura en Ingeniería Agrícola y de Biosistemas.



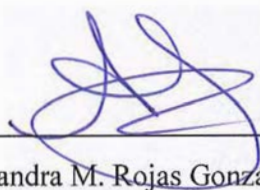
María Gabriela Blanco Barrientos

Candidata



Inga. M. Melissa Rojas Downing, Ph.D.

Directora, Comité Asesor



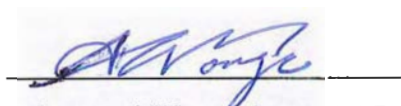
Inga. Alejandra M. Rojas González, Ph.D.

Comité Asesor



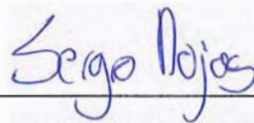
Ing. Jorge A. Elizondo Salazar, Ph.D.

Comité Asesor



Inga. Anayansi Wong Monge, M.Sc.

Miembro, Tribunal Examinador



Ing. Sergio Rojas Montero, M.Sc.

Miembro, Tribunal Examinador

## Dedicatoria

*A Dios, a mi familia.*

## Agradecimiento

*A mi mamá, mi papá, mis dos hermanas y mi novio, por estar siempre conmigo apoyándome en la universidad y darme amor por el campo.*

*Al comité asesor de esta tesis, directora Melissa Rojas y lectores, Alejandra Rojas y Jorge Elizondo, por la paciencia, apoyo y seguimiento a lo largo del proceso.*

*A la Estación Experimental Alfredo Volio Mata, por permitir el desarrollo del proyecto de investigación en sus instalaciones.*

*Al CIRAD, por proveer capacitación y soporte en la modelación con espectroscopía de infrarrojo cercano.*

*A mis amigas Alison y Jocelyn por ser un apoyo en los últimos años de universidad y en el proceso de tesis.*

*A la Escuela de Ingeniería de Biosistemas por el aprendizaje brindado.*

*A la Universidad de Costa Rica por la oportunidad de ser parte de mi crecimiento personal e intelectual.*

## Resumen

Actualmente las pruebas de calidad de forraje se realizan con química húmeda o con espectrometría en laboratorio, requieren de muestras destructivas y mayor tiempo para procesarse. La teledetección con sensores hiperespectrales aplicada al monitoreo del forraje, es una tecnología innovadora que permite mejorar la producción ganadera, ya que se obtienen resultados en tiempo real y a menor costo. Este estudio genera una línea base de investigación que tiene como objetivo estimar los parámetros de calidad del forraje estrella africana (*Cynodon nlemfuensis*), por medio de modelos generados utilizando teledetección en campo con datos hiperespectrales. Los datos hiperespectrales y auxiliares fueron tomados en dos parcelas experimentales con manejo de corte y de pastoreo, siendo estas las variables independientes, en la Estación Experimental Alfredo Volio Mata (EEAVM) de la Universidad de Costa Rica, con un enfoque multitemporal, durante los meses de junio a septiembre del 2022. Las variables dependientes (datos auxiliares) son la altura, biomasa seca y los cuatro parámetros de calidad obtenidos con química húmeda en el laboratorio (materia seca (MS), proteína cruda (PC), fibra detergente neutro (FDN) y fibra detergente ácido (FDA)). También, se tomaron datos climáticos como complementarios. Para justificar inconsistencias en el conjunto de datos hiperespectrales que se utilizaron para generar los modelos de estimación de parámetros de calidad de forrajes, se evaluaron estadísticamente los datos auxiliares (objetivo 1). Se obtuvo que la altura del pasto y la producción de biomasa seca no aumentaron de manera consistente a medida que la edad de rebrote se incrementaba. En ciertos ciclos de muestreo los parámetros de calidad no tuvieron el comportamiento esperado, debido a las complicaciones en el desarrollo del forraje en la estación medida.

Para generar los modelos de estimación de parámetros de calidad (objetivo 2), se utilizaron los datos hiperespectrales recolectados en campo con un equipo ASD FieldSpec4, en conjunto con los datos de MS, PC, FDN y FDA obtenidos en el laboratorio. Esto con el fin de tener un conjunto de datos de calibración y así comparar con los datos espectrales de validación. Para seleccionar el conjunto de datos representativos a utilizar en los modelos, se removieron espectros que contenían anomalías, y se aplicó un análisis de componentes principales. Seguidamente, se realizaron los modelos de estimación de forraje, con dos combinaciones de pretratamientos (primera derivada, y primera derivada con la variación normal estándar) y diferentes cortes en el espectro, a causa de los ruidos generados por los efectos ambientales como alta humedad, lluvia y entrada de luz al equipo. Los resultados de la precisión de los modelos que se realizaron con regresión de mínimos cuadrados parciales (objetivo 3), generaron valores de  $r^2$  de 0,81, 0,17, 0,39 y 0,48 respectivamente para la MS, PC, FDN y FDA, por lo que se considera que el único modelo replicable es el de materia seca, categorizado como muy satisfactorio según la relación de rendimiento y de desviación.

## Índice

<b>1. Introducción</b> .....	1
<b>2. Marco teórico</b> .....	6
2.1. <i>Marco conceptual</i> .....	6
2.1.1. <i>Parámetros de calidad en especies forrajeras</i> .....	6
2.1.1.1. <i>Materia seca, proteína cruda, fibra detergente neutro y fibra detergente ácido</i> .....	6
2.1.2. <i>Estrella africana</i> .....	7
2.1.3. <i>Teledetección y espectroscopía de infrarrojo cercano</i> .....	7
2.2. <i>Antecedentes</i> .....	11
<b>3. Objetivos</b> .....	15
3.1. <i>Objetivo general</i> .....	15
3.2. <i>Objetivos específicos</i> .....	15
<b>4. Metodología</b> .....	15
4.1. <i>Descripción general</i> .....	15
4.2. <i>Sitio de estudio</i> .....	17
4.3. <i>Establecimiento del diseño experimental</i> .....	17
4.4. <i>Recolección de datos hiperespectrales y auxiliares</i> .....	19
4.5. <i>Objetivo 1: Análisis de datos recolectados en campo</i> .....	20
4.6. <i>Objetivo 2: Desarrollo de modelos de estimación de calidad del pasto</i> .....	21
4.6.1. <i>Pretratamiento de los datos hiperespectrales</i> .....	21
4.6.2. <i>Construcción del modelo de regresión</i> .....	24
4.7. <i>Objetivo 3: Evaluación de la precisión de los modelos</i> .....	25
4.7.1. <i>Evaluación de la precisión de los modelos</i> .....	25
<b>5. Resultados y discusión</b> .....	26
5.1. <i>Análisis de los datos auxiliares recolectados en campo</i> .....	26
5.1.1. <i>Altura del pasto</i> .....	26
5.1.2. <i>Producción de biomasa seca</i> .....	30
5.1.3. <i>Calidad del pasto</i> .....	34
5.1.4. <i>Humedad del suelo</i> .....	40
5.2. <i>Análisis de los datos hiperespectrales recolectados en campo</i> .....	42

5.3.	<b><i>Eliminación de los datos atípicos</i></b> .....	44
5.3.1.	<i>Aplicación de pretratamientos al espectro para remover datos atípicos</i> .....	44
5.3.2.	<i>Análisis de componentes principales para remover datos atípicos</i> .....	46
5.4.	<b><i>Eliminación de ruidos en el espectro con pretratamientos</i></b> .....	51
5.5.	<b><i>Exploración de cada conjunto de datos espectrales pretratados para los mejores modelos</i></b> .....	55
5.5.1.	<i>Análisis de componentes principales para los mejores modelos de Materia Seca y Fibra Detergente Ácido</i> .....	56
5.5.2.	<i>Análisis de componentes principales para los mejores modelos de Proteína Cruda y Fibra Detergente Neutro</i> .....	57
5.6.	<b><i>Modelos de regresión de mínimos cuadrados parciales (PLSR)</i></b> .....	58
5.6.1.	<i>Conjunto de datos con manejo de pasto en corte y en pastoreo juntos</i> .....	59
5.6.2.	<i>Conjunto de datos con manejo de pasto en corte</i> .....	60
5.6.3.	<i>Conjunto de datos con manejo de pasto en pastoreo</i> .....	61
5.6.4.	<i>Mejores modelos obtenidos</i> .....	63
5.7.	<b><i>Longitudes de onda importantes para la explicación de los parámetros de calidad</i></b> .	68
6.	<b>Conclusiones</b> .....	72
7.	<b>Recomendaciones</b> .....	73
8.	<b>Referencias</b> .....	75
Apéndice A:	.....	83
Apéndice B:	.....	91
Apéndice C:	.....	93

## Índice de figuras

<b>Figura 1.</b> Diagrama de la metodología para el trabajo final de graduación.....	16
<b>Figura 2.</b> Ubicación de las parcelas grandes de muestreo para, a) el lote con manejo de pasto de corte y b) el lote con manejo de pasto de pastoreo, del lote 25 de la Estación Experimental Alfredo Volio Mata de la Universidad de Costa Rica. ....	17
<b>Figura 3.</b> Diseño experimental de parcela grande.....	18
<b>Figura 4.</b> Diagrama de aplicación de pretratamientos a los diferentes conjuntos de datos generados, una vez eliminados los datos atípicos. ....	24
<b>Figura 5.</b> Gráfico de los promedios de altura para cada edad de crecimiento en el lote de corte, para ambos ciclos de muestreo. ....	27
<b>Figura 6.</b> Gráfico de cajas de la altura de los 9 valores por subparcela en el lote de corte para ambos ciclos de muestreo. ....	27
<b>Figura 7.</b> Gráfico de los promedios de altura para cada edad de crecimiento en el lote de pastoreo, para ambos ciclos de muestreo. ....	28
<b>Figura 8.</b> Gráfico de cajas de la altura de los 9 valores por subparcela en el lote de pastoreo para los tres ciclos de muestreo. ....	29
<b>Figura 9.</b> Factores variantes en las parcelas, donde a) es la subparcela del lote de pastoreo, ciclo 3 de crecimiento, 35 días de edad, con 27,33 cm de altura promedio y con presencia de boñiga, b) es la hierba ruibarbo ( <i>Rumex alpinus</i> ), y c) es la hierba mozotillo ( <i>Achyranthes aspera</i> L.) presente en el lote de pastoreo. ....	29
<b>Figura 10.</b> Datos de biomasa seca del pasto con manejo de corte, para los dos ciclos de crecimiento analizados.....	30
<b>Figura 11.</b> Factores variantes en las subparcelas del lote de corte, donde a) es el ciclo 1 de 35 días, con 33,30 cm de altura promedio en los 9 subpíxeles, y b) es el ciclo 2 de 35 días, con 11,59 cm de altura promedio en los 9 subpíxeles. ....	31
<b>Figura 12.</b> Leguminosa trébol blanco ( <i>Trifolium repens</i> ) presente en el lote de manejo de corte. ....	32
<b>Figura 13.</b> Datos de biomasa seca del lote de pastoreo, para los tres ciclos de crecimiento analizados.....	33
<b>Figura 14.</b> Datos de los patrones de calidad de análisis bromatológico del lote con manejo de corte, para la materia seca (MS); del primer ciclo de crecimiento y del segundo ciclo de crecimiento.....	34
<b>Figura 15.</b> Datos de los patrones de calidad de análisis bromatológico del lote de pastoreo, para la materia seca (MS); del primer ciclo de crecimiento, del segundo ciclo de crecimiento y del tercer ciclo de crecimiento. ....	35
<b>Figura 16.</b> Datos de los patrones de calidad de análisis bromatológico del lote de corte, para la proteína cruda (PC); del primer ciclo de crecimiento y del segundo ciclo de crecimiento. ....	36
<b>Figura 17.</b> Datos de los patrones de calidad de análisis bromatológico del lote de pastoreo, para la proteína cruda (PC); del primer ciclo de crecimiento (1), del segundo ciclo de crecimiento (2) y del tercer ciclo de crecimiento (3). ....	37



<b>Figura 18.</b> Datos de los patrones de calidad de análisis bromatológico del lote de corte, para la fibra detergente neutro (FDN) y fibra detergente ácido (FDA); ambos del primer ciclo de crecimiento y del segundo ciclo de crecimiento. ....	38
<b>Figura 19.</b> Datos de los patrones de calidad de análisis bromatológico del lote de pastoreo, para la fibra detergente neutro (FDN) y fibra detergente ácido (FDA); del primer ciclo de crecimiento, del segundo ciclo de crecimiento y del tercer ciclo de crecimiento. ....	39
<b>Figura 20.</b> Gráfico de cajas de la humedad en el suelo en el lote de corte para los dos ciclos de crecimiento.....	40
<b>Figura 21.</b> Gráfico de cajas de la humedad en el suelo en el lote de pastoreo para los tres ciclos de crecimiento.....	41
<b>Figura 22.</b> Espectro general de los datos de corte y pastoreo juntos, en reflectancia, sin pretratamientos.....	43
<b>Figura 23.</b> Espectro general de los datos de corte y pastoreo juntos, en absorbancia, sin pretratamientos.....	43
<b>Figura 24.</b> Espectros preprocesados con el método de primera derivada (Savitzky-Golay), con la totalidad de los datos (n=57).....	45
<b>Figura 25.</b> Espectros preprocesados con el método de primera derivada (Savitzky-Golay) en conjunto con la variación estándar normalizada (SNV), con la totalidad de los datos (n=57).....	46
<b>Figura 26 .</b> Espectros preprocesados con el método de primera derivada (Savitzky-Golay), con la totalidad de los datos (n=57) y con eliminación de ruidos en el espectro, en 1.357-1.479, 1.790-1.985 y 2.300-2.500 nm.....	47
<b>Figura 27.</b> Puntuaciones (scores) del primer y segundo componente principal (a), y tercer y cuarto componente principal (b), del PCA realizado con el espectro preprocesado (n=57). Los datos atípicos se resaltan con una elipse roja.....	48
<b>Figura 28.</b> Puntuaciones (scores) del primer y segundo componente principal (a), y tercer y cuarto componente principal (b), del PCA realizado con el espectro preprocesado, sin datos atípicos (n=46). Realizado en ChemFlow Galaxy.....	49
<b>Figura 29.</b> Espectros preprocesados con el método de primera derivada (Savitzky-Golay), sin los datos atípicos (n=46 datos). ....	50
<b>Figura 30.</b> Espectros preprocesados con los métodos de primera derivada (Savitzky-Golay) en conjunto con la variación estándar normalizada (SNV), sin los datos atípicos (n=46 datos).....	50
<b>Figura 31.</b> Espectros preprocesados con el método de primera derivada (Savitzky-Golay), sin los datos atípicos (n=46 datos) y con cortes en el espectro en 1.357-1.455, 1.791-2.029 y 2.301-2.500 nm. ....	51
<b>Figura 32.</b> Espectros preprocesados con los métodos de primera derivada (Savitzky-Golay) en conjunto con la variación estándar normalizada (SNV), sin los datos atípicos (n=46 datos) y con cortes en el espectro en 1.357-1455, 1.791-2.029 y 2.301-2.500 nm. ....	52
<b>Figura 33.</b> Espectros preprocesados con el método de primera derivada (Savitzky-Golay), sin los datos atípicos (n=46 datos) y con cortes en el espectro en 1.357-1.455 y 1.791-2.500 nm. ....	52

<b>Figura 34.</b> Espectros preprocesados con los métodos de primera derivada (Savitzky-Golay) en conjunto con la variación estándar normalizada (SNV), sin los datos atípicos (n=46 datos) y con cortes en el espectro en 1.357-1.455, 1.791-2.500 nm. ....	53
<b>Figura 35.</b> Espectros preprocesados con el método de primera derivada (Savitzky-Golay), sin los datos atípicos (n=46 datos) y con cortes en el espectro en 350-400, 1.357-1.455 y 1.791-2.500 nm. ....	53
<b>Figura 36.</b> Espectros preprocesados con los métodos de primera derivada (Savitzky-Golay) en conjunto con la variación estándar normalizada (SNV), sin los datos atípicos (n=46 datos) y con cortes en el espectro en 350-400, 1.357-1.455 y 1.791-2.500 nm. ....	54
<b>Figura 37.</b> Espectros preprocesados con el método de primera derivada (Savitzky-Golay), sin los datos atípicos (n=46 datos) y con cortes en el espectro en 350-400, 1.357-1.455, 1.791-2.065 y 2.300-2.500 nm. ....	54
<b>Figura 38.</b> Espectros preprocesados con los métodos de primera derivada (Savitzky-Golay) en conjunto con la variación estándar normalizada (SNV), sin los datos atípicos (n=46 datos) y con cortes en el espectro en 350-400, 1.357-1.455, 1.791-2.065 y 2.300-2.500 nm. ....	55
<b>Figura 39.</b> Puntuaciones (scores) del primer y segundo componente principal del PCA realizado en los datos de corte con el método de primera derivada (Savitzky-Golay), para el rango de eliminación de ruido del espectro 2, utilizado para la MS (a), y para el rango de eliminación de ruido del espectro 3, utilizado para la FDA (b). ....	57
<b>Figura 40.</b> Puntuaciones (scores) del primer y segundo componente principal del PCA realizado en los datos de corte y pastoreo en el conjunto de datos con eliminación de ruido en el espectro 2, con el método de primera derivada (Savitzky-Golay), utilizado para la FDN (a), y con los métodos de primera derivada en conjunto con la variación estándar normalizada (SNV), utilizado para la PC (b). ....	58
<b>Figura 41.</b> Correlación entre la MS de referencia y la MS predicha por medio de PLSR para 20 muestras evaluadas. ....	65
<b>Figura 42.</b> Correlación entre la PC de referencia y la PC predicha por medio de PLSR para 46 muestras evaluadas. ....	66
<b>Figura 43.</b> Correlación entre la FDN de referencia y la FDN predicha por medio de PLSR para 46 muestras evaluadas. ....	67
<b>Figura 44.</b> Correlación entre la FDA de referencia y la FDA predicha por medio de PLSR para 20 muestras evaluadas. ....	68
<b>Figura 45.</b> Gráfico de la variable de importancia para la proyección (VIP), mostrando la importancia de cada longitud de onda en el desarrollo del modelo de calidad de pasto para materia seca, a lo largo del espectro. ....	69
<b>Figura 46.</b> Gráfico de la variable de importancia para la proyección (VIP), mostrando la importancia de cada longitud de onda en el desarrollo del modelo de calidad de pasto para proteína cruda, a lo largo del espectro. ....	69

<b>Figura 47.</b> Gráfico de la variable de importancia para la proyección (VIP), mostrando la importancia de cada longitud de onda en el desarrollo del modelo de calidad de pasto para fibra detergente neutro, a lo largo del espectro. ....	70
<b>Figura 48.</b> Gráfico de la variable de importancia para la proyección (VIP), mostrando la importancia de cada longitud de onda en el desarrollo del modelo de calidad de pasto para fibra detergente ácido, a lo largo del espectro. ....	71
<b>Figura A1.</b> Gráfico de precipitación y humedad relativa correspondiente a los días de muestreo del lote de corte (Fuente: Instituto Meteorológico Nacional). ....	85
<b>Figura A2.</b> Gráfico de precipitación y humedad relativa correspondiente a los días de muestreo del lote de pastoreo (Fuente: Instituto Meteorológico Nacional). ....	85
<b>Figura A3.</b> Gráfico de radiación global total correspondiente a los días de muestreo del lote de corte (Fuente: Instituto Meteorológico Nacional). ....	86
<b>Figura A4.</b> Gráfico de radiación global total correspondiente a los días de muestreo del lote de pastoreo (Fuente: Instituto Meteorológico Nacional). ....	86
<b>Figura A5.</b> Repeticiones 2 y 3 del lote de pastoreo, para el día 14 del ciclo 3 de crecimiento, donde se observa material senescente que no fue comido por el ganado que pastoreó. ....	89
<b>Figura A6.</b> Datos de los patrones de clorofila para el lote con manejo de pasto de corte, del primer ciclo de crecimiento y del segundo ciclo de crecimiento, tomados como datos complementarios para el proyecto de investigación. ....	90
<b>Figura A7.</b> Datos de clorofila para el lote con manejo de pasto de pastoreo, del primer ciclo de crecimiento, del segundo ciclo de crecimiento y del tercer ciclo de crecimiento, tomados como datos complementarios para el proyecto de investigación. ....	90
<b>Figura B1.</b> Espectros correspondientes al lote con manejo de corte, preprocesados con el método de primera derivada (Savitzky-Golay), sin los datos atípicos (n=20 datos) y con ruidos. ....	92
<b>Figura B2.</b> Espectros correspondientes al lote con manejo de pastoreo, preprocesados con el método de primera derivada (Savitzky-Golay), sin los datos atípicos (n=26 datos) y con ruidos. ....	92
<b>Figura C1.</b> Gráfico de error mínimo cuadrado (RMSE) vs variable latente (LV) para el parámetro de calidad de materia seca. ....	100
<b>Figura C2.</b> Gráfico de error mínimo cuadrado (RMSE) vs variable latente (LV) para el parámetro de calidad de proteína cruda (PC). ....	101
<b>Figura C3.</b> Gráfico de error mínimo cuadrado (RMSE) vs variable latente (LV) para el parámetro de calidad de fibra detergente neutro (FDN). ....	102
<b>Figura C4.</b> Gráfico de error mínimo cuadrado (RMSE) vs variable latente (LV) para el parámetro de calidad de fibra detergente ácido (FDA). ....	103

**Figura C5.** Histograma de los resultados de laboratorio (a), y de los resultados del modelo (b), ambos para la materia seca (MS). ..... 104

**Figura C6.** Histograma de los resultados de laboratorio (a), y de los resultados del modelo (b), ambos para la proteína cruda (PC). ..... 104

**Figura C7.** Histograma de los resultados de laboratorio (a), y de los resultados del modelo (b), ambos para la fibra detergente neutro (FDN). ..... 105

**Figura C8.** Histograma de los resultados de laboratorio (a), y de los resultados del modelo (b), ambos para la fibra detergente ácido (FDA). ..... 105

## Índice de tablas

<b>Tabla 1.</b> Rangos de eliminación de ruido del espectro realizados por distintos autores.....	23
<b>Tabla 2.</b> Resultado de los análisis de componentes principales (PCA) realizados para cada eliminación de ruidos del espectro.....	56
<b>Tabla 3.</b> Mejores resultados de modelos PLSR con los datos de los lotes con manejo de corte y de pastoreo juntos. ....	60
<b>Tabla 4.</b> Mejores resultados de los modelos PLSR con los datos del lote con manejo de corte. ....	61
<b>Tabla 5.</b> Mejores resultados de los modelos PLSR con los datos del lote con manejo de pastoreo. ....	62
<b>Tabla 6.</b> Resumen de los mejores modelos obtenidos para cada parámetro de calidad estudiado. ....	64
<b>Tabla A1.</b> Cronograma final de toma de datos en campo en la Estación Experimental Alfredo Volio Mata de la Universidad de Costa Rica.....	84
<b>Tabla A2.</b> Valores de p de la ANOVA para la comparación de las todas variables dependientes con todas las variables independientes, incluyendo dos interacciones. ....	87
<b>Tabla A3.</b> Resultado de prueba de Tukey y media de datos para la comparación de las variables dependientes con el ciclo (1 y 2 para corte, y 1, 2 y 3 para pastoreo). ....	87
<b>Tabla A4.</b> Resultado de prueba de Tukey y media de datos para la comparación de las variables dependientes con la variable independiente de manejo (corte y pastoreo). ....	88
<b>Tabla A5.</b> Resultado de prueba de Tukey y media de datos para la interacción entre el ciclo y la edad con la variable dependiente de altura en el pasto. ....	88
<b>Tabla A6.</b> Resultado de prueba de Tukey y media de datos para la interacción entre el ciclo y la edad con la variable dependiente de biomasa seca en el pasto. ....	89
<b>Tabla C1.</b> Resultados de los modelos de MS y PC para los datos correspondientes a los lotes con manejo de corte y pastoreo juntos.....	94
<b>Tabla C2.</b> Resultado de los modelos de FDN y FDA para los datos correspondientes a los lotes con manejo de corte y pastoreo juntos.....	94
<b>Tabla C3.</b> Resultados de los modelos de MS y PC para los datos correspondientes al lote con manejo de corte. ....	95
<b>Tabla C4.</b> Resultados de los modelos de FDN y FDA para los datos correspondientes al lote con manejo de corte. ....	95
<b>Tabla C5.</b> Resultados de los modelos de MS y PC para los datos correspondientes al lote con manejo de pastoreo. ....	96
<b>Tabla C6.</b> Resultados de los modelos de FDN y FDA para los datos correspondientes al lote con manejo de pastoreo. ....	96

<b>Tabla C7.</b> Resultados de los modelos de MS y PC para los datos correspondientes a los lotes con manejo de corte y pastoreo juntos, en absorbancia, sin pretratamientos. ....	97
<b>Tabla C8.</b> Resultados de los modelos de MS y PC para los datos correspondientes a los lotes con manejo de corte y pastoreo juntos, en absorbancia, sin pretratamientos. ....	97
<b>Tabla C9.</b> Resultados de los modelos de MS y PC para los datos correspondientes al lote con manejo de corte, en absorbancia, sin pretratamientos.....	98
<b>Tabla C10.</b> Resultados de los modelos de FDN y FDA para los datos correspondientes al lote con manejo de corte, en absorbancia, sin pretratamientos.....	98
<b>Tabla C11.</b> Resultados de los modelos de MS y PC para los datos correspondientes al lote con manejo de pastoreo, en absorbancia, sin pretratamientos. ....	99
<b>Tabla C12.</b> Resultados de los modelos de FDN y FDA para los datos correspondientes al lote con manejo de pastoreo, en absorbancia, sin pretratamientos. ....	99

## 1. Introducción

La creciente demanda de productos de origen animal, especialmente los cárnicos y lácteos, ha ocasionado que la producción mundial de estos aumente también. Para el año 2022, la producción mundial de leche creció en un 0,7%, llegando a 897 Mt, y se prevé que el consumo mundial per cápita de productos lácteos frescos subirá un 1,0% anual durante los próximos 10 años (Organización para la Cooperación y el Desarrollo; Organización de las Naciones Unidas para la Alimentación y la Agricultura, 2023). Es necesario tomar en cuenta estas proyecciones ya que la población mundial para el 2050 será de 9.700 millones de personas, y cada una de ellas necesita satisfacer su requerimiento diario calórico (Organización de las Naciones Unidas, 2019). Por esta razón, se debe optimizar el campo agrícola, y los ciclos forraje-animal-subproductos, para poder alimentar a la población equitativamente.

En Costa Rica, el consumo de leche y sus derivados alcanzó 212 L por persona en el 2017, siendo el tercero más alto de Latinoamérica (Cubero, 2018). La producción ganadera ha contribuido al desarrollo agropecuario, comercial, social y económico de las zonas rurales y del país en general. Esta actividad se desarrolla en las seis regiones económicas del país, dominando las regiones Huetar Norte y Chorotega (Arguedas Villalobos, 2017). El 89,4% de las fincas utilizan el pastoreo extensivo como sistema productivo principal, el 1,9% un sistema estabulado, y el 8,7% restante, un sistema semiestabulado. También, cabe recalcar que para el 2019 se registró un 20,42% del territorio nacional con cobertura de pastos, donde la mayoría de este porcentaje está destinado a la ganadería bovina (Hernández et al., 2022).

En todo establecimiento ganadero, el monitoreo y manejo de los recursos forrajeros es fundamental para proveer alimento de excelente calidad. Se debe contar con una buena estimación del forraje producido por potrero que puede ser utilizado por los animales. La evaluación forrajera permite presupuestar este recurso, asignando la cantidad de forraje por lote necesario por aparto para la alimentación del ganado en la finca, y mejorar la producción mensual de pasto (García Martínez et al., 2018). Lo anterior aplica para un sistema de pastoreo, estabulado o semiestabulado. Los principales sistemas de alimentación del ganado lechero son el pasto mejorado y el natural, con el 46,8% y el 42,8% cada uno respectivamente (INEC, 2020).

La dieta de un bovino en una finca lechera consiste en: alimento balanceado (concentrado), sales minerales, melaza, forrajes y otros suplementos adicionales. Los concentrados a base de granos son parte de la fuente de nutrientes para las vacas en lactancia, ya que poseen altas concentraciones de proteína y energía. Este es el insumo de mayor costo en la alimentación en todo el ciclo de vida del animal, especialmente en lactancia. Debido a esto, es conveniente contar con especies forrajeras de excelente calidad como principal componente de la ración alimentaria, reduciendo los costos de producción considerablemente. Los pastos considerados de mejor calidad son aquellos que tienen aproximadamente 16% de proteína cruda, 65% de biomasa aprovechable y 2.400 kcal de energía metabolizable por kg de materia seca (Ministerio de Agricultura y Ganadería [MAG], 2006). Los parámetros de proteína cruda y fibra detergente neutro son relevantes al

momento de determinar la ración necesaria del animal, de acuerdo con su ciclo de lactancia (MAG, 2006).

En Costa Rica, uno de los pastos más comunes para la alimentación del ganado lechero y de engorde es el estrella africana (*Cynodon nlemfuensis*), utilizándose para pastoreo o corte. Este forraje se considera como pasto mejorado y es la segunda especie de importancia en el país, ya que ha sido manipulado genéticamente para ser más productivo y resistente a las variaciones climáticas, plagas y enfermedades (Instituto Nacional de Estadística y Censos [INEC], 2020).

La agricultura de precisión es ampliamente utilizada en las industrias agrícolas y hortícolas, sin embargo, la aplicación en forrajes no ha sido tan prominente como en otros cultivos. El uso de tecnologías de monitoreo vegetativo se popularizó en la década de los 80's con teledetección enfocada al manejo de pasturas y mapeo de las áreas con mejor productividad de acuerdo con la aplicación de fertilizantes (Vickery et al., 1980). Se han desarrollado productos comerciales para estimar la disponibilidad e índice de crecimiento del forraje.

Otro ámbito en este campo de estudio es la utilización de los datos hiperespectrales, los cuales han mejorado en resolución con el paso del tiempo. Se han abierto puertas a avances como el índice de vegetación de diferencia normalizado (NDVI, por sus siglas en inglés), sensores ópticos como el Greenseeker<sup>TM</sup> (Trotter, 2010) y métodos de laboratorio con espectroscopía de infrarrojo cercano (NIRS, por sus siglas en inglés) para determinar parámetros de calidad (Pullanagari et al., 2013). Los métodos de laboratorio requieren pruebas destructivas, son costosos, demandantes de tiempo, y el muestreo es complejo (Pullanagari et al., 2013).

En esta investigación se determinan los parámetros de calidad del pasto estrella africana (*Cynodon nlemfuensis*), al aplicar la tecnología de teledetección en campo, utilizando datos hiperespectrales. Poder medir la calidad de los forrajes en tiempo real en una finca, es de suma importancia ya que permite tomar decisiones más prontas, como tiempo de cosecha, tipo de forraje adecuado y fertilización necesaria en el sistema productivo, mejorando la alimentación del ganado. Por medio de la identificación de las bandas espectrales que definan la calidad del forraje, un productor podría hacer uso de una herramienta previamente desarrollada, como, por ejemplo, un sensor hiperespectral montado en un dron junto con su modelo respectivo, que le permita procesar los datos hiperespectrales tomados en campo, y así obtener parámetros de calidad. También, podría hacer uso de las imágenes satelitales de los satélites hiperespectrales con bandas entre 400-2.500 nm, tales como como PRISMA, Orbital Sidekick GHOST, o PIXXEL, que fueron puestos en órbita entre el 2019 y el 2023 (NASA SBIR program, 2023). Se ha demostrado que para estudiar por medio de teledetección características vegetativas, se requiere de alta resolución espectral y espacial. Es necesario contar con sensores modernos, como el hiperespectral, que puedan resolver las características espectrales causadas por cambios bioquímicos (responsables de la calidad de forrajes) (Pullanagari et al., 2013).



La toma de datos hiperespectrales en el pasto estrella africana, también permitió obtener la firma espectral de este en el proyecto de investigación 737-C0-208 titulado “Establecimiento de la metodología para la obtención de la firma espectral de tres especies forrajeras en Costa Rica”. La aplicación de esta tecnología en dicho forraje comúnmente sembrado en fincas centroamericanas es considerado novedoso. El desarrollo de esta investigación será de gran aporte para el sector ganadero y forrajero, puesto que, se obtendrá un modelo de calibración replicable para el sitio de estudio. Se espera que dicho modelo permita el desarrollo de herramientas que apoyen al productor en la eficiencia de la toma de parámetros bromatológicos. Finalmente, es necesario relacionar la propuesta de esta investigación con los Objetivos de Desarrollo Sostenible, donde el objetivo número dos de hambre cero, se pondrá en acción al estar involucrado el sector agropecuario, ya que una mejor estimación de la calidad de los forrajes apoya a la cadena de productos lácteos y cárnicos. También se incluye el objetivo número doce de producción y consumo responsable, ya que se pretende mejorar los resultados comerciales, sostenibilidad y resiliencia en los sistemas agrícolas que produzcan forraje.

La calidad de los forrajes en las fincas puede variar de acuerdo con los elementos presentes en el suelo, el clima, el manejo del sistema de pastoreo, y las enmiendas que se apliquen. Por estas razones, es importante realizar pruebas bromatológicas para conocer el estado nutricional de este cultivo (de Alckmin et al., 2020). Estas pruebas con química húmeda y NIRS en laboratorio, son las comúnmente utilizadas por su grado de confiabilidad, y son las pruebas aceptadas por la Asociación Oficial de Químicos Agrícolas (AOAC por sus siglas en inglés). Estas tienen un aspecto negativo reflejado en la necesidad de realizar pruebas destructivas, el desafío de tomar muestras representativas, retrasos entre el tiempo de muestreo y los resultados de las pruebas, y, el costo monetario de realizarlas (Pullanagari et al., 2013). Cabe recalcar que la mayoría de las investigaciones referentes al tema, se han realizado en laboratorio, hay faltante de investigaciones relacionadas con pruebas en campo (no destructivas), lo que permitiría extenderlo a mayores escalas, y resultando de gran ayuda para los productores.

El uso del NIRS es una técnica de detección que depende de la variabilidad de los compuestos químicos y físicos de diferentes muestras a evaluar. De acuerdo con la proporción y combinación de absorción de energía de los ejemplares, se puede conocer la vibración de enlaces de carbono, nitrógeno, azufre y demás, en el intervalo espectral (Prananto et al., 2020). Esta tecnología emergente se utiliza en laboratorios para análisis de nutrientes en suelos y plantas, al operar con una longitud de onda entre los 700-2.500 nm. Tiene la ventaja de ofrecer pruebas rápidas, no destructivas, poco laboriosas y en tiempo real (García-Martínez et al., 2011).

Los estudios de infrarrojo cercano (NIR, por sus siglas en inglés) en plantas, se reconocen desde Knipling (1970), el cual estableció las bases físicas y fisiológicas de la reflectancia visible y radiación en la vegetación. Se han realizado estudios de digestibilidad, contenidos de proteína cruda (PC), fibra detergente neutra (FDN) y fibra detergente ácido (FDA) (Prananto et al., 2020). Investigaciones recientes en el extranjero, dentro de las cuales se encuentran las de Pullanagari et

al. (2013) en Nueva Zelanda y Lugassi et al. (2015) en Israel, varían los métodos de NIRS para obtener los porcentajes de parámetros de calidad para las muestras vegetativas.

Teniendo en cuenta que los métodos convencionales no se pueden extender a grandes escalas por ser muestras representativas, se analiza el uso de tecnologías de teledetección a nivel de la superficie y en tiempo real. Por medio de teledetección de la reflectancia del dosel, con sensores hiperspectrales, se pueden obtener datos espectrales suficientemente detallados para obtener algunos parámetros asociados a la calidad de forrajes. Algunos de estos pueden ser, PC, FDN, FDA, materia seca (MS), cenizas, diferencia catión-anión, lignina, lípidos, energía metabolizable y digestibilidad de materia orgánica (Safari et al., 2016).

La MS representa el peso total de un forraje menos su contenido de agua, y varía a lo largo del año dependiendo del estado de madurez, especie y manejo (INIA Uruguay, 2018). La PC depende de la relación suelo-planta-animal, así como de interacciones con las estaciones climáticas, por lo que es un componente clave para la actividad ruminal, por ende, del consumo y digestibilidad (de Alckmin et al., 2020). La FDN determina en gran medida la cantidad de forraje que puede consumir un animal. A medida que la FDN aumenta, el consumo de MS se reduce (Analytics Beyond Measure, 2018). Finalmente, la FDA es un indicador de digestibilidad (Ball et al., 2017).

La aplicación de la teledetección para la estimación de rendimiento de cultivos se ha realizado en varios estudios con imágenes multiespectrales, radares, índices de vegetación y datos satelitales. Pocos investigadores han utilizado datos hiperspectrales para predecir los rendimientos de forraje. Por ejemplo, Coto & Rojas (2021) realizaron un estudio para comparar la información hiper y multiespectral de pasto estrella africana bajo condiciones de pastoreo, mediante espectrorradiometría de campo e información satelital con Sentinel 2; obteniendo índices de área foliar NDVI y el índice de vegetación ajustado al suelo (SAVI, por sus siglas en inglés). Los índices mencionados, se calcularon para valorar la concordancia con la hiperspectrometría del forraje estrella africana.

En este trabajo de un año (2022-2023), se evaluaron los datos hiperspectrales y auxiliares obtenidos en campo, para el cultivo forrajero estrella africana (*Cynodon nlemfuensis*). Para la recolección de datos se realizó colaboración con el proyecto para obtener los datos de interés en campo durante dos ciclos de crecimiento, ya que esta investigación es un estudio complementario y cumple objetivos diferentes al proyecto 737-CO-208. El forraje en estudio estuvo presente en dos parcelas experimentales de 15,5 m por 12,5 m, que se encuentran ubicadas en la Estación Experimental de Ganado Lechero Alfredo Volio Mata (EEAVM) de la Universidad de Costa Rica. Los datos hiperspectrales se obtuvieron con un espectrorradiómetro ASD FieldSpec4, para determinar mediante modelos matemáticos los parámetros de calidad de MS, PC, FDN y FDA. Esto se realizó con la finalidad de validar el método aplicado, ya que los resultados bromatológicos de laboratorio se tomaron como la muestra control.

Para obtener los parámetros de calidad de forrajes mencionados, se utilizó el análisis multivariado con las bandas espectrales utilizando la plataforma abierta ChemFlow Galaxy y el apoyo del

software libre RStudio. Esta plataforma utiliza modelos matemáticos para la predicción cuantitativa de las muestras, siguiendo un modelo de calibración que se debe seleccionar para obtener resultados consistentes (Kastanek & Shiley, 2020). Las métricas de validación del modelo utilizadas fueron el coeficiente de determinación ( $r^2$ ), el error cuadrático medio (RMSE, por sus siglas en inglés), la relación de rendimiento y de desviación (RPD, por sus siglas en inglés) y la importancia de la variable para la proyección (VIP, por sus siglas en inglés).

## 2. Marco teórico

### 2.1. Marco conceptual

#### 2.1.1. Parámetros de calidad en especies forrajeras

Las pasturas presentan fluctuaciones en su calidad y cantidad a lo largo de los meses del año, resultado de la distribución temporal de la lluvia y cambios en la temperatura. Debido a esto, es importante destacar el hecho que las decisiones (enmiendas, pastoreo, y suplementos para el ganado con sus respectivas dietas nutritivas) se deben tomar en contexto a una gran impredecibilidad. Consecuentemente, el valor de las pasturas es una combinación de la producción y de la calidad nutritiva (Serrano et al., 2020).

La bromatología es la ciencia que estudia a los alimentos en cuanto a su producción, manipulación, conservación, elaboración y distribución. Esta comprende la medición de las cantidades a suministrar a los individuos de acuerdo con las especificaciones alimenticias de cada tipo de animal. A continuación, se van a mencionar los parámetros medibles para determinar la calidad de pastos. La concentración de proteína se obtiene de acuerdo con el contenido de nitrógeno que es esencial para la producción de leche y crecimiento animal. El extracto etéreo, es el conjunto de sustancias que incluyen los ácidos grasos, las ceras y algunos pigmentos, constituye una porción de alto valor energético. La lignina es el material adherido a la celulosa y la hemicelulosa; limita el acceso a estos azúcares y de su contenido depende la digestibilidad del pasto (Mora, 2012).

#### 2.1.1.1. Materia seca, proteína cruda, fibra detergente neutro y fibra detergente ácido

El término de materia seca se utiliza en la formulación de dietas para identificar el restante después de remover el agua en el forraje. Este valor es importante porque indica la cantidad de nutrientes que potencialmente pueden ser aprovechados por el animal para ganancia de peso. También, se puede saber cuánta agua está consumiendo el animal del forraje, aparte del agua suministrada por los abrevaderos (Bueso Ponce, 2017).

La proteína cruda le provee al ganado aminoácidos esenciales para digerir las pasturas más eficientemente. Si llegara a faltar energía en la ración, se pueden ocasionar altos niveles de amonio en el rumen, convirtiéndose en urea. Esta urea aparece en la sangre, leche y luego en la orina, resultando en baja eficiencia reproductiva (Di Marco, 2012). Debido a esto, un forraje con alta concentración de proteína es recomendable.

Uno de los métodos para calcular la cantidad de fibra o de pared celular en forrajes, es por medio de la FDN, FDA y la lignina detergente ácida. Estos valores se utilizan para calcular la cantidad de forrajes que pueden digerir los animales, los nutrientes digeribles totales y otros rangos energéticos. El concepto de “detergente” surge a partir de que la teoría establece que las células vegetales pueden ser divididas en partes compuestas por hemicelulosa, celulosa y lignina, las cuales son paredes celulares menos digeribles. Los componentes mencionados se pueden separar

por medio de dos tipos de detergentes: uno neutro y uno ácido (Analytics Beyond Measure, 2018). La FDN es la porción de la muestra que es insoluble en detergente neutro, y está compuesta por celulosa, hemicelulosa, lignina y sílice; a mayor FDN, menos consumo de materia seca. La FDA es la porción de la muestra que es insoluble en un detergente ácido, y está compuesta por celulosa y lignina; a mayor FDA, menor digestibilidad de forraje (Mandevu et al., 1999).

### *2.1.2. Estrella africana*

El pasto estrella africana tiene altos rendimientos, por lo que se valora como un pasto de alta calidad. Con el manejo adecuado puede producir desde 3.500 a 5.800 kg/ha de materia seca anuales. Este forraje posee raíces profundas que le permiten crecer de forma agresiva en la época de lluvia, por lo que se adapta al clima tropical húmedo de Costa Rica (Villalobos, 2020). Tiene una edad de cosecha de 21 a 42 días. Entre algunos de sus usos se encuentra el pastoreo, control de erosión del suelo, como heno y ensilaje (MAG, 2006). Los niveles de PC del pasto estrella africana se encuentran entre 18-22%, la FDN entre 63-77% (MAG, 2006) y la FDA entre 30-34% (Johnson et al., 2001).

### *2.1.3. Teledetección y espectroscopía de infrarrojo cercano*

La teledetección es una tecnología avanzada para obtener información de un objeto, al analizar los datos adquiridos por un sensor a una cierta distancia del objetivo. Una de las metas de la teledetección es medir las firmas espectrales y la composición química de todos los rasgos principales que comprendan dentro del campo visual del sensor. Según Ben-Dor (2013), las bandas hiperespectrales contienen: visibles, infrarrojo cercano, de onda corta, media y larga, dominios espaciales micro y macroscópicos. Además, se pueden obtener datos de distintos tipos de objetos (sólido, líquido o gaseoso). Un espectrómetro puede coleccionar desde unas cuantas, a cientos de bandas de información, permitiendo construir eficientemente espectros de reflectancia continuos para cada píxel en una imagen. De acuerdo con lo establecido, cada píxel en una imagen puede estar asociado con un gran número de puntos de datos espectrales, construyendo todo el espectro de luz completo (Pu, 2017).

La teledetección hiperespectral puede proveer información detallada debido a su alta resolución de bandas espectrales, con el propósito de encontrar objetos, identificar materiales y detectar procesos. Esta tecnología se desarrolló para mejorar la identificación de materiales y determinación de propiedades físicas y químicas en minerales, agua, vegetación, suelos y entre otros (Pu, 2017). Un sensor hiperespectral puede extraer un diagnóstico de rasgos espectrales en resolución de 20 a 40 nm para la superficie de la Tierra. Sin embargo, la vegetación es sensible a la radiación solar proveniente desde el rango ultravioleta hasta el rango espectral infrarrojo corto, NIR y regiones de infrarrojo medio (0,4-2,5  $\mu\text{m}$ ). El espectro reflejado de NIR está influenciado por el desarrollo de la planta, crecimiento y senescencia; la capa del mesófilo en las hojas es la que controla la cantidad de energía NIR que es reflejada (Pu, 2017).

La NIRS es una técnica emergente para realizar análisis de suelos y plantas. Esta técnica de espectroscopía usa rangos de reflectancia entre los 700 y 2.500 nm, ofrece un análisis de nutrientes en plantas rápido, no destructivo, barato, menos costoso y a tiempo real. Actualmente, numerosos estudios también se han enfocado en el uso de NIRS para análisis de suelos, indicando que se puede utilizar para predecir las propiedades de este. Utilizar NIRS a nivel del dosel, permite una medición directa de estado nutritivo del cultivo (Prananto et al., 2020).

La teledetección al nivel del dosel cumple lo esperado para obtener resultados rápidos y no destructivos; sin embargo, es necesario comprender el funcionamiento desde la absorción de luz en una planta. En las hojas vegetativas verdes, las regiones relevantes de radiación electromagnética son la región visible (400-700 nm), responsable de la absorción de luz por pigmentos fotosintéticos. La región NIR (700-1.100 nm) es donde se absorbe la materia seca; y la región infrarroja corta (1.100-2.500 nm), donde se absorbe el agua (Mishra et al., 2017).

#### *2.1.3.1. Procesamiento de datos hiperespectrales*

Para poder obtener las características distinguibles de los datos hiperespectrales, estos deben ser procesados por diferentes pretratamientos, a continuación, se detallan los usados en esta investigación.

Los pretratamientos deben aplicarse precavidamente, ya que pueden ayudar a minimizar las variaciones no deseadas, pero también podrían reducir la señal neta del objeto de interés. Por lo tanto, se debe conocer previamente el modo de acción del pretratamiento y la presentación de la muestra (Huang et al., 2010). Los pretratamientos escogidos para esta investigación fueron basados por lo sugerido por distintos autores que realizaron experimentos en espectroscopía de campo, para plantas forrajeras. Por ejemplo, Pullanagari et al. (2012) y de Alckmin et al. (2020), utilizaron la primera derivada, y Lingjie & Chengci (2018) y Smith et al. (2019) aplicaron la primera derivada con la variación normal estándar (SNV por sus siglas en inglés), que son procedimientos para reducir la influencia de ruidos causados por desvío de la línea base y de fondo.

Las derivadas son de los pretratamientos comúnmente aplicados a los datos espectrales. Son principalmente utilizadas para resolver la superposición de picos (o mejorar la resolución) y eliminar el desvío de la línea base constante y lineal entre muestras (Huang et al., 2010). La derivada se puede obtener con el algoritmo que aplica el filtro Savitzky-Golay. Este consiste en reemplazar cada valor de la curva del espectro con un nuevo valor obtenido a partir de un ajuste polinomial de bajo grado, el cual puede ser grado 1, 2 o hasta 3; en este caso se utiliza una derivada de orden 1, polinomio de grado 2, con un tamaño de ventana específico. En la Ecuación 1, se observa la transformación de la primera derivada del espectro en reflectancia (Mutanga, 2005), sin embargo, se realizó con el espectro en absorbancia, para minimizar el comportamiento no-lineal (Fourty & Baret, 1998).

$$R'_{\lambda(i)} = \frac{(R_{\lambda(j+1)} - R_{\lambda(j)})}{\Delta\lambda} \quad (1)$$

Donde  $R'_{\lambda(i)}$  es la primera derivada de reflectancia a una longitud de onda  $i$  en medio de las bandas  $j$  y  $j+1$ .  $R_{\lambda(i+1)}$  es la reflectancia en la banda  $j+1$ ,  $R_{\lambda(j)}$  es la reflectancia en la banda  $j$ , y  $\Delta_{\lambda}$  es la diferencia entre longitudes de onda entre  $j$  y  $j+1$ .

La SNV, es un filtro que realiza una normalización del espectro. Consiste en substraer cada espectro por su propio promedio y dividirlo por su propia desviación estándar (Ecuación 2), por lo que después de la SNV, cada espectro tendrá un promedio de 0 y una desviación estándar de 1. Se utiliza para reducir los efectos multiplicativos de la dispersión y el tamaño de las partículas (Zeaiter & Rutledge, 2009).

$$x_{i,j}^{SNV} = \frac{(x_{i,j} - \bar{x}_i)}{\sqrt{\frac{\sum_{j=1}^p (x_{i,j} - \bar{x}_i)^2}{p-1}}} \quad (2)$$

Donde  $x_{i,j}^{SNV}$  es el elemento del espectro transformado, y  $x_{i,j}$  es el elemento original correspondiente del espectro  $i$  en la variable  $j$ ;  $\bar{x}_i$  es el promedio del espectro  $i$ , y  $p$  es el número de variables o longitudes de onda del espectro.

El análisis de componentes principales (PCA, por sus siglas en inglés), realiza un modelo de exploración de datos, reduciendo el número de dimensiones en extensos conjuntos de datos, de forma que retiene la mayoría de la información original en componentes principales. Este proceso se conduce para visualizar la varianza espectral, y detectar la influencia de cada dato espectral en el conjunto de datos completo (Esbensen et al., 2009).

La validación cruzada dejando uno fuera (leave-one-out cross validation, por su nombre en inglés), es un método que consiste en dividir el conjunto de datos en un bloque de validación y un bloque de calibración, donde se deja solamente una única muestra en el bloque de validación, lo que obliga a calibrar tantos modelos como número de muestras existen. El proceso se repite  $n$  veces (donde  $n$  es el número total de observaciones en el conjunto de datos), dejando fuera cada vez una observación diferente del bloque de calibración (Zach, 2020). Este método se utiliza cuando se tiene una cantidad de muestras limitada para calibración y validación.

El modelo de regresión de mínimos cuadrados parciales (PLSR, por sus siglas en inglés), es un tipo de análisis multivariado, el cual usa un modelo PLS predictivo de 2 bloques para modelar la relación entre dos matrices,  $X$  y  $Y$ . En adición, PLSR modela la “estructura” de  $X$  y de  $Y$ , lo cual aporta resultados más enriquecedores que los que daría una regresión múltiple. Este tipo de regresión aporta un modelado multivariado cuantitativo, con posibilidades inferenciales similares a una regresión múltiple, pruebas  $t$  y análisis de varianza (ANOVA, por sus siglas en inglés). También, se utiliza para analizar datos con ruido, colinealidad, y hasta variables incompletas tanto en  $X$  como en  $Y$  (Wold et al., 2001). Se representa por la siguiente ecuación:

$$Y = \beta X + \varepsilon \quad (3)$$

Donde  $Y$  es la variable dependiente,  $X$  es la variable independiente,  $\beta$  es el coeficiente y  $\varepsilon$  es el residual.

Para evaluar la precisión de un modelo, se pueden utilizar el  $r^2$  y el RMSE. El  $r^2$  indica el grado de colinealidad entre los datos predichos y medidos, y describe el porcentaje de variación de la variable  $X$  en la variable  $Y$  (Pullanagari et al., 2012). El RMSE mide la diferencia de la desviación estándar entre los datos medidos y los predichos (Ecuación 4); se considera que es una medida absoluta de ajuste, mientras que el  $r^2$  es una medida relativa de ajuste. Valores bajos de RMSE indican un mejor ajuste; este permite medir qué tan preciso el modelo predice la respuesta, y es el criterio más importante de ajuste cuando el propósito inicial del modelo es la predicción (Pullanagari et al., 2012).

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (\hat{y} - y)^2}{n}} \quad (4)$$

Donde  $\hat{y}$  indica el valor predicho,  $y$  es la medida realizada en el laboratorio;  $\bar{y}$  es el promedio de los valores medidos y  $n$  el número de muestras.

La RPD, es un indicador de calibración de la calidad del modelo en términos de la habilidad que tenga un modelo NIRS para predecir su constituyente; entre más alto sea el valor de RPD, mejor será la calidad del modelo (Karlinasari et al., 2014). Para materiales agrícolas, un RPD mayor de 1,5 es considerado satisfactorio y útil para evaluaciones iniciales y predicciones preliminares (Schimleck et al., 2001). También, los autores Kusumo et al. (2009) establecen que, bajo condiciones de laboratorio, el deseado nivel de predicción se da cuando  $r^2 > 0,8$  y cuando  $RPD > 2$ , sin embargo, para mediciones en campo, se aceptan valores más bajos de RPD (Biewer et al., 2009). Estos valores RPD se calcularon con:

$$RPD = \frac{SD(y)}{\sqrt{\frac{\sum_{i=1}^n (\hat{y} - y)^2}{n}}} = \frac{SD(y)}{RMSE} \quad (5)$$

Donde  $SD$  corresponde a la desviación estándar de los valores de laboratorio, y el denominador es el RMSE de validación cruzada.

La VIP, traduce la importancia de cada longitud de onda en la construcción del modelo PLS (Ecuación 6). Las VIP son calculadas para todas las columnas de  $Y$ , y son números positivos. Cuando  $VIP > 1$  se considera como importante para el desarrollo del modelo (Chong & Jun, 2005).

$$VIP_k(a) = K \sum_a w_{ak}^2 \left( \frac{SSY_a}{SSY_t} \right) \quad (6)$$

Donde  $VIP_k(a)$  es la importancia de la  $k$ -ésima variable predictora (longitud de onda), basado en un modelo con factores  $a$  (componentes de PLS);  $w_{ak}$  representa los pesos del PLS de la  $k$ -ésima variable en un  $a$ -ésimo factor de PLS;  $SSY_a$  es la suma de cuadrados de  $Y$  por un modelo PLSR con factores  $a$ ;  $SSY_t$  es la suma total de los cuadrados de  $Y$  explicada en todos los factores  $a$  de un modelo PLS.



## 2.2. Antecedentes

Por medio de técnicas de teledetección, se puede obtener índices de calidad de forrajes con un previo tratamiento de datos hiperespectrales tomados en campo, de una forma rápida, económica y no destructiva. En la siguiente información, se encuentra una variedad de investigaciones referentes al tema de manera cronológica, con equipos que toman datos hiperespectrales en tiempo real en lotes de forraje, y autores que realizan procesamiento de datos para obtener índices de calidad.

Rahman et al. (2003), examinaron las características espaciales de firmas espectrales de vegetación tipo chaparral y pasturas en el sur de California. Determinaron el tamaño de píxel óptimo para realizar estudios de ecosistemas a nivel de paisaje. Los datos se recolectaron durante el otoño y verano, utilizando muestreo de campo con un espectrómetro (UniSpec, PP Systems) e imágenes con vuelos AVIRIS. El espectrómetro colecta información con longitudes de onda entre los 300 y 1.100 nm a aproximadamente intervalos de 3 nm y longitudes de onda de 10 nm. La investigación concluyó que se necesitan 6 m<sup>2</sup> de píxeles para estimar óptimamente la biomasa, fotosíntesis y contenido de agua en pasturas del sur de California.

De manera similar, Kawamura et al. (2009), estimaron la biomasa y nutrientes de pastura utilizando un espectrorradiómetro de campo en conjunto con un equipo ASD FieldSpec Pro FR el cual tiene un intervalo de muestreo de 1,4 nm en un rango de 350-1.000 nm y de 2 nm en el rango de 1.000-2.500 nm. El equipo también contó con un “CAPP” con luz artificial para eliminar el obstáculo de las variabilidades climáticas. Se aplicó el pretratamiento de primera derivada de reflectancia, usando el método de suavizamiento de Savitzky-Golay, y con un polinomio de tercer grado; también se utilizó la eliminación del continuo. El método utilizado para la estimación fue PLSR, asistido con el coeficiente de determinación. Realizaron una reflectancia derivada eliminada del continuo, partiendo de los datos obtenidos en PLSR. Utilizaron un sistema de GPS para mapear los patrones de distribución espacial de la biomasa dentro de un lote objetivo. Se seleccionaron ocho lotes para maximizar el rango de estado fisiológico de la planta. Finalmente, indicaron que el intervalo de muestras es esencial en 5 m<sup>2</sup> para capturar la mayor cantidad de biomasa y contenido nutricional en pasturas en colinas. Sugieren que la alta resolución espectral es crucial para cuantificar los parámetros de calidad en forrajes.

Con pastos tipo ryegrass perenne (*Lolium perenne L.*) y trébol blanco (*Trifolium repens L.*), se realizó un estudio en Nueva Zelanda por Pullanagari et al. (2012). Se tomaron mediciones espectrales a la altura del dosel in situ con un espectrorradiómetro ASD FieldSpec Pro FR, con el sensor cubierto con una tapa (CAPP-top grip) para asegurar un espectro de reflectancia consistente con luz artificial. El rango espectral fue de 350-2.500 nm con resoluciones de 1,4 nm de 350-1.000 y de 1.000-2.500 con resolución de 2,0 nm. Las aproximaciones de parámetros de calidad realizadas fueron para PC, FDA, FDN, cenizas, diferencia de dieta catión-anión, lignina, lípido, energía metabolizable y materia orgánica digerible. La metodología utilizada fue regresión de mínimos cuadrados, pero previamente se prepararon los datos para eliminar anomalías con los

pretratamientos de primera derivada (con el filtro Savitzky-Golay) y centrado de la media. Se realizó análisis estadístico multivariado con el software PARLES para desarrollar relaciones entre los datos espectrales procesados y las muestras destructivas tratadas en laboratorio. La precisión del método se evaluó con el coeficiente de determinación ( $r^2$ ) y demás parámetros estadísticos. Los resultados entre los parámetros de calidad de las pasturas presentaron que la PC tiene una correlación negativa con la FDA, FDN y lignina,  $r^2 = -0,84$ ,  $-0,80$  y  $-0,75$ . La FDA tiene una correlación con todos los parámetros de calidad con  $r^2 = -0,94$  a  $0,94$ , igualmente para la FDN, a excepción de las cenizas.

En la investigación previamente mencionada de Pullanagari et al. (2012), se recomendó investigar los cambios espectrales en pasturas permanentes a largo del año y a través de toda la temporada, en vista de evaluar la necesidad de una calibración estacional del NIRS. Los modelos se pueden hacer más precisos, ya que hay influencia de diferentes composiciones botánicas, hierbas, etapas de crecimiento, tipos de suelo y estructura del dosel.

En Israel, Lugassi et al. (2015) desarrollaron una investigación para predecir el contenido de proteína cruda y fibra detergente neutro de especies perennes para pastoreo de ovejas como *Atractylis serratuloides*, *Noaea mucronata* y *Thymelea hirsuta*. Esto se realizó por medio de infrarrojo cercano e infrarrojo de onda corta. Se utilizó un espectrorradiómetro ASD FieldSpec-Pro JR equipado con una sonda de contacto, para realizar las mediciones espectrales en el laboratorio luego de cortar las muestras. Se utilizó el método de pendiente espectral, el cual consiste en calcular varias pendientes en los distintos rangos espectrales (interpolación de reflectancias), hasta encontrar una correlación entre las muestras secas y frescas. Estos investigadores compararon sus resultados con muestras secas calculadas en laboratorio, obteniendo correlaciones satisfactorias con  $r^2 = 0,92$  al compararlo con lo obtenido con NIRS.

En la investigación realizada en el Reino Unido por Bell et al. (2018), se utilizaron forrajes permanentes como ryegrass perenne con trébol blanco o rojo (*Trifolium repens* o *Trifolium pretense*). Se evaluaron efectos en las pasturas como: fase de producción (en pastoreo o en descanso para crecimiento), MS, PC, FDN, FDA, carbohidratos solubles en agua, cenizas, materia orgánica digestible y materia seca digestible. Las pruebas se realizaron con un dispositivo móvil de NIRS (NIR4, Aunir), el cual escanea la muestra recién cortada de pastura en menos de un minuto y realiza el análisis de nutrientes. Este equipo escanea las muestras cuatro veces, y consiste en un espectro de energía infrarrojo reflejado de la muestra de pasto iluminada por el escáner, sin embargo, no menciona resolución. Se utilizó un modelo lineal mixto en el software Genstat, donde se establece el efecto de la pastura (permanente o temporal), fase de producción (pastoreado o en descanso) y mes del año en nutrientes del pasto. En este artículo se obtuvo que la altura del pasto y la cobertura estuvieron correlacionadas con concentraciones de PC y cenizas (ambas  $p < 0,001$ ), y negativamente correlacionadas con concentraciones de materia seca, FDA y FDN (ambas con  $p < 0,05$ ).

Bell et al. (2018), concluyeron que, al combinar la medida de la altura del pasto o de la cobertura herbal en un estudio de los nutrientes del forraje a tiempo real con NIRS, se puede identificar cambios temporales (estaciones del año) o espaciales (dentro o entre lotes). Dichos cambios pueden impactar el pastoreo o la producción de ensilaje dentro de una actividad productiva. Concluyeron que para forrajes pastoreados a una altura menor de 7 cm, tienen concentraciones significativamente menores de PC, digestibilidad de materia orgánica y digestibilidad de materia seca, en comparación con coberturas más altas y amplias.

Los autores Lingjie y Chengci (2018) investigaron acerca del uso de NIR en la medición de vegetación en campo, para construir un modelo calibrado y estimar el rendimiento de la biomasa y contenidos nutricionales, desde el inicio del crecimiento hasta etapas de latencia. Se utilizó un espectrorradiómetro ASD FieldSpec FR, con un rango espectral entre 350-2.500 nm a intervalos de 1 nm. Los parámetros por obtener fueron: biomasa, FDN, FDA y PC, para lo cual aplicaron pretratamientos de primera derivada en conjunto con la SNV, y se realizaron los modelos con PLSR. Cuando se añadieron los datos de todas las etapas de crecimiento se obtuvieron mejores resultados. También realizaron regresión lineal múltiple (MLR, por sus siglas en inglés), con las bandas más significativas, para lo cual obtuvieron  $r^2$  de 0,72, 0,67, 0,78 y 0,66 para el rendimiento, FDA, FDN y PC respectivamente.

Con un enfoque diferente, los autores Gao et al. (2019) en China, recuperaron el contenido de fósforo del forraje a partir de teledetección hiperespectral con un algoritmo de aprendizaje automático. Utilizaron un dron y un espectrorradiómetro ASD portable para tomar las mediciones, así como muestras destructivas. Los resultados muestran que la primera derivada y la eliminación del continuo puede recuperar más bandas características que están principalmente localizadas en las regiones NIR e infrarrojo de onda corta, al comparar con los datos en solamente absorbancia ( $\text{Log}(1/R)$ ) o los originales.

A través del estudio realizado por Smith et al. (2019) en Victoria, Australia, se incluyeron más parámetros de calidad de forraje: FDA, cenizas, PC, MS, digestibilidad de materia seca in vivo, digestibilidad de materia orgánica in vivo, FDN y carbohidratos solubles en agua. El equipo utilizado fue un ASD FieldSpec 4, en un campo experimental de ryegrass perenne, en diferentes estadios del crecimiento. Se realizaron distintos tipos de correcciones de dispersión a los datos espectrales, como la SNV, detrend, corrección multiplicativa de dispersión estandarizada (MSC, por sus siglas en inglés), MSC con pesos, MSC inverso, escala y desplazamiento, escala y lineal, escala y cuadrático y primera derivada. Para construir los modelos realizaron análisis de PCA, y seguidamente modelaron con PLSR y mínimos cuadrados parciales modificado (MPLSR, por sus siglas en inglés). Para todos los parámetros en estudio, los modelos más exitosos fueron los realizados con MPLSR con la primera derivada. Para FDA el pretratamiento más exitoso fue sin corrección de dispersión, para PC fue la derivada, escala y desplazamiento, para MS fue SNV, y la FDN se vio favorecida con SNV. Se obtuvieron resultados de  $r^2$  entre 0,87 y 0,39 para estos parámetros estudiados.

En otro artículo realizado por de Alckmin et al. (2020), donde se trabajó con ryegrass perenne, enfocando en la obtención de PC, con un método no destructivo y en tiempo real, basado solamente en la reflectancia del dosel. El equipo utilizado fue un ASD FieldSpec 3 y 4, en Holanda y en Australia, respectivamente, con muestreos de 1,4 nm en un rango de 350-1.000 nm y de 2 nm en el rango de 1.000-2.500 nm. Se contrastaron diferentes rangos espectrales al seleccionar un número mínimo de bandas y, se analizaron cercanías entre la PC expresada como materia seca en función del peso por área. El pretratamiento de los datos espectrales utilizó el filtro Savitzky-Golay para remover el ruido causado por alta frecuencia y prevenir el sobre-suavizamiento; el tamaño de la ventana fue de 15 nm. Para la selección de las bandas específicas, se utilizó un algoritmo de machine learning, donde los resultados indicaron que el rango adecuado del NIR está entre los 400 y 1.100 nm. Dentro de este rango, once bandas amplias de 10 nm de ancho de banda lograron un mejor comportamiento que otros comparados en literatura.

Otra investigación de relevancia se realizó en China, donde los autores Sun et al. (2022) obtuvieron la biomasa y valores nutritivos de mezclas de pasto con trébol, a partir del análisis de espectros y altura del cultivo, con métodos quimiométricos. Se utilizó el equipo ASD FieldSpec 4 Standard-Res, con un rango espectral entre 350-2.500 nm. Utilizaron dos métodos quimiométricos para realizar los modelos, los cuales fueron el PLSR y máquinas de vectores de soporte (SVM, por sus siglas en inglés Support Vector Machine), para obtener el rendimiento de materia seca, digestibilidad in vitro, FDN, digestibilidad de la FDN, FDA, PC, rendimiento de PC y composición botánica. Los resultados mostraron que ambos métodos pueden estimar el rendimiento del forraje y las variables de calidad, aunque el desempeño del PLSR fue más estable en términos del  $r^2$  y el error cuadrático medio relativo.

### **3. Objetivos**

#### *3.1. Objetivo general*

Generar modelos para determinar los parámetros de calidad de materia seca, proteína cruda, fibra detergente neutro y fibra detergente ácido, del pasto estrella africana (*Cynodon nlemfuensis*), ubicado en la Estación Experimental Alfredo Volio Mata (EEAVM) de la Universidad de Costa Rica, utilizando espectroscopía de campo.

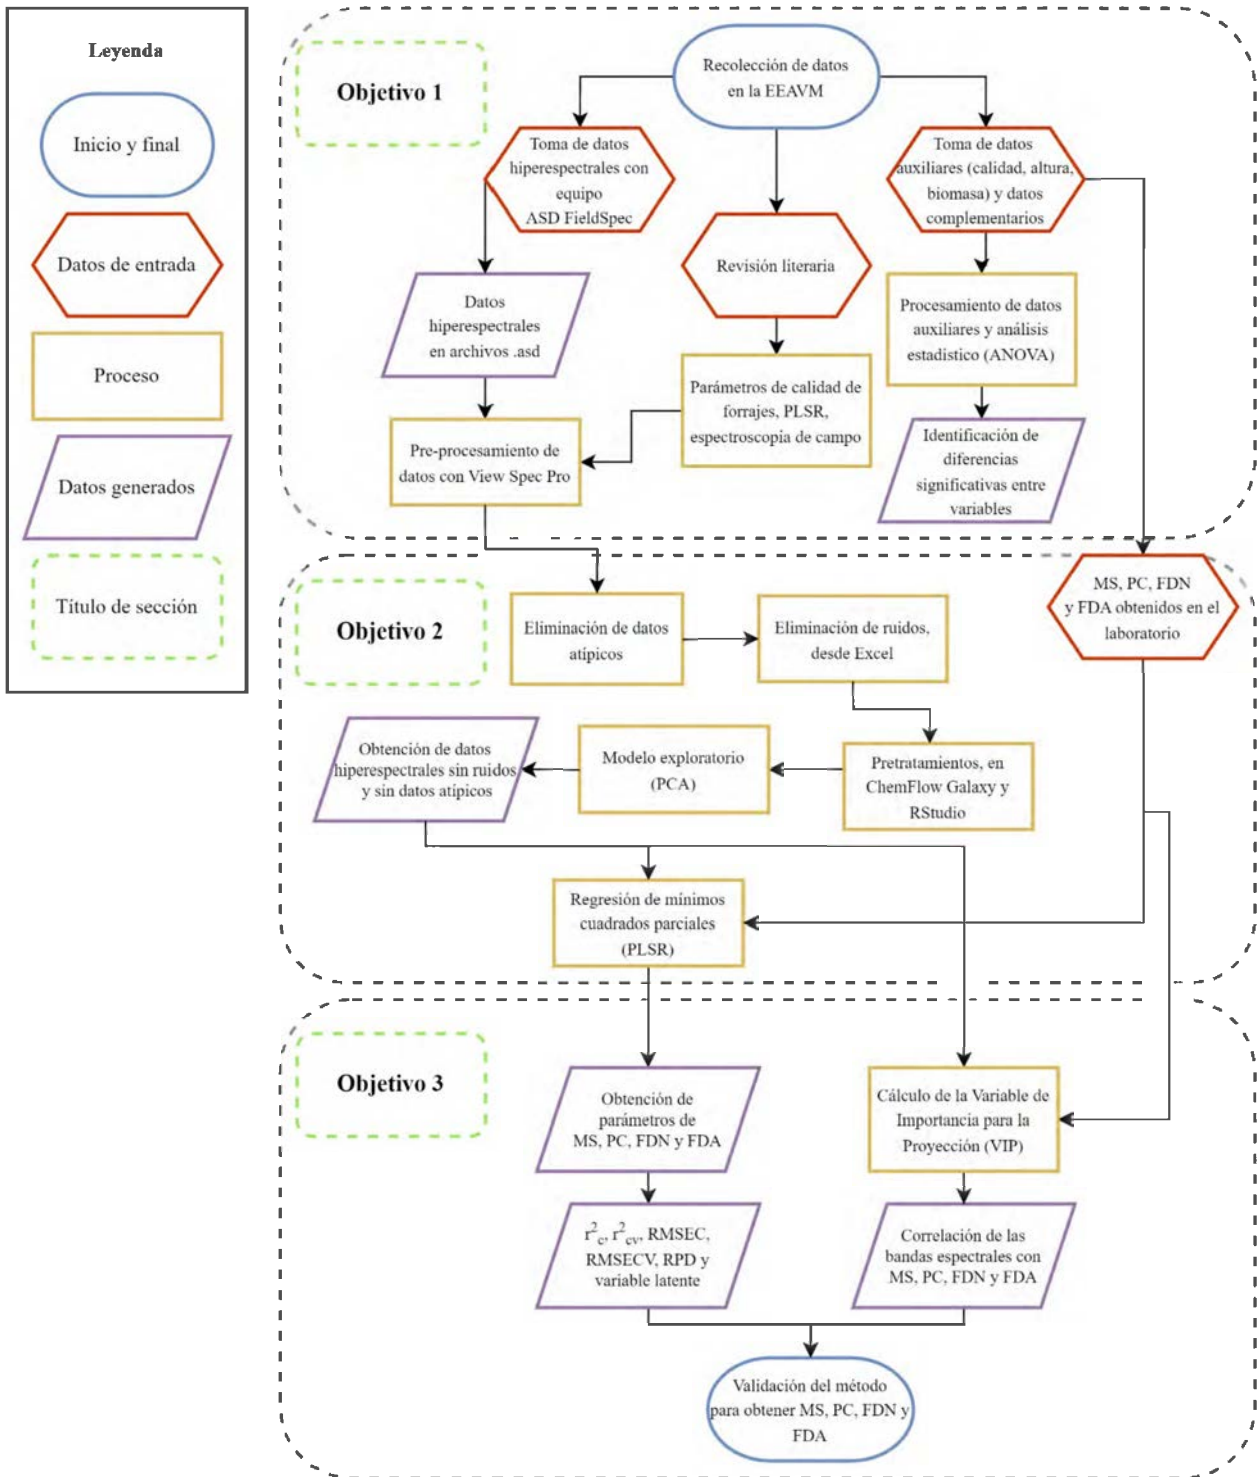
#### *3.2. Objetivos específicos*

1. Analizar los datos hiperespectrales y auxiliares recolectados en campo, para mejorar la precisión de los modelos de determinación de los parámetros de calidad del pasto estrella africana.
2. Desarrollar modelos de estimación de materia seca, proteína cruda, fibra detergente neutro y fibra detergente ácido, mediante regresión de mínimos cuadrados parciales, utilizando los datos hiperespectrales y auxiliares.
3. Evaluar la precisión de los modelos para estimar los parámetros de calidad de: materia seca proteína cruda, fibra detergente neutro y fibra detergente ácido, mediante el coeficiente de determinación y error cuadrático medio.

### **4. Metodología**

#### *4.1. Descripción general*

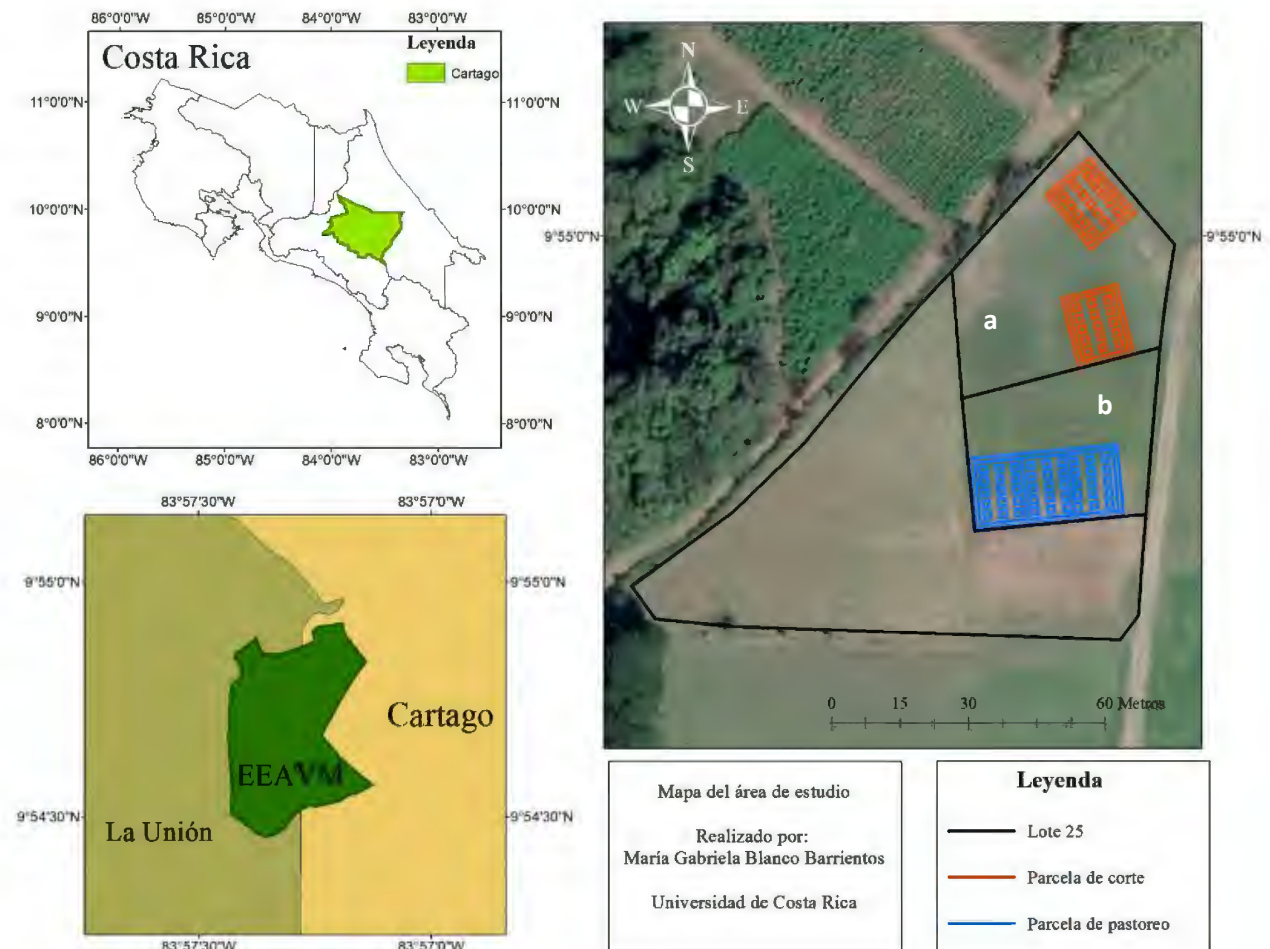
El objetivo de este proyecto fue determinar cuatro parámetros de calidad: materia seca, proteína cruda, fibra detergente neutro y fibra detergente ácido, del forraje estrella africana (*Cynodon nlemfuensis*), a través de espectroscopía de campo. La EEAVM cuenta con parcelas de pasto estrella africana para corte o pastoreo, y con el laboratorio de bromatología dentro de la misma estación. Las parcelas experimentales fueron establecidas por el proyecto de investigación 737-C0-208, llamado “Establecimiento de la metodología para la obtención de la firma espectral de tres especies forrajeras en Costa Rica con enfoque multitemporal”, siendo esta investigación un estudio complementario de este proyecto con diferentes objetivos. Los datos que se recolectaron en las parcelas experimentales fueron: 1) datos hiperespectrales recolectados con un espectroradiómetro ASD FieldSpec4, 2) los datos auxiliares de: MS, PC, FDN y FDA del forraje obtenido del análisis bromatológico de laboratorio, la altura del forraje y la biomasa seca. Además, se recolectaron datos complementarios como la humedad del suelo y condición climática. Posteriormente a la recolección de los datos, se organizaron para hacer un análisis estadístico y correlacionar las variables de laboratorio con los espectros, para obtener modelos de composición bromatológica para el forraje en estudio. En el diagrama de la Figura 1, se observa la metodología propuesta.



**Figura 1.** Diagrama de la metodología para el trabajo final de graduación.

#### 4.2. Sitio de estudio

El sitio de estudio (Figura 2) comprendió la EEAVM de la Universidad de Costa Rica, ubicada a 1.542 m.s.n.m. en el Alto de Ochomogo, provincia de Cartago (latitud norte 9°54'41" y longitud oeste 83°57'16"), entre el cantón de Cartago y de La Unión. Se trabajaron dos parcelas experimentales, una de corte y otra de pastoreo, ambas de estrella africana, y con un tipo de suelo franco arcilloso. La precipitación media anual es de 1.500 mm (concentrada de mayo a noviembre) con una temperatura promedio de 17,9 °C (Instituto Meteorológico Nacional, 2020). Los datos fueron recolectados entre los meses de junio a septiembre del 2022 (ver Tabla A1).



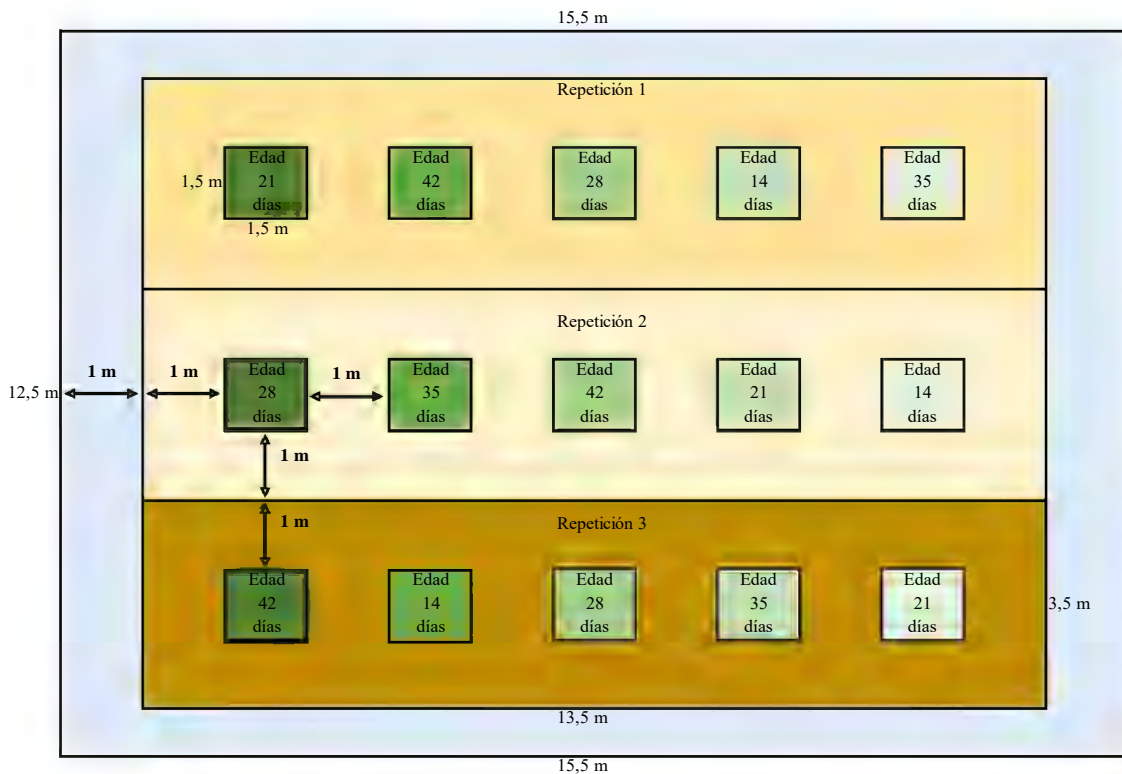
**Figura 2.** Ubicación de las parcelas grandes de muestreo para, a) el lote con manejo de pasto de corte y b) el lote con manejo de pasto de pastoreo, del lote 25 de la Estación Experimental Alfredo Volio Mata de la Universidad de Costa Rica.

#### 4.3. Establecimiento del diseño experimental

Para recolectar los parámetros de calidad del pasto estrella africana, se llevó a cabo un diseño experimental previamente establecido en el proyecto 737-C0-208 inscrito en la Vicerrectoría de

Investigación de la Universidad de Costa Rica. Las variables independientes son la edad del pasto, ciclo de crecimiento (1, 2 o 3) y el manejo de la parcela (corte o pastoreo). Las variables dependientes (datos auxiliares) para esta investigación son la altura, la biomasa y los parámetros de calidad MS, PC, FDN y FDA.

El diseño experimental para cada ensayo es un diseño de bloques completos al azar, con tres ciclos de crecimiento que varían en ubicación y tiempo para representar aleatoriedad y que el modelo no sea tan determinístico (Figura 2). Se realiza un acomodamiento de tratamientos de parcela dividida (Figura 3), donde se considera una parcela grande de estrella africana con tres repeticiones para ambos tipos de manejo de corte y pastoreo. Se tienen dos parcelas grandes en diferentes ubicaciones dentro del lote 25 de la EEAVM. Se considera como *subparcela* las cinco y cuatro fechas de muestreo que corresponden a las edades del forraje siendo cada 14, 21, 28 y 35 días para la parcela grande que tiene como tratamiento el pastoreo; y 14, 21, 28, 35 y 42 días para la parcela grande que tiene como tratamiento el corte. Cada repetición tiene cinco subparcelas permanentes de muestreo de 2,25 m<sup>2</sup> (1,5 x 1,5 m) cada una, marcadas en GPS y con señalización permanente en la tierra. Teniendo en cuenta lo anterior, la subparcela facilita una “parcela real” central de 1,0 m<sup>2</sup> para realizar sin interrupciones de efecto de borde, las mediciones de espectro. Las unidades experimentales son las subparcelas de campo, la unidad de observación son los espectros y los datos auxiliares (MS, PC, FDN y FDA obtenidos en laboratorio, la altura del forraje y la biomasa seca). Adicionalmente, se recolectaron como datos complementarios la humedad del suelo y la condición climática.



**Figura 3.** Diseño experimental de parcela grande.



Las parcelas fueron de secano, con tratamiento de malezas manual y el manejo de cosecha y pastoreo se realizó en todo el sitio experimental, para que hubiese mayor representatividad. Una vez que se completaron las mediciones necesarias para cada ciclo de crecimiento, se llevaron a cabo las labores de corte y pastoreo, esto ayudó a que el crecimiento de forraje inicie de nuevo para el próximo ciclo de crecimiento.

#### *4.4. Recolección de datos hiperespectrales y auxiliares*

De acuerdo con el diseño experimental, los datos hiperespectrales y auxiliares se tomaron al mismo tiempo, dependen de la edad del forraje, prácticas de manejo de corte, pastoreo y clima. Se sistematizó el almacenamiento de la información recolectada en campo y los análisis bromatológicos.

Para realizar la recolección de datos hiperespectrales, se utilizó un radioespectrómetro de campo ASD Inc. FieldSpec 4 Wide-Res de la Escuela de Ingeniería de Biosistemas de la UCR. El equipo en mención tiene un rango espectral de 350-2.500 nm, con una resolución de ancho de banda de 3 nm a VNIR y 30 nm a SWIR. El rango del equipo hiperespectral, corresponde a los mencionados por Mishra et al. (2017), donde en forrajes, las regiones relevantes de radiación electromagnética son la región visible (400-700 nm), responsable de la absorción de luz por pigmentos fotosintéticos. La región NIR (700-1.100 nm) es donde se absorbe la materia seca. La región infrarroja corta (1.100-2.500 nm), donde se absorbe el agua.

Las mediciones comenzaron inmediatamente después de la cosecha o pastoreo, para empezar con el primer ciclo de crecimiento y a diferentes edades fenológicas. Se tomaron los datos de 8 am a 2 pm para reducir el efecto de la nubosidad. En cada día de muestreo, cada subparcela se dividía en nueve secciones iguales y se tomaban tres muestras en cada sección. El radioespectrómetro se calibraba contra un panel de espectro blanco después de tratar cada sección. Se realizó un promedio de las 27 mediciones tomadas en cada subparcela, posteriormente a la eliminación de la brecha del equipo (gap remove, en inglés) a los 1.000 y 1.800 nm.

La toma de datos auxiliares, que son la altura del forraje, humedad del suelo, rendimiento de biomasa seca y valor nutritivo del forraje, se realizaron el mismo día que las mediciones espectrales. La altura del forraje se tomó en cada una de las nueve secciones por subparcela con una regla de mano, y el valor se tomó como el punto más alto donde el forraje toque la regla. Para tomar las muestras de suelo, se excavó con un barreno a tres profundidades (10, 20 y 30 cm), y se guardaron tres muestras por cada profundidad en bolsas plásticas selladas; este paso se iteró en cada repetición de muestreo, para cada edad analizada. Cada bolsa se identificó de acuerdo con el manejo (corte o pastoreo), repetición, profundidad y edad del forraje. La humedad del suelo se midió por medio del método gravimétrico, realizado en el Laboratorio de Aguas, Suelo y Ambiente de la Escuela de Ingeniería de Biosistemas. Los valores nutritivos del forraje fueron realizados en el laboratorio de bromatología de la EEAVM.

Para obtener el valor nutritivo del forraje, se recolectó una muestra destructiva inmediatamente después de cada medición espectral para cuantificar el contenido de agua en el forraje y composición nutritiva. La muestra fue recortada, en tres subsecciones aleatorias dentro de la subparcela, a mano con tijeras de jardín a nivel del suelo, con ayuda de un cuadrante de 0,25 m<sup>2</sup>. Esta muestra se utilizó para dos funciones, primero cada subsección se pesó en campo para obtener el rendimiento de biomasa verde. Segundo, se tomó una muestra entre 0,6 y 1,0 kg, se empacó en bolsas plásticas rotuladas, y se llevó al laboratorio de bromatología en la EEAVM, donde el forraje fue analizado con métodos químicos para obtener la MS, PC, FDN y FDA.

Cuando se llevó a cabo la toma de datos en campo, era necesario realizarlo cuando no lloviera por que los equipos de recolección de datos se pueden dañar, y los datos no se recolectarían correctamente, especialmente los datos espectrales los cuales dependían de la luz solar y pueden presentar ruido cuando la humedad es alta. Debido a esto, lo que se tenía propuesto al inicio del proyecto de realizar tres ciclos para cada parcela, con 42 días corte y 35 días pastoreo, no se cumplió en todos los casos. En corte, solamente se pudieron realizar dos ciclos, con el ciclo 1, incompleto el día 28, y el ciclo 2 incompletos los días 0 y 42, debido a la presencia de precipitación. Para el caso del lote de pastoreo, si se pudieron completar los tres ciclos, pero con el ciclo 1 incompleto el día 28. Este día 28 del ciclo 1 para ambas parcelas, sucedió el 1 julio del 2022, donde se dio la tormenta tropical Bonnie, que afectó las condiciones climáticas normales del país.

#### *4.5. Objetivo 1: Análisis de datos recolectados en campo*

Para realizar el análisis de los datos hiperespectrales, se comenzó organizándolos en carpetas de acuerdo con las anotaciones que se hicieron en campo, para identificar correctamente el tipo de pasto estrella africana, corte o pastoreo, ciclo (1, 2 o 3), día (0, 14, 21, 28, 35 o 42), repetición (1, 2 o 3), subpíxel (1, 2, 3, ...9) y dato. Una vez identificados en carpetas, se procedió a cambiar el nombre de cada espectro con el programa “Bulk Rename” de forma automática. También, se realizó un control de calidad de los espectros y se eliminaron las anomalías causadas por anotaciones en campo de espacios dentro del subpíxel que tenían boñiga, suelo desnudo, y que se habían tomado por error o por cambio en la irradiancia solar. Se removieron otros espectros anormales, para lo cual se utilizó el programa View Spec Pro, donde se identificaron por presentar reflectancias mayores a 0,7 y menor a -0,2, entre las bandas de 750 y 1.800 nm, ya que se salían del promedio de datos. Según Ozaki et al. (2005), estas anomalías se pueden deber a fluctuaciones en los detectores y circuitos internos, así como a factores externos como entrada de luz y humedad. Se transformaron los datos que estaban en reflectancia (R) a absorbancia ( $\log(1/R)$ ), para reducir la no-linealidad. Esta no-linealidad es causada por la dispersión de la luz provocando una fuente de incertidumbre para las mediciones radiométricas, reduciendo la precisión de la medición (Pullanagari et al., 2012). Finalmente, se procedió a realizar un “gap remove” de todos los datos, en dos zonas, en 1.000 nm y en 1.800 nm, ya que el equipo realiza un cambio de sensor en esas dos longitudes de onda, provocando un leve brinco en el espectro.

El procesamiento de los datos auxiliares recolectados en campo, consistió en calcular los promedios de cada repetición, para tener un dato por cada subparcela, de acuerdo con el manejo (corte o pastoreo), la repetición (1, 2 o 3) y la edad (14, 21, 28, 35, 42). Seguidamente se realizaron pruebas de estadística descriptiva en el software Infostat, y un ANOVA con un nivel de significancia de  $p=0,05$ ; también se realizó la prueba Tukey para identificar diferencias significativas entre variables ( $\alpha=0,05$ ) (Tablas A2, A3, A4, A5 y A6).

#### *4.6. Objetivo 2: Desarrollo de modelos de estimación de calidad del pasto*

Las variables de entrada para el desarrollo de los modelos de estimación de calidad del pasto, son los datos hiperespectrales y los análisis bromatológicos de laboratorio obtenidos a través de la recolección de datos del objetivo 1. De esta manera, se obtienen como variables de salida, la estimación de calidad del pasto, con base en espectroscopía de campo. Cabe aclarar que los datos fueron tomados con diferentes edades de crecimiento para que los modelos no sean dependientes de una edad específica, y de esta manera, aumentar la robustez del mismo.

Previamente al desarrollo de los modelos de estimación de MS, PC, FDN y FDA, se realizaron una serie de pasos de pretratamiento para reducir los posibles ruidos de los datos que ingresarán al modelo y así obtener el mejor resultado posible. Los cortes para reducir los ruidos se efectuaron en Excel. El análisis estadístico se realizó con la plataforma en línea ChemFlow Galaxy para desarrollar relaciones entre los datos espectrales procesados y las variables medidas de interés. Esta plataforma tiene una colección de herramientas para extraer información de datos espectrales, así como una interfaz amigable con el usuario para simplificar los procesos de programación. ChemHouse es el creador de ChemFlow, ChemData y CheMoocs, los cuales son divisiones para que las personas puedan aprender a procesar datos espectrales. Algunas investigaciones con ChemFlow comprenden espectros de olivas, madera, bacterias, lácteos, etc. (ChemProject, 2020).

##### *4.6.1. Pretratamiento de los datos hiperespectrales*

Primeramente, se cortaron ciertas regiones del espectro que contenían interferencia de ruidos a causa del agua en las hojas, del vapor de agua en el aire y entradas de luz. Las regiones con los ruidos más pronunciados de los datos medidos en campo se encuentran entre los 1.357-1.455 nm, 1.791-2.065 nm y 2.300-2.500 nm.

Previamente a realizar cada corte, se aplicó el filtro Savitzky-Golay, el cual utiliza una derivada de orden 1, polinomio de grado 2, con una ventana de 11. Se escoge la ventana de este tamaño para perder menos longitud de onda y datos, ya que se tiene un conjunto de datos pequeño para generar un modelo PLSR.

Seguidamente, se aplicó una segunda combinación de pretratamientos, la cual consiste en el mismo filtro Savitzky-Golay, en conjunto con la SNV. La SNV se utiliza para realizar una normalización del espectro y reducir los efectos multiplicativos de la dispersión y el tamaño de las partículas (Zeaiter & Rutledge, 2009).

Después de la aplicación de los pretratamientos, se procede a realizar la exploración de los datos con el análisis de los componentes principales (PCA, por sus siglas en inglés), en ChemFlow Galaxy. El PCA transforma variables potencialmente correlacionadas en conjuntos de variables más pequeñas llamadas componentes principales. Este análisis es muy efectivo para visualizar y explorar amplios conjuntos de datos, o datos con muchas características, ya que puede identificar fácilmente patrones o datos atípicos (Maćkiewicz & Ratajczak, 1993). La existencia de los datos atípicos llegaría a afectar seriamente la precisión y la estimación (Zeng & Chen, 2018), por lo que se deben eliminar utilizando un agrupamiento espectral con las puntuaciones (o “scores” en inglés) de los componentes principales.

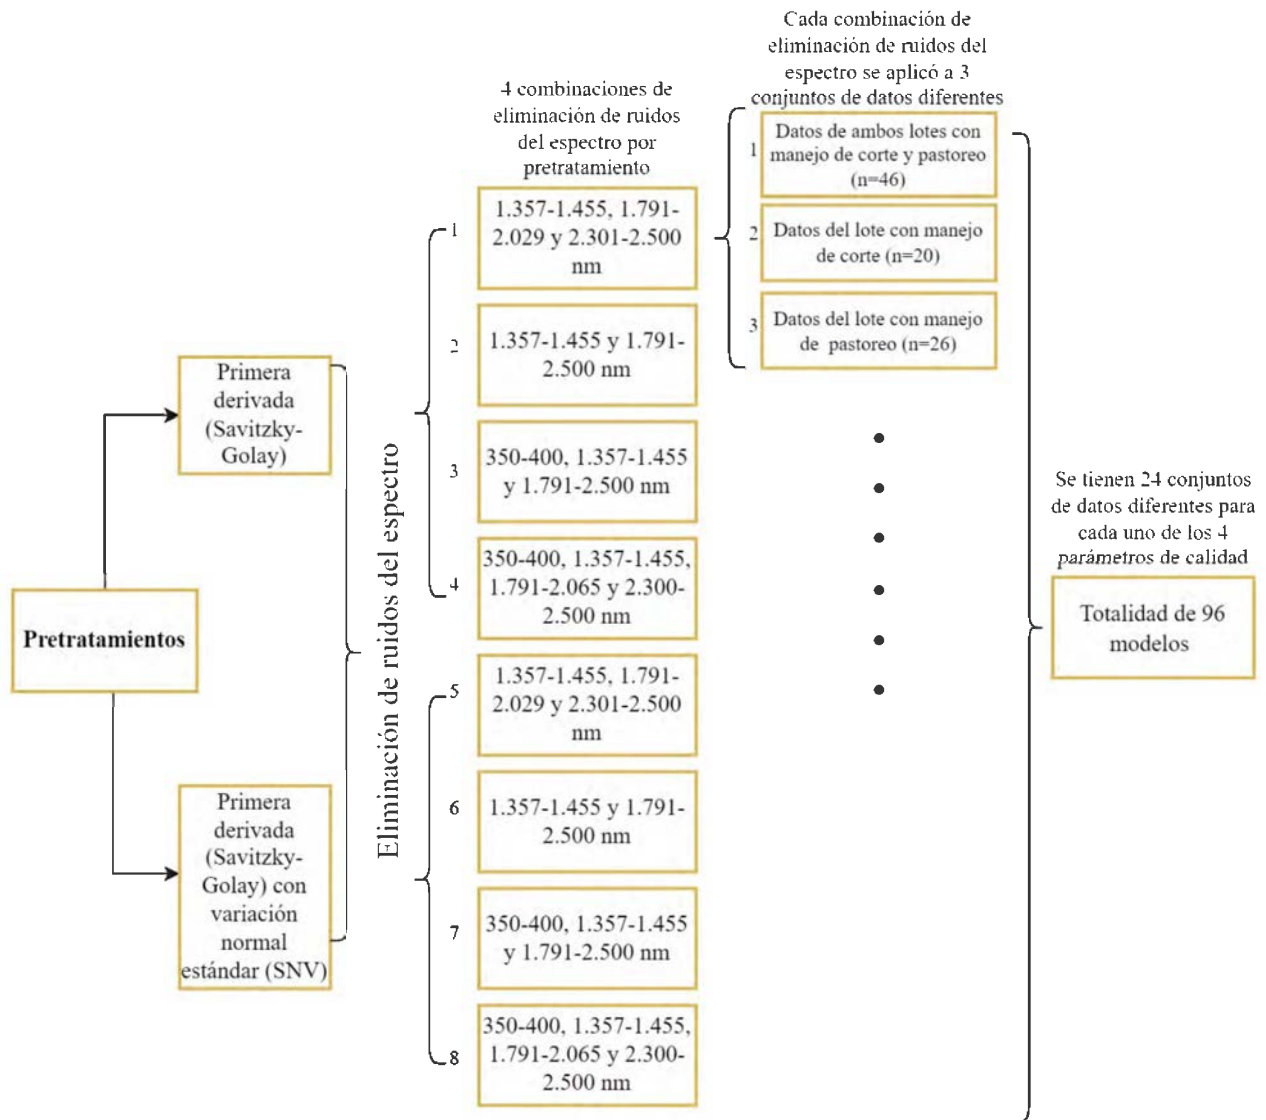
En el PCA se aplicaron 20 componentes principales, analizando solamente los primeros 4. En este caso se tiene un conjunto total de 57 datos, donde 33 corresponden al conjunto de datos de pastoreo, y 24 corresponden al conjunto de datos de corte. Cada dato dentro del conjunto de datos engloba una totalidad de 2.150 bandas, pero al realizar la primera eliminación de ruidos del espectro, cada dato contiene 1.578 bandas. De esta manera, se cumple con lo estipulado en la teoría para poder aplicar un PCA, donde se necesita que el tamaño de cada dato sea de más de 200 (en este caso, bandas) (Comrey & Lee, 1992). Se encontraron y eliminaron 11 datos atípicos debido a variabilidad de la calibración del blanco del equipo, cambios ambientales como en la luz y nubes. Una vez eliminados los datos atípicos, se realiza de nuevo el PCA a los 46 espectros para revisar la nube de agrupamiento de datos y observar que estén más juntos entre sí.

Para finalizar el preprocesamiento de los datos espectrales, se procede a realizar la eliminación de ruidos en el espectro. Cada longitud de onda proporciona información que puede ser más o menos valiosa dependiendo del parámetro de calidad, por lo que se realizaron 4 combinaciones diferentes de eliminaciones de ruidos en el espectro para obtener el mejor modelo posible para cada parámetro de calidad. Estas eliminaciones de ruidos en el espectro se aplicaron a los 4 parámetros de calidad en estudio, y generaron las siguientes combinaciones: 1) 1.357-1.455 nm, 1.791-2.029 nm y 2.301-2.500 nm; 2) 1.357-1.455 nm, 1.791-2.500 nm; 3) 350-400 nm, 1.357-1.455 nm, 1.791-2.500 nm; 4) 350-400 nm, 1.357-1.455 nm, 1.791-2.065 nm, 2.300-2.500 nm, y se realizaron según lo que distintos autores aplicaron en sus datos (Tabla 1). A cada uno de estos conjuntos de datos, también se les realizó un PCA para conocer su varianza explicada.

**Tabla 1.** Rangos de eliminación de ruido del espectro realizados por distintos autores.

<b>Rango de eliminación</b>	<b>Razón de eliminación</b>	<b>Autor</b>
350-400 ; 350-500	Introducción de luz al sensor.	(de Alckmin et al., 2020) ; (Pullanagari et al., 2012)
1.325-1.475 ; 1.341-1.479 ; 1.340-1.475 ; 1.340-1.500 ; 1.351-1.420	Altos niveles de ruido atmosférico. Bandas asociadas a absorción de vapor de agua y ruidos.	(de Alckmin et al., 2020) ; (Kawamura et al., 2013) ; (Sun et al., 2022) (Safari et al., 2016) (Gao et al., 2019)
1.751-1.999 ; 1.775-2.000 ; 1.770-1.965 ; 1.801-1960	Interferencia de ruido por el agua en las hojas y vapor de agua.	(Kawamura et al., 2013) ; (de Alckmin et al., 2020) ; (Sun et al., 2022) ; (Gao et al., 2019)
2.351-2.500 ; 2.400-2.500 ; 2.400-2.500 ; 1.970-2.450 ; 2.425-2.500 ; 2.301-2.500	Introducción de luz al sensor. Bandas asociadas a absorción de vapor de agua y ruidos.	(Kawamura et al., 2013) ; (Pullanagari et al., 2012) ; (de Alckmin et al., 2020) ; (Smith et al., 2019) ; (Sun et al., 2022) ; (Gao et al., 2019)

Para la calibración de los modelos, se realizó primeramente la validación cruzada dejando uno fuera (leave-one-out cross-validation, más conocido en inglés), a los 46 espectros de campo (20 de corte y 26 de pastoreo). Este método es muy utilizado cuando se tiene un bajo número de muestras disponibles para la construcción de los modelos (Alomar et al., 2015). Se realizaron 3 conjuntos de datos de acuerdo con los lotes de manejo (corte, pastoreo, y corte y pastoreo juntos) para cada combinación de eliminación de ruidos del espectro, de forma que al final se obtuvieron 96 modelos, tal y como se especifica en el diagrama de la Figura 4.



**Figura 4.** Diagrama de aplicación de pretratamientos a los diferentes conjuntos de datos generados, una vez eliminados los datos atípicos.

#### 4.6.2. Construcción del modelo de regresión

Se utilizó el software RStudio con el paquete “rnirs” para identificar la mejor combinación de pretratamientos para el modelo, y luego desarrollarlos en ChemFlow Galaxy. Los modelos se realizaron con el método de estadística multivariado de PLSR, el cual trata con numerosas variables colineales y también cuando la cantidad de longitudes de onda es mayor que la cantidad de observaciones (Wold et al., 2001).

El modelo de calibración se realizó con la técnica de mínimos cuadrados parciales (PLS, por sus siglas en inglés) aplicada a los 24 conjuntos de datos. Posteriormente se aplica el modelo de regresión para predecir los estimados de calidad desconocidos, llamados como grupo de prueba o

validación (Pullanagari et al., 2012). El algoritmo de PLS utilizado fue Kernel, con 4 bloques para validación cruzada. Se utilizó la variable latente que más se acercara al menor error para obtener el modelo. También, de acuerdo con la Ecuación 3,  $Y$  es la variable dependiente, que son los parámetros de calidad del pasto y  $X$  es la variable independiente, que es la reflectancia espectral.

#### 4.7. Objetivo 3: Evaluación de la precisión de los modelos

##### 4.7.1. Evaluación de la precisión de los modelos

La precisión de los modelos de calibración y validación para cada tipo de conjunto de datos y de parámetro de calidad, se evaluó por medio de las mediciones estadísticas de:  $r^2$  y el RMSE. En general, el  $r^2$  indica el grado de colinealidad entre los datos predichos y medidos, y describe el porcentaje de variación de la variable  $X$  en la variable  $Y$  (Pullanagari et al., 2012). Se obtuvieron dos valores de  $r^2$ , uno para el modelo de calibración ( $r^2_c$ ) y otro para la validación cruzada ( $r^2_{cv}$ ). Cabe recalcar que el  $r^2_{cv}$  (coeficiente de determinación de validación cruzada) es el  $r^2$  correspondiente a la predicción del modelo, que se obtuvo utilizando la técnica específica de validación cruzada de “leave-one-out cross-validation”.

La diferencia de la desviación estándar entre los datos medidos y predichos de los parámetros de calidad del pasto, se midieron con el RMSE. El error cuadrático medio de calibración (RMSEC), y el error cuadrático medio de validación cruzada (RMSECV, por sus siglas en inglés), se calcularon con la Ecuación 4. También se utilizó el valor RPD, que corresponde a la relación entre la desviación estándar de los datos de laboratorio, y entre el RMSECV (Ecuación 5), el cual se usa para evaluar qué tan bien el modelo de calibración puede predecir datos cuantitativos (Kawamura et al., 2009). Se establecieron 5 niveles de precisión de la predicción basados en Ikoyi & Younge (2022) y los valores se consideraron según: 1) la recomendación de Biewer et al. (2009), donde un RPD menor de 2,0 se considera aceptable para mediciones en campo, y 2) la indicación de Schimleck et al. (2001), donde valores mayores de 1,5 es considerado satisfactorio y útil para materiales agrícolas en predicciones preliminares. Estos niveles de predicción establecidos son: 1)  $RPD < 1,0$ , no confiable, 2)  $RPD = 1,1 - 1,4$ , poco confiable, 3)  $RPD = 1,5 - 1,9$ , satisfactorio, 4)  $RPD = 2,0 - 2,9$ , muy satisfactorio y 5)  $RPD > 3,0$ , excelente.

También se utiliza la importancia de la variable para la proyección (VIP), la cual se realiza a partir de un PLSR usando algoritmos simples y es calculado por la Ecuación 6. El VIP traduce la importancia de cada longitud de onda en la construcción del modelo PLS. Cuando el valor de  $VIP > 1$  se considera como importante para el desarrollo del modelo (Chong & Jun, 2005), permitiendo que se puedan identificar las bandas más relevantes para obtener información de cada uno de los 4 parámetros de calidad en estudio.

## 5. Resultados y discusión

### 5.1. Análisis de los datos auxiliares recolectados en campo

En la siguiente sección se presentan los resultados obtenidos durante cuatro meses de muestreo, para el pasto estrella africana, donde se evalúan las posibles diferencias significativas. Se evaluaron las variables dependientes (datos auxiliares) altura, biomasa seca y calidad (MS, PC, FDN y FDA) del pasto, y las variables independientes, la edad, ciclo de crecimiento y manejo del pasto (corte y pastoreo). También, este análisis se realizó por subparcela (unidad experimental) de muestreo, correspondiente a un área de 1,5 x 1,5 m<sup>2</sup> en el lote 25 de la EEAVM. En conjunto, se mencionan algunas variables explicativas, también registradas, que son la humedad del suelo, precipitación diaria y radiación incidente, para identificar la posibilidad de irregularidades en el espectro tomado. Finalmente, se discute el preprocesamiento de los datos hiperespectrales, así como las zonas de interés en el espectro.

#### 5.1.1. Altura del pasto

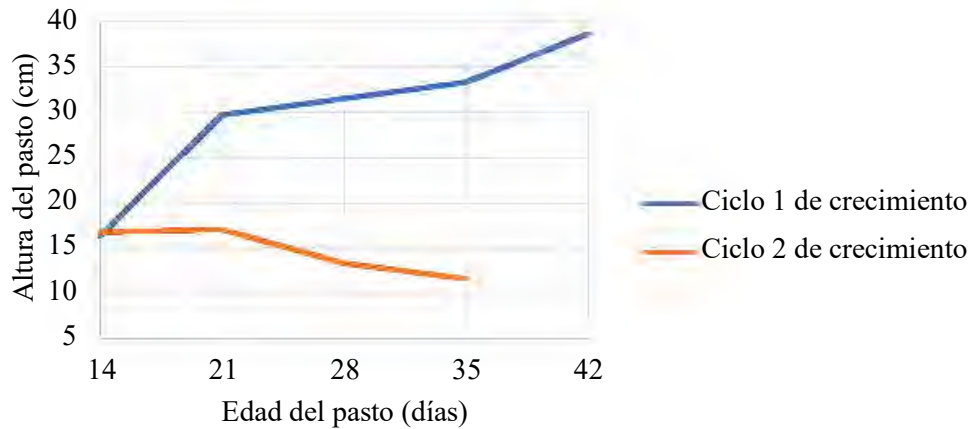
La variable dependiente de altura mostró diferencias significativas ( $p < 0,0001$ ) entre los ciclos de muestreo de cada manejo de pasto, a continuación, se explican los resultados concernientes al manejo de pasto en corte y al manejo de pasto en pastoreo de manera separada.

##### 5.1.1.1. Manejo de pasto en corte

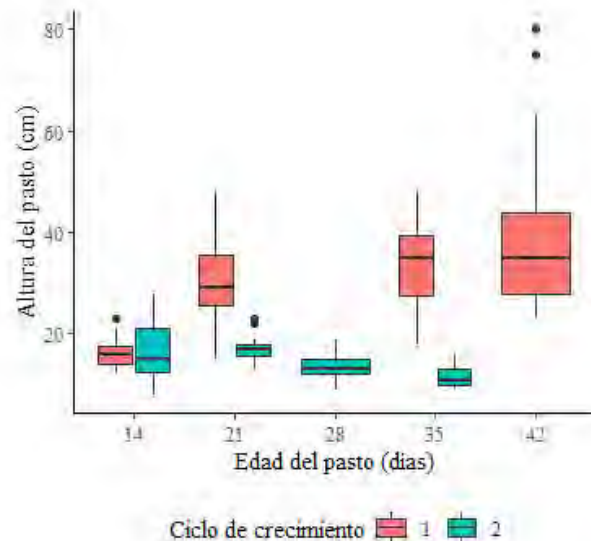
En el lote de pasto donde se manejó bajo corte, se observó una tendencia creciente en la altura del pasto durante el primer ciclo de crecimiento, donde se encontraron los valores más bajos a la edad de 14 días con un promedio de 16,22 cm entre las repeticiones realizadas, y los valores más altos a los 42 días con 38,63 cm (Figura 5). Estos resultados son similares a los reportados por Luna-Cruz (2019), ya que a los 14, 21 y 28 días los valores fueron de 18,73; 24,5 y 30,83 cm, respectivamente. Como se observa en la Figura 6, hubo cierta variabilidad en los datos tomados en campo, especialmente a la edad de los días 35 y 42, con una desviación estándar de 7,82 y 14,41 cm, respectivamente; lo cual se puede deber a las diferencias entre las subparcelas de muestreo.

En el caso del segundo ciclo de crecimiento (Figura 5), las alturas del pasto se presentaron de manera contraria a lo esperado y disminuyeron a medida que aumentaba la edad de rebrote. Los valores más altos se registraron en los días 14 y 21, con un promedio de 16,74 y 17,04 cm, respectivamente; mientras que el valor más bajo se registró en el día 35 con un promedio de 11,59 cm. Aunque los datos obtenidos en campo no mostraron una desviación estándar importante (Figura 6), no se observó un aumento constante de la altura del pasto a medida que avanzaba la edad de rebrote, como se esperaría. Esta falta de crecimiento se pudo deber a la disminución en la precipitación del ciclo 2, tal como se observa en la Figura A1, la cual no fue sustituida con riego.





**Figura 5.** Gráfico de los promedios de altura para cada edad de crecimiento en el lote de corte, para ambos ciclos de muestreo.

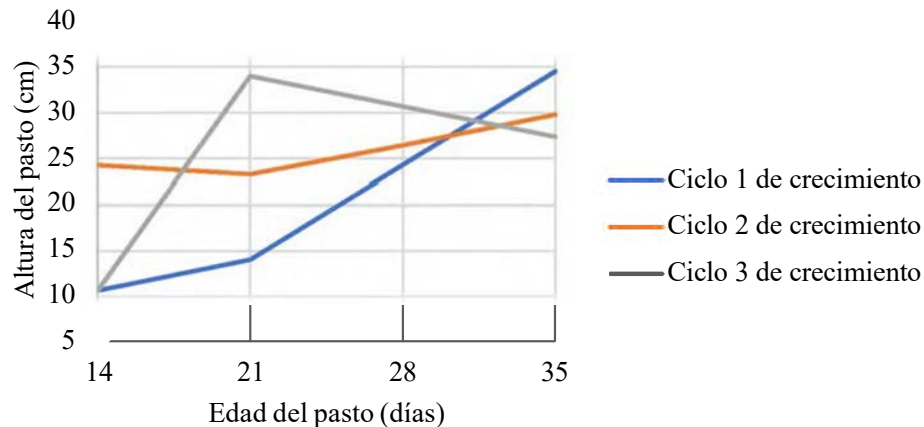


**Figura 6.** Gráfico de cajas de la altura de los 9 valores por subparcela en el lote de corte para ambos ciclos de muestreo.

Al realizar una comparación entre la altura del pasto del ciclo de crecimiento 1 y 2, se obtuvo que si hay diferencias significativas ( $p < 0,05$ ) con la prueba estadística de Tukey, ya que el promedio de los datos del ciclo 1 es de 29,45 cm y del ciclo 2 de 14,68 cm (Tabla A3). Esta diferencia se atribuye principalmente a que las subparcelas eran diferentes entre ellas, ya que el pasto no puede decrecer como tal. Adicionalmente, la precipitación acumulada de todo el ciclo 1 fue de 519,6 mm, y para el ciclo 2 de 313,0 mm, provocando que el agua disponible para el desarrollo vegetativo de la planta disminuyera.

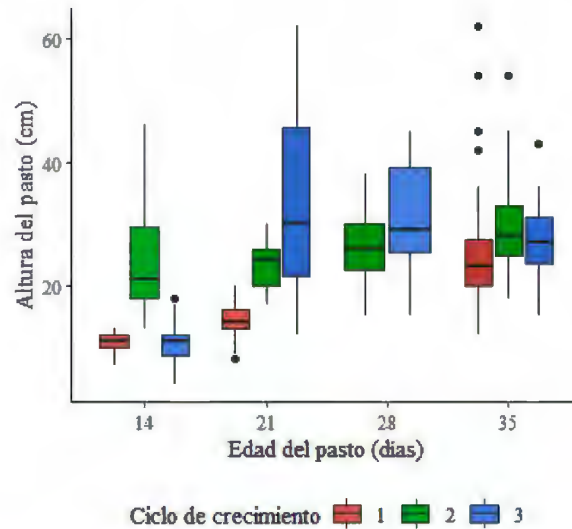
### 5.1.1.2. Manejo de pasto en pastoreo

En el lote de pasto donde se manejó bajo pastoreo, se observó que en los datos de altura de pasto hubo gran variabilidad, ya que, al ser pastoreado y no cortado, las vacas no lo cosechan uniformemente. En el primer ciclo de crecimiento, se presentó la máxima altura entre ciclos, que fue de 34,52 cm en el día 35. También, tanto el ciclo 1 de crecimiento como el 2, mantuvieron una tendencia creciente con respecto a la edad del forraje (Figura 7). Al analizar el segundo ciclo de crecimiento, se obtuvo la mayor altura del pasto en el día 35 con 30 cm; sin embargo, fue el ciclo con el forraje más bajo, ya que la precipitación acumulada de todo el ciclo fue la menor con 161,4 mm (Figura A2).



**Figura 7.** Gráfico de los promedios de altura para cada edad de crecimiento en el lote de pastoreo, para ambos ciclos de muestreo.

El ciclo 3 mostró la mayor variabilidad en los datos de altura de pasto recolectados en el campo, como se puede apreciar en el gráfico de cajas de la Figura 8; también cabe recalcar que en el ciclo 1 solo se pudieron realizar 3 mediciones (días 14, 21 y 35) por anomalías en el clima a causa de la tormenta tropical Bonnie del 1 de julio del 2022. Además, el día 21 fue reportado como el de mayor altura en todo el ciclo, con 34 cm, y luego continuó con una tendencia decreciente a medida que aumentaba el tiempo de muestreo. Esta tendencia anormal en la altura del pasto se debe a una mayor incidencia de boñigas en algunas subparcelas, igual que la presencia de hierbas como el ruibarbo (*Rumex alpinus*), trébol blanco y mozotillo (*Achyranthes aspera L.*) (Figura 9).



**Figura 8.** Gráfico de cajas de la altura de los 9 valores por subparcela en el lote de pastoreo para los tres ciclos de muestreo.



**Figura 9.** Factores variantes en las parcelas, donde a) es la subparcela del lote de pastoreo, ciclo 3 de crecimiento, 35 días de edad, con 27,33 cm de altura promedio y con presencia de boñiga, b) es la hierba ruibarbo (*Rumex alpinus*), y c) es la hierba mozotillo (*Achyranthes aspera* L.) presente en el lote de pastoreo.


Por medio del análisis de varianza, se obtuvo que, hay diferencias significativas entre ciclos ( $p < 0,0001$ ). Al realizar la prueba Tukey, se identificó que existen diferencias significativas entre el ciclo 1 de crecimiento con respecto a los ciclos 2 y 3, y que no hay diferencias entre el ciclo 2 y 3 de crecimiento. Esto se debe a que el promedio de las aturas del pasto fue de 15,13; 24,64 y 25,67 cm, para el ciclo 1, 2 y 3, respectivamente (Tabla A3).

Finalmente, al realizar la interacción entre el manejo (corte y pastoreo) y la edad, no se obtuvo diferencias significativas ( $p = 0,2196$ ), lo que demuestra que a pesar de que los lotes varían en cuanto a fertilidad, compactación, hierbas u otros factores, la altura del pasto fue consistente en ambos tipos de manejo conforme aumentó la edad de crecimiento.

## 5.1.2. Producción de biomasa seca

### 5.1.2.1. Manejo de pasto en corte

Para el primer ciclo de crecimiento, se registró el valor más alto de biomasa seca a los 35 días con un promedio de 5,20 ton/ha, y el valor más bajo a los 21 días con 2,71 ton/ha (Figura 10). Estos valores de biomasa seca son menores a los reportados por Ferrufino et al. (2022) (6,14 ton/ha para el día 35 y 4,06 ton/ha para el día 21) en estrella africana en la misma EEAVM.



**Figura 10.** Datos de biomasa seca del pasto con manejo de corte, para los dos ciclos de crecimiento analizados.

En el ciclo 2, el día 21 es el más alto con 2,98 ton/ha y el más bajo es el día 28 con 1,81 ton/ha, mientras que se esperaba que el tope de biomasa sea a la edad mayor de 35 días. Al comparar con el día 35 del ciclo 1 de crecimiento (5,20 ton/ha), en el ciclo 2 se obtuvo aproximadamente un 60% menos biomasa seca (2,09 ton/ha). Teniendo esto en consideración, se obtiene que hay diferencias significativas ( $p=0,0001$ ) entre la biomasa seca entre ciclos. En la Figura 11 se aprecia de forma visual la diferencia de altura y biomasa entre ciclos, con fotografías de dos subparcelas de muestreo para el ciclo 1 y 2, ambos con 35 días de edad. Finalmente, al realizar interacciones con cada ciclo y la edad, se obtiene que en todas las edades del ciclo 1 no hay diferencias significativas, y sucede lo mismo con el ciclo 2 (Tabla A6).



**Figura 11.** Factores variantes en las subparcelas del lote de corte, donde a) es el ciclo 1 de 35 días, con 33,30 cm de altura promedio en los 9 subpíxeles, y b) es el ciclo 2 de 35 días, con 11,59 cm de altura promedio en los 9 subpíxeles.

Las incongruencias en la falta de aumento de la biomasa a través del tiempo se pueden explicar con la precipitación acumulada en la misma edad de rebrote. Entre los días 21 y 35, esta fue en total de 53,60 mm en el ciclo 2, mientras que en el ciclo 1, para esos mismos días de rebrote fue de 109,80 mm (consultar Figura A1). Los autores Taffarel et al. (2016) concluyeron que con edades superiores se pueden obtener mayores producciones de biomasa, que es lo contrario a lo sucedido en ambos ciclos de muestreo debido a la escasez hídrica.

Dado que las mediciones de biomasa en las subparcelas se realizaron de manera aleatoria y tenían distintas ubicaciones para cada ciclo, es importante considerar que las diferencias en biomasa se deben a varias razones. Primeramente, algunos subpíxeles mostraron una mayor cantidad de biomasa en comparación con otros subpíxeles dentro de la misma subparcela, lo cual puede atribuirse a la presencia de hierbas o suelo desnudo en esas áreas específicas, tal como sucede en el ciclo 1 que presentó hierbas adicionales como el trébol blanco (Figura 12). Segundo, la variabilidad en la toma de datos en campo también contribuyó a estas diferencias, ya que cada semana la subparcela de muestreo correspondiente presentaba características distintas, como hierbas, macollas de estrella africana más fuertes que otras, o alguna posible fertilidad del suelo distinta, aunque esta variable no se midió. La fertilidad del suelo es uno de los primordiales factores que afectan el crecimiento y rendimiento del pasto, ya que los principales nutrientes que requiere la planta para su desarrollo son el nitrógeno, fósforo y potasio, que provienen de un suelo sano (Sierra B., 1992).



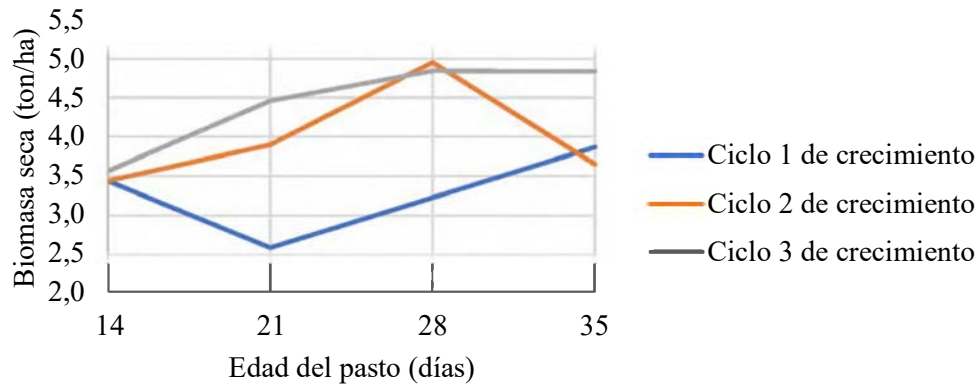
**Figura 12.** Leguminosa trébol blanco (*Trifolium repens*) presente en el lote de manejo de corte.

#### 5.1.2.2. Manejo de pasto en pastoreo

En el ciclo 1, se obtuvieron los valores más bajos de biomasa seca en comparación con los otros dos ciclos, puesto que en el día 21 disminuyó a 2,59 ton/ha, lo cual es 20% más bajo que el valor de biomasa reportado por Ferrufino et al. (2022). La disminución de biomasa en comparación con los otros dos ciclos (Figura 13), pudo ocurrir ya que, durante el ciclo 1 se dio la tormenta tropical Bonnie, afectando las condiciones normales del clima (por ejemplo, la radiación) y por ende la cantidad de forraje por m<sup>2</sup>. También, esta disminución de biomasa se atribuye a que en el día 21 la subparcela muestreada tenía boñiga y hierbas, afectando la biomasa disponible de estrella africana.

En el ciclo 2, la biomasa alcanzó su tope en el día 28, ya que la precipitación acumulada entre el día 21 y 28 fue de 89,60 mm; pero para el día 35 disminuyeron las lluvias considerablemente (21,60 mm entre fechas), ocasionando que la biomasa pasara de 4,95 ton/ha a 3,65 ton/ha. Este tope de biomasa supera en un 22% los resultados de biomasa seca obtenidos por Sánchez-Hernández (2022) en época lluviosa, igualmente para un lote de pastoreo.

La biomasa seca del ciclo 3 mostró un comportamiento creciente a lo largo del tiempo, lo que indica un aumento en la producción a medida que avanzaba el ciclo, siendo este comportamiento el esperado durante esta investigación. Este ciclo alcanzó su máximo rendimiento con 4,83 ton/ha a los 35 días de crecimiento, como se observa en la Figura 13. El aumento en el rendimiento se debe al período de tiempo del ciclo comprendido entre el 26 de agosto y el 1 de octubre, donde la lluvia acumulada alcanzó los 461,6 mm, superando la precipitación acumulada y la frecuencia de los dos ciclos anteriores.



**Figura 13.** Datos de biomasa seca del lote de pastoreo, para los tres ciclos de crecimiento analizados.

Para el caso de la biomasa seca, el ciclo 1 y 3 son significativamente diferentes, pero el ciclo 2 tiene similitudes tanto con el ciclo 1 como con el ciclo 2. Cabe destacar que, en un sistema de pastoreo, el material residual (remanente de pastoreos anteriores) se incluye en las estimaciones de biomasa disponible, llegando a representar hasta 55,04% de la biomasa (Villalobos & Arce, 2013).

En la Tabla A2, se observa que, al comparar las variables independientes de manejo de corte y pastoreo, se cumple lo estipulado por Villalobos & Arce (2013), en el caso de que hay diferencias significativas entre los dos tipos de manejo ( $p=0,0004$ ). Esta diferencia se debe a que la biomasa en pastoreo es mayor, por un 21,15% al manejo de corte. También, se reportaron diferencias significativas al realizar la ANOVA entre los diferentes ciclos al considerar la edad ( $p=0,0496$ ), lo cual se debe a las diferencias entre precipitación (variable temporal) y ubicación de cada parcela grande, así como a la poca uniformidad que se da en un lote de pastoreo.

No solo esta investigación se ha visto afectada en el crecimiento y rendimiento del forraje, sino que es una problemática a nivel nacional que desde hace varios años ha implicado un reto para los productores ganaderos. Según los datos de la Cámara Nacional de Productores de Leche (CNPL), desde el 2019 hasta enero de 2023 los fertilizantes aumentaron su precio un 220%. Sin embargo, para ese mismo lapso, se unen otras condiciones como el impacto en el cambio climático a causa de los fenómenos El Niño y La Niña (Rodríguez, 2023). Como consecuencia de ambos factores, los pastos no han tenido un crecimiento usual, y, por ende, la producción de leche ha disminuido.

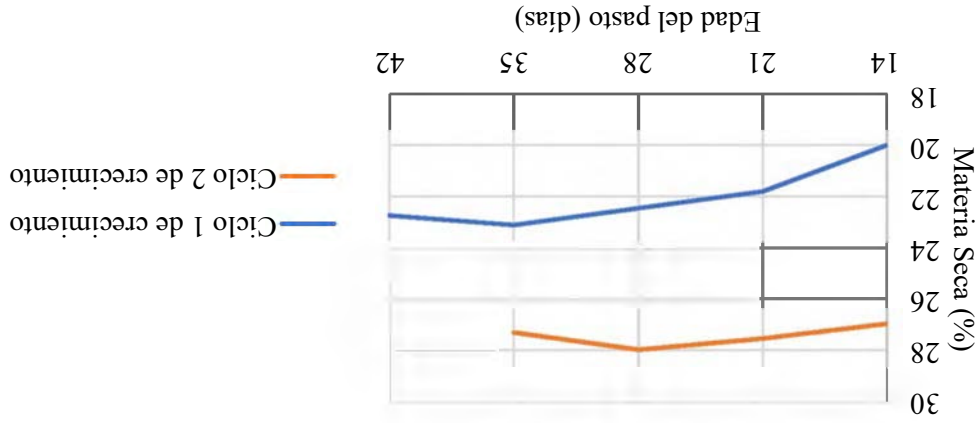
Diversos factores influyen en el rendimiento de los cultivos, siendo el agua el principal, puesto que, cuando esta no se suministra en las cantidades requeridas, se afecta el crecimiento y rendimiento (Ruiz-Álvarez et al., 2011). Según Ismail & Depeweg (2005), la magnitud de afectación varía según la especie y la etapa de crecimiento, pero todos los cultivos presentan mayor sensibilidad al déficit hídrico durante la emergencia, floración y formación de granos.

### 5.1.3. Calidad del pasto

A continuación, se muestran los cuatro parámetros de calidad de forraje evaluados por medio de química húmeda en el laboratorio de bromatología de la EFAVM, los cuales son la MS, PC, FDN y FDA. En la variable independiente de manejo, se obtuvo que, existen diferencias significativas entre el manejo de corte y pastoreo, para los parámetros de calidad de PC, FDN y FDA con un valor de  $p=0,0008$  para PC y  $p<0,0001$  para ambas fibras (Tabla A2). También, se obtuvo que, para los cuatro parámetros de calidad, al realizar interacciones entre manejo:edad y ciclo:edad, no hay diferencias significativas (Tabla A2), lo cual presenta posibles incongruencias en el desarrollo de las plantas a lo largo del tiempo.

#### 5.1.3.1. Materia seca (MS)

La MS del lote de corte presenta diferencias significativas ( $p<0,0001$ ) entre ciclos, esto se relaciona con lo estipulado anteriormente con la biomasa seca. En la Figura 14, se observa para ambos ciclos de crecimiento que la MS incrementa con el tiempo en las primeras tres edades de muestra. Sin embargo, al final de ambos ciclos se ve un decrecimiento en la MS, lo cual se debe al aumento en la precipitación para esas edades de muestra, por ende, aumenta el contenido de agua en la planta (0,37% para el ciclo 1 y 0,67% para el ciclo 2) (Tabla D3) y disminuye la MS. Es relevante considerar la radiación solar incidente, que en este caso disminuyó entre los días 35 y 42 del ciclo 1 y entre los días 28 y 35 del ciclo 2. Este factor influyó notablemente en los procesos de fotosíntesis y desarrollo de las plantas (Muñoz-González et al., 2016).



**Figura 14.** Datos de los patrones de calidad de análisis bromatológico del lote con manejo de corte, para la materia seca (MS); del primer ciclo de crecimiento y del segundo ciclo de crecimiento.


Los resultados de los análisis de materia seca (MS) para el lote de pastoreo se presentan de manera gráfica en la Figura 15. Contrario a las expectativas, los valores de MS no exhiben una tendencia lineal con respecto al tiempo, sino que muestran oscilaciones a medida que progresa la edad en los tres ciclos de muestreo durante el crecimiento. Este patrón oscilante se repite en los ciclos 2 y 3 de crecimiento, caracterizado por una disminución en el día 21, seguida de un aumento en el día 28 y



nuevamente una disminución en el día 35. Cabe resaltar que en el ciclo 1, no se dispone de datos para el día 28 debido a la influencia de la tormenta tropical Bonnie el 1 de julio de 2022.

La precipitación acumulada entre los días de muestreo, mostrada en la Figura A2 presenta una tendencia similar a la MS en los ciclos 2 y 3 de la (Figura 15), exhibiendo picos altos en el día 28 y valores bajos en los días 21 y 35. Específicamente, se observaron picos de precipitación acumulada de 89,60 y 118,60 mm en el día 28 para el ciclo 2 y el ciclo 3, respectivamente.

Los resultados promedio de MS fueron de 28,13; 26,79 y 22,38% para los ciclos 1, 2 y 3, respectivamente, coincidiendo de manera cercana con el promedio obtenido por Ferrufino et al. (2022) de 23,20%. Según el ANOVA de dos vías, se encontraron diferencias significativas entre ciclos ( $p < 0,0001$ ). Sin embargo, con base en el análisis de Tukey, no se encontraron diferencias significativas entre los ciclos 1 y 2, pero si hay diferencias en el ciclo 3, con respecto a los ciclos 1 y 2. Los valores más altos de MS se registraron en el ciclo 1 con 28,82% en la edad del día 35, y el ciclo 2 con el mismo valor, pero en su día 28.

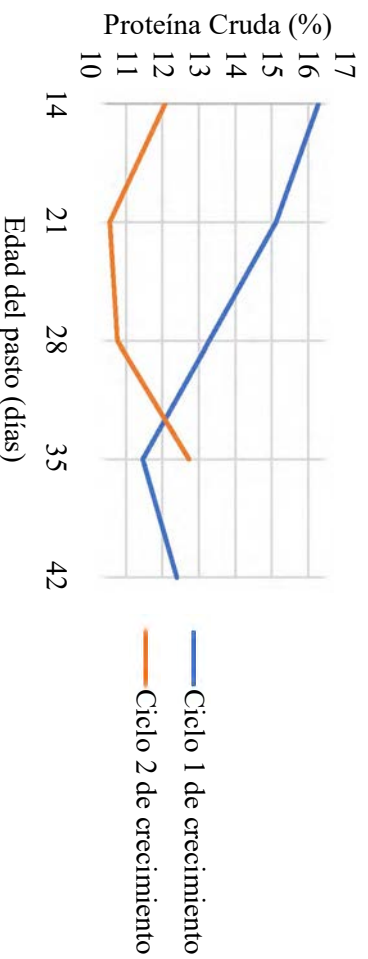


**Figura 15.** Datos de los patrones de calidad de análisis bromatológico del lote de pastoreo, para la materia seca (MS); del primer ciclo de crecimiento, del segundo ciclo de crecimiento y del tercer ciclo de crecimiento.

### 5.1.3.2. Proteína cruda (PC)

En el lote destinado al manejo de corte, representado en la Figura 16, se puede observar el comportamiento de la PC para el ciclo de crecimiento 1. Se evidencia la tendencia esperada de decrecimiento conforme avanza la edad, alcanzando su punto más bajo al día 35. Sin embargo, en el ciclo 2 de crecimiento, se presenta una leve modificación en la tendencia a partir del día 21, donde la concentración de PC comienza a aumentar con la edad del pasto. De acuerdo con Toro Velázquez et al. (2010) la PC se reduce conforme aumenta la edad de crecimiento, debido a un efecto de dilución producto del crecimiento vegetativo de la planta, en el que a mayor madurez aumenta el contenido de carbohidratos estructurales y disminuye el contenido de nitrógeno en la planta.


Debido a que al finalizar ambos ciclos se presenta un comportamiento ascendente de la concentración de PC, en el análisis de Tukey se concluye que no existen diferencias significativas entre estos ciclos, registrando un promedio de 13,81% para el primer ciclo de crecimiento y un 11,53% para el segundo ciclo de crecimiento. Cabe destacar que el rango límite necesario de PC para una fermentación ruminal óptima oscila entre el 6 al 8% de PC (Monção et al., 2016). En consecuencia, se infiere que la cosecha óptima para ambos ciclos pudo haberse efectuado en el día 49. Este análisis considera que, a partir del día 28, la disminución diaria del contenido proteico podría alcanzar un valor de 0,32%, conforme lo establecido por Ferrufino et al. (2022) en la misma EEAVM con estrella africana.



**Figura 16.** Datos de los patrones de calidad de análisis bromatológico del lote de corte, para la proteína cruda (PC); del primer ciclo de crecimiento y del segundo ciclo de crecimiento.

En el lote destinado al pastoreo, se identificaron ciertas irregularidades en la concentración de PC. En el ciclo 1, se observó un comportamiento decreciente de la PC, como era esperado (Ferrufino et al., 2022), registrando un 9,23% en el día 35 (Figura 17). Por otro lado, el ciclo 2 mostró un comportamiento oscilante, mientras que en el ciclo 3 se observó una disminución hasta el día 28, alcanzando un 9,84%. Cabe mencionar que, bajo condiciones de mayor radiación, la PC tiende a reducirse en conjunto con el contenido de carbohidratos solubles (Hernández et al., 2005), fenómeno que se evidenció en el ciclo 2, el cual presentó los picos más altos de radiación con 3,18 MJ/m<sup>2</sup> (Figura A4) y la PC más baja (9,24%).

Es relevante destacar la ausencia de diferencias significativas entre ciclos ( $p=0,0877$ ), dado que el promedio de los datos de los tres ciclos se aproxima al 10% de PC. Según Reuter de Oliveira et al. (2014), la reducción en el contenido proteico en pastos se atribuye al aumento en la pared celular. No obstante, los resultados de altura y biomasa indican que no hubo un crecimiento uniforme en la pared celular en las subparcelas muestreadas, lo que conllevó a una falta de disminución consistente en la PC a lo largo del tiempo. Además, es notable mencionar que no se hallaron diferencias significativas en cuanto a la edad ( $p=0,3034$ ) (Tabla A2), reafirmando la posible presencia de incongruencias en el desarrollo a lo largo del tiempo.




**Figura 17.** Datos de los patrones de calidad de análisis bromatológico del lote de pastoreo, para la proteína cruda (PC); del primer ciclo de crecimiento (1), del segundo ciclo de crecimiento (2) y del tercer ciclo de crecimiento (3).

### 5.1.3.3. Fibra detergente neutro (FDN) y fibra detergente ácido (FDA)

Los resultados correspondientes a la FDN y FDA en el lote con manejo de pasto de corte, se presentan en la Figura 18, donde se esperaría que ambas fibras tengan un comportamiento creciente con respecto a la edad del forraje. Sin embargo, esta expectativa solo se cumple para la FDN del ciclo 1, mientras que la FDA en este mismo ciclo se mantiene en un rango constante entre 33,88 y 32,87% durante el período estudiado. Estos valores se aproximan a los esperados en la literatura, que oscilan entre 30-34% (Johnson et al., 2001). En el ciclo 1, el crecimiento del forraje conllevó a su maduración, lo que a su vez posibilitó el aumento de la fibra y a una posible disminución del potencial de ingesta a lo largo del tiempo, sin embargo, este último parámetro no se midió, pero está relacionado (Ball et al., 2017).

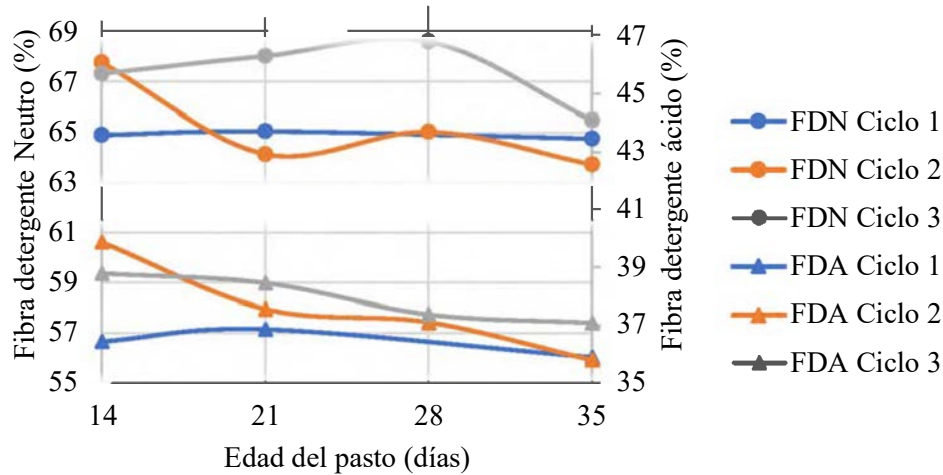
En cuanto a la FDN, no se encontraron diferencias significativas entre ciclos al realizar la prueba Tukey, evidenciando un promedio de 61,62% para el ciclo 1 y 63,57% para el ciclo 2, los cuales son menor y mínimo de acuerdo con los valores que se esperan de FDN para estrella africana en la literatura (63-77%) (MAG, 2006). En contraste, la FDA mostró diferencias significativas entre los ciclos de crecimiento 1 y 2 ( $p < 0,05$ ). Una posible explicación radica en la disminución de la radiación solar incidente entre los días 28 y 35 del ciclo de crecimiento 2, fenómeno que incidió en la celulosa y lignina presentes en el forraje, inhibiendo su adecuado crecimiento vegetativo durante dicho ciclo.



**Figura 18.** Datos de los patrones de calidad de análisis bromatológico del lote de corte, para la fibra detergente neutro (FDN) y fibra detergente ácido (FDA); ambos del primer ciclo de crecimiento y del segundo ciclo de crecimiento.

Los resultados correspondientes a la FDN y FDA en el lote con manejo de pastoreo se observan en la Figura 19, donde se esperaría un incremento progresivo; sin embargo, ocurre lo contrario, ya que ambas fibras disminuyen con respecto a la edad de crecimiento, lo que significa un posible aumento en la digestibilidad del pasto. Asimismo, se reafirma que el crecimiento en la pared celular fue moderado, dado que solo la FDN en el ciclo 3 evidenció un aumento, pasando de un 67,33% en el día 14 a un 68,60% en el día 28.

El pasto estrella africana tiende a producir mayor cantidad de material senescente, lo cual resulta en que los animales consuman principalmente rebrotes tiernos en el dosel de la pastura sin alcanzar el estrato inferior (Andrade, 2006). Este material senescente tiene mayor pared celular y por ende más fibra, pero se forma cuando hay altas tasas de crecimiento (Fulkerson & Slak, 1993), tal y como sucedió en el ciclo 3. En la Figura A5, se observan fotografías tomadas el día 14 del ciclo 3 de crecimiento de pastoreo, donde se aprecia material senescente que no fue comido por el ganado, y precisamente fue el ciclo registró el mayor promedio de FDN entre ciclos con un valor de 67,36%. También cabe resaltar que no se observaron diferencias significativas entre ciclos al realizar la prueba Tukey, tanto para la FDN como para la FDA, indicando que la variación en la temporalidad y el cambio de área para cada ciclo no impactaron en estas fracciones de fibra.



**Figura 19.** Datos de los patrones de calidad de análisis bromatológico del lote de pastoreo, para la fibra detergente neutro (FDN) y fibra detergente ácido (FDA); del primer ciclo de crecimiento, del segundo ciclo de crecimiento y del tercer ciclo de crecimiento.

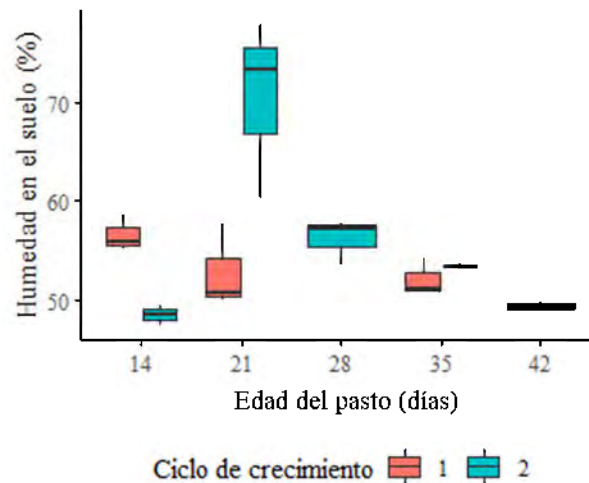
La Tabla A2, revela diferencias significativas al comparar las variables independientes de manejo entre corte y pastoreo, específicamente en ambas fracciones de fibra ( $p < 0,0001$  para ambas fibras). Esta diferencia se origina porque la FDN en el lote de corte es en promedio de 62,60% y en el lote de pastoreo de 65,89%, lo cual se confirma con la investigación de Pincay-Figueroa, et al. (2016), quienes también obtuvieron valores superiores, donde la FDN aumentó un 2,3% en el lote de pastoreo. A diferencia, los mismos autores señalaron una disminución de 1,2% en la FDA en el lote de pastoreo, contrastando con los datos presentados en la Tabla A2, donde la FDA en el lote de corte promedia un 35,16%, mientras que en el lote de pastoreo asciende a un promedio de 37,39%, indicando un aumento en el lote de pastoreo.

Con respecto a la edad de rebrote, se observaron diferencias significativas en la FDA con un  $p = 0,0085$ . Este hallazgo concuerda con la investigación de Jiménez-Castro (2018), quien también obtuvo diferencias significativas en el contenido de FDA en pasto estrella africana, entre los días 14 y 56 de crecimiento durante la época lluviosa. No obstante, cabe mencionar que estos autores obtuvieron un aumento de la FDA, no una disminución como se observa en las Figura 19. Con respecto a los cambios en la composición de la pared celular, en pastos como la estrella africana, la fracción de hemicelulosa disminuye conforme avanzan los días de cosecha, mientras que la celulosa y lignina aumentan (Mandevu et al., 1999), pero en esta investigación más bien disminuyeron estos dos últimos (relacionados con la FDA). Sin embargo, de acuerdo con la digestibilidad del pasto y su aporte de energía, es preferible que el contenido de FDA sea bajo en pastos (Jiménez-Castro, 2018).

#### 5.1.4. Humedad del suelo


Los resultados de la humedad del suelo realizados con la prueba gravimétrica se muestran en la Figura 20 para el lote de corte, y en la Figura 21 para el lote de pastoreo; estos se encuentran a 20 cm de profundidad. En ambos gráficos de cajas se observa que hubo variabilidad en los datos, especialmente porque, de acuerdo con la prueba de textura de suelo, en los primeros 30 cm de profundidad se muestra un suelo franco arcilloso, donde debido a su composición, deberían tener un máximo de 55% de humedad de suelo según los valores (obtenidos con el software SPAW). Sin embargo, se resalta que los datos para construir las ecuaciones de pedotransferencia en el SPAW son con suelos de Estados Unidos que en muchos casos no contienen los niveles de ceniza que se pueden encontrar en suelos volcánicos costarricenses. La prueba de textura de suelo de la calicata en el horizonte 1 a 30 cm de profundidad, indica que hay un 45% de arena, 20% de limo y 35% de arcilla, además se cuenta con y 35% de poros en el suelo.

Como mencionado anteriormente, se puede observar que la mayoría de los valores del lote de corte se encuentran entre 47,40 y 77,80%, sin embargo, es muy probable que los valores del día 21 del ciclo 2 muestren algún error humano, que impidió dar un resultado menor. El promedio de todos los datos medidos es de 55,07%, y si se elimina el ciclo 2 del día 21, el promedio es de 52,97% acercándose al valor obtenido con el software SPAW. La EEAVM se ubica a aproximadamente 14 km del Volcán Irazú, por lo que es posible la presencia de cenizas en el suelo, estas cenizas volcánicas con comportamiento arenoso (componente principal de los suelos en estudio), tienen gran capacidad de retención de agua (Dörner et al., 2010).



**Figura 20.** Gráfico de cajas de la humedad en el suelo en el lote de corte para los dos ciclos de crecimiento.

En el lote de pastoreo, los resultados fueron similares, ya que el promedio de todos los datos fue de 54,95%, e igualmente se encuentran algunos picos, como en los días 21 y 35. Una posible causa del aumento en la humedad del suelo para este lote, puede ser por el contenido de materia orgánica (boñiga y orina) que proveen las vacas, lo cual cambia la composición del horizonte 1, provocando que sea alto en carbono orgánico y aumente la retención de agua en el suelo (Nyamangara et al., 2001).



**Figura 21.** Gráfico de cajas de la humedad en el suelo en el lote de pastoreo para los tres ciclos de crecimiento.

## ***5.2. Análisis de los datos hiperespectrales recolectados en campo***

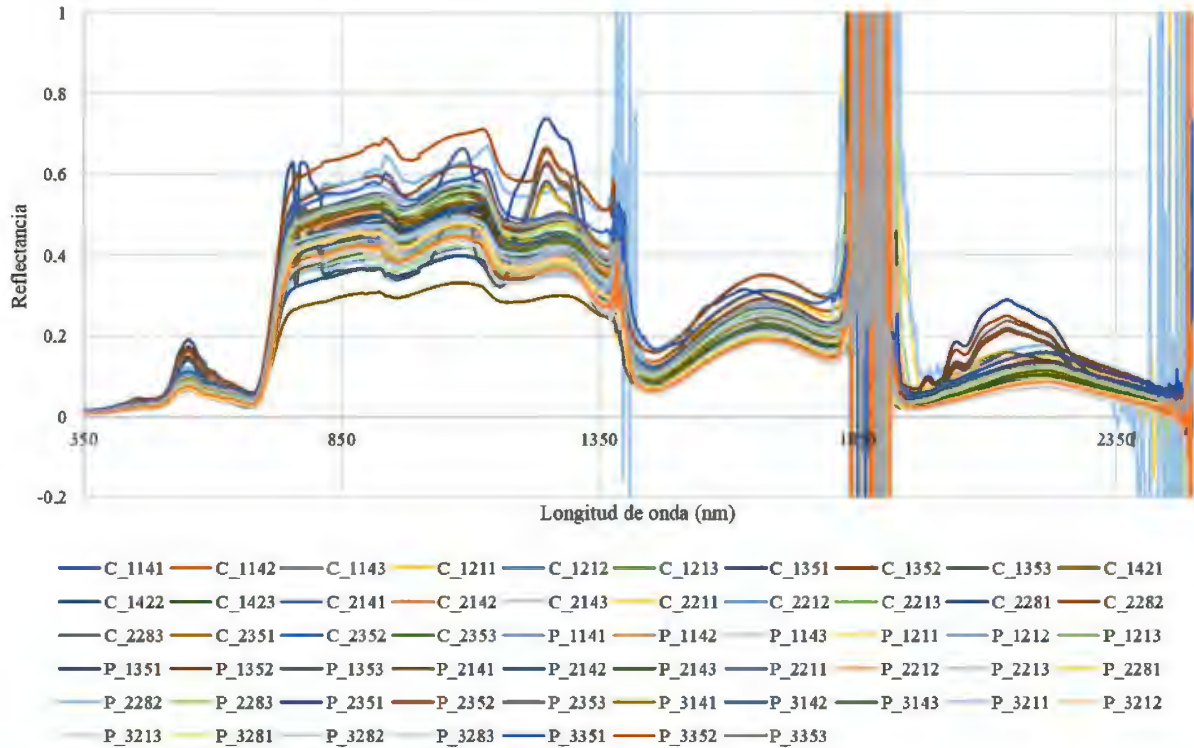
En la Figura 22, se observan los promedios de los espectros de cada subparcela, tomados en campo en reflectancia (R), y en la Figura 23 se aprecian los datos en absorbancia ( $\text{Log}(1/R)$ ). Cada dato se representa de acuerdo con el manejo (corte o pastoreo), ciclo de crecimiento (1, 2 o 3), edad del pasto (14, 21, 28, 35 o 42 días), y repetición (1, 2 o 3); la nomenclatura de los datos se realizó con el orden mencionado. Un ejemplo de nomenclatura de dato es C\_1423, donde “C” corresponde a corte, “1” al ciclo 1 de crecimiento, “42” a la edad del pasto de 42 días, y “3” es la tercera repetición realizada.

En ambos gráficos se identifica el ruido que existe en los datos hiperespectrales debido a las condiciones atmosféricas, especialmente en las zonas de los 1.400, 1.800 y 2.500 nm. En estas franjas es donde se identifica la humedad (Mishra et al., 2017), debido al alto contenido de agua en las plantas vivas. Según las pruebas realizadas en el laboratorio, el pasto estrella africana muestreado tiene contenidos de agua en promedio de 74,73%, además, en campo las hojas presentan evapotranspiración y en algunas ocasiones por la temporada de lluvias se tenían aumentos de la humedad atmosférica (alrededor del 97%), causando que el equipo detecte con mayor facilidad el agua incidente.


En la Figura 22, hay ciertos espectros que se muestran fuera de la tendencia, principalmente los espectros tomados el 19 de agosto con errores de la calibración en el blanco del equipo. Estos corresponden al ciclo 2 del día 35 del lote de pastoreo y al ciclo 2 del día 28 del lote de corte. También, los espectros del día 21 del ciclo 1 de pastoreo muestran un ruido particular en la zona de 1.900-2.000 nm, lo cual se puede deber a la humedad relativa del aire en el momento de la medición, que fue de 97%.

En los siguientes pasos se mostrará la identificación de los datos atípicos para posteriormente removerlos con ayuda del PCA, así como la eliminación de ciertos rangos espectrales debidos a los ruidos.





**Figura 22.** Espectro general de los datos de corte y pastoreo juntos, en reflectancia, sin pretratamientos.



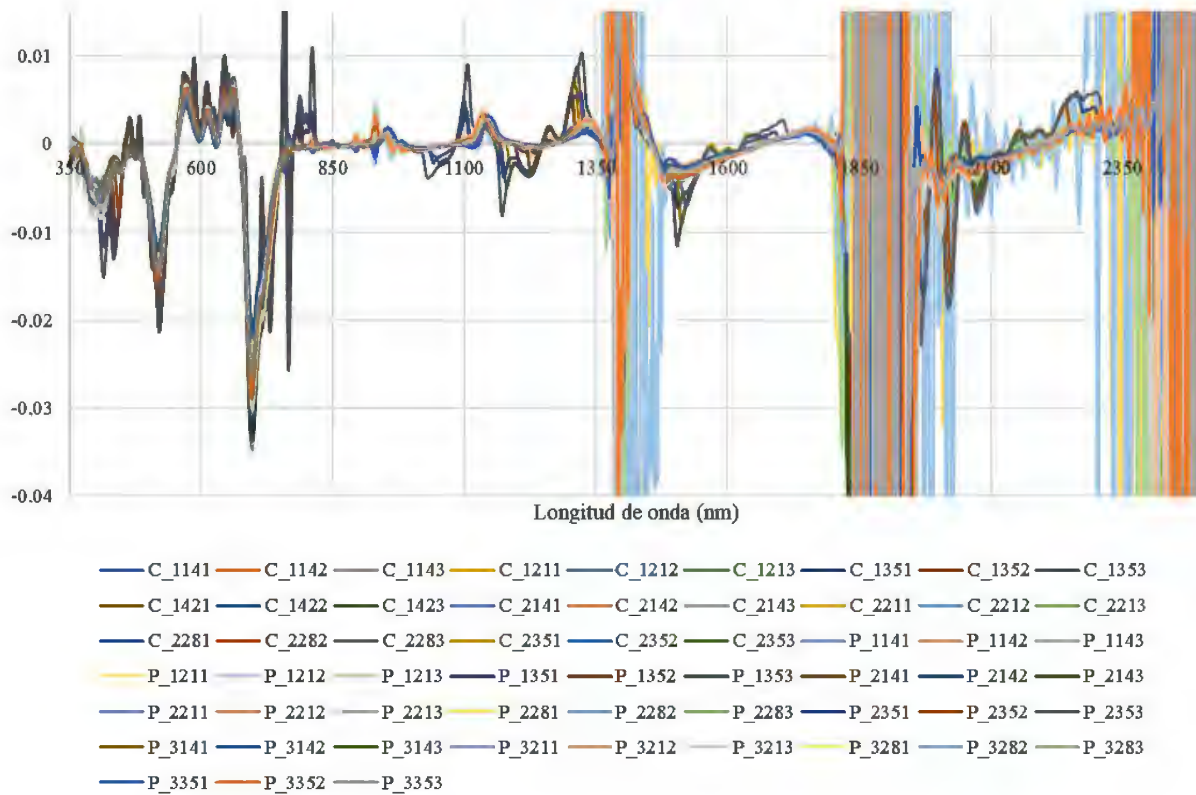
**Figura 23.** Espectro general de los datos de corte y pastoreo juntos, en absorbancia, sin pretratamientos.

### *5.3. Eliminación de los datos atípicos*

Una vez que se obtuvieron los espectros en absorbancia, se procedió a aplicar dos combinaciones de pretratamientos: 1) la primera derivada con el algoritmo Savitzky-Golay, y 2) la primera derivada con el algoritmo Savitzky-Golay en conjunto con la SNV. Luego, se aplicó una primera eliminación de ruidos en las zonas ubicadas en 1.357-1.479, 1.790-1.985 y 2.300-2.500 nm, con base en las regiones del espectro que contenían interferencia de ruidos a causa del agua en las hojas, del vapor de agua en el aire y entradas de luz. Seguidamente, se realiza un PCA con 20 componentes principales para identificar el conjunto de datos representativos, con los pretratamientos más aptos, y se analizan solamente los primeros 4 componentes principales. De esta manera, se logra obtener un nuevo conjunto de datos más limpio, y que proporciona un modelo más estable para los parámetros de calidad en estudio.

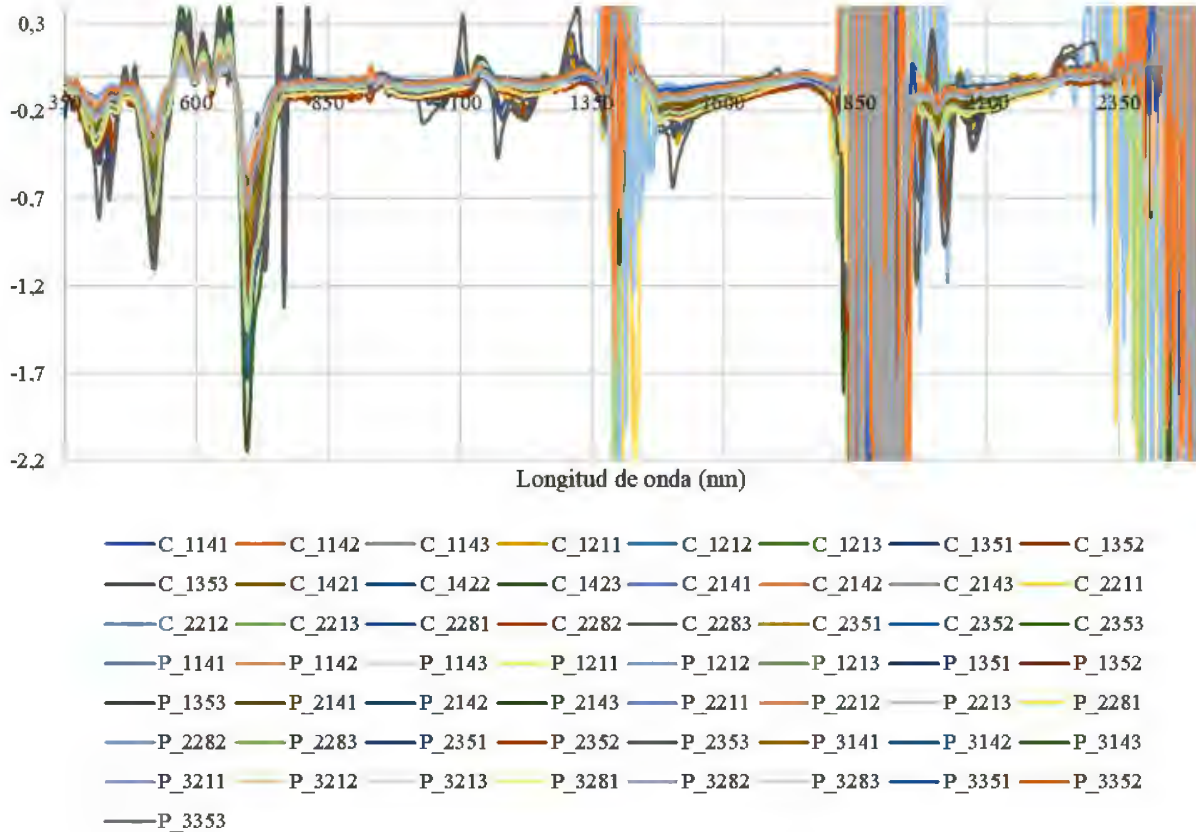
#### *5.3.1. Aplicación de pretratamientos al espectro para remover datos atípicos*

La Figura 24 muestra un gráfico del espectro de la totalidad de los datos preprocesados al aplicar el filtro de primera derivada con el algoritmo Savitzky-Golay. Las regiones que contienen ruidos excesivos por presencia de agua o entrada de luz a la sonda se observan más marcadas entre los 1.357-1.455 nm, 1.791-2.100 nm y 2.300-2.500 nm. También, la primera derivada permite suavizar los datos para incrementar la precisión de estos, sin distorsionar la tendencia de la señal (Mutanga, 2005), de esta manera, cada longitud de onda tiene un pico que proporcionará información valiosa para obtener un modelo para los parámetros de calidad en estudio. La aplicación de este filtro permite recuperar más características de las bandas que ayuden a obtener un mejor modelo (Gao et al., 2019).



**Figura 24.** Espectros preprocesados con el método de primera derivada (Savitzky-Golay), con la totalidad de los datos (n=57).

Seguidamente, se generó un segundo conjunto de datos igual al de la Figura 24 pero con un pretratamiento de más, siendo el filtro de primera derivada en conjunto con la variación estándar normalizada (SNV), lo cual se grafica en la Figura 25. La SNV se utiliza para reducir los efectos multiplicativos de la dispersión y el tamaño de las partículas (Zeaiter & Rutledge, 2009), por esta razón, al comparar ambos gráficos, hay una leve disminución en las bandas que generan ruidos. Se decide probar con la adición de este filtro porque de acuerdo con la teoría, mejora la predicción de modelos realizados con mínimos cuadrados parciales cuando se usan datos NIR con efectos de dispersión. Sin embargo, la SNV asume que los efectos multiplicativos son uniformes a lo largo de todo el rango espectral, lo cual no siempre es el caso, provocando que se puedan incluir artefactos (distorsiones en los datos) al aplicar esta transformación (Zeaiter & Rutledge, 2009). En conclusión, añadir el SNV puede traer ventajas o desventajas al modelo de predicción, lo cual se averiguará más adelante.

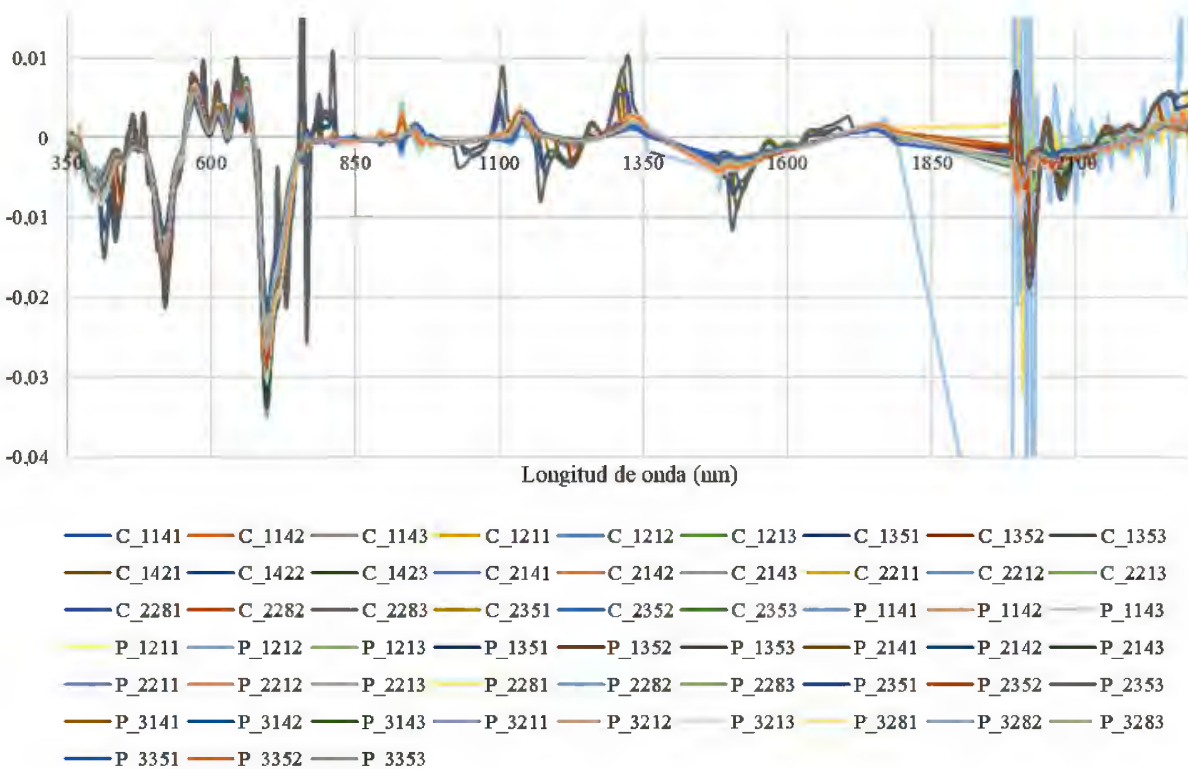


**Figura 25.** Espectros preprocesados con el método de primera derivada (Savitzky-Golay) en conjunto con la variación estándar normalizada (SNV), con la totalidad de los datos (n=57).

### 5.3.2. Análisis de componentes principales para remover datos atípicos

Después de realizar las transformaciones matemáticas y corte de ruidos del espectro inicial, se realizó el PCA, para visualizar la varianza del espectro y detectar alguna influencia de cada dato espectral con el conjunto de datos (Esbensen, 2009). En el proceso de la descomposición del PCA, los datos espectrales disponibles fueron transformados en componentes principales no-lineales o variables latentes. Esto describió la mayoría de la variación presente en el espectro. Seguidamente, las distinciones del gráfico de puntuaciones (scores), se utilizaron para identificar los datos atípicos (outliers) y para discriminar las diferencias espectrales como clústeres, los cuales se utilizan para el desarrollo del modelo.


En la Figura 26 se muestra un gráfico del conjunto de datos utilizado para realizar el PCA, donde se realizaron eliminación de ruidos en el espectro en las zonas con más ruidos ubicadas en 1.357-1.479, 1.790-1.985 y 2.300-2.500 nm. Este conjunto de datos para realizar el primer PCA, corresponde al espectro con solamente la transformación de la primera derivada, ya que acentúa las bandas con ruidos, que seguidamente van a ser un indicador de datos atípicos.



**Figura 26 .** Espectros preprocesados con el método de primera derivada (Savitzky-Golay), con la totalidad de los datos (n=57) y con eliminación de ruidos en el espectro, en 1.357-1.479, 1.790-1.985 y 2.300-2.500 nm.

En los gráficos de la Figura 27, se ilustra el PCA para el PC1 (componente principal 1, por sus siglas en inglés) y PC2, y para los PC3 y PC4. Donde la varianza explicada es de 53,49% para PC1, 24,19% para PC2, 8,80% para PC3 y 3,63% para PC4. También se realizó un PCA con el conjunto de datos con ambos pretratamientos (primera derivada y SNV), pero la varianza explicada en el primer y segundo componente principal resultó valores muy bajos (PC1=14,29% y PC2=12,08%), por lo que se confirma que el conjunto de datos con solo un pretratamiento (primera derivada), captura mejor la varianza de los datos en cada eje. Por lo que para la identificación de la eliminación de datos atípicos se utilizó el conjunto de datos con solamente el pretratamiento de la primera derivada.


A partir de estos gráficos se logra visualizar cuáles son los datos atípicos que se destacan fuera del clúster de datos, los cuales están encerrados en rojo y son los siguientes: P\_1211, P\_1212, P\_2351, P\_2352, P\_2353, P\_1352, P\_1353, C\_2281, C\_2282, C\_2283 y C\_2351. Por ende, estos deben ser eliminados del conjunto de datos inicial para que el modelo sea más uniforme. Como resultado se tiene un conjunto de datos con los lotes de manejo de corte y pastoreo, de 46 datos.



**Figura 27.** Puntuaciones (scores) del primer y segundo componente principal (a), y tercer y cuarto componente principal (b), del PCA realizado con el espectro preprocesado (n=57). Los datos atípicos se resaltan con una elipse roja.

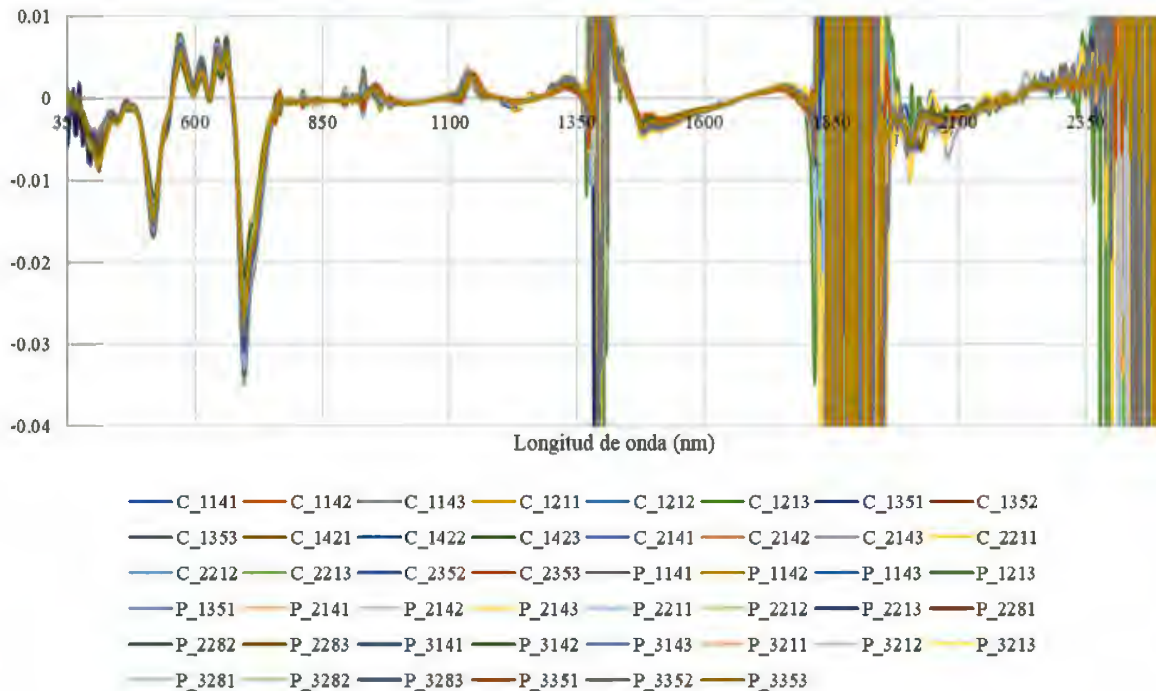
Los datos P\_2351, P\_2352, P\_2353, C\_2281, C\_2282, C\_2283, pertenecen tanto al lote con manejo de corte como pastoreo, y fueron tomados con un error de calibración con el blanco el día de la toma de datos, correspondiente al 19 de agosto. Esto se sabe porque en el gráfico de la Figura 26, son los que se muestran en color gris, y realizan picos inusuales en las zonas de 750, 800, 1.100, 1.180, 1.330 y 1.510 nm.

Seguidamente, se procede a realizar el PCA una segunda vez, habiendo eliminado previamente estos datos que no cumplen la tendencia de los demás, de forma que se remueva la menor cantidad de espectro, para obtener toda la información posible de las bandas necesarias. Tal como se aprecia en la Figura 28, los datos se presentan con menor variabilidad, ya que la varianza explicada en PC1 es de 70,55%, en PC2 de 7,76%, PC3 de 4,79% y PC4 de 3,47%. También, en el gráfico de la Figura 28 a), no se identifican aglomeraciones separadas de los datos con manejo de corte, o de los datos con manejo de pastoreo, sino que se comportan con una similitud aleatoria en la nube de datos. Luego, en la Figura 28 b), si se muestran algunos datos más lejos que otros, pero como la varianza explicada es tan baja en los PC3 y PC4, esto ya no es significativo para considerarlos como datos atípicos.

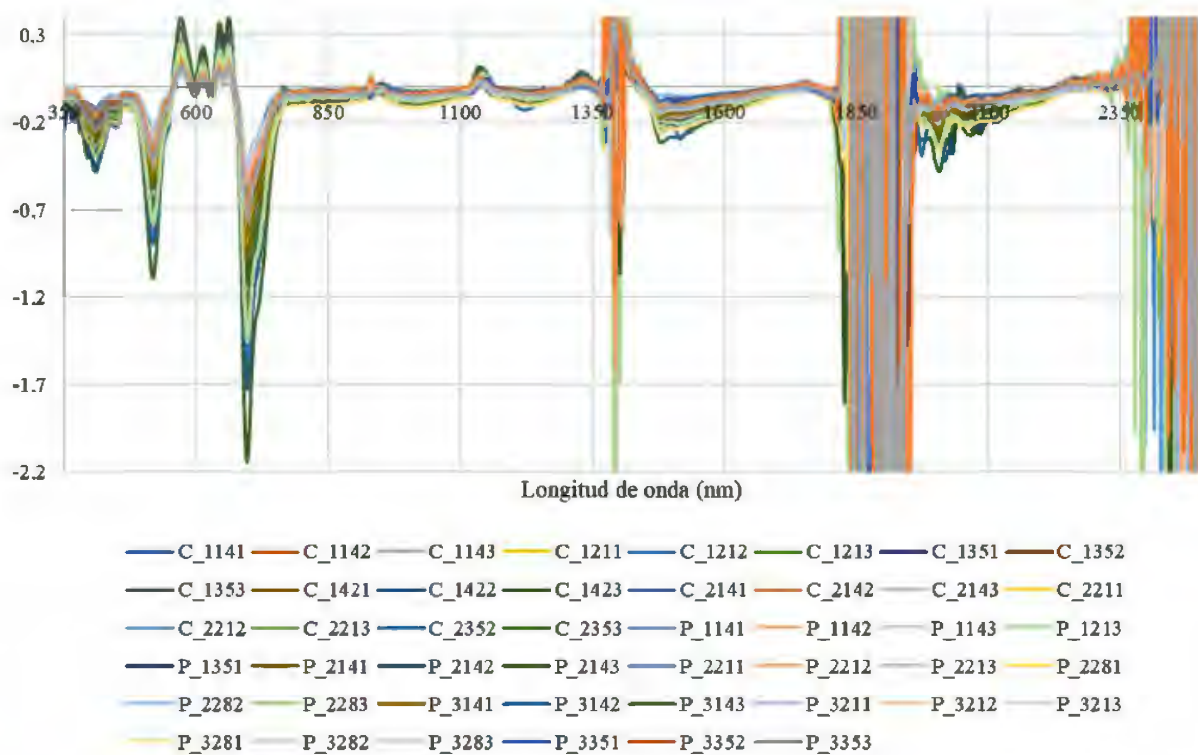


**Figura 28.** Puntuaciones (scores) del primer y segundo componente principal (a), y tercer y cuarto componente principal (b), del PCA realizado con el espectro preprocesado, sin datos atípicos (n=46). Realizado en ChemFlow Galaxy.

En la Figura 29 se aprecia el gráfico del espectro sin datos atípicos y con ruidos, del conjunto de datos con solo la transformación de la primera derivada. Seguidamente se utilizó este nuevo conjunto de datos para aplicarle también la SNV (Figura 30), y de esta forma se tienen los dos conjuntos de datos con diferentes combinaciones de pretratamientos para modelar los parámetros de calidad de MS, PC, FDN y FDA.



**Figura 29.** Espectros preprocesados con el método de primera derivada (Savitzky-Golay), sin los datos atípicos (n=46 datos).



**Figura 30.** Espectros preprocesados con los métodos de primera derivada (Savitzky-Golay) en conjunto con la variación estándar normalizada (SNV), sin los datos atípicos (n=46 datos).

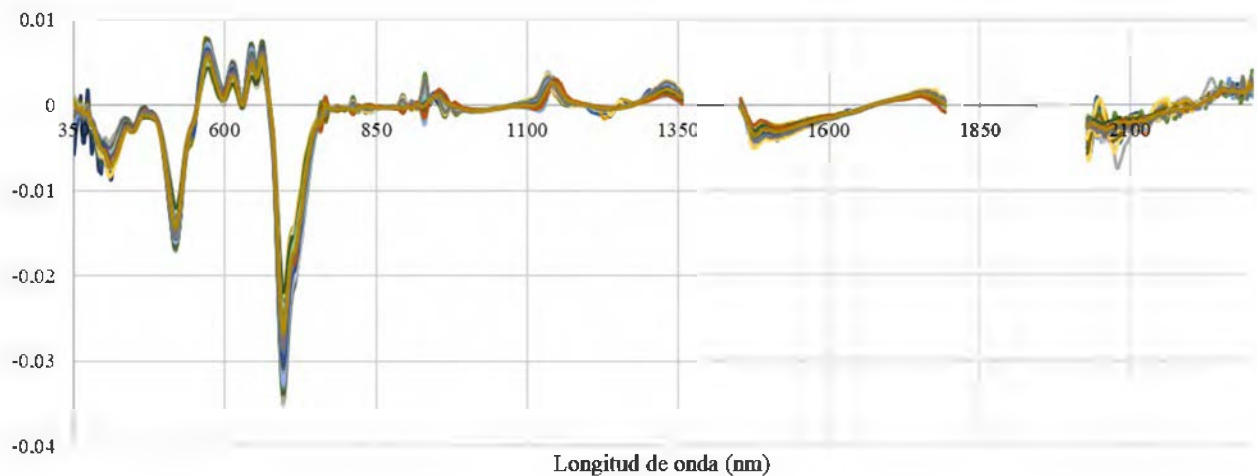


#### 5.4. Eliminación de ruidos en el espectro con pretratamientos

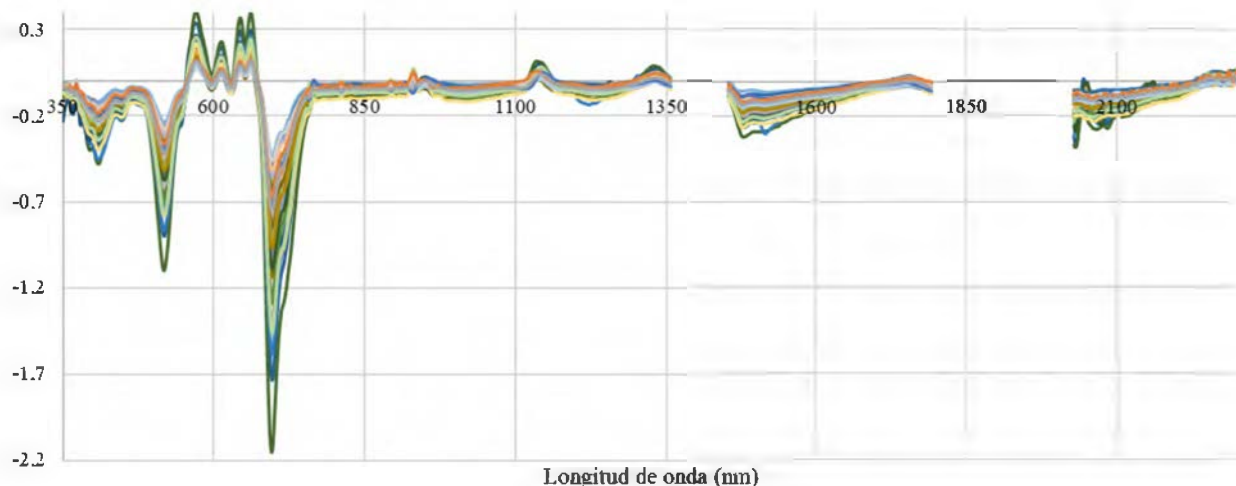
Una vez que se tuvieron listos los dos conjuntos de datos con los diferentes pretratamientos, sin datos atípicos, se procedió a realizar la eliminación de ruidos del espectro, de acuerdo con las experiencias de los autores mencionados en la Tabla 1. Para esto, se generaron 4 combinaciones diferentes de cortes en el espectro, al eliminar los ruidos en distintas longitudes de onda, para probar cuál combinación se ajusta mejor al modelo de cada uno de los cuatro parámetros de calidad en estudio. Por lo que se tienen un total de 8 conjuntos de datos, para probar los 2 tipos de pretratamientos con sus respectivas combinaciones de eliminación de ruidos; estos se grafican de forma ilustrativa en las Figuras 31, 32, 33, 34, 35, 36, 37 y 38, las cuales se explican brevemente.

- Eliminación de ruido del espectro 1: rangos de 1.357-1.455, 1.791-2.029 y 2.301-2.500 nm

Este conjunto de datos se realizó para analizar si con solamente remover los ruidos en las zonas de aproximadamente 1.400, 1.900 y después de 2.301 nm, los modelos podrían dar buenos resultados a pesar de tener leves ruidos visibles entre 2.029 y 2.301 nm (Figuras 31 y 32), ya que en ese rango se encuentran algunos componentes de los 4 parámetros de calidad en estudio, pero especialmente de PC y FDN (Lugassi et al., 2015).



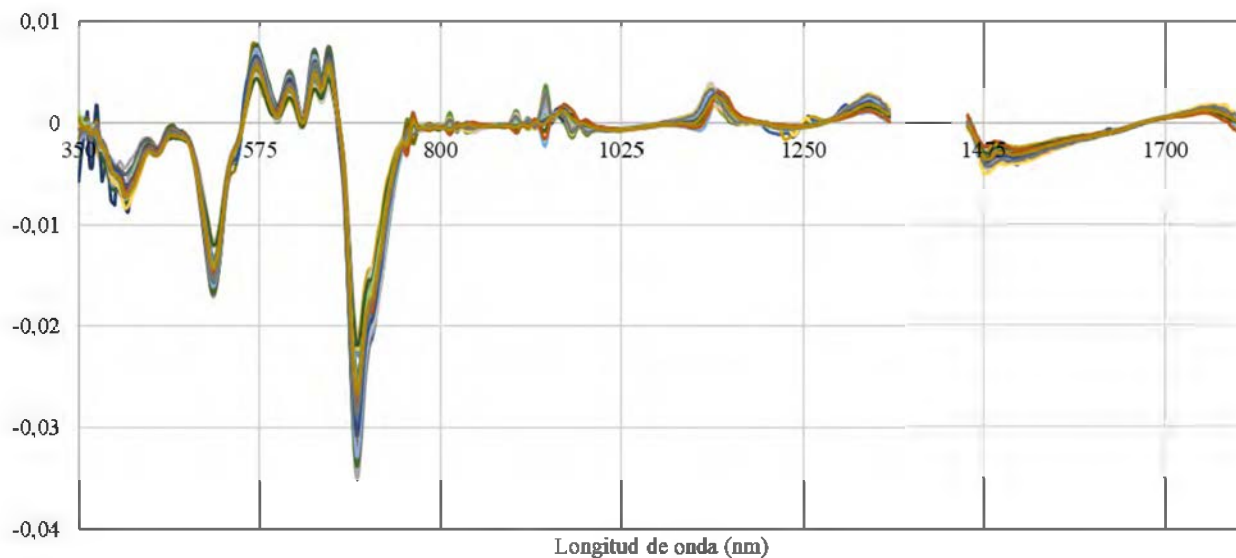
**Figura 31.** Espectros preprocesados con el método de primera derivada (Savitzky-Golay), sin los datos atípicos (n=46 datos) y con cortes en el espectro en 1.357-1.455, 1.791-2.029 y 2.301-2.500 nm.




**Figura 32.** Espectros preprocesados con los métodos de primera derivada (Savitzky-Golay) en conjunto con la variación estándar normalizada (SNV), sin los datos atípicos (n=46 datos) y con cortes en el espectro en 1.357-1.455, 1.791-2.029 y 2.301-2.500 nm.

- Eliminación de ruido del espectro 2: rangos de 1.357-1.455 y 1.791-2.500 nm

En este caso, los gráficos de las Figuras 33 y 34 muestran los datos donde se removió todo el espectro después de 1.791 nm, de forma que no se dejó ningún ruido visible, a excepción del rango entre 350-400 nm, que se observa un leve ruido específicamente en la Figura 33.



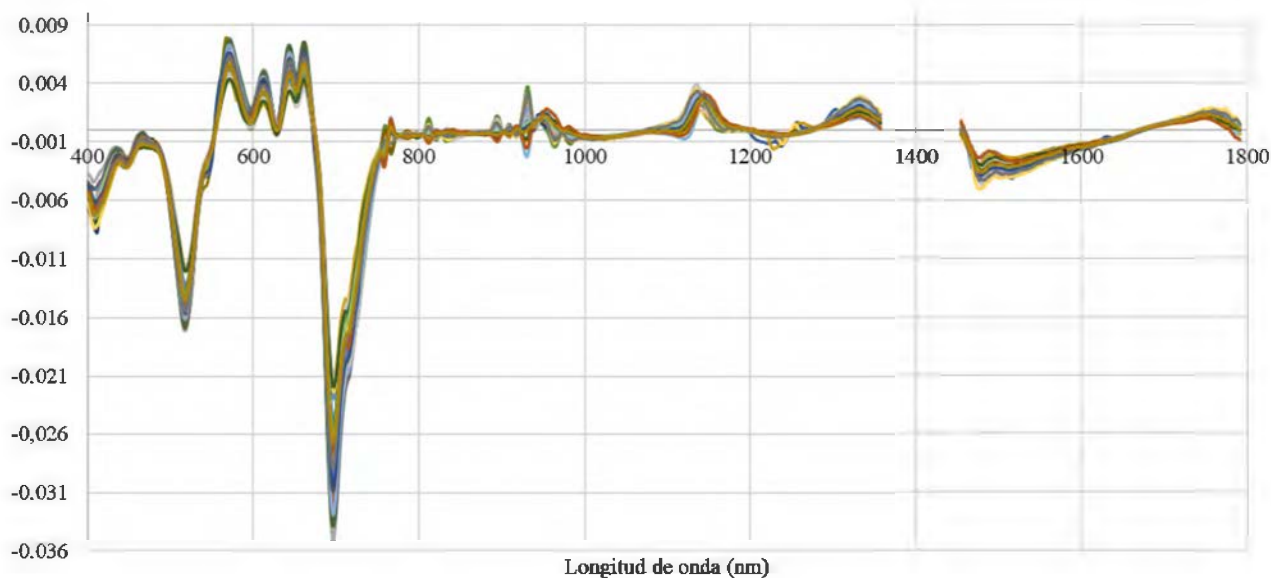
**Figura 33.** Espectros preprocesados con el método de primera derivada (Savitzky-Golay), sin los datos atípicos (n=46 datos) y con cortes en el espectro en 1.357-1.455 y 1.791-2.500 nm.




**Figura 34.** Espectros preprocesados con los métodos de primera derivada (Savitzky-Golay) en conjunto con la variación estándar normalizada (SNV), sin los datos atípicos (n=46 datos) y con cortes en el espectro en 1.357-1.455, 1.791-2.500 nm.

- Eliminación de ruido del espectro 3: rangos de 350-400, 1.357-1.455 y 1.791-2.500 nm

Este conjunto de datos (Figuras 35 y 36) es igual a la eliminación de ruidos 2, pero con la excepción que se removió la zona de 350-400 nm ya que algunos autores como de Alckmin et al. (2020) y Pullanagari et al. (2012) especifican que en esa zona hay introducción de luz al sensor.



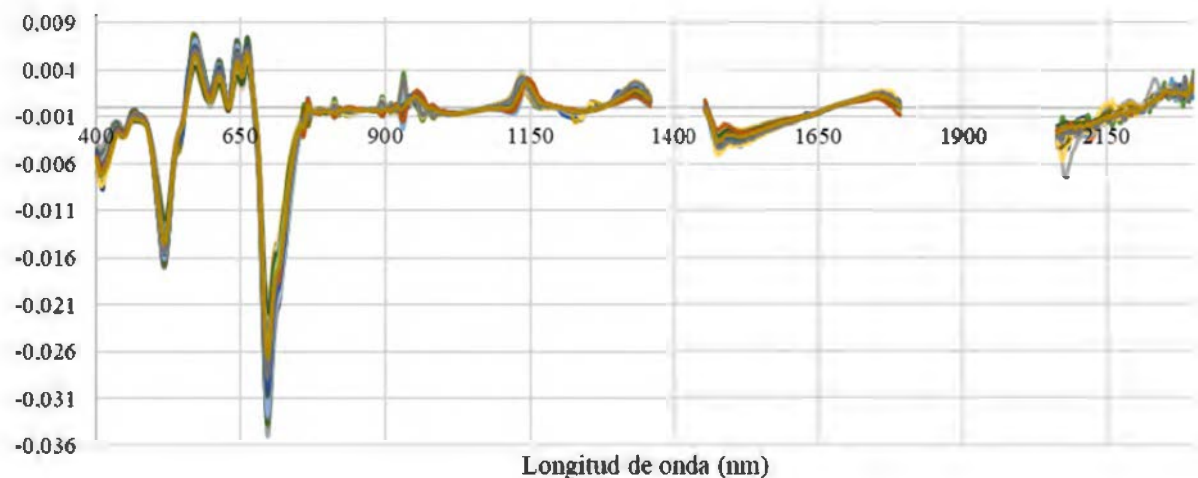
**Figura 35.** Espectros preprocesados con el método de primera derivada (Savitzky-Golay), sin los datos atípicos (n=46 datos) y con cortes en el espectro en 350-400, 1.357-1.455 y 1.791-2.500 nm.



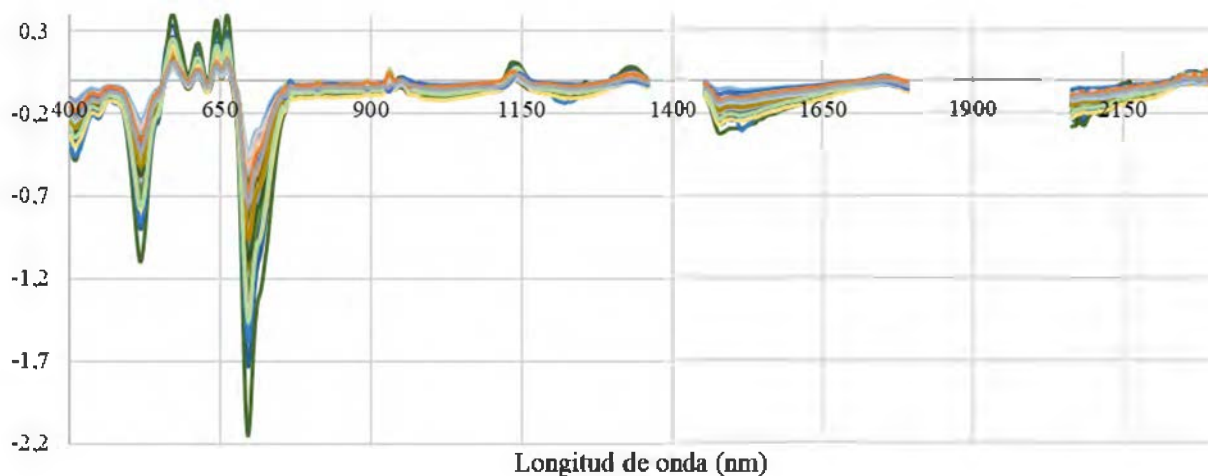
**Figura 36.** Espectros preprocesados con los métodos de primera derivada (Savitzky-Golay) en conjunto con la variación estándar normalizada (SNV), sin los datos atípicos (n=46 datos) y con cortes en el espectro en 350-400, 1.357-1.455 y 1.791-2.500 nm.

- Eliminación de ruido del espectro 4: rangos de 350-400, 1.357-1.455, 1.791-2.065 y 2.300-2.500 nm

Este conjunto de datos (Figuras 37 y 38) es similar a la eliminación de ruidos 1, pero con la excepción que se removió la zona de 350-400 nm, se dejaron más bandas entre 1.791-2.065, y se eliminó la banda 2.301 nm, que provocaba un leve pico de ruido.



**Figura 37.** Espectros preprocesados con el método de primera derivada (Savitzky-Golay), sin los datos atípicos (n=46 datos) y con cortes en el espectro en 350-400, 1.357-1.455, 1.791-2.065 y 2.300-2.500 nm.



**Figura 38.** Espectros preprocesados con los métodos de primera derivada (Savitzky-Golay) en conjunto con la variación estándar normalizada (SNV), sin los datos atípicos (n=46 datos) y con cortes en el espectro en 350-400, 1.357-1.455, 1.791-2.065 y 2.300-2.500 nm.

### 5.5. Exploración de cada conjunto de datos espectrales pretratados para los mejores modelos

Para identificar el mejor modelo que se ajuste a cada parámetro de calidad, se generaron distintos modelos de exploración con cuatro tipos diferentes de rangos de eliminación de ruidos del espectro, y dos diferentes combinaciones de pretratamientos. Para cada uno de estos conjuntos de datos pretratados, se generaron pruebas de PCA y se observan en la Tabla 2.

El conjunto de datos con mayor varianza explicada en el PC1 (máximo de 89,28% y mínimo de 80,95%) es el de corte (n=26 datos) con las eliminaciones de ruidos del espectro 2 y 3. Esto expresa que en teoría el conjunto de datos de corte es el más ideal para realizar los modelos. También, los análisis de PCA que se realizaron solo con el pretratamiento de primera derivada (SG1), dieron mejores resultados en el PC1 que al comparar con la mezcla de los dos pretratamientos (SG1+SNV). Sin embargo, una vez realizados los modelos, el parámetro de calidad de PC, se vio beneficiado por un conjunto de datos con la aplicación de ambos pretratamientos.

Con respecto a la eliminación de ruidos en el espectro, tres de los cuatro modelos de obtención de parámetros de calidad reaccionaron mejor a la eliminación de ruidos del espectro 2, la cual tiene un rango de 1.357-1.455 nm y de 1.791-2.500 nm. Solamente el modelo de FDA se vio favorecido por la eliminación de ruidos de espectro 3, que comprende entre 350-400, 1.357-1.455 y 1.791-2.500 nm.

**Tabla 2.** Resultado de los análisis de componentes principales (PCA) realizados para cada eliminación de ruidos del espectro.


Eliminación de ruido del espectro	Rango (nm)	Varianza explicada del Análisis de Componentes Principales					
		Corte y pastoreo		Corte		Pastoreo	
		SG1	SG1+SNV	SG1	SG1+SNV	SG1	SG1+SNV
1	1.357-1.455, 1.791-2.029 y 2.301-2.500	PC1: 72,98%	PC1: 35,71%	PC1: 80,95%	PC1: 44,3%	PC1: 64,88%	PC1: 31,02%
		PC2: 8,04%	PC2: 19,53%	PC2: 5,02%	PC2: 14,5%	PC2: 12,62%	PC2: 25,63%
2	1.357-1.455 y 1.791-2.500	PC1: 80,20%	PC1: 35,22%	PC1: 88,59%	PC1: 48,02%	PC1: 71,42%	PC1: 36,02%
		PC2: 8,17%	PC2: 28,47%	PC2: 3,76%	PC2: 20,69%	PC2: 13,42%	PC2: 28,57%
3	350-400, 1.357-1.455 y 1.791-2.500	PC1: 81,72%	PC1: 42,94%	PC1: 89,28%	PC1: 51,47%	PC1: 73,97%	PC1: 40,04%
		PC2: 8,63%	PC2: 27,74%	PC2: 3,84%	PC2: 21,20%	PC2: 13,99%	PC2: 29,86%
4	350-400, 1.357-1.455, 1.791-2.065 y 2.300-2.500	PC1: 78,09%	PC1: 37,93%	PC1: 85,04%	PC1: 45,09%	PC1: 70,22%	PC1: 34,44%
		PC2: 8,41%	PC2: 24,50%	PC2: 4,38%	PC2: 17,49%	PC2: 13,46%	PC2: 27,07%

SG1: Pretratamiento de primera derivada con filtro de Savitzky-Golay.

SG1+SNV: Pretratamientos de primera derivada con filtro de Savitzky-Golay y variación normal estándar.

### 5.5.1. Análisis de componentes principales para los mejores modelos de Materia Seca y Fibra Detergente Ácido


Para los parámetros de calidad de MS y FDA, se encontró que ambos modelos se vieron favorecidos por el conjunto de datos con solamente manejo de pasto de corte (n=20 datos), y con la aplicación del pretratamiento de primera derivada. Donde el modelo de MS obtuvo mejores resultados con la eliminación de ruido del espectro 2, de 1.357-1.455 nm y de 1.791-2.500 nm, y el modelo de FDA con el rango de eliminación de ruido del espectro 3, de 350-400 nm, 1.357-1.455 nm y 1.791-2.500 nm. En la Figura 39 a), se muestra el resultado del PCA utilizado para el parámetro de MS, y en la Figura 39 b), se muestra el PCA utilizado para el parámetro de FDA. El gráfico de la figura de la izquierda tiene una varianza explicada de 88,59% para el PC1 y de 3,76% para el PC2. El gráfico de la figura de la derecha tiene una varianza explicada de 89,28% para el PC1 y de 3,84% para el PC2 (Tabla 2).



**Figura 39.** Puntuaciones (scores) del primer y segundo componente principal del PCA realizado en los datos de corte con el método de primera derivada (Savitzky-Golay), para el rango de eliminación de ruido del espectro 2, utilizado para la MS (a), y para el rango de eliminación de ruido del espectro 3, utilizado para la FDA (b).

### 5.5.2. Análisis de componentes principales para los mejores modelos de Proteína Cruda y Fibra Detergente Neutro

Para los parámetros de calidad de PC y FDN, se encontró que ambos modelos se vieron favorecidos por la eliminación de ruido del espectro 2, de 1.357-1.455 nm y de 1.791-2.500 nm, para el conjunto de datos de corte y pastoreo, con n=46 datos. En la Figura 40 a), se muestra el resultado del PCA utilizado para el parámetro de FDN, y en la Figura 40 b), se muestra el PCA utilizado para el parámetro de PC. El conjunto de datos utilizado para la PC tiene ambos pretratamientos de primera derivada y SNV, y el conjunto de datos para la FDN tiene solamente el pretratamiento de primera derivada. El gráfico de la figura de la izquierda tiene una varianza explicada de 80,20% para el PC1 y de 8,17% para el PC2. El gráfico de la figura de la derecha tiene una varianza explicada de 35,22% para el PC1 y de 28,47% para el PC2 (Tabla 2).



**Figura 40.** Puntuaciones (scores) del primer y segundo componente principal del PCA realizado en los datos de corte y pastoreo en el conjunto de datos con eliminación de ruido en el espectro 2, con el método de primera derivada (Savitzky-Golay), utilizado para la FDN (a), y con los métodos de primera derivada en conjunto con la variación estándar normalizada (SNV), utilizado para la PC (b).

### 5.6. Modelos de regresión de mínimos cuadrados parciales (PLSR)

A partir de cada conjunto de datos estudiado, los cuales se dividen según el lote de manejo donde se tomaron los datos en campo, y la eliminación de ruido del espectro que se realizó (4 tipos diferentes), se lograron predecir los parámetros de calidad de MS, PC, FDN y FDA (Figura 4). Los pretratamientos escogidos para cada modelo corresponden a aquellos con mejor resultado de  $r^2$ , RMSE y cantidad de variables latentes (LV, por sus siglas en inglés). Los resultados de todos los modelos que se probaron se encuentran en las Tablas C1, C2, C3, C4, C5 y C6 en apéndices, donde se escogen los modelos de acuerdo a los valores más elevados de  $r^2$  y de RPD, los más bajos de RMSE, y la mayor cantidad de variables latentes.

Cabe recalcar que los indicadores estadísticos  $r^2$  y RMSEC de la etapa de calibración, sufren un deterioro (sus valores disminuyen y aumentan, respectivamente) al pasar a la etapa de validación cruzada ( $r^2_{cv}$  y RMSECV). Esto sucede en todos los modelos analizados, y es esperable ya que, en la etapa de calibración, las mismas muestras que participan en el modelo de regresión son predichas por este. En cambio, la validación cruzada equivale a un tipo de validación externa, pero que evita tener que reducir el número de muestras que participan en la calibración si se considera el proceso completo (Alomar et al., 2015). A continuación, se van a mostrar los modelos con mejores resultados según el conjunto de datos de acuerdo con el lote de manejo y los mejores a nivel general de esta investigación.



### 5.6.1. Conjunto de datos con manejo de pasto en corte y en pastoreo juntos

En la Tabla 3 se describen los resultados de los modelos realizados con los datos tomados en los lotes con manejo de corte y de pastoreo, juntos, con  $n=46$  datos. Al ser el conjunto con más datos, el modelo presenta mayor robustez, sin embargo, como los datos de pastoreo muestran ciertas irregularidades a causa de su manejo, los modelos rondan resultados de  $r^2_{cv}$  entre los 0,59 a 0,17 y de RMSECV entre 2,05 y 2,96. Estos valores se consideran bajos para  $r^2$ , ya que en condiciones de laboratorio se espera obtener un  $r^2 > 0,8$  (Kusumo et al., 2009). Sin embargo, como estos datos se tomaron en campo, el valor de  $r^2$  va a ser menor a causa de las interferencias de luz y humedad, material vegetal vivo, hierbas entre otros. También cabe resaltar que el parámetro de FDA es el que presenta menor brecha entre el  $r^2_{cv}$  y el  $r^2_c$ .

Los resultados de RPD muestran que la precisión de los modelos de PC, FDN y FDA para este conjunto de datos con  $n=46$ , es poco confiable, ubicándose en el rango de RPD entre 1,1 y 1,4. Sin embargo, para el modelo de MS, es satisfactorio porque se encuentra entre 1,5 y 1,9 (RPD=1,56). Una observación que puede explicar el bajo coeficiente de determinación y RPD de los parámetros de PC, FDN y FDA, es que los tres presentaron diferencias significativas con respecto a la variable de manejo, en las pruebas de laboratorio (Tabla A4), por ende, estos tres modelos se realizaron con conjuntos de datos que no son similares entre sí.

Para este conjunto de datos se encontró que el mejor rango de eliminación de ruido del espectro para los modelos de PC, FDN y FDA fue el 2, que corresponde a 1.357-1.455 y 1.791-2.500 nm, y para el modelo de MS el que dio el mejor resultado fue el rango 1, el cual deja más bandas espectrales entre 2.029 y 2.301 nm.

**Tabla 3.** Mejores resultados de modelos PLSR con los datos de los lotes con manejo de corte y de pastoreo juntos.

<b>Propiedad</b>	<b>MS</b>	<b>PC</b>	<b>FDN</b>	<b>FDA</b>
<b>Pretratamiento</b>	1 <sup>era</sup> deri. (11), SNV	1 <sup>era</sup> deri. (11), SNV	1 <sup>era</sup> deri. (11)	1 <sup>era</sup> deri. (11)
<b>Rango de eliminación de ruido del espectro (nm)</b>	1.357-1.455, 1.791-2.029 y 2.301-2.500	1.357-1.455 y 1.791-2.500	1.357-1.455 y 1.791-2.500	1.357-1.455 y 1.791-2.500
<b>Cantidad de datos (n)</b>	46	46	46	46
<b>Número de variables latentes</b>	5	3	3	2
<b>r<sup>2</sup><sub>c</sub></b>	0,79	0,37	0,56	0,48
<b>RMSEC</b>	1,69	2,57	2,37	1,92
<b>r<sup>2</sup><sub>cv</sub></b>	0,59	0,17	0,39	0,38
<b>RMSECV</b>	2,19	2,96	2,67	2,05
<b>SD<sub>lab</sub></b>	3,42	3,14	3,40	2,58
<b>RPD</b>	1,56	1,06	1,27	1,26

r<sup>2</sup><sub>c</sub>: coeficiente de determinación para el modelo de calibración

r<sup>2</sup><sub>cv</sub>: coeficiente de determinación para el modelo de validación cruzada

RMSEC: Error mínimo cuadrado de calibración

RMSECV: Error mínimo cuadrado de validación cruzada

SD<sub>lab</sub>: Desviación estándar de los datos de calidad de forraje del laboratorio

RPD: Relación de rendimiento y de desviación

1<sup>era</sup> deri. (11): Primera derivada con ventana de 11

### 5.6.2. Conjunto de datos con manejo de pasto en corte

En la Tabla 4 se describen los resultados de los modelos realizados con los datos tomados en el lote con manejo de corte, con n=20 datos. Este es el conjunto que presenta menos datos, pero también son las bandas con menos irregularidades en el espectro, tal como se puede apreciar al comparar las Figuras B1 y B2. Este lote con manejo de corte presenta ciertas ventajas que favorecen haber obtenido un espectro más regular, tales como: un terreno más uniforme porque no es pisoteado por los animales, no tiene presencias de boñiga y orina, menos hierbas y la uniformización del día 0 se realizó con máquina cortadora.

Los modelos rondan resultados de r<sup>2</sup><sub>cv</sub> entre los extremos de 0,81 a 0,08, y de RMSECV entre 1,41 y 3,06. También cabe resaltar que el parámetro de MS es el que presenta menor brecha entre el r<sup>2</sup><sub>cv</sub> y el r<sup>2</sup><sub>c</sub>, así como un valor de RPD=2,31, que se categoriza como un modelo muy satisfactorio; de esta manera, se considera como el mejor modelo obtenido en esta investigación. Para el caso de los modelos de FDN y FDA, los valores de RPD se encuentran entre 1,1 y 1,4, lo cual se categoriza con un nivel de predicción poco confiable, y el modelo de PC tiene un RPD=1,01 por lo que entra en la categoría de no confiable.

Con respecto al análisis de los datos bromatológicos de laboratorio, los parámetros de MS y FDA fueron los que obtuvieron un menor valor de p (0,1387 y 0,0085 respectivamente) con respecto a la edad, ya que lo deseado es observar cambios en la planta a lo largo de su desarrollo (Tabla A2).

**Tabla 4.** Mejores resultados de los modelos PLSR con los datos del lote con manejo de corte.

<b>Propiedad</b>	<b>MS</b>	<b>PC</b>	<b>FDN</b>	<b>FDA</b>
<b>Pretratamiento</b>	1 <sup>era</sup> deri. (11)	1 <sup>era</sup> deri. (11), SNV	1 <sup>era</sup> deri. (11)	1 <sup>era</sup> deri. (11)
<b>Rango de eliminación de ruido del espectro (nm)</b>	1.357-1.455 y 1.791-2.500	350-400, 1.357- 1.455, 1.791- 2.065 y 2.300- 2.500	1.357-1.455, 1.791-2.029 y 2.301-2.500	350-400, 1.357- 1.455 y 1.791- 2.500
<b>Cantidad de datos (n)</b>	20	20	20	20
<b>Número de variables latentes</b>	2	1	2	2
<b>r<sup>2</sup><sub>c</sub></b>	0,89	0,28	0,66	0,70
<b>RMSEC</b>	1,16	2,77	1,77	1,45
<b>r<sup>2</sup><sub>cv</sub></b>	0,81	0,08	0,3	0,48
<b>RMSECV</b>	1,41	3,06	2,40	1,80
<b>SD<sub>lab</sub></b>	3,26	3,09	2,81	2,46
<b>RPD</b>	2,31	1,01	1,17	1,37

r<sup>2</sup><sub>c</sub>: coeficiente de determinación para el modelo de calibración

r<sup>2</sup><sub>cv</sub>: coeficiente de determinación para el modelo de validación cruzada

RMSEC: Error mínimo cuadrado de calibración

RMSECV: Error mínimo cuadrado de validación cruzada

SD<sub>lab</sub>: Desviación estándar de los datos de calidad de forraje del laboratorio

RPD: Relación de rendimiento y de desviación

1<sup>era</sup> deri. (11): Primera derivada con ventana de 11

### 5.6.3. Conjunto de datos con manejo de pasto en pastoreo

Para los datos que incluyen solamente los tomados en el lote con manejo de pastoreo (n=26), los modelos tienen resultados muy variables y bajos de r<sup>2</sup>, así como con una amplia brecha entre el r<sup>2</sup><sub>cv</sub> y el r<sup>2</sup><sub>c</sub>, especialmente en PC y FDN. Sin embargo, la FDA fue la que presentó menor brecha entre estos dos coeficientes de determinación, lo cual se atribuye a que este parámetro no presentó diferencias significativas entre ciclos de pastoreo (Tabla A3). En la Tabla 5, los valores de r<sup>2</sup><sub>cv</sub> para los 4 parámetros de calidad, se encuentran entre 0,63 y 0,01, y para el caso del RMSECV entre 1,80 y 2,86.

Para la MS, se generó un modelo satisfactorio con RPD=1,64 y un r<sup>2</sup><sub>cv</sub> = 0,63 con 7 variables latentes, lo cual se puede deber a que es el único parámetro de calidad que no presentó diferencias significativas en cuanto al manejo, en sus resultados de calidad realizados en el laboratorio con química húmeda (Tabla A2), entonces no se vio tan afectado por las irregularidades de estos datos espectrales. Por otro lado, los parámetros de calidad de PC, FDN y FDA si se vieron afectados por las irregularidades espectrales, ya que el RPD demuestra que los modelos de PC y FDN son no

confiables ( $RPD < 1,0$ ) y el de FDA es poco confiable ( $RPD = 1,11$ ) para predecir los datos cuantitativos. Cabe recalcar que, al observar los datos de la  $SD_{lab}$  de estos 3 parámetros de calidad, son las más bajas de los 3 conjuntos de datos en estudio, confirmado en este caso, que posiblemente la baja calidad de los modelos se debe a los espectros.

Para este conjunto de datos se encontró que el mejor rango de eliminación de ruido del espectro para los modelos de MS y FDA fue el 4, que corresponde a 350-400, 1.357-1.455, 1.791-2.065 y 2.300-2.500 nm; para el modelo de PC fue el rango 2, y para el modelo de FDN fue el rango 1.

**Tabla 5.** Mejores resultados de los modelos PLSR con los datos del lote con manejo de pastoreo.

<b>Propiedad</b>	<b>MS</b>	<b>PC</b>	<b>FDN</b>	<b>FDA</b>
<b>Pretratamiento</b>	1 <sup>era</sup> deri. (11)	1 <sup>era</sup> deri. (11)	1 <sup>era</sup> deri. (11)	1 <sup>era</sup> deri. (11)
<b>Rango de eliminación de ruido del espectro (nm)</b>	350-400, 1.357-1.455, 1.791-2.065 y 2.300-2.500	1.357-1.455 y 1.791-2.500	1.357-1.455, 1.791-2.029 y 2.301-2.500	350-400, 1.357-1.455, 1.791-2.065 y 2.300-2.500
<b>Cantidad de datos (n)</b>	26	26	26	26
<b>Número de variables latentes</b>	7	3	1	2
<b><math>r^2_c</math></b>	0,95	0,29	0,10	0,41
<b>RMSEC</b>	0,94	2,34	2,74	1,64
<b><math>r^2_{cv}</math></b>	0,63	0,04	0,01	0,22
<b>RMSECV</b>	2,11	2,66	2,86	1,80
<b><math>SD_{lab}</math></b>	3,46	2,54	2,78	2,00
<b>RPD</b>	1,64	0,96	0,97	1,11

$r^2_c$ : coeficiente de determinación para el modelo de calibración

$r^2_{cv}$ : coeficiente de determinación para el modelo de validación cruzada

RMSEC: Error mínimo cuadrado de calibración

RMSECV: Error mínimo cuadrado de validación cruzada

$SD_{lab}$ : Desviación estándar de los datos de calidad de forraje del laboratorio

RPD: Relación de rendimiento y de desviación

1<sup>era</sup> deri. (11): Primera derivada con ventana de 11

#### 5.6.4. Mejores modelos obtenidos

La evaluación de la precisión de los mejores modelos para los parámetros de calidad en estudio se indica en la Tabla 6, donde el rango 2 fue el más apropiado para la eliminación de ruido del espectro (1.357-1.455 y 1.791-2.500 nm), para MS, PC y FDN. A pesar de que existe una amplia variedad de transformaciones matemáticas para desarrollar una mejor relación funcional entre los datos medidos en el laboratorio y entre las medidas de reflectancia in situ, la primera derivada del Log (1/R), y la primera derivada del Log (1/R) en conjunto con el SNV, probaron ser útiles en la predicción con una precisión estadística mejorada en comparación con la absorbancia (Log (1/R)) sin pretratamientos (Tablas C7, C8, C9, C10, C11 y C12). Los análisis realizados en la PC y FDN demostraron que aplicar ambas combinaciones de pretratamientos genera los  $r^2$  más altos y RMSE más bajos, y la MS y FDA obtuvieron los mejores resultados con solamente la primera derivada.

El número de variables latentes indica la complejidad del modelo, por lo que, cuanto más LV tenga, más complejo e inestable tiende a volverse (Fernandes, 2015), sin embargo, este valor también se determina basado en el menor RMSECV calculado en la validación cruzada dejando uno fuera, para evitar el sobreajuste del modelo. De acuerdo con este concepto, se puede observar que, entre los modelos desarrollados, los valores oscilan entre 2 y 3 LV, lo cual indica estabilidad de los modelos para sus respectivos RMSECV (Figuras C1, C2, C3 y C4).

Los parámetros de PC y FDN fueron los que tuvieron los modelos con valores más bajos, lo cual se puede deber a que según Pullanagari et al. (2012), las bandas con mayor influencia se encuentran en las zonas que se eliminaron para esta investigación a causa del ruido, provocando que se perdiera información espectral que puede ser útil para la estimación de calidad de forraje. Para PC, los autores mencionados encontraron que algunas de las bandas con mayor influencia son 1.985, 2.230, 2.250 y 2.385 nm, y para FDN son 1.920, 1.985, 2.290 y 2.365 nm. También, los resultados de laboratorio realizados con química húmeda de estos dos parámetros no tuvieron el comportamiento esperado de acuerdo con la edad de crecimiento del pasto, lo cual puede ser otro factor que afectara los resultados de los modelos. Por esta razón, los modelos obtenidos de PC, FDN y FDA se categorizan como poco confiables (RPD entre 1,1-1,4) en su precisión de predicción. Sin embargo, para la FDA se obtuvo un  $r^2_{cv}$  de 0,48 con un RMSECV de 1,80 y RPD=1,4. Cabe recalcar que este RPD se encuentra entre el límite de poco confiable (1,1-1,4) y satisfactorio (1,5-1,9), y de acuerdo con Safari et al. (2016), podría tener capacidad de predicción aceptable ya que son datos tomados en campo y tienen condiciones variables.

El modelo correspondiente a la MS, tuvo los mejores resultados ya que el mejor  $r^2_{cv}$  calculado fue de 0,81 con su RMSECV de 1,41 y RPD=2,31 (muy satisfactorio). En los modelos de MS y FDA, se utilizó solamente el conjunto de datos con manejo de pasto de corte (Figura B1), que presentó un espectro más uniforme y con menos ruidos a pesar de tener solo 6 datos menos que el conjunto de datos con manejo de pastoreo.

**Tabla 6.** Resumen de los mejores modelos obtenidos para cada parámetro de calidad estudiado.

<b>Propiedad</b>	<b>MS</b>	<b>PC</b>	<b>FDN</b>	<b>FDA</b>
<b>Pretratamiento</b>	1 <sup>era</sup> deri. (11)	1 <sup>era</sup> deri. (11), SNV	1 <sup>era</sup> deri. (11)	1 <sup>era</sup> deri. (11)
<b>Rango de eliminación de ruido del espectro (nm)</b>	1.357-1.455 y 1.791-2.500	1.357-1.455 y 1.791-2.500	1.357-1.455 y 1.791-2.500	350-400, 1.357-1.455 y 1.791- 2.500
<b>Manejo</b>	Corte	Corte y Pastoreo	Corte y Pastoreo	Corte
<b>Cantidad de datos (n)</b>	20	46	46	20
<b>Número de variables latentes</b>	2	2	3	2
<b>r<sup>2</sup><sub>c</sub></b>	0,89	0,37	0,56	0,70
<b>RMSEC</b>	1,16	2,57	2,37	1,45
<b>r<sup>2</sup><sub>cv</sub></b>	0,81	0,17	0,39	0,48
<b>RMSECV</b>	1,41	2,96	2,67	1,80
<b>SD<sub>lab</sub></b>	3,26	3,14	3,40	2,46
<b>RPD</b>	2,31	1,06	1,27	1,37

r<sup>2</sup><sub>c</sub>: coeficiente de determinación para el modelo de calibración

r<sup>2</sup><sub>cv</sub>: coeficiente de determinación para el modelo de validación cruzada

RMSEC: Error mínimo cuadrado de calibración


RMSECV: Error mínimo cuadrado de validación cruzada

SD<sub>lab</sub>: Desviación estándar de los datos de calidad de forraje del laboratorio

RPD: Relación de rendimiento y de desviación


1<sup>era</sup> deri. (11): Primera derivada con ventana de 11

El resultado obtenido para MS (Figura 41) se asemeja al modelo de Fernandes (2015), ya que el autor alcanzó valores de MS con un  $r^2$  de 0,87 y un error de calibración cuadrático (SEC) de 0,99 para muestras frescas, y un  $r^2$  de 0,89 para muestras procesadas (secas), demostrando que la metodología se puede aplicar en muestras frescas también.



**Figura 41.** Correlación entre la MS de referencia y la MS predicha por medio de PLSR para 20 muestras evaluadas.


Para el caso de la PC (Figura 42), el modelo no se comportó como esperado, y generó los resultados de  $r^2_{cv}$  más bajo y RMSECV más alto de todos los modelos; esta correlación no debe ser replicable, porque generaría un claro error en futuras muestras. Al comparar los resultados de otros autores, se confirma que, si existe posibilidad de obtener buenos modelos para PC, ya que, en muestras tomadas en campo, Smith et al. (2019) obtuvieron un  $r^2_{cv}$  de 0,96 con un error de 1,38, utilizando el mismo equipo, eliminando menos bandas del espectro (350-453, 1.340-1.424, 1.829-1.969 y 2.451-2.500 nm) y respetando las bandas 2.230, 2.250 y 2.385 que previamente se mencionaron ser de relevancia. También cabe destacar que dichos autores utilizaron un escudo de luz en el sensor, con una estructura con forma de balde invertido, para prevenir las entradas de luz, lo cual les permitió obtener un espectro con menos ruido.



**Figura 42.** Correlación entre la PC de referencia y la PC predicha por medio de PLSR para 46 muestras evaluadas.


El modelo de FDN tuvo un  $r^2_{cv}$  bajo de 0,39 (Figura 43), por lo que tampoco se recomienda que este modelo sea utilizado para replicar la correlación. Los autores Lingjie y Chengci (2018) obtuvieron un valor de  $r^2_{cv}$  para FDN de 0,77 y un RMSECV de 4,71, un error aún más alto que el obtenido en esta investigación, que es de 2,67. Estos autores también probaron que el modelo presentó valores de  $r^2_{cv}$  más altos para FDN y FDA con datos provenientes de la planta en etapa de dormancia ( $r^2_{cv}=0,86$  y  $0,97$  respectivamente), y también, las plantas de dicha investigación tuvieron un comportamiento creciente a lo largo de su desarrollo, para ambas fibras. Como se observó en las Figuras 18 y 19, las muestras de estrella africana no tuvieron un comportamiento creciente de ambas fibras, por ende, no llegaron a su estado máximo de desarrollo, provocando que la respuesta espectral de las plantas no cambiara a lo largo del tiempo, y tampoco permitiera que el modelo respondiese mejor. Por ende, a mayor cantidad de hemicelulosa y celulosa presente en la planta, mayor probabilidad de que el modelo de FDN y FDA sea favorable para su replicación.





**Figura 43.** Correlación entre la FDN de referencia y la FDN predicha por medio de PLSR para 46 muestras evaluadas.

Para el caso del modelo de FDA (Figura 44), el valor de  $r^2_{cv}$  fue el segundo más alto de todos los cuatro parámetros de calidad estudiados. Esto se puede deber, a que fue el único parámetro que presentó diferencias significativas en la edad, lo cual facilitó que la porción de hemicelulosa fuera detectada por el espectro ya que la planta no se desarrolló como esperado. Tanto Lingjie & Chengci (2018) y Pullanagari et al. (2012), obtuvieron valores de  $r^2_{cv}$  de 0,80 y 0,82, con RMSECV de 2,45 y 2,23 respectivamente. Por ende, en esta investigación se logró obtener un error menor para FDA (RMSECV=1,80) al comparar los reportados por los autores.

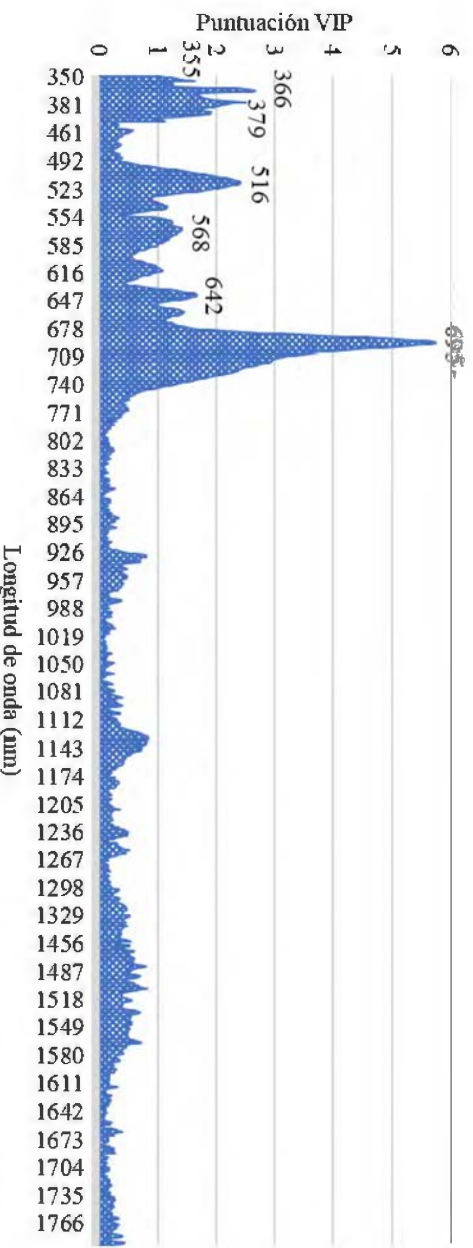


**Figura 44.** Correlación entre la FDA de referencia y la FDA predicha por medio de PLSR para 20 muestras evaluadas.

### 5.7. Longitudes de onda importantes para la explicación de los parámetros de calidad

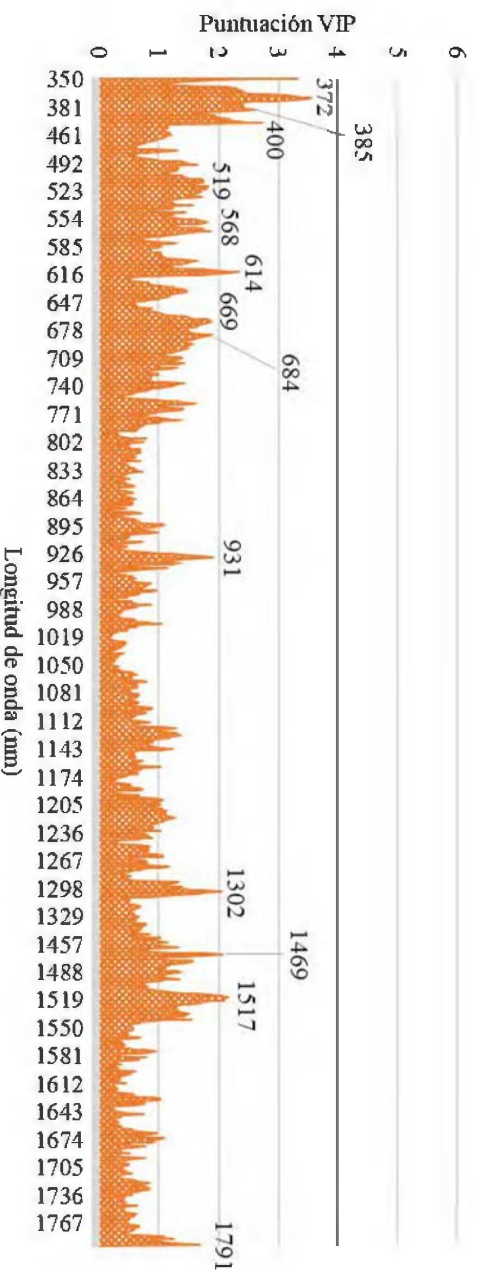
La contribución de cada banda puede ser visualizada al calcular la variable de importancia para la proyección (VIP), lo cual se calculó con Chemflow Galaxy, a partir de una PLSR y de un gráfico de las curvas con los valores de respuesta (eje “y”) para cada una de las longitudes de onda (eje “x”). Cada gráfico se muestra en las Figuras 45, 46, 47, y 48 para cada parámetro de calidad en estudio, y con el mejor pretratamiento escogido según el mejor modelo analizado. Como es de esperar, la mayoría de las bandas importantes ocurren en la región visible (400-750 nm), región infrarrojo cercano (800-950 nm) y según la teoría, también en la región infrarroja de onda corta (1.950-2.350 nm) (Pullanagari et al., 2012), pero esta zona se eliminó a causa de ruidos relacionados al vapor de agua. La incidencia de estas regiones puede ser atribuida a la absorbancia de la radiancia visible por la clorofila, el cual es un pigmento abundante en la vegetación verde. También se establece una fuerte relación entre la concentración de clorofila y contenido de nitrógeno en las plantas, a causa de la presencia de enlaces N – H (Curran, 1989).

El modelo de materia seca presentó alta incidencia en las bandas entre 355-695 nm. Los autores Sun et al. (2022) no encontraron picos fuertes con altos valores de VIP, sin embargo, también, tuvieron valores de  $VIP > 1$  en las bandas ubicadas entre 350-700 nm, y en la banda de 2.375 nm, pero esta última no se tiene en el modelo realizado en esta investigación.




**Figura 45.** Gráfico de la variable de importancia para la proyección (VIP), mostrando la importancia de cada longitud de onda en el desarrollo del modelo de calidad de pasto para materia seca, a lo largo del espectro.

La proteína es el componente bioquímico que contiene mayor cantidad de nitrógeno en las plantas. Para el mejor modelo de PC, los picos con los valores más altos de VIP se observan entre 372-684 nm, y algunos entre 1.302-1.517 nm (Figura 46). A pesar de haber resultado un modelo con coeficiente de determinación muy bajo, las bandas de 372 y 684 coinciden con Safari et al. (2016) para la especie *Lolium-Cynosuuretum*. También la banda de 931 fue obtenida por Pullanagari et al. (2012) para PC en ryegrass perenne y trébol blanco. Lugassi et al. (2015), menciona que los contenidos de PC se podrían observar en: 1.748-1.764 nm, 1.766-1.794 nm, 2.070-2.088 nm, 2.278-2.286 nm, 2.316-2.330 nm and 2.334-2.344 nm, sin embargo, solo la banda de 1.791 nm se acerca a las mencionadas por el autor, ya que no se tienen las demás bandas a causa de ruidos.



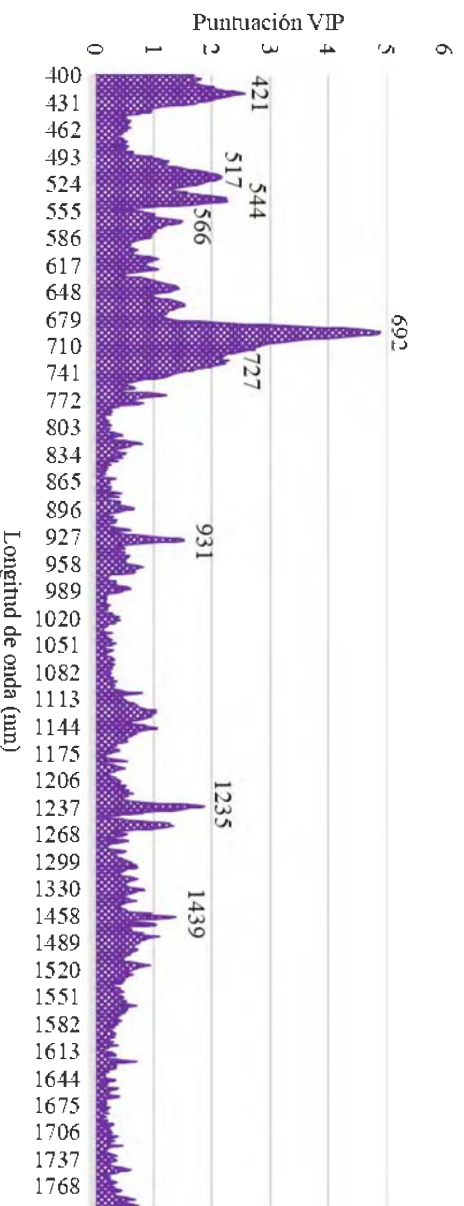
**Figura 46.** Gráfico de la variable de importancia para la proyección (VIP), mostrando la importancia de cada longitud de onda en el desarrollo del modelo de calidad de pasto para proteína cruda, a lo largo del espectro.

Lingjie y Chengci (2018), encontraron que las bandas más favorables para detectar FDN son: 556, 560, 566, 571, 575, 644, 1.142 y 1.145 nm. En la Figura 47, se identifica que las bandas de 556 y 560, calzan con las de los autores, así como 1.142 y 1.145 que son levemente mayores a 1, pero también se consideran de importancia. El rango de la banda 1.120 nm está caracterizado por contener lignina, y de 1.200 a 1.400 nm, se encuentra agua, celulosa, almidón y lignina, a causa de los enlaces C – H y O – H (Curran, 1989); siendo la lignina, hemicelulosa y celulosa, componentes que caracterizan la FDN. También, la FDN se puede encontrar en 2.070-2.088 nm y 2.278-2.286 nm (Lugassi et al., 2015), pero estas bandas no se tienen en el modelo ya que se cortaron por ruidos.



**Figura 47.** Gráfico de la variable de importancia para la proyección (VIP), mostrando la importancia de cada longitud de onda en el desarrollo del modelo de calidad de pasto para fibra detergente neutro, a lo largo del espectro.

La banda que presenta mayor importancia para la FDA, es la de 692 nm (Figura 48), la cual indica una transición de electrones en la clorofila-a (Curran, 1989); los autores Sun et al. (2022), también obtuvieron gran relevancia en la banda ubicada entre 650-750 nm para la FDA. La concentración de clorofila tiende a ser mayor en hojas más jóvenes y digestibles en comparación con las hojas más fibrosas y maduras (Madakadze et al., 1999). Por esto, se considera como una posibilidad que haya un vínculo proporcional entre el valor de la fibra y la clorofila (Figuras A6 y A7), para los datos de esta investigación, ya que ambos parámetros tuvieron un comportamiento similar a lo largo del tiempo. También se destacan las bandas de 1.235 y 1.439 nm, que contienen enlaces de O-H, indicadores de lignina y celulosa.



**Figura 48.** Gráfico de la variable de importancia para la proyección (VIP), mostrando la importancia de cada longitud de onda en el desarrollo del modelo de calidad de pasto para fibra detergente ácido, a lo largo del espectro.

## 6. Conclusiones

- Según el análisis de varios ciclos de crecimiento del pasto estrella africana, se observó que la altura y la producción de biomasa seca no aumentaron de manera consistente a medida que la edad de rebrote se incrementaba, contradiciendo las expectativas iniciales, lo cual se puede deber a la variabilidad climática y diferencias entre las subparcelas muestreadas.
- Los parámetros de calidad de MS, PC, FDN y FDA, no tuvieron el comportamiento esperado según la teoría en la mayoría de los ciclos analizados, lo cual puede deberse a las inconsistencias en el desarrollo del forraje en las fechas de muestreo, que se observan en los resultados de altura y biomasa.
- El manejo de los lotes influyó en cuatro de los seis datos auxiliares medidos, ya que solamente la altura y la MS no muestran diferencias significativas. Cuando un lote es de pastoreo hay ciertos factores que se deben considerar, tales como: la carga de las cuatro patas del animal que causa compactación, las boñigas y orines que están dispersas en lugares diferentes, fertilización, y también que hay más incidencia de hierbas. Por otro lado, el lote de corte solamente depende de la fertilización y de compactación causada por la maquinaria.
- El análisis de componentes principales fue un proceso exploratorio importante para detectar los datos atípicos causados por la variabilidad de la calibración del blanco del equipo, interferencia de luz y entrada de humedad. De la totalidad de los datos tomados, la mayoría de los datos atípicos correspondieron a los del lote con manejo de pastoreo, con una varianza explicada entre 71,42% y 64,88% para el primer componente principal.
- La remoción de rangos de longitudes de onda con ruidos fue un paso esencial en el desarrollo de los modelos, ya que la presencia de agua en la planta y el ambiente afectó considerablemente el aprovechamiento de las bandas entre 1.357-1.455 nm y 1.791-2.500 nm.
- El modelo con mejores resultados fue el de MS, con el conjunto de datos con manejo de pasto de corte, y se considera que es el único modelo replicable y muy satisfactorio, para la EEAVM por sus resultados de  $r^2_{cv}=0,81$ ,  $RMSECV=1,41$  y  $RPD=2,31$ .
- Los parámetros de calidad que resultaron con menor precisión y se consideran poco confiables, fueron los de PC, FDN, y FDA con valores de RPD entre 1,1 y 1,4. lo cual se atribuye a que las bandas necesarias para obtener estos parámetros se encuentran dentro de los rangos eliminados a causa de ruidos en el espectro (1.357-1.455 y 1.791-2.500 nm).
- Los modelos generados utilizando teledetección en campo con datos hiperespectrales, son una línea base de investigación que, a largo plazo podría ayudar a los ganaderos y agricultores de forrajes a mejorar su productividad, rendimiento en la granja y construir

resiliencia en el sistema productivo, al permitir que las decisiones se puedan tomar de forma más precisa y oportuna.

## 7. Recomendaciones

- Se recomienda utilizar una estructura con forma de balde invertido negro y oscuro, para proteger la sonda del equipo para tomar los datos espectrales, y reducir los ruidos por entradas y cambios de la luz.
- A modo de continuidad de esta investigación, se podrían realizar los modelos con regresión lineal múltiple, ya que algunos autores la recomiendan por ser más eficiente e intuitivo.
- Se sugiere realizar correlaciones entre los espectros y la incidencia de la humedad del suelo, ya que en esta investigación las muestras de humedad del suelo mostraron mucha variabilidad, entonces no se utilizaron para comparar.
- Un análisis de la fertilidad del suelo ayudaría a explicar de forma más precisa el comportamiento del pasto a lo largo del tiempo.
- Como continuidad a esta investigación, se pueden realizar modelos más robustos, con mayor cantidad de datos e idealmente con diferencia en ubicación de fincas, ya que algunos autores obtuvieron mejores resultados al incrementar su número de muestras de pasto, que provenían de diferentes sistemas productivos.
- Cuando se vaya a realizar un modelo, si los datos de laboratorio o de referencia, no tienen diferencias significativas entre sí con respecto al manejo, hay mayor probabilidad que se obtenga un coeficiente de determinación más alto al realizar el modelo.
- Para darle continuidad a esta investigación se podría cargar el modelo para materia seca en ASD Indico Pro para escanear y predecir nuevas muestras en tiempo real, y realizar el proceso de validación con muestras de otra época del año y otros lotes de la EEAVM con el pasto estrella africana.
- Un dato que se podría utilizar para mejorar la precisión del modelo es la altura dentro del conjunto de datos que se vaya a cargar en el PLSR, tal como lo realizó la autora Sun et al. (2022).
- Tomando en cuenta que los modelos realizados con los conjuntos de datos con manejo de pastoreo fueron los menos confiables, y que en Costa Rica este manejo es el predominante en el país, se recomienda enfocar una investigación en sistemas de pastoreo para la generación de modelos de determinación de parámetros de calidad de pastos.

- Se recomienda validar el modelo de MS con un nuevo conjunto de datos de MS obtenidos a través de laboratorio para confirmar la precisión de la estimación y que el modelo logra su objetivo previsto.
- Para probar si se pueden obtener mejores precisiones de los modelos de MS y de FDA, se sugiere utilizar solamente las regiones de las bandas seleccionadas en el  $VIP > 1$ , y excluyendo las que tienen valores de  $VIP < 1$ .



## 8. Referencias

- Alomar, D., Alarcón, M., & Kusanovic, A. (2015, Mayo 6). Predicción de la calidad de lana mediante Espectroscopía de Refractividad en el Infrarrojo Cercano (NIRS). *AgroSur*, 1, 19-24. <https://doi.org/DOI:10.4206/agrosur.2015.v43n1-03>
- Analytics Beyond Measure. (2018). *El análisis de la fibra en el pienso animal*. FOSS. <https://www.fossanalytics.com/-/media/files/documents/papers/laboratories-segment/ebook-fibre-analysis-of-animal-feed-es.pdf>
- Andrade, M. (2006). *Evaluación de técnicas de manejo para mejorar la utilización del pasto kikuyo (Pennisetum clandestinum Hochst. Ex Chiov) en la producción de ganado lechero en Costa Rica*. (Tesis de licenciatura ed.). San José, Costa Rica: Universidad de Costa Rica. <http://repositorio.sibdi.ucr.ac.cr:8080/jspui/handle/123456789/5871>
- Arguedas Villalobos, S. (2017). *Encadenamientos productivos y multiplicadores de empleo e ingreso para la actividad económica cría de ganado vacuno a partir de la matriz insumo producto Costa Rica 2012*. San José, Costa Rica: Universidad de Costa Rica. Retrieved 23 de Junio de 2022, from <http://repositorio.sibdi.ucr.ac.cr:8080/jspui/bitstream/123456789/4333/1/41407.pdf>
- Ball, D., Collins, M., Lacefield, G., Martin, N., Mertens, D., Olson, K., . . . Wolf, M. (2017). *Understanding forage quality*. University of Wisconsin. <https://fyi.extension.wisc.edu/forage/files/2017/04/FQ.pdf>
- Ben-Dor, E. T. (2013). *Hyperspectral remote sensing, in Airborne Measurements for Environmental Research: Methods and Instruments*, eds. Weinheim, Germany: M. Wendisch and J.-L. Brenguier.
- Biewer, S., Fricke, T., & Wachendorf, M. (2009). Development of canopy reflectance models to predict forage quality of legume-grass mixtures. *Crop Science*, 49(5), 1917-1926. <https://doi.org/doi:10.2135/cropsci2008.11.0653>
- Bueso Ponce, M. (2017). *Nutrición Ganado de Engorde: Importancia de la materia seca*. Programa Nacional de Extensión Agrícola y Ganadera. Honduras: Texas Tech University. Retrieved 12 de Junio de 2022, from [https://www.depts.ttu.edu/icfie/Countries\\_projects/LAC/Honduras/CAFOGAH/fs4.pdf](https://www.depts.ttu.edu/icfie/Countries_projects/LAC/Honduras/CAFOGAH/fs4.pdf)
- ChemProject. (29 de Abril de 2020). *Chem Project Organization*. <https://www.chemproject.org/chemhouse/research-projects>
- Chong, I.-G., & Jun, C.-H. (2005). Performance of some variable selection methods when multicollinearity is present. *Chemometrics and intelligent laboratory systems*, 78(1-2), 103-112. <https://doi.org/https://doi.org/10.1016/j.chemolab.2004.12.011>
- Comrey, A. L., & Lee, H. B. (1992). *A first course in factor analysis*. Hillsdale.

- Coto F., A., & Rojas G., A. M. (28 de Junio de 2021). Comparativa multi e hiperespectral del pasto *Cynodon nlemfuensis* bajo condiciones tropicales y de pastoreo con ganado lechero. *Ingeniería: Revista de la Universidad de Costa Rica*, 32. <https://doi.org/10.15517/ri.v32i1.46129>
- Cubero, A. (13 de Octubre de 2018). Ticos consumen en promedio 216 kilos de lácteos al año. *La República*. Retrieved 8 de Enero de 2024, from <https://www.nacion.com/economia/agro/consumo-de-leche-por-persona-en-costa-rica-supera/5IOWM2CSU5BCRNK5KQVEXAP6VE/story/>
- Curran, P. J. (1989). Remote sensing of foliar chemistry. *Remote Sensing of Environment*, 30(3), 271-278. [https://doi.org/http://dx.doi.org/10.1016/0034-4257\(89\)90069-2](https://doi.org/http://dx.doi.org/10.1016/0034-4257(89)90069-2)
- de Alckmin, G. T., Lucieer, A., Roerink, G., Rawnsley, R., Hoving, I., & Kooistra, L. (2020, Setiembre 20). Retrieval of Crude Protein in Perennial Ryegrass Using Spectral Data at the Canopy Level. *remote sensing*. <https://doi.org/http://dx.doi.org/10.3390/rs12182958>
- Di Marco, O. (31 de Julio de 2012). *Ergomix*. Retrieved 01 de Noviembre de 2021, from Estimación de calidad de los forrajes: <https://www.engormix.com/ganaderia-carne/articulos/estimacion-calidad-forrajes-t29621.htm>
- Dörner, J., Dec, D., Peng, X., & Horn, R. (2010). Effect of land use change on the dynamic behaviour of structural properties of an Andisol in southern Chile under saturated and unsaturated hydraulic conditions. *Geoderma*, 159, 189-197. <https://doi.org/http://dx.doi.org/10.1016/j.geoderma.2010.07.011>
- Esbensen, K. H., Guyot, D., Westad, F., & Houmolle. (2009). *Multivariate data analysis—in practice: An introduction to multivariate data analysis and experimental design* (5 ed.). Oslo, Norway. <https://doi.org/doi-org.ezproxy.sibdi.ucr.ac.cr/10.1002/cem.692>
- Fernandes, A. F. (2015). *Uso da espectroscopia de reflectância do infravermelho próximo (NIRS) para previsão da composição bromatológica de vagens de algaroba e palma forrageira*. Sobral: Universidad Estadual Vale do Acaraú. <https://www.alice.cnptia.embrapa.br/alice/bitstream/doc/1055858/1/CNPC2015Usodaespectroscopia.pdf>
- Ferrufino, A. J., Mora, D., & Villalobos, L. A. (2022). Biomasa y bromatología del pasto Estrella Africana (*Cynodon nlemfuensis* Vanderyst) con cinco períodos de rebrote. *Agronomía Mesoamericana*, 33(2), 477-486. <https://doi.org/https://revistas.ucr.ac.cr/index.php/agromeso/index>
- Fourty, T., & Baret, F. (Mayo de 1998). On spectral estimates of fresh leaf biochemistry. *International Journal of Remote Sensing*, 19(7), 1283-1297. <https://doi.org/http://dx.doi.org/10.1080/014311698215441>
- Fulkerson, W. J., & Slak, K. (1993). Productivity of *Lotus pendunculatus* and *Trifolium repens* in a base pasture of kikuyu grass. *Proceedings of the Eight Annual conference of the Grassland Society of New South Wales*, (págs. 111-112).

- Gao, J., Meng, B., Liang, T., Feng, Q., Ge, J., Yin, J., . . . Xie, H. (2019). Modeling alpine grassland forage phosphorus based on hyperspectral remote sensing and multi-factor machine learning algorithm in the east of Tibetal Plateau, China. *ISPRS Journal of Photogrammetry and Remote Sensing*, *147*, 104-117. <https://doi.org/https://doi.org/10.1016/j.isprsjprs.2018.11.015>
- García Martínez, G., Irisarri, G., & Golluscio, R. (2018). Uso de un sistema de seguimiento forrajero basado en imágenes satelitales. 4. Retrieved Octubre 23, 2021, from [https://forratec.com.ar/newsletter/\\_2018/10/fls-2018-10-27.html](https://forratec.com.ar/newsletter/_2018/10/fls-2018-10-27.html)
- García-Martínez, S., Gálvez-Sola, L. N., Alonso, A., Agulló, E., Rubio, F., Ruiz, J. J., & Moral, R. (2011, Septiembre 26). Quality assessment of tomato landraces and virus-resistant breeding lines: quick estimation by near infrared reflectance spectroscopy. *Journal of the Science of Food and Agriculture*, *92*(6), 1178-1185. <https://onlinelibrary.wiley.com/doi/10.1002/jsfa.4661>
- Hernández, S., Aguilar, H., Ávila, I., Acuña, S., Vargas, Y., Vargas, A., & Obando, M. F. (2022). *Informe final del Paisaje Productivo de Pastos*. San José, Costa Rica: CONARE, CeNAT, PRIAS. <https://doi.org/ISBN 978-9977-77-464-0>
- Hernández, S., O. P. , J., J. G., R., & Elías, H. (2005, Mayo). Manejo de praderas asociadas de gramíneas y leguminosas para pastoreo en el trópico. *Revista electrónica REDVET*, *6*(5), 1695-7504. <https://www.redalyc.org/pdf/636/63617216009.pdf>
- Huang, J., Romero-Torres, S., & Moshgbar, M. (2010, Octubre 1). *Practical Considerations in Data Pre-treatment for NIR and Raman Spectroscopy*. American Pharmaceutical Review: <https://www.americanpharmaceuticalreview.com/Featured-Articles/116330-Practical-Considerations-in-Data-Pre-treatment-for-NIR-and-Raman-Spectroscopy/>
- Ikoyi, A. Y., & Younge, B. A. (6 de Junio de 2022). Faecal near-infrared reflectance spectroscopy profiling for the prediction of dietary nutritional characteristics for equines. *Animal Feed Science and Technology*, *290*. <https://doi.org/https://doi.org/10.1016/j.anifeedsci.2022.115363>
- INEC. (Octubre de 2020). Resultados generales de la actividad ganadera vacuna y porcina. *Encuesta Nacional Agropecuaria 2020*(2215-5570).
- INIA Uruguay. (2018). Algunos conceptos sobre calidad de forrajes. *Sistema Ganadero Extensivo*, *33* y *34*. Retrieved Noviembre 01, 2021, from <http://www.ainfo.inia.uy/digital/bitstream/item/11188/1/Ficha-tecnica-33-Algunos-conceptos-sobre-calidad-de-forrajes.pdf>
- Ismail, S., & Depeweg, H. (2005). Water productivity and crop production simulation under surge flow irrigation on short furrows in Egypt. *Irrigation and Drainage*, *54*, 103-113. <https://vdocuments.mx/water-productivity-and-crop-production-simulation-under-surge-flow-irrigation.html?page=1>

- Jiménez-Castro, J. P. (2018). *Efecto de la época y los días de rebrote sobre la producción y la calidad nutritiva de pastos en Costa Rica*. Heredia, Costa Rica: Universidad Nacional.
- Johnson, C. R., Reiling, B. A., Mislevy, P., & Hall, M. B. (2001). Effects of nitrogen fertilization and harvest date on field, digestibility, fiber, and protein fractions of tropical grasses. *Journal of Animal Science*, 79, 2439-2448.
- Karlinasari, L., Sabed, M., Nyoman, I., Wistara, J., & Purwanto, Y. A. (2014, Diciembre). Near infrared (NIR) spectroscopy for spectroscopy for estimating the chemical composition of (*Acacia mangium* Willd.) wood. *Journal of Indian Academy of Wood Science*, 11(2), 162-167. <https://doi.org/DOI: 10.1007/s13196-014-0133-z>
- Kastanek, M., & Shiley, D. (2020). *Quantitative Prediction of Materials Properties using Reflectance Spectroscopy*. Malvern Panalytical. Retrieved 29 de Septiembre de 2021.
- Kawamura, K., Betteridge, K., Sanches, I. D., Touhy, M. P., Costall, D., & Inoue, Y. (2009). Field radiometer with canopy pasture probe as a potential tool to estimate and map pasture biomass and mineral components: a case study in the Lake Taupo catchment, New Zealand. *New Zealand Journal of Agricultural Research*, 52, 417-434. <https://doi.org/DOI: 10.1080/00288230909510524>
- Kawamura, K., Watanabe, N., Sakanoue, S., Lee, H.-J., Lim, J., & Yoshitoshi, R. (2013). Genetic algorithm-based partial least squares regression for estimating legume content in a grass-legume mixture using field hyperspectral measurements. *Japanese Society of Grassland Science*, 59, 166-172. <https://doi.org/doi: 10.1111/grs.12026>
- Knipling, E. B. (1970). Physical and physiological basis for the reflectance of visible and near-infrared radiation from vegetation. *Remote Sensing of Environment*, 1(3), 155-159. [https://doi.org/10.1016/S0034-4257\(70\)80021-9](https://doi.org/10.1016/S0034-4257(70)80021-9)
- Kusumo, B. H., Hedley, M. J., Hedley, C. B., Arnold, G. C., & Tuohy, M. P. (2009). Predicting pasture root density from soil spectral reflectance: Field measurement. *European Journal of Soil Science*, 61(1), 1-13. <https://doi.org/doi:10.1111/j.1365-2389.2009.01199.x>
- Lingjie, Z., & Chengci, C. (20 de Abril de 2018). Using remote sensing to estimate forage biomass and nutrient contents at different growth stages. *Biomass and Bioenergy*, 115, 74-81. <https://doi.org/https://doi.org/10.1016/j.biombioe.2018.04.016>
- Lugassi, R., Chudnovsky, A., Dvash, L., & Goldshleger, N. (2015). Estimating Pasture Quality of Fresh Vegetation Based on Spectral Slope of Mixed Data of Dry and Fresh Vegetation—Method Development. *remote sensing*, 8045-8066.
- Luna Cruz, A. D. (2019). *Determinación de la edad óptima de pastoreo para Estrella Africana (Cynodon plectostachyus) en el sistema lechero de la granja experimental Universidad Francisco de Paula Santander de Ocaña*. San José de Cúcuta, Colombia: Universidad Francisco de Paula Santander. <https://repositorio.ufps.edu.co/bitstream/handle/ufps/4369/1630463.pdf?sequence=1&isAllowed=y>

- Maćkiewicz, A., & Ratajczak, W. (8 de Diciembre de 1993). Principal Components Analysis (PCA). *Computers & Geosciences*, 19(3). What is principal component analysis?: <https://www.ibm.com/topics/principal-component-analysis>
- Madakadze, I., Stewart, A., Madakadze, M., Peterson, R., Coulman, E., & Smith, L. (1999). Field evaluation of the chlorophyll meter to predict yield and nitrogen concentration of switchgrass. *J Plant Nutr*, 22(6), 1001-1010. <https://doi.org/https://doi.org/10.1080/01904169909365689>
- MAG. (Junio de 2006). *MAG*. Retrieved 24 de Octubre de 2021, from Biblioteca virtual MAG: [http://www.mag.go.cr/bibliotecavirtual/Hb-ppv2\(2\).pdf](http://www.mag.go.cr/bibliotecavirtual/Hb-ppv2(2).pdf)
- Mandebvu, P., West, J. W., Hill, G. M., Gates, R. N., Hatfield, R. D., Mullinix, B. G., . . . Caudle, A. B. (1999). Comparison of Tifton 85 and Coastal Bermuda grasses for Yield, Nutrient Traits, Intake, and Digestion by Growing Beef Steers. *Journal of Animal*, 77, 1572-1586.
- Mishra, P., Shahrimie, M., Herrero-Langrero, A., Lohumi, S., Diezma, B., & Scheunders, P. (2017, Octubre 23). Close range hyperspectral imaging of plants: A review. *Biosystems Engineering*, 164, 49-67. <https://doi.org/10.1016/j.biosystemseng.2017.09.009>
- Monção, F., de Oliveira, E., Gabriel, A., Nascimento, F., Pedroso, F., & Freitas, L. L. (2016). Nutritional parameters of leaf blade from different tropical forages. *Scientia Agraria Paranaensis*, 15(2), 185-193. <https://doi.org/http://doi.org/10.18188/1983-1471/sap.v15n2p185-193>
- Mora, D. (24 de Abril de 2012). *Pastos y praderas suis.blogspot*. Retrieved 23 de Noviembre de 2021, from Pastos, forrajes y manejo de praderas: <https://pastosypraderasuis.blogspot.com/2012/04/de-que-manera-se-analizan-los-pastos-de.html>
- Muñoz-González, J. C., Huerta-Bravo, M., Lara Bueno, A., Rangel Santos, R., & de la Rosa Arana, J. L. (29 de Junio de 2016). Producción de materia seca de forrajes en condiciones de Trópico Húmedo en México. *Revista Mexicana de Ciencias Agrícolas*(16), 3329-3341. <https://www.scielo.org.mx/pdf/remexca/v7nspe16/2007-0934-remexca-7-spe16-3329.pdf>
- Mutanga, O. S. (Marzo de 2005). Estimating tropical pasture quality at canopy level using band depth analysis with continuum removal in the visible domain. *International journal of Remote Sensing*, 26(6), 1093–1108. <https://ftp.granit.unh.edu/submissions/sharing/papers/read/Mutanga%20et%20al.pdf>
- NASA SBIR program. (18 de Julio de 2023). Hyperspectral satellite imagery for Earth observation: <https://hyperspectral.azavea.com/>
- Nyamangara, J., Gotosa, J., & Mpfu, S. E. (2001). Cattle manure effects on structural stability and water retention capacity of a granitic sandy soil in Zimbabwe. *Soil and Tillage Research*, 62(3-4), 157-162. [https://doi.org/https://doi.org/10.1016/S0167-1987\(01\)00215-X](https://doi.org/https://doi.org/10.1016/S0167-1987(01)00215-X)

- Organización de las Naciones Unidas. (17 de Junio de 2019). *Noticias ONU*.  
<https://news.un.org/es/story/2019/06/1457891>
- Organización para la Cooperación y el Desarrollo; Organización de las Naciones Unidas para la Alimentación y la Agricultura. (2023). *OCDE-FAO Perspectivas Agrícolas 2023-2032*. (O. Publishing, Ed.) Paris: OCDE Publishing.  
<https://doi.org/https://doi.org/10.1787/2ad6c3ab-es>.
- Ozaki, Y., McClure, W., & Christy, A. (2005). *Spectral analysis: Near infrared spectroscopy in food science and technology*. New Jersey: Wiley Interscience.  
<https://onlinelibrary.wiley.com/doi/book/10.1002/0470047704>
- Pincay-Figueroa, P. E., López-González, F., Velarde-Guillén, J., Heredia-Nava, D., Martínez-Castañeda, F. E., Vicente, F., . . . Arriaga-Jordán, C. M. (2016, Diciembre 2). Cut and carry vs. grazing of cultivated pastures in smallscale dairy systems in the central highlands of Mexico. *Journal of Agriculture and Environment for International Development*, 110(2), 349-363. <https://doi.org/10.12895/jaeid.20162.496>
- Prananto, J. A., Weaver, T., & Budiman, I. (2020). Near infrared (NIR) spectroscopy as a rapid and cost-effective method for nutrient analysis of plant leaf tissues. In *Advances in Agronomy* (Vol. 164, pp. 1-49). Sydney, Australia.  
<https://doi.org/10.1016/bs.agron.2020.06.001>
- Pu, R. (2017). *Hyperspectral Remote Sensing*. (C. Press, Ed.) United States: Taylor & Francis Group, LLC.
- Pullanagari, R. R., Dynes, R. A., King, W. M., Yule, I. J., Thulin, S., Knox, N. M., & Ramoelo, A. (2013). Remote sensing of pasture quality. *Assessment and impact of grass and forage quality*, 7. Retrieved Octubre 23, 2021, from <https://www.researchgate.net/publication/343933767>
- Pullanagari, R. R., Yule, I. J., Tuohy, M., Dynes, R. A., & Hedley, M. (2012, Noviembre 13). In-field hyperspectral proximal sensing for estimating quality parameters of mixed pasture. *Precision Agriculture*, 351-369. <https://doi.org/10.1007/s11119-011-9251-4>
- Rahman, A. F., Gamon, J. A., Sims, D. A., & Schmidts, M. (2003). Optimum pixel size for hyperspectral studies of ecosystem function in southern California chaparral and grassland. *Remote Sensing of Environment*, 84, 192-207.
- Reuter de Oliveira, E. P. (2014). Ruminal degradability of dry matter of leaves and stem of genotypes of *Cynodon* spp. four ages of regrowth. *Semina: Ciências Agrárias*, 35(5), 2659–2672. <https://doi.org/http://doi.org/10.5433/1679-0359.2014v35n5p2659>
- Rodriguez, N. (3 de Marzo de 2023). Costos de insumos y clima limitan crecimiento de la producción de leche. *América Retail*. Costos de insumos y clima limitan crecimiento de la producción de leche: <https://www.america-retail.com/costa-rica/costos-de-insumos-y-clima-limitan-crecimiento-de-la-produccion-de-leche/>

- Ruiz-Álvarez, O., Arteaga-Ramírez, R., Vázquez-Peña, M., López-López, R., & Ontivetos-Capurata, R. (2011, Septiembre). Requerimiento de riego y predicción del rendimiento en gramíneas forrajeras mediante un modelo de simulación en Tabasco, México. *Agrociencia*, 45(7), 2521-9766. [https://www.scielo.org.mx/scielo.php?script=sci\\_arttext&pid=S1405-31952011000700001](https://www.scielo.org.mx/scielo.php?script=sci_arttext&pid=S1405-31952011000700001)
- Safari, H., Fricke, T., & Wachendorf, M. (2016). Determination of fibre and protein content in heterogeneous pastures using field spectroscopy and ultrasonic sward height measurements. *Computers and electronics in agriculture*, 256-263.
- Sánchez-Hernández, M. A., Morales-Terán, G., Rivas-Jacobo, M. A., Mendoza-Pedroza, S. I., Sánchez-Hernández, C., & Fraire-Cordero, S. (2022). Forage yield of African star grass (*Cynodon nlemfuensis* Vanderyst) at different cut heights. *Agro Productividad*, 15(7), 27-33. <https://doi.org/https://doi.org/10.32854/agrop.v15i7.2322>
- Schimleck, L. R., Evans, R., & Ilic, J. (2001). Estimation of Eucalyptus delegatensis wood properties by near infrared spectroscopy. *Canadian Journal of forest Research*, 31, 1671-1675. <https://doi.org/10.1139/cjfr-31-10-1671>
- Serrano, J., Shahidian, S., da Silva, J. M., Paixao, L., Carreira, E., Carmona-Cabezas, R., . . . Rato, A. E. (2020, Junio 28). Evaluation of Near Infrared Spectroscopy (NIRS) and Remote Sensing (RS) for Estimating Pasture Quality in Mediterranean Montado Ecosystem. *applied sciences*, 10(4463). <https://doi.org/10.3390/app10134463>
- Sierra B., C. (1992). Fertilidad del suelo y praderas permanentes. *Instituto de Investigaciones Agropecuarias. Estación Experimental Remehue*, 31, 57-86. <https://hdl.handle.net/20.500.14001/34654>
- Smith, C., Cogan, N., Badenhors, P., Spangenberg, G., & Smith, K. (2019, Junio 3). Field Spectroscopy to Determine Nutritive Value Parameters of Individual Ryegrass Plants. *agronomy*. <https://doi.org/doi:10.3390/agronomy9060293>
- Sun, S., Zuo, Z., Yue, W., Morel, J., Parsons, D., Liu, J., . . . Zhou, Z. (2022). Estimation of biomass and nutritive value of grass and clover mixtures by analyzing spectral and crop height data using chemometric methods. *Computers and Electronics in Agriculture*, 192, 0168-1699. <https://doi.org/https://doi.org/10.1016/j.compag.2021.106571>
- Taffarel, L. E., Mesquita, E. E., Dalazen Castagnara, D., Galbeiro, S., Barcellos Costa, P., & Rabello de-Oliveira, P. S. (2016). Tifton 85 grass responses to different nitrogen levels and cutting intervals. *Semina: Ciências Agrárias*, 37(4), 20-67. <https://doi.org/http://doi.org/10.5433/1679-0359.2016v37n4p2067>
- Toro Velásquez, P. A. (2010). Composição química, fracionamento de carboidratos e proteínas e digestibilidade in vitro de . *Revista Brasileira de Zootecnia*, 39(6), 1206-1213. <https://doi.org/https://doi.org/10.1590/S1516-35982010000600007>
- Trotter, M. (2010). Precision agriculture for pasture, rangeland and livestock systems. *CRC for Spatial Information*, 6. Retrieved 23 de Octubre de 2021, from

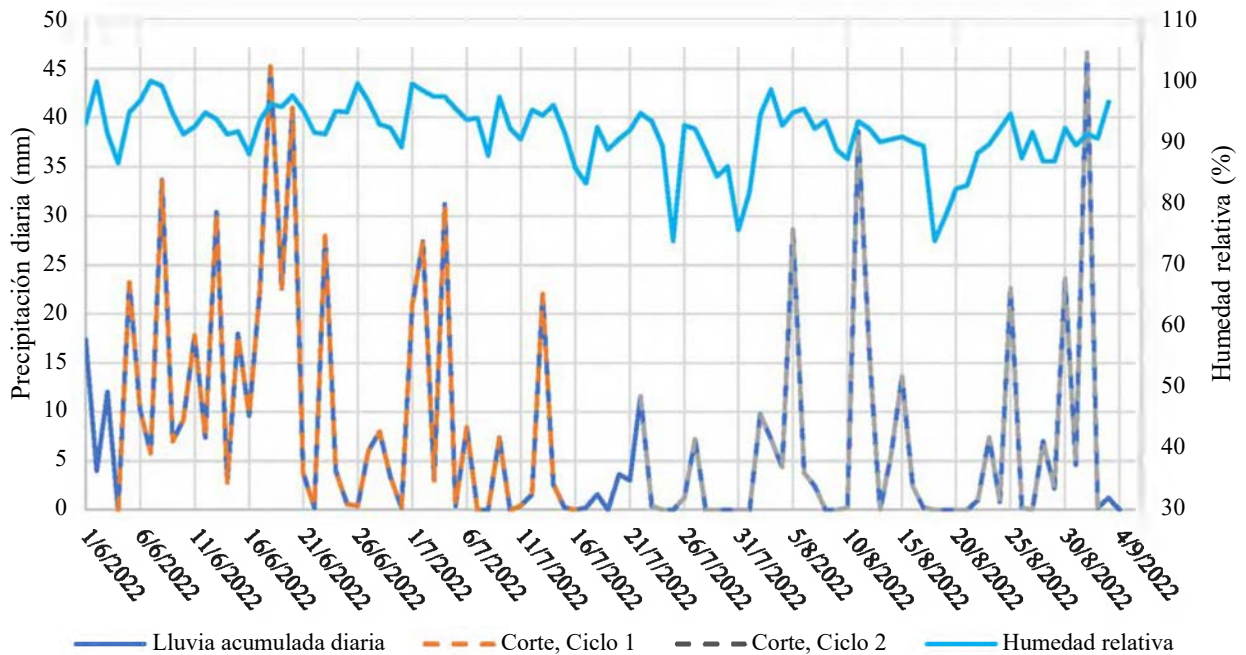
- [http://www.agronomyaustraliaproceedings.org/images/sampled/2010/crop-production/precision-agriculture/7130\\_trotter.pdf](http://www.agronomyaustraliaproceedings.org/images/sampled/2010/crop-production/precision-agriculture/7130_trotter.pdf)
- Vickery, P., Hedges, D., & Duggin, M. (1980). Assessment of the fertilizer requirement of improved pasture from remote sensing information. *Remote sensing of environment*, 131-148. [https://doi.org/https://doi.org/10.1016/0034-4257\(80\)90004-8](https://doi.org/https://doi.org/10.1016/0034-4257(80)90004-8)
- Villalobos, L. (2020). *Fichas de forrajes (piso, corte, arbustivas)*. MAG, Red nacional de pastos y forrajes. <http://proleche.com/wp-content/uploads/2020/10/Fichas-de-Forrajes.pdf>
- Villalobos, L., & Arce, J. (2013). Evaluación agronómica y nutricional del pasto estrella africana (*Cynodon nlemfuensis*) en la zona de Monteverde, Puntarenas, Costa Rica. I. Disponibilidad de biomasa y fenología. *Agronomía Costarricense*, 37(1), 91-101. <https://doi.org/https://doi.org/10.15517/RAC.V37I1.10715>
- Wold, S., Sjostrom, M., & Eriksson, L. (2001). PLS-regression: a basic tool of chemometrics. *Chemometrics and Intelligent Laboratory Systems*, 38(2001), 109-130. <https://www-sciencedirect-com.ezproxy.sibdi.ucr.ac.cr/science/article/pii/S0169743901001551>
- Zach. (3 de Noviembre de 2020). *Intro to Leave-One-Out Cross-Validation (LOOCV)*. Statology: <https://www.statology.org/leave-one-out-cross-validation/>
- Zeaiter, M., & Rutledge, D. (2009). Comprehensive Chemometrics. *Chemical and Biochemical Data Analysis*, 3, 121-231. <https://doi.org/https://doi-org.ezproxy.sibdi.ucr.ac.cr/10.1016/B978-044452701-1.00074-0>
- Zeng, L., & Chen, C. (2018). Using remote sensing to estimate forage biomass and nutrient contents at different growth stages. *Biomass and Bioenergy*, 115, 74-81. <https://doi.org/https://doi.org/10.1016/j.biombioe.2018.04.016>



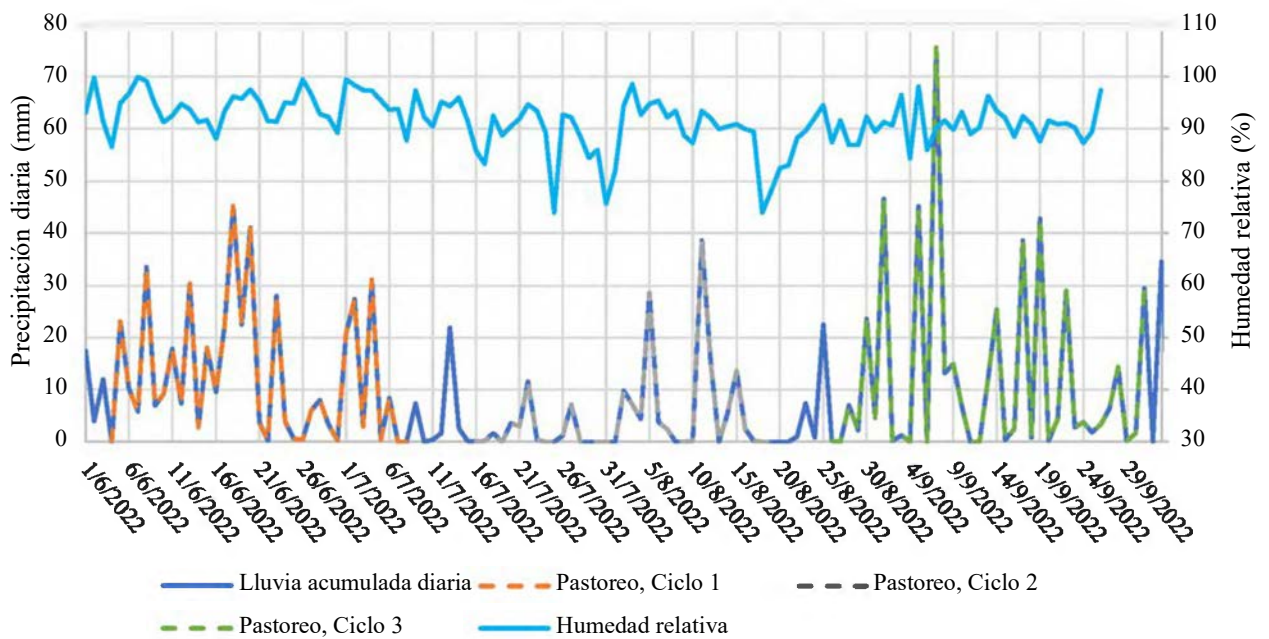
**Apéndice A:**  
**Objetivo 1**

**Tabla A1.** Cronograma final de toma de datos en campo en la Estación Experimental Alfredo Volio Mata de la Universidad de Costa Rica.

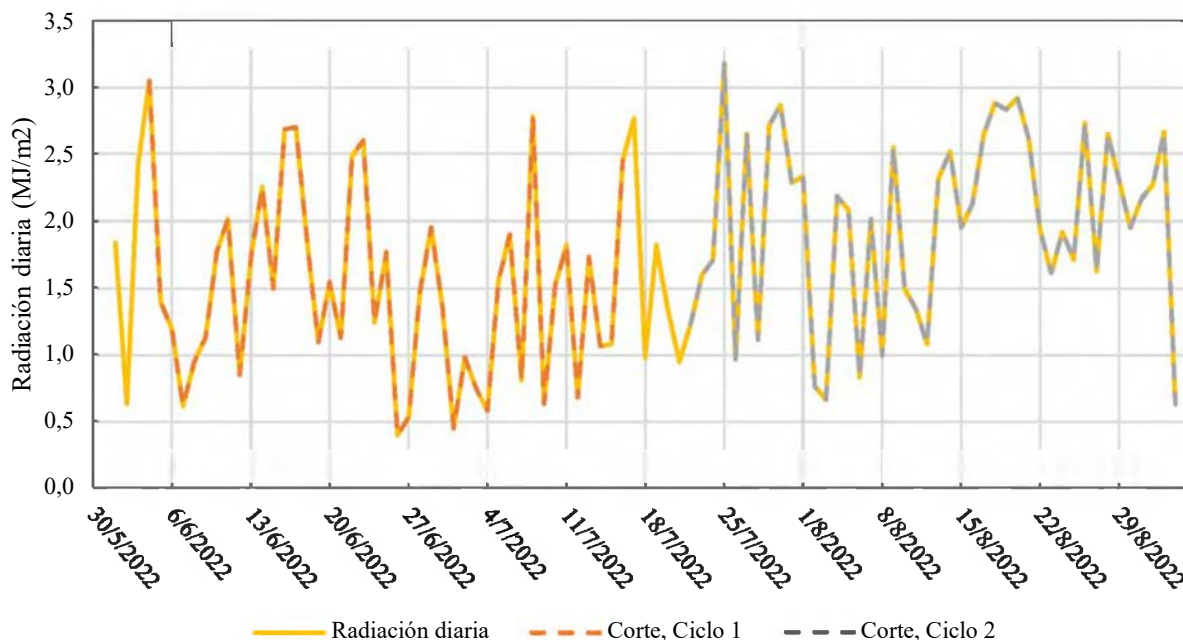
	Corte parcela 25		Pastoreo parcela 25			
Fecha		Etapas crecimiento	Comentario		Etapas crecimiento	Comentario
4/6/2022	Ciclo 1	Día 0	Datos completos	Ciclo 1	Día 0	Datos completos
10/6/2022						
17/6/2022		Día 14	Datos completos		Día 14	Datos completos
24/6/2022		Día 21	Datos completos		Día 21	Datos completos
1/7/2022		Día 28	Tormenta Tropical Bonnie		Día 28	Tormenta Tropical Bonnie
8/7/2022		Día 35	Datos completos		Día 35	Datos completos
15/7/2022		Día 42	Datos completos		Día 0	Datos completos
22/7/2022	Ciclo 2	Día 0	No hay datos, llovió	Ciclo 2	Día 7	Datos completos, se tomaron por equivocación
29/7/2022					Día 14	Datos completos
5/8/2022		Día 14	Datos completos		Día 21	Datos completos
12/8/2022		Día 21	Datos completos		Día 28	Datos completos
19/8/2022		Día 28	Datos completos		Día 35	Datos completos
26/8/2022		Día 35	Datos completos		Día 0	Datos completos
2/9/2022		Día 42	No hay datos, llovió			
9/9/2022				Ciclo 3	Día 14	Datos completos
16/9/2022					Día 21	Datos completos
23/9/2022					Día 28	Datos completos
30/9/2022					Día 35	Datos completos




**Figura A1.** Gráfico de precipitación y humedad relativa correspondiente a los días de muestreo del lote de corte (Fuente: Instituto Meteorológico Nacional).



**Figura A2.** Gráfico de precipitación y humedad relativa correspondiente a los días de muestreo del lote de pastoreo (Fuente: Instituto Meteorológico Nacional).



**Figura A3.** Gráfico de radiación global total correspondiente a los días de muestreo del lote de corte (Fuente: Instituto Meteorológico Nacional).



**Figura A4.** Gráfico de radiación global total correspondiente a los días de muestreo del lote de pastoreo (Fuente: Instituto Meteorológico Nacional).

**Tabla A2.** Valores de p de la ANOVA para la comparación de las todas variables dependientes con todas las variables independientes, incluyendo dos interacciones.

<b>Variable</b>	<b>Manejo</b>	<b>Ciclo</b>	<b>Edad</b>	<b>Manejo:Edad</b>	<b>Ciclo:Edad</b>
<b>MS</b>	0,1262 <sup>n.s.</sup>	<0,0001	0,1387 <sup>n.s.</sup>	0,0610 <sup>n.s.</sup>	0,8281 <sup>n.s.</sup>
<b>PC</b>	0,0008	0,0877 <sup>n.s.</sup>	0,3034 <sup>n.s.</sup>	0,9673 <sup>n.s.</sup>	0,4833 <sup>n.s.</sup>
<b>FDN</b>	<0,0001	0,0308	0,1519 <sup>n.s.</sup>	0,7197 <sup>n.s.</sup>	0,5408 <sup>n.s.</sup>
<b>FDA</b>	<0,0001	0,0002	0,0085	0,7065 <sup>n.s.</sup>	0,5919 <sup>n.s.</sup>
<b>Altura</b>	0,7802 <sup>n.s.</sup>	<0,0001	<0,0001	0,2196 <sup>n.s.</sup>	0,0003
<b>Biomasa seca</b>	0,0004	0,0001	0,0766 <sup>n.s.</sup>	0,2281 <sup>n.s.</sup>	0,0496

<sup>n.s.</sup> no significativo. Datos comparados mediante análisis de varianza ( $\alpha=0,05$ ).

**Tabla A3.** Resultado de prueba de Tukey y media de datos para la comparación de las variables dependientes con el ciclo (1 y 2 para corte, y 1, 2 y 3 para pastoreo).

<b>Variable</b>	<b>Altura (cm)</b>	<b>Biomasa seca (ton/ha)</b>	<b>MS (%)</b>	<b>PC (%)</b>	<b>FDN (%)</b>	<b>FDA (%)</b>
<b>Ciclo 1, Corte</b>	29,45 b	3,82 b, c	21,92 a	13,81 b	61,62 a	33,51 a
<b>Ciclo 2, Corte</b>	14,68 a	2,22 a	27,47 b	11,53 a, b	63,57 a, b	36,80 b
<b>Ciclo 1, Pastoreo</b>	15,13 a	3,30 a, b	28,13 b	10,31 a	64,91 b, c	36,41 b
<b>Ciclo 2, Pastoreo</b>	24,74 b	3,99 b, c	26,94 b	9,24 a	65,17 b, c	37,59 b
<b>Ciclo 3, Pastoreo</b>	25,67 b	4,43 c	22,38 a	10,90 a, b	67,36 c	37,93 b

Datos comparados mediante análisis de varianza seguido por prueba Tukey ( $\alpha=0,05$ ). Medias con una letra común no son significativamente diferentes ( $p>0,05$ ).

**Tabla A4.** Resultado de prueba de Tukey y media de datos para la comparación de las variables dependientes con la variable independiente de manejo (corte y pastoreo).

Variable	Altura (cm)	Biomasa seca (ton/ha)	MS (%)	PC (%)	FDN (%)	FDA (%)
<b>Corte</b>	22,07 a	3,02 a	24,70 a	12,67 a	62,60 a	35,16 a
<b>Pastoreo</b>	22,46 a	3,96 b	25,61 a	10,13 b	65,89 b	37,39 b

Datos comparados mediante análisis de varianza seguido por prueba Tukey ( $\alpha=0,05$ ). Medias con una letra común no son significativamente diferentes ( $p>0,05$ ).

**Tabla A5.** Resultado de prueba de Tukey y media de datos para la interacción entre el ciclo y la edad con la variable dependiente de altura en el pasto.

Ciclo	Edad (días)	Altura (cm)	Tukey
P1	14	10,67	a
P3	14	10,67	a
C2	35	11,59	a, b
C2	28	13,33	a, b
P1	21	14,04	a, b, c
C1	14	16,22	a, b, c, d
C2	14	16,74	a, b, c, d
C2	21	17,04	a, b, c, d
P2	35	19,52	a, b, c, d, e
P1	35	20,70	a, b, c, d, e
P2	14	23,26	a, b, c, d, e, f
P2	21	26,41	a, b, c, d, e, f
P3	35	27,33	b, c, d, e, f
C1	21	29,67	c, d, e, f
P2	28	29,78	c, d, e, f
P3	28	30,67	d, e, f
C1	35	33,30	e, f
P3	21	34,00	e, f
C1	42	38,63	f

Donde, C: Manejo de Corte, P: Manejo de Pastoreo. Datos comparados mediante análisis de varianza seguido por prueba Tukey ( $\alpha=0,05$ ). Medias con una letra común no son significativamente diferentes ( $p>0,05$ ).


**Tabla A6.** Resultado de prueba de Tukey y media de datos para la interacción entre el ciclo y la edad con la variable dependiente de biomasa seca en el pasto.

Ciclo	Edad (días)	Biomasa seca (ton/ha)	Tukey
C2	28	1,81	a
C2	14	1,99	a
C2	35	2,09	a
P1	21	2,59	a, b
C1	21	2,71	a, b
C2	21	2,98	a, b
C1	14	3,13	a, b
P1	14	3,44	a, b
P2	14	3,44	a, b
P3	14	3,57	a, b
P2	35	3,65	a, b
P1	35	3,87	a, b
P2	21	3,90	a, b
C1	42	4,24	a, b
P3	21	4,46	a, b
P3	35	4,84	b
P3	28	4,85	b
P2	28	4,95	b
C1	35	5,20	b


Donde, C: Manejo de Corte, P: Manejo de Pastoreo. Datos comparados mediante análisis de varianza seguido por prueba Tukey ( $\alpha=0,05$ ). Medias con una letra común no son significativamente diferentes ( $p>0,05$ ).



**Figura A5.** Repeticiones 2 y 3 del lote de pastoreo, para el día 14 del ciclo 3 de crecimiento, donde se observa material senescente que no fue comido por el ganado que pastoreó.



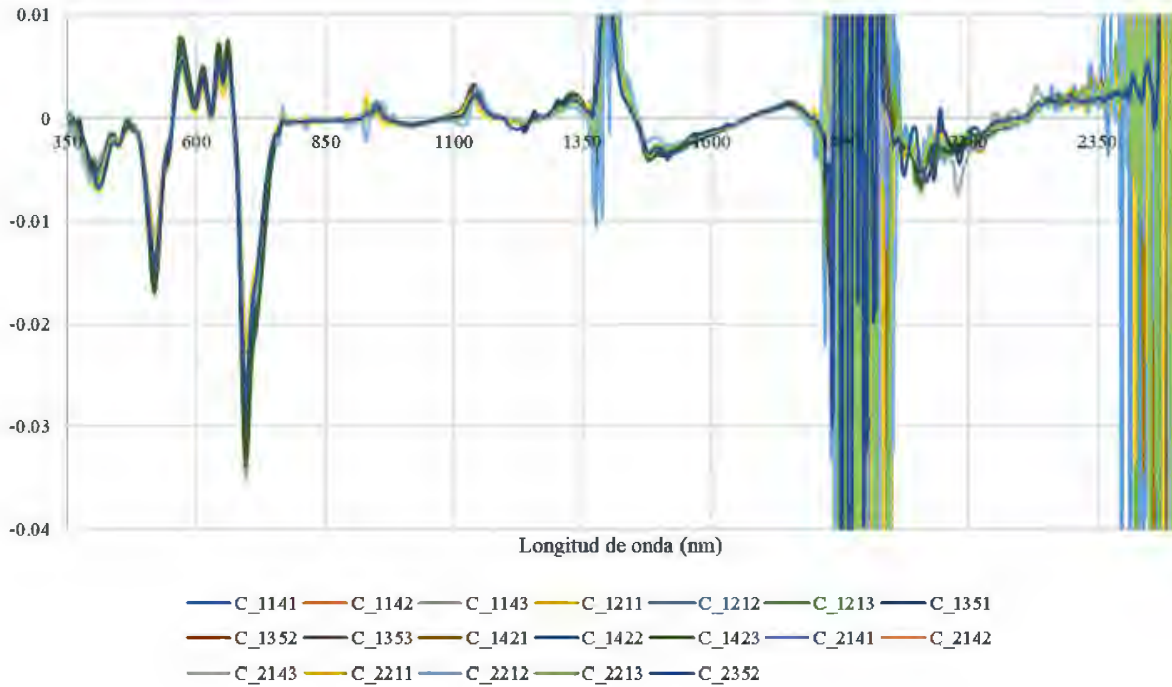
**Figura A6.** Datos de los patrones de clorofila para el lote con manejo de pasto de corte, del primer ciclo de crecimiento y del segundo ciclo de crecimiento, tomados como datos complementarios para el proyecto de investigación.



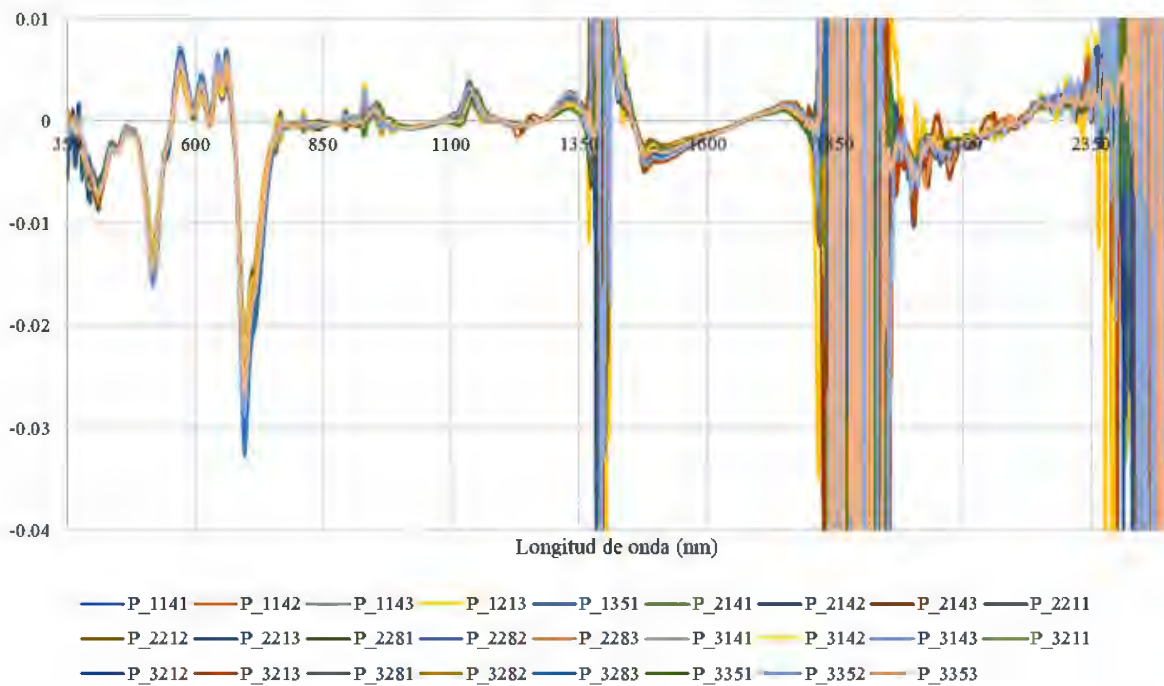
**Figura A7.** Datos de clorofila para el lote con manejo de pasto de pastoreo, del primer ciclo de crecimiento, del segundo ciclo de crecimiento y del tercer ciclo de crecimiento, tomados como datos complementarios para el proyecto de investigación.



**Apéndice B:**  
**Objetivo 2**



**Figura B1.** Espectros correspondientes al lote con manejo de corte, preprocesados con el método de primera derivada (Savitzky-Golay), sin los datos atípicos (n=20 datos) y con ruidos.



**Figura B2.** Espectros correspondientes al lote con manejo de pastoreo, preprocesados con el método de primera derivada (Savitzky-Golay), sin los datos atípicos (n=26 datos) y con ruidos.

**Apéndice C:  
Objetivo 3**

**Tabla C1.** Resultados de los modelos de MS y PC para los datos correspondientes a los lotes con manejo de corte y pastoreo juntos.

Conjunto de datos para eliminación de ruidos	Corte y Pastoreo (n=46)											
	MS						PC					
	Pretrat.	$r^2_{cv}$	RMSECV	$r^2_c$	RMSEC	LV	Pretrat.	$r^2_{cv}$	RMSECV	$r^2_c$	RMSEC	LV
1	1 <sup>era</sup> deri. (11), SNV	0,59	2,19	0,79	1,69	5	1 <sup>era</sup> deri. (11)	0,14	2,96	0,32	2,98	2
2	1 <sup>era</sup> deri. (11), SNV	0,52	2,40	0,74	1,88	5	1 <sup>era</sup> deri. (11), SNV	0,17	2,96	0,42	2,51	3
3	1 <sup>era</sup> deri. (11)	0,53	2,37	0,72	1,91	4	1 <sup>era</sup> deri. (11), SNV	0,12	2,95	0,20	2,87	1
4	1 <sup>era</sup> deri. (11)	0,58	2,21	0,77	1,74	4	1 <sup>era</sup> deri. (11), SNV	0,12	2,95	0,22	2,88	1

Los valores en paréntesis corresponden a la ventana utilizada en la primera derivada.

$r^2_c$ : coeficiente de determinación para el modelo de calibración

$r^2_{cv}$ : coeficiente de determinación para el modelo de validación cruzada

RMSEC: Error mínimo cuadrado de calibración

RMSECV: Error mínimo cuadrado de validación cruzada

1<sup>era</sup> deri. (11): Primera derivada con ventana de 11

MS: Materia Seca

PC: Proteína Cruda

LV: Variable Latente

**Tabla C2.** Resultado de los modelos de FDN y FDA para los datos correspondientes a los lotes con manejo de corte y pastoreo juntos.

Conjunto de datos para eliminación de ruidos	Corte y Pastoreo (n=46)											
	FDN						FDA					
	Pretrat.	$r^2_{cv}$	RMSECV	$r^2_c$	RMSEC	LV	Pretrat.	$r^2_{cv}$	RMSECV	$r^2_c$	RMSEC	LV
1	1 <sup>era</sup> deri. (11)	0,39	2,66	0,60	2,25	3	1 <sup>era</sup> deri. (11)	0,36	2,09	0,51	1,87	2
2	1 <sup>era</sup> deri. (11)	0,39	2,67	0,56	2,37	3	1 <sup>era</sup> deri. (11)	0,38	2,05	0,48	1,92	2
3	1 <sup>era</sup> deri. (11)	0,36	2,75	0,52	2,47	3	1 <sup>era</sup> deri. (11)	0,37	2,05	0,47	1,94	2
4	1 <sup>era</sup> deri. (11)	0,32	2,80	0,56	2,37	3	1 <sup>era</sup> deri. (11)	0,38	2,05	0,50	1,90	2

Los valores en paréntesis corresponden a la ventana utilizada en la primera derivada.

$r^2_c$ : coeficiente de determinación para el modelo de calibración

$r^2_{cv}$ : coeficiente de determinación para el modelo de validación cruzada

RMSEC: Error mínimo cuadrado de calibración

RMSECV: Error mínimo cuadrado de validación cruzada

1<sup>era</sup> deri. (11): Primera derivada con ventana de 11

FDN: Fibra Detergente Neutro

FDA: Fibra Detergente Ácido

LV: Variable Latente

**Tabla C3.** Resultados de los modelos de MS y PC para los datos correspondientes al lote con manejo de corte.

Conjunto de datos para eliminación de ruidos	Corte (n=20)											
	MS						PC					
	Pretrat.	$r^2_{cv}$	RMSECV	$r^2_c$	RMSEC	LV	Pretrat.	$r^2_{cv}$	RMSECV	$r^2_c$	RMSEC	LV
1	1 <sup>era</sup> deri. (11)	0,81	1,42	0,89	1,20	2	1 <sup>era</sup> deri. (11)	0,02	3,16	0,15	3,00	1
2	1 <sup>era</sup> deri. (11)	0,81	1,41	0,89	1,16	2	1 <sup>era</sup> deri. (11), SNV	0,02	3,20	0,18	2,94	1
3	1 <sup>era</sup> deri. (11)	0,75	1,65	0,86	1,34	2	1 <sup>era</sup> deri. (11), SNV	0,06	3,07	0,22	2,87	1
4	1 <sup>era</sup> deri. (11)	0,77	1,55	0,86	1,33	2	1 <sup>era</sup> deri. (11), SNV	0,08	3,06	0,28	2,77	1

Los valores en paréntesis corresponden a la ventana utilizada en la primera derivada.

$r^2_c$ : coeficiente de determinación para el modelo de calibración

$r^2_{cv}$ : coeficiente de determinación para el modelo de validación cruzada

RMSEC: Error mínimo cuadrado de calibración

RMSECV: Error mínimo cuadrado de validación cruzada

1<sup>era</sup> deri. (11): Primera derivada con ventana de 11

MS: Materia Seca

PC: Proteína Cruda

LV: Variable Latente

**Tabla C4.** Resultados de los modelos de FDN y FDA para los datos correspondientes al lote con manejo de corte.

Conjunto de datos para eliminación de ruidos	Corte (n=20)											
	FDN						FDA					
	Pretrat.	$r^2_{cv}$	RMSECV	$r^2_c$	RMSEC	LV	Pretrat.	$r^2_{cv}$	RMSECV	$r^2_c$	RMSEC	LV
1	1 <sup>era</sup> deri. (11)	0,30	2,40	0,66	1,77	2	1 <sup>era</sup> deri. (11)	0,44	1,86	0,55	1,73	1
2	1 <sup>era</sup> deri. (11)	0,28	2,46	0,57	1,99	2	1 <sup>era</sup> deri. (11), SNV	0,47	1,87	0,69	1,49	2
3	1 <sup>era</sup> deri. (11)	0,24	2,47	0,35	2,39	1	1 <sup>era</sup> deri. (11)	0,48	1,80	0,70	1,45	2
4	1 <sup>era</sup> deri. (11)	0,29	2,40	0,57	1,99	2	1 <sup>era</sup> deri. (11)	0,43	1,87	0,55	1,75	1

Los valores en paréntesis corresponden a la ventana utilizada en la primera derivada.

$r^2_c$ : coeficiente de determinación para el modelo de calibración

$r^2_{cv}$ : coeficiente de determinación para el modelo de validación cruzada

RMSEC: Error mínimo cuadrado de calibración

RMSECV: Error mínimo cuadrado de validación cruzada

1<sup>era</sup> deri. (11): Primera derivada con ventana de 11

FDN: Fibra Detergente Neutro

FDA: Fibra Detergente Ácido

LV: Variable Latente

**Tabla C5.** Resultados de los modelos de MS y PC para los datos correspondientes al lote con manejo de pastoreo.

Conjunto de datos para eliminación de ruidos	Pastoreo (n=26)											
	MS						PC					
	Pretrat.	$r^2_{cv}$	RMSECV	$r^2_c$	RMSEC	LV	Pretrat.	$r^2_{cv}$	RMSECV	$r^2_c$	RMSEC	LV
1	1 <sup>era</sup> deri. (11)	0,63	2,15	0,96	0,85	7	1 <sup>era</sup> deri. (11)	0,01	2,70	0,25	2,35	2
2	1 <sup>era</sup> deri. (11)	0,36	2,87	0,66	2,13	6	1 <sup>era</sup> deri. (11)	0,04	2,66	0,29	2,34	3
3	1 <sup>era</sup> deri. (11)	0,37	2,86	0,88	1,38	6	1 <sup>era</sup> deri. (11)	0,02	2,64	0,16	2,48	2
4	1 <sup>era</sup> deri. (11)	0,63	2,11	0,95	0,94	7	1 <sup>era</sup> deri. (11)	0,00	2,65	0,05	2,58	1

Los valores en paréntesis corresponden a la ventana utilizada en la primera derivada.

$r^2_c$ : coeficiente de determinación para el modelo de calibración

$r^2_{cv}$ : coeficiente de determinación para el modelo de validación cruzada

RMSEC: Error mínimo cuadrado de calibración

RMSECV: Error mínimo cuadrado de validación cruzada

1<sup>era</sup> deri. (11): Primera derivada con ventana de 11

MS: Materia Seca

PC: Proteína Cruda

LV: Variable Latente

**Tabla C6.** Resultados de los modelos de FDN y FDA para los datos correspondientes al lote con manejo de pastoreo.

Conjunto de datos para eliminación de ruidos	Pastoreo (n=26)											
	FDN						FDA					
	Pretrat.	$r^2_{cv}$	RMSECV	$r^2_c$	RMSEC	LV	Pretrat.	$r^2_{cv}$	RMSECV	$r^2_c$	RMSEC	LV
1	1 <sup>era</sup> deri. (11)	0,01	2,86	0,10	2,74	1	1 <sup>era</sup> deri. (11)	0,21	1,82	0,43	1,81	2
2	1 <sup>era</sup> deri. (11)	0,00	2,87	0,08	2,77	1	1 <sup>era</sup> deri. (11)	0,20	1,82	0,37	1,69	2
3	1 <sup>era</sup> deri. (11)	0,00	2,87	0,08	2,77	1	1 <sup>era</sup> deri. (11)	0,21	1,81	0,37	1,69	2
4	1 <sup>era</sup> deri. (11)	0,00	2,86	0,09	2,76	1	1 <sup>era</sup> deri. (11)	0,22	1,80	0,41	1,64	2

Los valores en paréntesis corresponden a la ventana utilizada en la primera derivada.

$r^2_c$ : coeficiente de determinación para el modelo de calibración

$r^2_{cv}$ : coeficiente de determinación para el modelo de validación cruzada

RMSEC: Error mínimo cuadrado de calibración

RMSECV: Error mínimo cuadrado de validación cruzada

1<sup>era</sup> deri. (11): Primera derivada con ventana de 11

FDN: Fibra Detergente Neutro

FDA: Fibra Detergente Ácido

LV: Variable Latente

**Tabla C7.** Resultados de los modelos de MS y PC para los datos correspondientes a los lotes con manejo de corte y pastoreo juntos, en absorbancia, sin pretratamientos.

Conjunto de datos para eliminación de ruidos	Corte y Pastoreo (n=46)											
	MS						PC					
	Pretrat.	$r^2_{cv}$	RMSECV	$r^2_c$	RMSEC	LV	Pretrat.	$r^2_{cv}$	RMSECV	$r^2_c$	RMSEC	LV
1	Ninguno	0,29	3,05	0,27	2,41	6	Ninguno	0,08	3,00	0,10	2,80	3
2	Ninguno	2,27	2,92	0,40	1,40	12	Ninguno	0,13	2,92	0,21	2,30	6
3	Ninguno	0,31	2,39	0,43	1,64	10	Ninguno	0,10	2,98	0,11	2,85	2
4	Ninguno	0,25	2,96	0,39	1,29	14	Ninguno	0,08	3,00	0,10	2,81	3

$r^2_c$ : coeficiente de determinación para el modelo de calibración  
 $r^2_{cv}$ : coeficiente de determinación para el modelo de validación cruzada  
 RMSEC: Error mínimo cuadrado de calibración  
 RMSECV: Error mínimo cuadrado de validación cruzada  
 1<sup>era</sup> deri. (11): Primera derivada con ventana de 11  
 MS: Materia Seca  
 PC: Proteína Cruda  
 LV: Variable Latente

**Tabla C8.** Resultados de los modelos de MS y PC para los datos correspondientes a los lotes con manejo de corte y pastoreo juntos, en absorbancia, sin pretratamientos.

Conjunto de datos para eliminación de ruidos	Corte y Pastoreo (n=46)											
	FDN						FDA					
	Pretrat.	$r^2_{cv}$	RMSECV	$r^2_c$	RMSEC	LV	Pretrat.	$r^2_{cv}$	RMSECV	$r^2_c$	RMSEC	LV
1	Ninguno	0,14	3,15	0,16	2,84	3	Ninguno	0,10	2,45	0,12	2,28	2
2	Ninguno	0,16	3,11	0,21	2,49	5	Ninguno	0,10	2,44	0,12	2,28	2
3	Ninguno	0,16	3,11	0,25	2,06	9	Ninguno	0,12	2,43	0,13	2,28	2
4	Ninguno	0,14	3,04	0,17	2,84	3	Ninguno	0,11	2,43	0,13	2,27	2

$r^2_c$ : coeficiente de determinación para el modelo de calibración  
 $r^2_{cv}$ : coeficiente de determinación para el modelo de validación cruzada  
 RMSEC: Error mínimo cuadrado de calibración  
 RMSECV: Error mínimo cuadrado de validación cruzada  
 1<sup>era</sup> deri. (11): Primera derivada con ventana de 11  
 FDN: Fibra Detergente Neutro  
 FDA: Fibra Detergente Ácido  
 LV: Variable Latente

**Tabla C9.** Resultados de los modelos de MS y PC para los datos correspondientes al lote con manejo de corte, en absorbancia, sin pretratamientos.

Conjunto de datos para eliminación de ruidos	Corte (n=20)											
	MS						PC					
	Pretrat.	$r^2_{cv}$	RMSECV	$r^2_c$	RMSEC	LV	Pretrat.	$r^2_{cv}$	RMSECV	$r^2_c$	RMSEC	LV
1	Ninguno	0,26	2,80	0,34	1,95	4	Ninguno	0,08	2,96	0,11	2,68	1
2	Ninguno	0,34	2,64	1,89	0,39	4	Ninguno	0,08	2,97	0,11	2,68	1
3	Ninguno	0,44	1,83	0,45	1,62	1	Ninguno	0,07	2,97	0,10	2,69	1
4	Ninguno	0,30	2,73	0,36	1,90	4	Ninguno	0,08	2,97	0,11	2,69	1

$r^2_c$ : coeficiente de determinación para el modelo de calibración  
 $r^2_{cv}$ : coeficiente de determinación para el modelo de validación cruzada  
 RMSEC: Error mínimo cuadrado de calibración  
 RMSECV: Error mínimo cuadrado de validación cruzada  
 1<sup>era</sup> deri. (11): Primera derivada con ventana de 11  
 MS: Materia Seca  
 PC: Proteína Cruda  
 LV: Variable Latente

**Tabla C10.** Resultados de los modelos de FDN y FDA para los datos correspondientes al lote con manejo de corte, en absorbancia, sin pretratamientos.

Conjunto de datos para eliminación de ruidos	Corte (n=20)											
	FDN						FDA					
	Pretrat.	$r^2_{cv}$	RMSECV	$r^2_c$	RMSEC	LV	Pretrat.	$r^2_{cv}$	RMSECV	$r^2_c$	RMSEC	LV
1	Ninguno	0,15	2,58	0,17	2,29	1	Ninguno	0,42	1,87	0,43	1,66	1
2	Ninguno	0,18	2,54	0,20	2,21	1	Ninguno	0,44	1,83	0,45	1,62	1
3	Ninguno	0,18	2,54	0,20	2,21	1	Ninguno	0,44	1,84	0,44	1,63	1
4	Ninguno	0,15	2,58	0,18	2,28	1	Ninguno	0,42	1,87	0,43	1,66	1

$r^2_c$ : coeficiente de determinación para el modelo de calibración  
 $r^2_{cv}$ : coeficiente de determinación para el modelo de validación cruzada  
 RMSEC: Error mínimo cuadrado de calibración  
 RMSECV: Error mínimo cuadrado de validación cruzada  
 1<sup>era</sup> deri. (11): Primera derivada con ventana de 11  
 FDN: Fibra Detergente Neutro  
 FDA: Fibra Detergente Ácido  
 LV: Variable Latente



**Tabla C11.** Resultados de los modelos de MS y PC para los datos correspondientes al lote con manejo de pastoreo, en absorbancia, sin pretratamientos.


Conjunto de datos para eliminación de ruidos	Pastoreo (n=26)											
	MS						PC					
	Pretrat.	$r^2_{cv}$	RMSECV	$r^2_c$	RMSEC	LV	Pretrat.	$r^2_{cv}$	RMSECV	$r^2_c$	RMSEC	LV
1	Ninguno	0,12	3,25	0,27	1,86	6	Ninguno	0,00	2,62	0,03	2,33	2
2	Ninguno	0,08	3,31	0,29	1,31	10	Ninguno	0,00	2,58124	0,03	2,34	2
3	Ninguno	0,21	3,07	0,39	1,31	10	Ninguno	0,00	2,58	0,03	2,34	2
4	Ninguno	0,05	3,37	0,13	2,80	2	Ninguno	0,00	2,60	0,03	2,33	2

$r^2_c$ : coeficiente de determinación para el modelo de calibración  
 $r^2_{cv}$ : coeficiente de determinación para el modelo de validación cruzada  
 RMSEC: Error mínimo cuadrado de calibración  
 RMSECV: Error mínimo cuadrado de validación cruzada  
 1<sup>era</sup> deri. (11): Primera derivada con ventana de 11  
 MS: Materia Seca  
 PC: Proteína Cruda  
 LV: Variable Latente

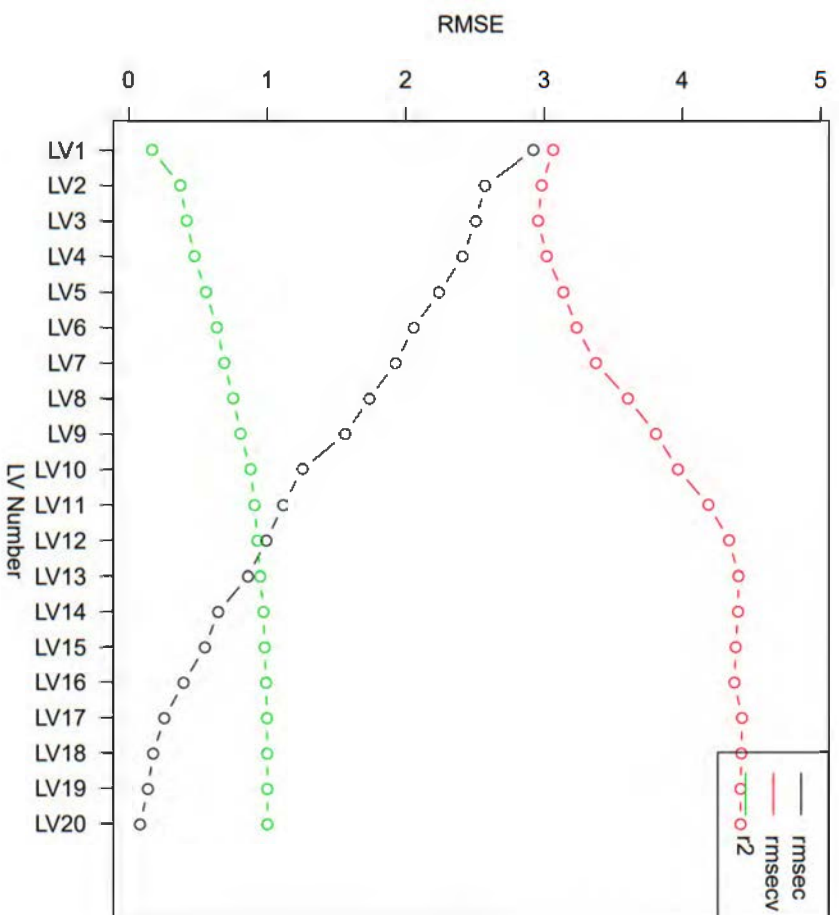
**Tabla C12.** Resultados de los modelos de FDN y FDA para los datos correspondientes al lote con manejo de pastoreo, en absorbancia, sin pretratamientos.

Conjunto de datos para eliminación de ruidos	Pastoreo (n=26)											
	FDN						FDA					
	Pretrat.	$r^2_{cv}$	RMSECV	$r^2_c$	RMSEC	LV	Pretrat.	$r^2_{cv}$	RMSECV	$r^2_c$	RMSEC	LV
1	Ninguno	0,00	2,94	0,02	2,72	1	Ninguno	0,00	2,07	0,00	1,90	2
2	Ninguno	0,00	2,95	0,01	2,71	1	Ninguno	0,00	2,06	0,01	1,88	1
3	Ninguno	0,00	2,94	0,01	2,70	1	Ninguno	0,00	2,05	0,03	1,80	2
4	Ninguno	0,00	2,93	0,01	2,71	1	Ninguno	0,00	2,07	0,03	1,71	2

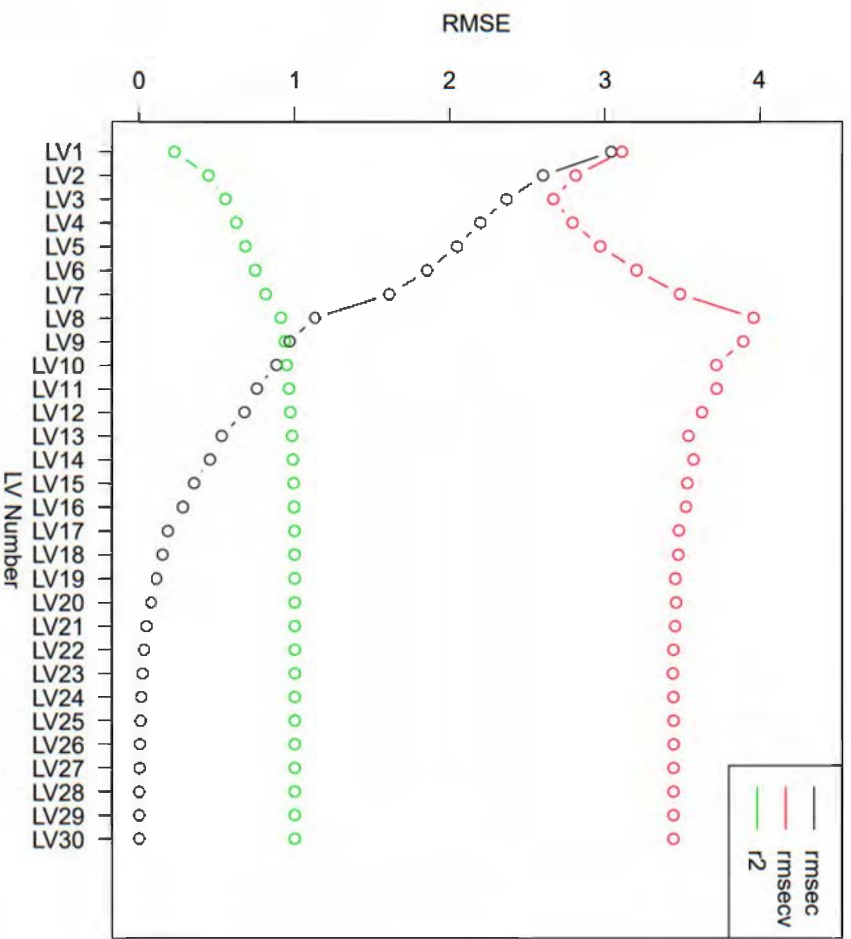
$r^2_c$ : coeficiente de determinación para el modelo de calibración  
 $r^2_{cv}$ : coeficiente de determinación para el modelo de validación cruzada  
 RMSEC: Error mínimo cuadrado de calibración  
 RMSECV: Error mínimo cuadrado de validación cruzada  
 1<sup>era</sup> deri. (11): Primera derivada con ventana de 11  
 FDN: Fibra Detergente Neutro  
 FDA: Fibra Detergente Ácido  
 LV: Variable Latente



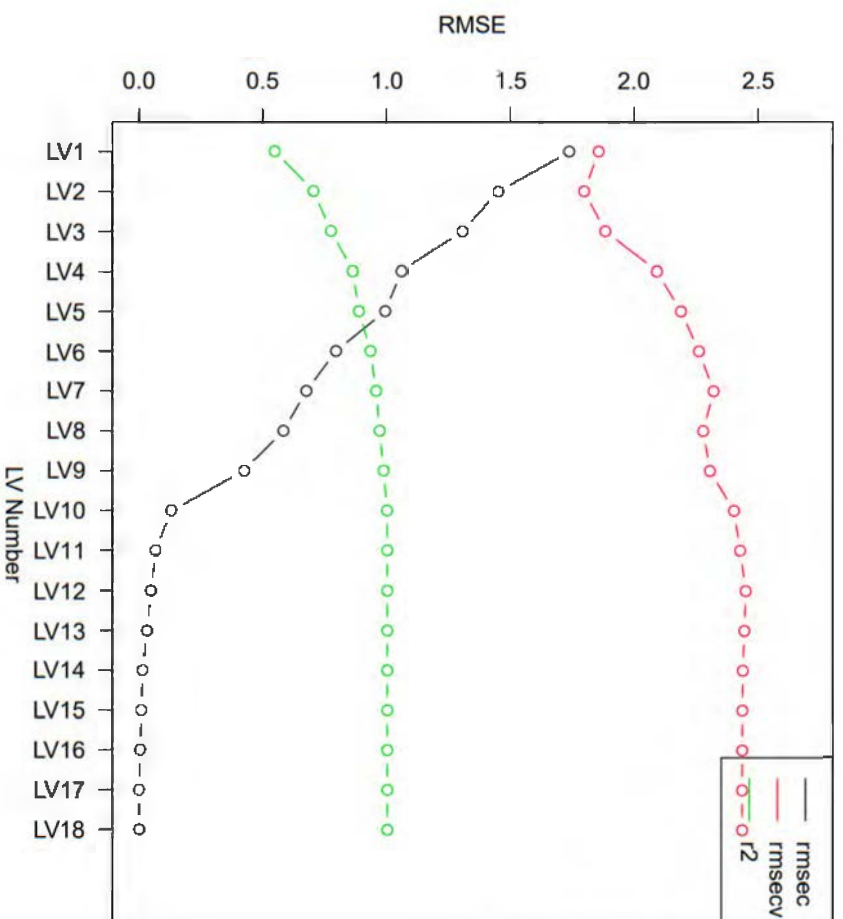
**Figura C1.** Gráfico de error mínimo cuadrado (RMSE) vs variable latente (LV) para el parámetro de calidad de materia seca.





**Figura C2.** Gráfico de error mínimo cuadrado (RMSE) vs variable latente (LV) para el parámetro de calidad de proteína cruda (PC).



**Figura C3.** Gráfico de error mínimo cuadrado (RMSE) vs variable latente (LV) para el parámetro de calidad de fibra detergente neutro (FDN).



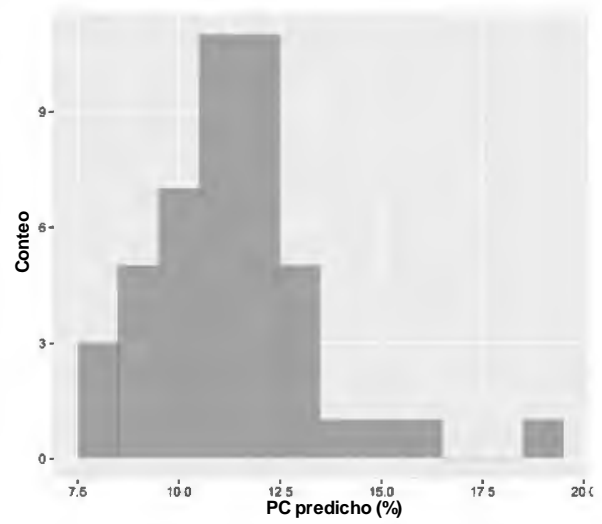
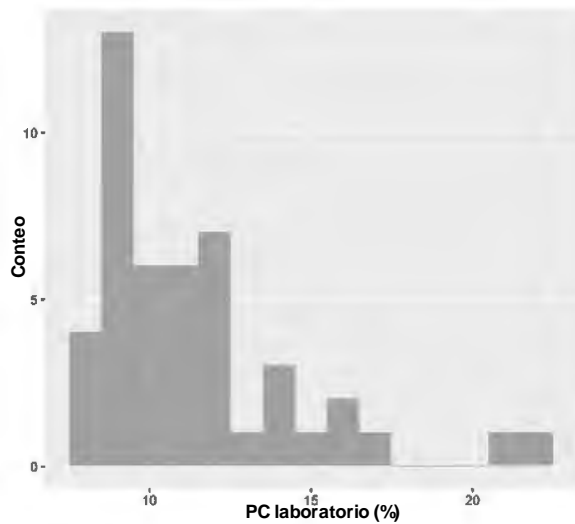
**Figura C4.** Gráfico de error mínimo cuadrado (RMSE) vs variable latente (LV) para el parámetro de calidad de fibra detergente ácido (FDA).



a)

b)


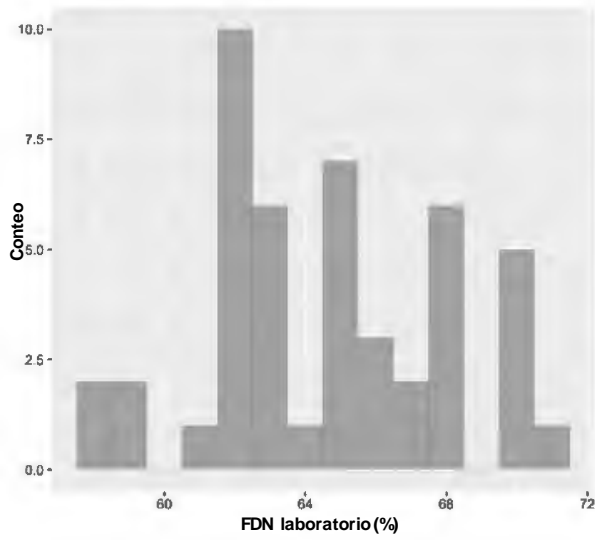
**Figura C5.** Histograma de los resultados de laboratorio (a), y de los resultados del modelo (b), ambos para la materia seca (MS).



a)

b)

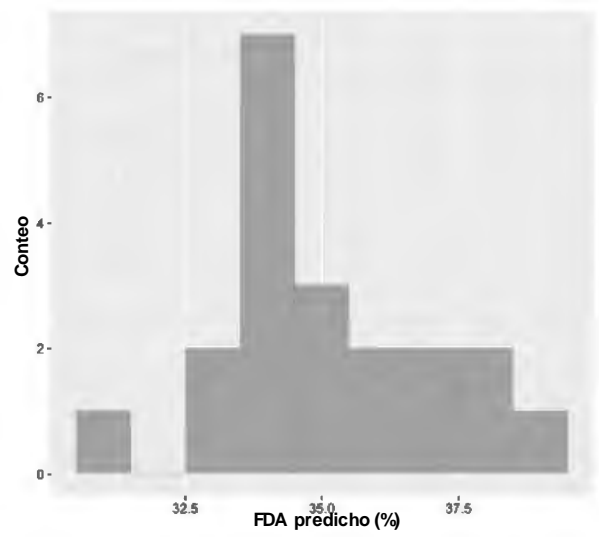
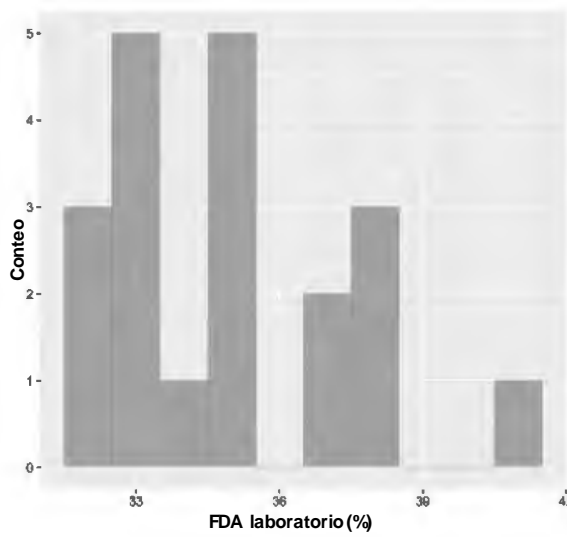
**Figura C6.** Histograma de los resultados de laboratorio (a), y de los resultados del modelo (b), ambos para la proteína cruda (PC).



a)

b)

**Figura C7.** Histograma de los resultados de laboratorio (a), y de los resultados del modelo (b), ambos para la fibra detergente neutro (FND).



a)

b)

**Figura C8.** Histograma de los resultados de laboratorio (a), y de los resultados del modelo (b), ambos para la fibra detergente ácido (FDA).

**Apéndice D:**  
**Datos recolectados**



**Tabla D1.** Resultados promedio de las pruebas bromatológicas realizadas en el laboratorio, para el lote con manejo de corte.

<b>Ciclo</b>	<b>Edad de crecimiento (día)</b>	<b>Materia Seca (%)</b>	<b>Proteína Cruda (%)</b>	<b>Fibra Detergente Neutro (%)</b>	<b>Fibra Detergente Ácido (%)</b>
1	14	20,01	16,27	59,93	33,88
	21	21,82	15,11	60,84	33,74
	35	23,12	11,46	61,31	32,97
	42	22,75	12,40	64,39	33,47
2	14	26,99	12,08	65,38	39,08
	21	27,56	10,56	62,48	37,70
	28	27,99	10,76	63,22	35,05
	35	27,32	12,73	63,21	35,36

**Tabla D2.** Resultados promedio de las pruebas bromatológicas realizadas en el laboratorio, para el lote con manejo de pastoreo.

<b>Ciclo</b>	<b>Edad de crecimiento (día)</b>	<b>Materia Seca (%)</b>	<b>Proteína Cruda (%)</b>	<b>Fibra Detergente Neutro (%)</b>	<b>Fibra Detergente Ácido (%)</b>
1	14	28,84	10,96	64,91	36,45
	21	26,72	10,75	65,06	36,87
	35	28,82	9,23	64,76	35,90
2	14	28,36	8,99	67,76	39,86
	21	24,11	9,75	64,15	37,57
	28	28,83	8,49	65,03	37,11
	35	26,48	9,73	63,74	35,81
3	14	23,80	12,90	67,33	38,78
	21	21,09	10,34	68,02	38,45
	28	23,52	9,84	68,60	37,38
	35	21,09	10,50	65,48	37,09

**Tabla D3.** Promedios de agua y alturas en la planta de acuerdo con la edad y manejo.

Manejo	Ciclo	Etapa fenológica (día)	Agua en la planta (%)	Altura (cm)
Corte	1	14	79,99	16,22
		21	78,18	29,67
		35	76,88	33,30
		42	77,25	38,63
	2	14	73,01	16,74
		21	72,44	17,04
		28	72,01	13,33
		35	72,68	11,59
Pastoreo	1	14	71,16	10,67
		21	73,28	14,04
		35	71,18	34,52
	2	14	71,64	24,26
		21	75,89	23,26
		28	71,17	26,41
		35	73,52	29,78
	3	14	76,20	10,67
		21	78,91	34,00
		28	76,48	30,67
		35	78,91	27,33