

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

Determinación de una metodología para la estimación del índice de área foliar en pasto Estrella Africana (*Cynodon nlemfuensis*) en la Estación Experimental Alfredo Volio Mata (EEAVM) de la Universidad de Costa Rica

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

Juan Carlos Hernández Lewis

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

## Aprobación

Trabajo Final de Graduación bajo la modalidad de proyecto de graduación, aprobado por la Comisión de Trabajos Finales de Graduación de la Escuela de Ingeniería de Biosistemas de la Universidad de Costa Rica, como requisito para optar por el grado académico de Licenciatura en Ingeniería Agrícola y de Biosistemas.



Juan Carlos Hernandez Lewis

Estudiante



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

Directora Trabajo Final de Graduación



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

Comité Asesor



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

Comité Asesor



Ing. Matías A. Chaves Herrera, M.sc.

Lector Invitado Ing.



Ing. Felipe Calleja Apéstegui, Ph.D.

Presidente Tribunal Examinador

## **Dedicatoria**

A mi padre, José Luis Hernández López, por todo su apoyo durante toda mi carrera universitaria.

## **Agradecimientos**

A mis padres, a mi hermano por acompañarme todos estos años y por su apoyo.

*A la profesora Melissa “GODning” Rojas Downing, PhD por su increíble apoyo tanto en el TFG como en mi formación, por todos sus consejos, paciencia (principalmente), apoyo y a siempre motivarme para ir más allá y dar lo mejor de mí en todo lo que haga, sin dudas, no pude haber elegido a una mejor directora para mi TFG.*

*A la profesora Alejandra Rojas González, PhD y al lector Jorge Elizondo Salazar, PhD por sus consejos, disponibilidad y apoyo a lo largo del TFG.*

*A mis amigos Andrés Cárdenas, Ignacio Mora, Sofía Núñez, Jorge Vega y Sebastián Villalobos por su apoyo y HORAS claramente no desperdiciadas en lolcito.*

*A la Estación Experimental Alfredo Volio Mata por brindar el sitio de estudio para poder llevar a cabo esta investigación.*

*A la Universidad de Costa Rica y a la Escuela de Ingeniería de Biosistemas por permitirme estudiar y brindarme tanto las herramientas como el conocimiento para poder llegar a ser un profesional.*

## Resumen

Tradicionalmente, los métodos utilizados para determinar el índice de área foliar para cualquier planta consisten en pruebas destructivas las cuales son ineficientes en términos de tiempo y de recursos. La teledetección cuenta con distintas plataformas las cuales permiten agilizar y mejorar los métodos para determinar el índice de área foliar de forma no intrusiva lo cual a su vez permite aumentar la escala de trabajo fácilmente de ser necesario.

En esta investigación se lleva a cabo un primer acercamiento al desarrollar un modelo para la estimación del índice de área foliar, utilizando datos hiperespectrales en el pasto Estrella Africana (*Cynodon nlemfuensis*) en la Estación Experimental Alfredo Volio Mata (EEAVM) de la Universidad de Costa Rica. Para esto se llevó a cabo la recolección de los datos hiperespectrales, así como de datos auxiliares durante los meses de junio hasta octubre del año 2022 en la parcela 25 de la EEAVM, la cual cuenta con pasto Estrella Africana bajo los manejos de corte y pastoreo.

De acuerdo con los resultados del análisis de varianza se determinó que el índice de área foliar es significativamente diferente entre los manejos, motivo por el cual se buscó modelar esta variable de forma independiente. Por otra parte, al tomar en consideración la edad del pasto, el índice de área foliar no presentó diferencias significativas entre las edades del pasto, lo cual se trató de un comportamiento no esperado.

La generación de los modelos para estimar el índice de área foliar se llevó a cabo comparando dos metodologías por manejo: 1) con modelos basados en índices de vegetación y 2) utilizando el modelo PLSR. En el caso de los modelos basados en índices de vegetación se utilizaron los índices NDVI, MTVI2, OSAVI, NDRE, RSI, EVI2 y OINLI para predecir el índice de área foliar mediante regresiones de diferentes tipos. Para los modelos PLSR se probaron combinaciones de métodos de preprocesado y variables latentes para determinar el modelo con la mayor precisión. Para el manejo de corte, el modelo basado en el índice de vegetación NDRE fue el que presentó los mejores resultados, alcanzando un valor de  $R^2$  de 0,6812 y un RMSE de 0,5089, al utilizar el conjunto de datos de borde rojo 2 (733-748 nm). Por otro lado, para el manejo de pastoreo se obtuvieron valores de  $R^2$  de 0,1914 y RMSE de 0,8597, al utilizar el índice NDRE y el conjunto de datos de borde rojo 3 (773-793 nm).

En cuanto a los resultados de los modelos PLSR, para el manejo de corte el conjunto de datos con el pretratamiento SNV, en conjunto con 3 variables latentes permitió obtener un  $R^2$  de 0,4147 y un RMSE de 0,7045. Lo que respecta al manejo de pastoreo, se lograron valores de  $R^2$  de 0,1769 y RMSE de 0,8772 con el modelo PLSR mediante 3 variables latentes y el conjunto de datos sin pretratamiento. Por lo que, para ambos tipos de manejo (corte y pastoreo) se determinó que la mejor metodología para la estimación del IAF fue la basada en índices de vegetación, utilizando el índice NDRE con distintas bandas de borde rojo de acuerdo con el tipo de manejo. Con base en los resultados obtenidos, únicamente se recomienda el uso de esta metodología para el manejo de corte, debido a los resultados poco satisfactorios del manejo de pastoreo.

## Índice

<b>1. INTRODUCCIÓN</b> .....	1
<b>2. MARCO TEÓRICO</b> .....	3
2.1. Marco conceptual .....	3
2.1.1. Teledetección.....	3
2.1.2. Datos espectrales .....	3
2.1.3. Índices de vegetación.....	3
2.1.4. Operador automatizado de modelos de transferencia radiativa (ARTMO).....	4
2.1.5. Método basado en IV.....	4
2.1.6. Análisis de componentes principales.....	4
2.1.7. Método de regresión de mínimos cuadrados parciales .....	5
2.1.8. Métodos de pretratamiento .....	5
2.1.9. Métricas .....	6
2.2. Antecedentes .....	6
<b>3. OBJETIVOS</b> .....	10
3.1. Objetivo general .....	10
3.2. Objetivos específicos.....	10
<b>4. METODOLOGÍA</b> .....	11
4.1. Descripción general.....	11
4.2. Sitio de estudio .....	13
4.2.1. Diseño Experimental .....	14
4.2.2. Recolección de datos .....	15
4.2.3. Factores externos que afectaron la recolección de datos .....	17
4.3. Objetivo 1: Análisis de datos hiperespectrales y auxiliares recolectados en campo.....	18
4.3.1. Procesamiento de datos auxiliares y análisis estadístico .....	18
4.3.2. Preprocesado de datos espectrales .....	18
4.4. Objetivo 2 y 3: Estimación de índice de área foliar y evaluación de ambas metodologías .	18
4.4.1. Análisis de componentes principales.....	19
4.4.2. Estimación del índice de área foliar utilizando índices de vegetación .....	20
4.4.3. Estimación del índice de área foliar utilizando el modelo PLSR .....	23
4.4.4. Determinación y clasificación de los mejores modelos.....	24
<b>5. RESULTADOS Y DISCUSIÓN</b> .....	27
5.1. Objetivo 1: Análisis de datos hiperespectrales y auxiliares recolectados en campo.....	27

5.1.1. Análisis de datos auxiliares .....	27
5.1.4. IAF y biomasa seca.....	43
5.1.2. Análisis de datos hiperespectrales .....	47
5.2. Objetivo 2 y 3: Estimación de índice de área foliar y determinación de la metodología más precisa.....	53
5.2.1. Análisis de componentes principales.....	53
5.2.2. Estimación del índice de área foliar utilizando índices de vegetación .....	57
5.2.3. Estimación del índice de área foliar utilizando el modelo PLSR .....	72
5.2.4. Comparación de resultados de la metodología basada en IV y PLSR para ambos tipos de manejo de pasto .....	86
<b>6. CONCLUSIONES</b> .....	<b>89</b>
<b>7. RECOMENDACIONES</b> .....	<b>90</b>
<b>8. REFERENCIAS</b> .....	<b>92</b>
<b>9. APÉNDICE A: OBJETIVO ESPECÍFICO 1</b> .....	<b>100</b>
<b>10. APÉNDICE B: OBJETIVOS ESPECÍFICOS 2 Y 3</b> .....	<b>108</b>
<b>11. APÉNDICE C: CÓDIGOS UTILIZADOS PARA EL DESARROLLO DE LOS MODELOS</b> .....	<b>145</b>

## Índice de figuras

<b>Figura 1.</b> Diagrama metodológico. ....	12
<b>Figura 2.</b> Ubicación de las parcelas experimentales de pasto Estrella Africana.....	13
<b>Figura 3.</b> Distribución de las parcelas experimentales para los manejos de corte (izquierda) y pastoreo (derecha). ....	14
<b>Figura 4.</b> Distribución de secciones en subparcelas experimentales para los manejos de pastoreo y corte.....	16
<b>Figura 5.</b> Metodología de medición del IAF utilizando el Licor LAI-2000 en una subparcela, con mediciones sobre el forraje (color negro) y bajo el forraje (color azul). ....	17
<b>Figura 6a.</b> Diagrama de combinaciones para los modelos basados en índices de vegetación. REG 1: borde rojo 1, REG 2: borde rojo 2, REG 3: borde rojo 3.....	22
<b>Figura 6b.</b> Combinación de bandas y generación de modelos basados en el IV NDVI.....	23
<b>Figura 7.</b> Diagrama de combinaciones para los modelos mínimos cuadrados parciales. RAW: Sin pretratamiento, SNV: Variación estándar normalizada (SNV, por sus siglas en ingles) y SMT: Suavizado.....	24
<b>Figura 8.</b> Método relativo para la determinación de los mejores modelos.....	26
<b>Figura 9.</b> Gráfico de cajas de IAF para ambos tipos de manejos (corte y pastoreo) con sus respectivos ciclos de crecimiento.....	29
<b>Figura 10.</b> Gráfico de cajas de IAF para cada ciclo de crecimiento del manejo de corte con sus respectivas edades del pasto. C: Corte.....	30
<b>Figura 11.</b> Gráfico de cajas de IAF para cada ciclo de crecimiento del manejo de pastoreo con sus respectivas edades del pasto. P: Pastoreo. ....	30
<b>Figura 12.</b> Gráfico de cajas de IAF para cada ciclo del manejo de corte con sus respectivas edades del pasto. ....	32
<b>Figura 13.</b> Gráfico de cajas de la biomasa para ambos tipos de manejos con sus respectivos ciclos de crecimiento.....	34
<b>Figura 14.</b> Gráfico de cajas de la biomasa para los manejos de corte y pastoreo con sus respectivas edades del pasto.....	35
<b>Figura 15.</b> Gráfico de cajas de la biomasa seca para cada ciclo de crecimiento del manejo de corte con sus respectivas edades del pasto. C: Corte. ....	36
<b>Figura 16.</b> Gráfico de cajas de la biomasa seca para cada ciclo de crecimiento del manejo de pastoreo con sus respectivas edades del pasto. P: Pastoreo. ....	38



<b>Figura 17.</b> Gráfico de cajas de la altura del pasto para ambos tipos de manejos con sus respectivos ciclos de crecimiento.....	40
<b>Figura 18.</b> Gráfico de cajas de la altura del pasto para cada ciclo de crecimiento del manejo de corte con sus respectivas edades del pasto. C: Corte. ....	41
<b>Figura 19.</b> Gráfico de cajas de la altura del pasto para cada ciclo de crecimiento del manejo de pastoreo con sus respectivas edades del pasto. P: Pastoreo. ....	42
<b>Figura 20.</b> Gráfico de cajas de la altura del pasto para los manejos de corte y pastoreo con sus respectivas edades del pasto.....	43
<b>Figura 21.</b> Distribución de valores de biomasa e IAF para ambos ciclos de crecimiento de corte.....	45
<b>Figura 22.</b> Distribución de valores de IAF para los tres ciclos de crecimiento de pastoreo.....	46
<b>Figura 23.</b> Distribución de valores de biomasa para los tres ciclos de crecimiento de pastoreo. ..	46
<b>Figura 24.</b> Espectros iniciales para la edad del pasto de 42 días del manejo de corte. ....	48
<b>Figura 25.</b> Espectros para la edad del pasto de 42 días del manejo de corte luego de excluir mediciones y aplicar la remoción de la brecha. ....	49
<b>Figura 26.</b> Espectro promedio final para la edad del pasto de 42 días del manejo de corte. ....	49
<b>Figura 27.</b> Espectros para el primer ciclo de crecimiento del manejo de corte. ....	50
<b>Figura 28.</b> Espectros para segundo ciclo de crecimiento del manejo de corte. ....	51
<b>Figura 29.</b> Espectros para primer ciclo de crecimiento del manejo de pastoreo. ....	52
<b>Figura 30.</b> Espectros para segundo ciclo de crecimiento del manejo de pastoreo.....	52
<b>Figura 31.</b> Espectros para tercer ciclo de crecimiento del manejo de pastoreo. ....	53
<b>Figura 32.</b> Puntuaciones de los componentes PC1 y PC2 del PCA realizado al conjunto de datos del manejo de corte antes de excluir mediciones. Las mediciones atípicas se resaltan con una elipse roja. ....	54
<b>Figura 33.</b> Puntuaciones de los componentes PC1 y PC2 del PCA realizado al conjunto de datos del manejo de corte luego de excluir mediciones. ....	55
<b>Figura 34.</b> Puntuaciones de los componentes PC1 y PC2 del PCA realizado al conjunto de datos del manejo de pastoreo antes de excluir mediciones. Las mediciones atípicas se resaltan con una elipse roja. ....	56
<b>Figura 35.</b> Puntuaciones de los componentes PC1 y PC2 del PCA realizado al conjunto de datos del manejo de pastoreo luego de excluir mediciones.....	57
<b>Figura 36.</b> Distribución de los valores medidos y estimados de IAF para el índice NDRE2 para el manejo de corte, con su línea de tendencia lineal (línea punteada). ....	62
<b>Figura 37.</b> Distribución de los valores medidos y estimados de IAF para el índice ONLI1 para el manejo de corte, con su línea de tendencia lineal (línea punteada). ....	63
<b>Figura 38.</b> Distribución de los valores medidos y estimados de IAF para el índice NDRE3 para el manejo de pastoreo, con su línea de tendencia lineal (línea punteada). ....	67

<b>Figura 39.</b> Distribución de los valores medidos y estimados de IAF para el índice MTVI2 para el manejo de pastoreo, con su línea de tendencia lineal (línea punteada). .....	67
<b>Figura 40.</b> Relación entre el IAF medido y el IV NDRE2 para el manejo de corte. ....	69
<b>Figura 41.</b> Relación entre el IAF medido y el IV NDRE1 para el manejo de corte. ....	70
<b>Figura 42.</b> Relación entre el IAF medido y el IV NDRE3 para el manejo de pastoreo.....	71
<b>Figura 43.</b> Relación entre el IAF medido y el IV MTVI2 para el manejo de pastoreo. ....	71
<b>Figura 44.</b> Relación entre el IAF medido y el IV ONLI3 para el manejo de pastoreo. ....	72
<b>Figura 45.</b> Espectros de todos los ciclos de crecimiento del manejo de corte tratados con el método de variación estándar normalizada (SNV). ....	74
<b>Figura 46.</b> Espectros de todos los ciclos de crecimiento del manejo de corte sin tratamiento (RAW).....	75
<b>Figura 47.</b> Espectros de todos los ciclos de crecimiento del manejo de corte tratados con el método de suavizado (SMT). ....	75
<b>Figura 48.</b> Distribución de los valores medidos y estimados de IAF para el modelo PLSR generado con el conjunto de datos sin tratamiento (RAW) del manejo de corte, con su línea de tendencia lineal (línea punteada). ....	76
<b>Figura 49.</b> Distribución de los valores medidos y estimados de IAF para el modelo PLSR generado con el conjunto de datos suavizado (SMT) del manejo de corte, con su línea de tendencia lineal (línea punteada). ....	77
<b>Figura 50.</b> Distribución de los valores medidos y estimados de IAF para el modelo PLSR generado con el conjunto de datos con combinación de métodos (SMT+SNV) del manejo de corte, con su línea de tendencia lineal (línea punteada).....	77
<b>Figura 51.</b> Distribución de los valores medidos y estimados de IAF para el modelo PLSR generado con el conjunto de datos tratados con la variación estándar normalizada (SNV) del manejo de corte, con su línea de tendencia lineal (línea punteada). ....	78
<b>Figura 52.</b> Distribución de los valores medidos y estimados de IAF para el modelo PLSR generado con el conjunto de datos con combinación de métodos (SNV+SMT) del manejo de corte, con su línea de tendencia lineal (línea punteada).....	78
<b>Figura 53.</b> Espectros de todos los ciclos de crecimiento del manejo de pastoreo sin tratamiento (RAW).....	80
<b>Figura 54.</b> Espectros de todos los ciclos de crecimiento del manejo de pastoreo tratados con el método de suavizado (SMT). ....	81
<b>Figura 55.</b> Espectros de todos los ciclos de crecimiento del manejo de pastoreo tratados con el método de variación estándar normalizada (SNV). ....	82
<b>Figura 56.</b> Espectros de todos los ciclos de crecimiento del manejo de pastoreo tratados con el método de variación estándar normalizada (SNV), para el intervalo de 750-1150 nm. ....	82
<b>Figura 57.</b> Distribución de los valores medidos y estimados de IAF para el modelo PLSR generado con el conjunto de datos sin tratamiento (RAW) del manejo de pastoreo, con su línea de tendencia lineal (línea punteada). ....	83

<b>Figura 58.</b> Distribución de los valores medidos y estimados de IAF para el modelo PLSR generado con el conjunto de datos tratados con la variación estándar normalizada (SNV) del manejo de pastoreo, con su línea de tendencia lineal (línea punteada). .....	84
<b>Figura 59.</b> Distribución de los valores medidos y estimados de IAF para el modelo PLSR generado con el conjunto de datos suavizado (SMT) del manejo de pastoreo, con su línea de tendencia lineal (línea punteada). .....	84
<b>Figura 60.</b> Distribución de los valores medidos y estimados de IAF para el modelo PLSR generado con el conjunto de datos con combinación de métodos (SNV+SMT) del manejo de pastoreo, con su línea de tendencia lineal (línea punteada). .....	85
<b>Figura 61.</b> Distribución de los valores medidos y estimados de IAF para el modelo PLSR generado con el conjunto de datos con combinación de métodos (SMT+SNV) del manejo de pastoreo, con su línea de tendencia lineal (línea punteada). .....	85
<b>Figura A. 1.</b> Contraste entre la tendencia del IAF y la radiación solar diaria para el manejo de corte.....	101
<b>Figura A. 2.</b> Contraste entre la tendencia del IAF y la precipitación diaria para el manejo de corte. ....	102
<b>Figura A. 3.</b> Contraste entre la tendencia del IAF y la temperatura promedio diaria para el manejo de corte.....	102
<b>Figura A. 4.</b> Contraste entre la tendencia de la biomasa y la radiación solar diaria para el manejo de corte.....	103
<b>Figura A. 5.</b> Contraste entre la tendencia de la biomasa y la precipitación diaria para el manejo de corte.....	103
<b>Figura A. 6.</b> Contraste entre la tendencia de la biomasa y la temperatura promedio diaria para el manejo de corte. ....	104
<b>Figura A. 7.</b> Contraste entre la tendencia del IAF y la radiación solar diaria para el manejo de pastoreo. ....	104
<b>Figura A. 8.</b> Contraste entre la tendencia del IAF y la precipitación diaria para el manejo de pastoreo. ....	105
<b>Figura A. 9.</b> Contraste entre la tendencia del IAF y la temperatura promedio diaria para el manejo de pastoreo. ....	105
<b>Figura A. 10.</b> Contraste entre la tendencia de la biomasa y la radiación solar diaria para el manejo de pastoreo. ....	106
<b>Figura A. 11.</b> Contraste entre la tendencia de la biomasa y la precipitación diaria para el manejo de pastoreo. ....	106
<b>Figura A. 12.</b> Contraste entre la tendencia de la biomasa y la temperatura promedio diaria para el manejo de pastoreo. ....	107

## Índice de tablas

<b>Tabla 1.</b> Bandas espectrales y sus rangos a utilizar. ....	20
<b>Tabla 2.</b> Índices de vegetación utilizados para estimar el IAF según Feng et al. (2019) y Nie et al. (2023). ....	21
<b>Tabla 3.</b> Resultados del análisis de varianza. ....	28
<b>Tabla 4.</b> Resultados de la prueba Tukey para el IAF según los ciclos de crecimiento. ....	29
<b>Tabla 5.</b> Resultados de la prueba Tukey para el IAF según el ciclo de crecimiento y la edad del pasto. ....	31
<b>Tabla 6.</b> Resultados de la prueba de Tukey para la biomasa seca según el ciclo de crecimiento. ....	33
<b>Tabla 7.</b> Resultados de la prueba Tukey para la biomasa seca según el ciclo de crecimiento y la edad del pasto. ....	37
<b>Tabla 8.</b> Radiación global total acumulada, precipitación acumulada y temperatura promedio por ciclo de crecimiento para los manejos de corte y pastoreo. ....	39
<b>Tabla 9.</b> Resultados de la prueba de Tukey para la altura del pasto según el ciclo de crecimiento. ....	40
<b>Tabla 10.</b> Resultados de la prueba Tukey para la altura de forraje según el tipo de manejo y la edad del pasto. ....	43
<b>Tabla 11.</b> Valores de referencia de cada subconjunto determinados con el método relativo para los manejos de corte y pastoreo. ....	58
<b>Tabla 12.</b> Mejores modelos determinados con el método relativo para todos los subconjuntos de manejo de corte. ....	60
<b>Tabla 13.</b> Comparación entre los tipos de clasificación de los mejores modelos basados en IV para el manejo de corte. ....	61
<b>Tabla 14.</b> Clasificación de los mejores modelos basados en índices para el manejo de corte. ....	61
<b>Tabla 15.</b> Mejores modelos determinados con el método relativo para todos los subconjuntos de manejo de pastoreo. ....	64
<b>Tabla 16.</b> Comparación entre los tipos de clasificación de los mejores modelos basados en IV para el manejo de pastoreo. ....	65
<b>Tabla 17.</b> Clasificación de los mejores modelos basados en índices para el manejo de pastoreo. ....	66

<b>Tabla 18.</b> Métricas de los mejores modelos PLSR para estimar IAF para cada uno de los métodos de pretratamiento del manejo de corte. ....	73
<b>Tabla 19.</b> Métricas de los mejores modelos PLSR para estimar IAF para cada uno de los métodos de pretratamiento del manejo de pastoreo. ....	80
<b>Tabla 20.</b> Mejores modelos para estimar el IAF generados con cada metodología según el tipo de manejo. ....	87
<b>Tabla A.</b> Resultados de la prueba de normalidad para los datos de ambos manejos utilizando la prueba de Kolmogorov-Smirnov. ....	101
<b>Tabla B1.</b> Primeros 5 modelos por tipo de regresión según su $R^2$ para el subconjunto del índice EVI2 para el manejo de corte. ....	109
<b>Tabla B2.</b> Primeros 5 modelos por tipo de regresión según su $R^2$ para el subconjunto del índice MTVI2 para el manejo de corte. ....	110
<b>Tabla B3.</b> Primeros 5 modelos por tipo de regresión según su $R^2$ para el subconjunto del índice ONLI1 para el manejo de corte. ....	111
<b>Tabla B4.</b> Primeros 5 modelos por tipo de regresión según su $R^2$ para el subconjunto del índice OSAVI para el manejo de corte. ....	112
<b>Tabla B5.</b> Primeros 5 modelos por tipo de regresión según su $R^2$ para el subconjunto del índice NDVI para el manejo de corte. ....	113
<b>Tabla B6.</b> Primeros 5 modelos por tipo de regresión según su $R^2$ para el subconjunto del índice ONLI2 para el manejo de corte. ....	114
<b>Tabla B7.</b> Primeros 5 modelos por tipo de regresión según su $R^2$ para el subconjunto del índice ONLI3 para el manejo de corte. ....	115
<b>Tabla B8.</b> Primeros 5 modelos por tipo de regresión según su $R^2$ para el subconjunto del índice RSI para el manejo de corte. ....	116
<b>Tabla B9.</b> Primeros 5 modelos por tipo de regresión según su $R^2$ para el subconjunto del índice NDRE1 para el manejo de corte. ....	117
<b>Tabla B10.</b> Primeros 5 modelos por tipo de regresión según su $R^2$ para el subconjunto del índice NDRE2 para el manejo de corte. ....	118
<b>Tabla B11.</b> Primeros 5 modelos por tipo de regresión según su $R^2$ para el subconjunto del índice NDRE3 para el manejo de corte. ....	119
<b>Tabla B12.</b> Primeros 5 modelos por tipo de regresión según su $R^2$ para el subconjunto del índice ONLI2 para el manejo de pastoreo. ....	120
<b>Tabla B13.</b> Primeros 5 modelos por tipo de regresión según su $R^2$ para el subconjunto del índice ONLI3 para el manejo de pastoreo. ....	121
<b>Tabla B14.</b> Primeros 5 modelos por tipo de regresión según su $R^2$ para el subconjunto del índice OSAVI para el manejo de pastoreo. ....	122
<b>Tabla B15.</b> Primeros 5 modelos por tipo de regresión según su $R^2$ para el subconjunto del índice RSI para el manejo de pastoreo. ....	123

<b>Tabla B16.</b> Primeros 5 modelos por tipo de regresión según su $R^2$ para el subconjunto del índice EVI2 para el manejo de pastoreo. ....	124
<b>Tabla B17.</b> Primeros 5 modelos por tipo de regresión según su $R^2$ para el subconjunto del índice NDVI para el manejo de pastoreo. ....	125
<b>Tabla B18.</b> Primeros 5 modelos por tipo de regresión según su $R^2$ para el subconjunto del índice MTVI2 para el manejo de pastoreo. ....	126
<b>Tabla B19.</b> Primeros 5 modelos por tipo de regresión según su $R^2$ para el subconjunto del índice ONLI1 para el manejo de pastoreo. ....	127
<b>Tabla B20.</b> Primeros 5 modelos por tipo de regresión según su $R^2$ para el subconjunto del índice NDRE1 para el manejo de pastoreo. ....	128
<b>Tabla B21.</b> Primeros 5 modelos por tipo de regresión según su $R^2$ para el subconjunto del índice NDRE2 para el manejo de pastoreo. ....	129
<b>Tabla B22.</b> Primeros 5 modelos por tipo de regresión según su $R^2$ para el subconjunto del índice NDRE3 para el manejo de pastoreo. ....	130
<b>Tabla B23.</b> Primeros 10 modelos del subconjunto del índice EVI2 de acuerdo con su valor de suma de relativos para el manejo de corte. ....	131
<b>Tabla B24.</b> Primeros 10 modelos del subconjunto del índice MTVI2 de acuerdo con su valor de suma de relativos para el manejo de corte. ....	131
<b>Tabla B25.</b> Primeros 10 modelos del subconjunto del índice NDVI de acuerdo con su valor de suma de relativos para el manejo de corte. ....	132
<b>Tabla B26.</b> Primeros 10 modelos del subconjunto del índice ONLI1 de acuerdo con su valor de suma de relativos para el manejo de corte. ....	132
<b>Tabla B27.</b> Primeros 10 modelos del subconjunto del índice ONLI2 de acuerdo con su valor de suma de relativos para el manejo de corte. ....	133
<b>Tabla B28.</b> Primeros 10 modelos del subconjunto del índice ONLI3 de acuerdo con su valor de suma de relativos para el manejo de corte. ....	133
<b>Tabla B29.</b> Primeros 10 modelos del subconjunto del índice OSAVI de acuerdo con su valor de suma de relativos para el manejo de corte. ....	134
<b>Tabla B30.</b> Primeros 10 modelos del subconjunto del índice RSI de acuerdo con su valor de suma de relativos para el manejo de corte. ....	134
<b>Tabla B31.</b> Primeros 10 modelos del subconjunto del índice NDRE1 de acuerdo con su valor de suma de relativos para el manejo de corte. ....	135
<b>Tabla B32.</b> Primeros 10 modelos del subconjunto del índice NDRE2 de acuerdo con su valor de suma de relativos para el manejo de corte. ....	135
<b>Tabla B33.</b> Primeros 10 modelos del subconjunto del índice NDRE3 de acuerdo con su valor de suma de relativos para el manejo de corte. ....	136
<b>Tabla B34.</b> Primeros 10 modelos del subconjunto del índice EVI2 de acuerdo con su valor de suma de relativos para el manejo de pastoreo. ....	136

<b>Tabla B35.</b> Primeros 10 modelos del subconjunto del índice NDVI de acuerdo con su valor de suma de relativos para el manejo de pastoreo.....	137
<b>Tabla B36.</b> Primeros 10 modelos del subconjunto del índice ONLI2 de acuerdo con su valor de suma de relativos para el manejo de pastoreo.....	137
<b>Tabla B37.</b> Primeros 10 modelos del subconjunto del índice ONLI3 de acuerdo con su valor de suma de relativos para el manejo de pastoreo.....	138
<b>Tabla B38.</b> Primeros 10 modelos del subconjunto del índice OSAVI de acuerdo con su valor de suma de relativos para el manejo de pastoreo.....	138
<b>Tabla B39.</b> Primeros 10 modelos del subconjunto del índice MTVI2 de acuerdo con su valor de suma de relativos para el manejo de pastoreo.....	139
<b>Tabla B40.</b> Primeros 10 modelos del subconjunto del índice RSI de acuerdo con su valor de suma de relativos para el manejo de pastoreo. ....	139
<b>Tabla B41.</b> Primeros 10 modelos del subconjunto del índice ONLI1 de acuerdo con su valor de suma de relativos para el manejo de pastoreo.....	140
<b>Tabla B42.</b> Primeros 10 modelos del subconjunto del índice NDRE1 de acuerdo con su valor de suma de relativos para el manejo de pastoreo.....	140
<b>Tabla B43.</b> Primeros 10 modelos del subconjunto del índice NDRE2 de acuerdo con su valor de suma de relativos para el manejo de pastoreo.....	141
<b>Tabla B44.</b> Primeros 10 modelos del subconjunto del índice NDRE3 de acuerdo con su valor de suma de relativos para el manejo de pastoreo.....	141
<b>Tabla B45.</b> Resultados de los modelos PLSR generados con el conjunto de datos sin tratamiento para el manejo de corte. ....	142
<b>Tabla B46.</b> Resultados de los modelos PLSR generados con el conjunto de datos sin tratamiento para el manejo de pastoreo.....	142
<b>Tabla B47.</b> Resultados de los modelos PLSR generados con el conjunto de datos SNV para el manejo de corte. ....	142
<b>Tabla B48.</b> Resultados de los modelos PLSR generados con el conjunto de datos SNV+SMT para el manejo de corte. ....	142
<b>Tabla B49.</b> Resultados de los modelos PLSR generados con el conjunto de datos SMT+SNV para el manejo de corte. ....	143
<b>Tabla B50.</b> Resultados de los modelos PLSR generados con el conjunto de datos sin tratamiento para el manejo de pastoreo.....	143
<b>Tabla B51.</b> Resultados de los modelos PLSR generados con el conjunto de datos SMT para el manejo de pastoreo. ....	143
<b>Tabla B52.</b> Resultados de los modelos PLSR generados con el conjunto de datos SNV para el manejo de pastoreo. ....	143
<b>Tabla B53.</b> Resultados de los modelos PLSR generados con el conjunto de datos SMT+SNV para el manejo de pastoreo.....	144

<b>Tabla B54.</b> Resultados de los modelos PLSR generados con el conjunto de datos SNV+SMT para el manejo de pastoreo.....	144
---	-----



## 1. INTRODUCCIÓN

El pasto Estrella Africana es una especie que ha sido utilizada en América latina, así como en Costa Rica, debido a su alta producción de biomasa, resistencia a plagas y enfermedades y a su alto valor nutricional, teniendo a su vez una excelente cobertura y establecimiento (Ferrufino et al., 2022). Se trata de un forraje que resulta productivo bajo un amplio rango de condiciones ambientales y tipos de suelo (Villalobos y Arce, 2013). Debido a esto y su uso extensivo, resulta de interés determinar una metodología para la estimación de su índice de área foliar (IAF), debido a que este se relaciona con la capacidad fotosintética y el potencial de producción de forraje.

El IAF cumple un papel crucial a la hora de determinar la estructura y el crecimiento de un cultivo, por lo que su monitoreo puede ayudar a la predicción de los requerimientos del cultivo (Ma et al., 2022a). Algunos estudios señalan que debido a lo costo-eficiente, prontitud y a su carácter no intrusivo, tecnologías de teledetección han llamado cada vez más la atención, ya que permiten analizar y mapear el IAF a escala global, en bosques, pastizales y en cultivos (Guo et al., 2021).

La teledetección permite generar datos espectrales los cuales son útiles para monitorear el estado de crecimiento de los cultivos haciendo uso de parámetros biofísicos, bioquímicos y fisiológicos, siendo el IAF un parámetro relacionado con mejoras en el rendimiento de los cultivos (Din et al., 2017). Además, el IAF se encuentra relacionado con algunas variables agronómicas, entre ellas la biomasa, sin embargo, su estimación directa mediante teledetección es complicada debido a que generalmente el IAF o la cobertura del suelo son los factores que influyen en la reflectancia del dosel (Casa et al., 2012).

Tradicionalmente, la determinación del IAF se lleva a cabo mediante pruebas destructivas, lo cual resulta laborioso y complicado de aplicar a gran escala (Guo et al., 2021). Esto se debe a que se suelen utilizar métodos que dependen de muestras de las hojas, motivo por el cual un aumento de la escala de trabajo va de la mano con un aumento en el tiempo, labores y costos de manera general (Ma et al., 2022a). Sin embargo, recientemente se han desarrollado sensores los cuales permiten estimar de manera no destructiva parámetros biofísicos de las plantas a una mayor escala, lo cual facilita el monitoreo del estado de crecimiento de un cultivo (Din et al., 2017). Con base en esto, esta investigación se centró en el uso de plataformas de teledetección como el radiotelespectrómetro, ya que permite obtener datos hiperspectrales los cuales se pueden utilizar para estimar propiedades de los cultivos como el IAF.

La estimación de propiedades fisiológicas de la vegetación mediante teledetección se ha realizado principalmente mediante dos abordajes, el empírico y el físico, donde el empírico presenta el inconveniente de que sus resultados son específicos para el sitio de estudio, vegetación, periodo y sensores utilizados (Yin et al., 2015). El abordaje empírico se basa en establecer relaciones estadísticas entre alguna propiedad de la vegetación, como el IAF, con datos obtenidos por

teledetección, presentando la ventaja de que da resultados precisos siendo a su vez un abordaje más directo que el físico (Berger et al., 2018).

Entre los métodos empíricos para determinar el IAF se encuentran los basados en índices de vegetación (IV) y los basados en bandas espectrales, los cuales hacen uso de regresiones para obtener un resultado (Berger et al., 2018). Los métodos basados en IV se basan en realizar regresiones de tipo lineal, exponencial, logarítmicas, cuadrática y potencial, las cuales permiten relacionar dichos índices con valores de IAF medidos en campo (Liang et al., 2020a). En cuanto a los métodos basados en bandas espectrales, se suelen utilizar modelos como la regresión de mínimos cuadrados parciales (PLSR, por sus siglas en inglés) y algoritmos de regresiones basados en machine learning para estimar el IAF (Xu et al., 2020).

El abordaje físico se basa en la inversión de modelos de transporte radiativo, los cuales relacionan la reflectancia y las propiedades biofísicas y bioquímicas del dosel vegetal, permitiendo que se pueda adaptar a una gran variedad de condiciones y cultivos (Yin et al., 2015). En el caso de los métodos físicos utilizados para estimar el IAF, el modelo de transferencia radiativa llamado PROSAIL se trata del más utilizado, este es la combinación de los modelos de propiedades espectrales ópticas de las hojas (PROSPECT) y dispersión de hojas arbitrariamente inclinadas (SAIL) (Xu et al., 2020).

Para esta investigación, se estimó el IAF utilizando IV y el modelo PLSR para un conjunto de datos hiperespectrales de pasto Estrella Africana, con el fin de identificar cual metodología fue más precisa al estimar el IAF, de el pasto Estrella Africana de la parcela 25 de la EEAVM. La recolección de datos se realizó en las parcelas experimentales del proyecto inscrito en Vicerrectoría de Investigación 737-C0208, ubicadas en la Estación Experimental de Ganado Lechero Alfredo Volio Mata (EEGLAVM) de la Universidad de Costa Rica. Esta investigación se dividió en tres etapas: 1) recolección de datos en campo; 2) estimación del IAF haciendo uso de IV y PLSR para el manejo de corte y 3) estimación del IAF haciendo uso de IV y PLSR para el manejo de pastoreo, donde el objetivo de estas últimas dos etapas fue identificar la metodología para la estimación del IAF en pasto Estrella Africana que presentó los resultados más precisos para cada tipo de manejo. El enfoque de esta investigación presenta potencial para el monitoreo del estado del pasto Estrella Africana debido a que el IAF actúa como indicador de la productividad bajo las modalidades de corte y pastoreo en condiciones tropicales.

## **2. MARCO TEÓRICO**

### *2.1. Marco conceptual*

#### *2.1.1. Teledetección*

La teledetección consiste en la adquisición de información de un objeto, ya sea un cultivo, la superficie terrestre, entre otros, de manera remota haciendo uso de sensores, los cuales mediante una interacción electromagnética con el objeto de estudio permiten recolectar datos de este (Tao et al., 2020). Dichos sensores se clasifican en dos categorías, activos y pasivos, de acuerdo con el objeto de estudio y a la información que se desea obtener de este. Un sensor pasivo se refiere a uno que recibe y mide energía reflejada de la superficie de la tierra y su atmosfera consumiendo muy poca energía, estos sensores se usan en radioespectrómetros, radiómetros, satélites, entre otros equipos (Mai, 2012). En cambio, un sensor activo además de detectar la energía reflejada, también actúa como una fuente, es decir, emite un pulso de energía por lo que permite la recolección de datos de día y de noche, el radar es el sensor de este tipo más común. (Mai, 2012).

#### *2.1.2. Datos espectrales*

Los datos hiperespectrales consisten en numerosas mediciones, muy poco distanciadas y continuas de la reflectancia en un rango establecido de longitudes de onda, lo cual da como resultado una mayor captura de información en comparación con el uso de mediciones multiespectrales (Hennessy et al., 2020). Los radioespectrómetros permiten capturar datos hiperespectrales en un rango de longitud de onda de 350-2500 nm, con un ancho de banda entre 1 y 10 nm, por lo que su uso se encuentra ligado al manejo de grandes volúmenes de datos (Hennessy et al., 2020).

#### *2.1.3. Índices de vegetación*

Los IV se tratan de la combinación de bandas espectrales, los cuales son utilizadas en procesos de inversión paramétrica para el monitoreo de cultivos, pastos y bosques (He et al., 2020). Existe una gran variedad de IV, los cuales se pueden relacionar con propiedades fisiológicas de las plantas como el IAF. Entre estos se encuentran el NDVI, el Índice de Vegetación Triangular Modificado (MTVI2 por sus siglas en inglés), el Índice de Razón Espectral (RSI por sus siglas en inglés), el Optimizado de Suelo Ajustado (OSAVI por sus siglas en inglés), el Índice de Vegetación No Lineal Optimizado (ONLI, por sus siglas en inglés) y el Índice de Vegetación Mejorado de dos bandas (EVI2 por sus siglas en inglés).

El NDVI es un IV muy utilizado para una gran cantidad de aplicaciones, entre las que se encuentra la predicción del IAF, sin embargo, se ha demostrado que este IV tiende a presentar una relación no lineal con parámetros biofísicos debido a su saturación en doseles densos (Haboudane et al., 2004). Algunos IV se han derivado del NDVI con el fin de corregir los efectos de factores externos, como la influencia del suelo en el OSAVI (Feng et al., 2019). Dentro de estas modificaciones al

NDVI se encuentra la sustitución de la banda de infrarrojo cercano por la de borde rojo como respuesta a los problemas de saturación del NDVI, dando origen al IV NDRE (Feng et al., 2019). Por otra parte, el MTVI2 surge como una alternativa al índice de vegetación triangular modificado (MTVI1, por sus siglas en inglés), con el fin de reducir los efectos del suelo mediante un factor de corrección, conservando a su vez su sensibilidad a los cambios en el IAF (Haboudane et al., 2004).

Dentro de los IV que han sido generados para reducir los efectos de la saturación se encuentra el ONLI, planteado por Feng et al. (2019), logrando adaptarse a diferentes condiciones y predecir el IAF de forma más efectiva que otros índices como el MTVI2. El IV EVI2 surgió como una alternativa de dos bandas al IV EVI, el cual hace uso de 3 bandas, entre ellas la azul, lo que suponía un reto a la hora de generar series de tiempo a largo plazo con este IV (Jiang et al., 2008). Esta alternativa es de interés ya que una de las ventajas del índice EVI es su alta sensibilidad a la biomasa y mínima influencia del suelo y factores atmosféricos (Jiang et al., 2008).

#### *2.1.4. Operador automatizado de modelos de transferencia radiativa (ARTMO)*

Se trata de un software libre para fines educativos y de investigación basado en MATLAB, el cual contiene un conjunto de modelos de transferencia radiativa (RTM, por sus siglas en inglés) enfocados en hojas y doseles (Verrelst et al., 2015). Permite realizar estimaciones de parámetros fisiológicos de las plantas como el IAF mediante herramientas basadas en IV, algoritmos de machine learning, entre los que se encuentra el PLSR e inversión de tablas de consulta (Verrelst et al., 2015).

#### *2.1.5. Método basado en IV*

Este método consiste en establecer una relación entre los IV calculados y el IAF medido en campo. Se lleva a cabo mediante el ajuste de modelos de regresión de tipo lineal, exponencial, logarítmicos, cuadráticos y potencial, con el fin de determinar el tipo de modelo que mejor se ajusta a los datos de IAF mediante el método de la curva de mejor ajuste (Liang et al., 2020a). Para llevar a cabo este método se requiere determinar una variable independiente y una dependiente, las cuales suelen ser los IV y el IAF medido respectivamente, siendo un valor del coeficiente de determinación ( $R^2$ ) mayor y una raíz del error cuadrático medio (RMSE) menor lo que determina qué regresión utilizar (Liang et al., 2020a).

#### *2.1.6. Análisis de componentes principales*

El análisis de componentes principales (PCA), es un método que lleva a cabo una transformación lineal la cual, a partir de un conjunto de datos, es capaz de determinar nuevas variables que permiten explicar la varianza del conjunto de datos original (Gambardella et al., 2021). Las nuevas variables son combinaciones lineales independientes de las variables del conjunto de datos

original, y entre sus ventajas se encuentran la reducción de la dimensionalidad de los datos y su reinterpretación (Gambardella et al., 2021).

Este método genera ejes, llamados componentes principales, los cuales representan la mayor parte de la varianza presente en un conjunto de datos, donde la distancia desde el origen de estos ejes hasta cada una de las observaciones del conjunto de datos se les llaman puntuaciones (scores, en inglés) (Holland, 2019). Debido a esto, la magnitud de las puntuaciones puede ser utilizada para determinar la presencia de observaciones atípicas, ya que se podría considerar que esa observación no forma parte del mismo grupo.

#### *2.1.7. Método de regresión de mínimos cuadrados parciales*

Se trata de un método de análisis estadístico multivariado, en el cual se combinan algunas de las propiedades del PCA, análisis de correlación canónica y análisis de regresiones lineales en un solo método (Liu et al., 2024). El objetivo principal de este método es generar una combinación lineal entre las variables dependientes y las variables independientes, mitigando a la vez el efecto de la multicolinealidad entre las variables independientes (Liu et al., 2024). Su funcionamiento es similar al PCA, donde su mayor diferencia radica en que el PLSR busca determinar componentes principales en los que se logre maximizar la covarianza entre las variables dependientes e independientes, lo cual permite que los componentes principales generados puedan explicar variaciones en las variables dependientes (Liu et al., 2024).

#### *2.1.8. Métodos de pretratamiento*

El algoritmo de suavizado de Savitzky–Golay se trata de un método que filtra señales con base en su frecuencia, de manera que las señales de alta frecuencia (ruido) son eliminadas, sin afectar a las señales de baja frecuencia (Liu et al., 2019). Esto se logra ajustando un polinomio de bajo grado a un conjunto de subdivisiones (ventanas) consecutivas del espectro (Liu et al., 2019). Este método se basa en el uso de polinomios de mínimos cuadrados locales para aproximar la forma de los espectros dentro de una ventana simétrica, para luego derivar este polinomio en el grado deseado, siendo el grado cero el utilizado para el proceso de suavizado (Zhang & Mouazen, 2023).

El método de variación estándar normalizada (SNV, por sus siglas en inglés), es el método de pretratamiento más utilizado debido a su simplicidad y efectividad a la hora de corregir los efectos de la dispersión (Roger et al., 2022). Sin embargo, a pesar de que su principal función es recuperar información de los componentes espectrales fundamentales, también puede tener efectos no deseados sobre los espectros (Roger et al., 2022). Este método para remover la dispersión corrige el efecto multiplicativo de la dispersión de la luz a nivel de espectro, haciendo uso de la transformación del espectro mediante la extracción de su promedio y dividiéndolo por su desviación estándar (Liu et al., 2019).

### 2.1.9. Métricas

Para evaluar la precisión de los modelos se utilizaron las métricas  $R^2$  (ecuación 1), RMSE (ecuación 2), RRMSE (ecuación 3) las cuales han sido recomendadas para la estimación de parámetros biofísicos por otros autores (Kganyago et al., 2021). El RMSE es un indicador de la magnitud del error entre los valores reales y los predichos por un modelo. En el caso del  $R^2$  y el RRMSE, ambas son métricas adimensionales, siendo la primera una correlación que refleja patrones espaciales y la segunda un índice que permite comparar entre diferentes tipos de variables y rangos (Kganyago et al., 2021). Además, se utilizó la relación de rendimiento y desviación (RDP, por sus siglas en inglés) (ecuación 4), el cual permite determinar la calidad de las predicciones de un modelo con base a la relación entre el RMSE y la desviación estándar (Dong et al., 2020). Donde valores inferiores a 1 se consideran muy malos, entre 1 y 1,4 malos, entre 1,4 y 1,8 aceptables, entre 1,8 y 2 buenos, entre 2 y 2,5 muy buenos y superiores a 2,5 excelentes).

$$R^2 = 1 - \frac{\sum_{i=1}^n (v_{est}^i - \bar{v}_{est})^2}{\sum_{i=1}^n (v_{est}^i - \bar{v}_{est})^2} \quad (1)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (V_{est}^i - V_{obs}^i)^2} \quad (2)$$

$$RRMSE = \frac{RMSE}{\bar{V}_{obs}} \quad (3)$$

$$RPD = \frac{SD}{RMSE} \quad (4)$$

Donde  $V_{obs}^i$  y  $V_{est}^i$  son los valores de IAF medidos y predichos respectivamente,  $\bar{V}_{obs}$  y  $\bar{V}_{est}$  son los valores promedio de IAF medidos y predichos respectivamente,  $n$  es el tamaño de la muestra y  $SD$  la desviación estándar de los valores medidos.

### 2.2. Antecedentes

La estimación de parámetros biofísicos de las plantas como el IAF, se ha llevado a cabo mediante una gran variedad de métodos, desde relaciones simples con índices de vegetación, regresiones basadas en machine learning y modelos físicos. A continuación, se mencionan estudios previos relevantes para esta investigación, en los cuales se abordan diferentes metodologías mediante las cuales diferentes autores han sido capaces de predecir el IAF en diferentes tipos de cultivos.

Varios de estos estudios se enfocan en realizar comparaciones entre diferentes tipos de regresiones, entre los que se encuentra el realizado por He et al. (2020), en China, en el cual se estimó el IAF en trigo, utilizando diferentes ángulos cenitales de mediación. Entre los métodos comparados se

encuentran el uso de índices de vegetación hiperespectrales, un algoritmo basado en machine learning llamado Back-Propagation Neural Network (BPNN) y el modelo estadístico PLSR. En dicho estudio se determinó que la región red-edge del espectro electromagnético es la más sensible a cambios en el IAF. Por otro lado, de los cuatro métodos estudiados, el uso del modelo PLSR presentó los resultados más representativos, siendo además poco sensible a los cambios en el ángulo cenital.

Mananze et al. (2018), realizaron un estudio en el cual se estimó el IAF en cultivos de maíz haciendo uso de conjuntos de datos multi e hiperespectrales, utilizando métodos basados en IV, en algoritmos de regresiones de machine learning y métodos de inversión. Los resultados de este estudio muestran que el método basado en IV fue superior a los demás, siendo el Índice Espectral de Tres Bandas (TBSI, por sus siglas en inglés) el IV que presenta la mayor precisión con RMSE de 0,35, concluyendo que es posible estimar el IAF del maíz haciendo uso de datos espectrales (Mananze et al., 2018).

Continuando con las comparaciones, Liang et al. (2015), desarrollaron un método de inversión híbrido para estimar el IAF en cultivos de alfalfa, avena, maíz, papa, entre otros, donde se calcularon 43 IV a partir de un conjunto de datos espectrales simulados por el modelo PROSAIL. Esto para determinar la sensibilidad del IAF a cada IV, los cuales fueron utilizados por el modelo de inversión híbrido para relacionarlos con valores de IAF simulados por el modelo PROSAIL, siendo el algoritmo RFR el que presentó los resultados más precisos y el índice SR el más confiable para estimar el IAF (Liang et al., 2015). Para determinar los mejores modelos basados en IV se realizó un ordenamiento ascendente con base en el RMSE para dos diferentes conjuntos de datos, luego se sumó el rango o posición en la que se encontraba cada modelo, de manera que un bajo valor de la suma corresponde a un mejor modelo (Liang et al., 2015).

En un estudio realizado por Zhang et al. (2021), se estimó el IAF utilizando imágenes hiperespectrales en conjunto con algoritmos de machine learning como el PLSR, regresión de máquinas de soporte vectorial (SVR) y refuerzo de gradientes extremo (Xgboost). Entre los resultados obtenidos por los autores se encuentran que, dependiendo del modelo utilizado, las longitudes de onda más sensibles a los cambios en el IAF varían levemente y el mejor algoritmo para estimar el IAF fue el Xgboost, con un coeficiente de determinación de 0.89 para calibración y validación.

Du et al. (2022), realizaron un estudio en el que estimaron el IAF en cultivos de maíz, utilizando imágenes digitales y algoritmos de machine learning como regresiones lineales, redes neuronales de retro propagación (BPNN) y el algoritmo Random forest. Los resultados de este estudio indican que luego de 500 repeticiones, el algoritmo que presentó las mejores métricas al estimar el IAF fue el Random Forest, alcanzando valores de  $R^2$  de hasta 0,88 y RMSE de 0,12, seguido por la

BPNN. Este estudio demuestra que a pesar de no utilizar datos multi o hiperespectrales, es posible utilizar los mismos métodos y obtener buenos resultados al estimar el IAF.

En un estudio realizado en Turquía por Tunca et al. (2024), en el cual se generaron modelos para estimar el IAF a partir de imágenes multi espectrales como respuesta a la creciente demanda de métodos no destructivos para monitorear el IAF en grandes áreas. Los algoritmos utilizados para estimar el IAF fueron el k vecinos más próximos (KNN), Regresor de árboles extra (ETR), refuerzo de gradiente extremo (Xgboost), Random Forest y regresor de soporte vectorial (SVR) (Tunca et al., 2024). Los resultados de este estudio indican que el modelo KNN fue el que presentó los mejores resultados, con valores de  $R^2$  de 0,97 y RMSE de 0,197, seguido del ETR.

Dong et al. (2020), realizaron una investigación con el fin de predecir la producción de biomasa utilizando estimaciones del IAF obtenidas a partir de imágenes satelitales Sentinel 2 y Landsat 8. Para la estimación del IAF utilizaron regresiones utilizando 6 IV, 3 sensibles a la banda de borde rojo (NDRE, CIRE y MSRRE) y 3 sin sensibilidad a esta banda (NDWII, CIgreen y EVI2). Los resultados de este estudio muestran que los IV MSRE y NDRE presentaron los mejores resultados para las imágenes Sentinel 2 y los basados en bandas NIR y SWIR como el NDWII permitieron obtener mejores resultados para las imágenes Landsat 8. Para este estudio, si bien no se llevó a cabo una comparación entre métodos, los autores lograron demostrar la influencia de la banda de borde rojo sobre la capacidad de los modelos basados en IV para predecir el IAF.

Wang et al. (2019), realizaron un estudio en el cual estimaron el IAF y la biomasa aérea en arroz, utilizando imágenes multiespectrales. Utilizaron regresiones basadas en IV, redes neuronales artificiales y en modelo Random Forest para estimar ambos parámetros de crecimiento del cultivo, donde para la estimación de IAF, obtuvieron un  $R^2$  y RMSE de hasta 0,74 y 1,46 respectivamente, al utilizar los IV NDRE, GNDVI y CIRE (Wang et al., 2019).

En un estudio realizado por Nie et al. (2023), como uno de sus objetivos, buscaron evaluar la capacidad de predicción de 17 diferentes IV con respecto al IAF de diferentes cultivos. Como resultado, determinaron que, para el trigo invernal y el algodón, el IV SR fue el que dio los mejores resultados ( $R^2$  de 0,76 y 0,71, respectivamente) y el MTCI para el maíz ( $R^2$  de 0,57) (Nie et al., 2023). Otro de los objetivos de este estudio fue comparar los resultados de diferentes algoritmos de regresión como el PLSR, SVM, PROSAIL-D y ANN, donde el PLSR obtuvo los mejores resultados al predecir el IAF en algodón y maíz ( $R^2$  de 0,91 y 0,86, respectivamente), y el PROSAIL-D en trigo ( $R^2$  de 0,81).

Darvishzadeh et al. (2008), realizaron un estudio en el que estimaron el IAF, contenido de clorofila foliar y del dosel en pastizales mediterráneos utilizando datos hiperespectrales. La estimación del IAF se realizó mediante el modelo PLSR y el uso de regresiones basadas en IV. Los resultados de



ambos métodos fueron similares, donde para el PLSR obtuvieron un  $R^2$  de 0,65 y un RMSE de 0,32 y para el IV SAVI2 un  $R^2$  de 0,64 y un RMSE de 0,33 (Darvishzadeh et al., 2008).

Ma et al. (2022b), realizaron un estudio en el que compararon diferentes tipos de regresión con el fin de comparar la capacidad de predicción de modelo GPR con respecto al PLSR, ANN e IV utilizando datos hiperespectrales en trigo invernal. Los resultados de este estudio muestran que el GPR y ANN presentaron las mayores métricas, con un RMSE de 0,74 para ambos y un  $R^2$  de 0,74 y 0,71 respectivamente, seguidos del modelo PLSR ( $R^2=0,67$  y  $RMSE=0,80$ ) y el IV RVI ( $R^2=0,55$  y  $RMSE=0,94$ ) (Ma et al., 2022b).

Además de las comparaciones entre diferentes tipos de regresión, también se han realizado estudios comparando los resultados obtenidos a partir de diferentes tipos de datos. Entre estos se encuentra el de Liang et al. (2020b), el cual buscó mejorar la precisión con la que se estima el IAF utilizando IV de acuerdo con el tipo de datos de los que se parten, analizando el efecto de los anchos de banda en la precisión de un modelo de inversión. Se determinó que el ancho de banda es uno de los factores que afectan la precisión de los modelos de inversión para el IAF y que los IV de banda angosta como el OSAVI, MTVI2 y SR reducen la precisión al aumentar el ancho de banda. Los IV de banda media como SR y Carte5 primero la aumentan y luego decrece y por último los de banda ancha como Carte2, OSAVI2 y NDVI la precisión sube al aumentar el ancho de banda.

En un estudio realizado por Li et al. (2014), buscaron determinar el mejor conjunto de características que permita predecir el IAF de forma precisa, para ello utilizaron diferentes técnicas de extracción de características como la reflectancia, primera derivada de la reflectancia, absorción e IV. Para evaluar los métodos utilizaron el modelo PLSR, cuyos resultados indicaron que al utilizar las 14 longitudes de onda con los mayores valores VIP, se obtuvieron valores de  $R^2$  de 0,88 y un RMSE de 0,94 (Li et al., 2014).

Dentro de los estudios que comparan tipos de datos se encuentra el de Kanning et al. (2018), quienes utilizaron imágenes hiperespectrales para predecir la producción de biomasa a partir de estimaciones del IAF y el contenido de clorofila, bajo 8 tratamientos de nitrógeno. Para este estudio, se utilizó el modelo PLSR para estimar el IAF, el cual dio como resultado valores de  $R^2$  de 0,79 y un RMSE de 0,18 (Kanning et al., 2018).

Feng et al. (2016), realizaron un estudio en el que se buscó establecer un modelo para la estimación del IAF en trigo, utilizando el análisis relacional de Grey (GRA), criterio de información de Akaike (AIC) y máquinas de soporte vectorial de mínimos cuadrados (LSSVM) en Beijín, China. En este caso, el análisis GRA se utilizó para determinar la correlación entre IV y los valores de IAF, el LSSVM para generar los modelos de regresión que relacionen el IAF con los IV y el AIC se utilizó para seleccionar los mejores modelos LSSVM (Feng et al., 2016). En cuanto a los resultados

obtenidos en este estudio, los autores fueron capaces de generar un modelo para predecir el IAF con un valor de  $R^2$  de hasta 0,81 y un RMSE de 0,765.

Por otra parte, también se han realizado estudios cuyo objetivo principal fue proponer un nuevo tipo de índice de vegetación, que permita estimar el IAF de manera más eficiente que otros índices. Dentro de esta categoría se encuentra el estudio de Feng et al. (2019), quienes llevaron a cabo la estimación del IAF mediante el uso de IV en trigo. En este estudio se presentó una metodología para la elaboración y optimización de un nuevo IV llamado Optimized Non-Linear Vegetation Index (ONLI), para esto se hizo uso de 20 diferentes IV para estimar el IAF, siendo el MTVI2, EVI2 y el RSI los que mejores resultados presentaron para las condiciones de estudio. Se comparó la precisión de índice ONLI con los más representativos, siendo este nuevo índice más preciso debido a que presenta una baja sensibilidad al efecto del suelo y la reflectividad al estimar el IAF.

Estos estudios mencionados anteriormente son relevantes para esta investigación debido a que se llevó a cabo una comparación entre métodos y entre tipos de datos, con el objetivo de determinar la combinación entre métodos y tipos de datos que permitió alcanzar los mejores resultados. Con respecto a la última categoría, en este caso si bien no se propone un nuevo índice, si hace uso del IV generado en el estudio mencionado, de ahí su relevancia para esta investigación.

### **3. OBJETIVOS**

#### *3.1. Objetivo general*

Determinar una metodología para la estimación del índice de área foliar estimado a partir de datos hiperespectrales en pasto Estrella Africana (*Cynodon nlemfuensis*) en la Estación Experimental Alfredo Volio Mata (EEAVM) de la Universidad de Costa Rica.

#### *3.2. Objetivos específicos*

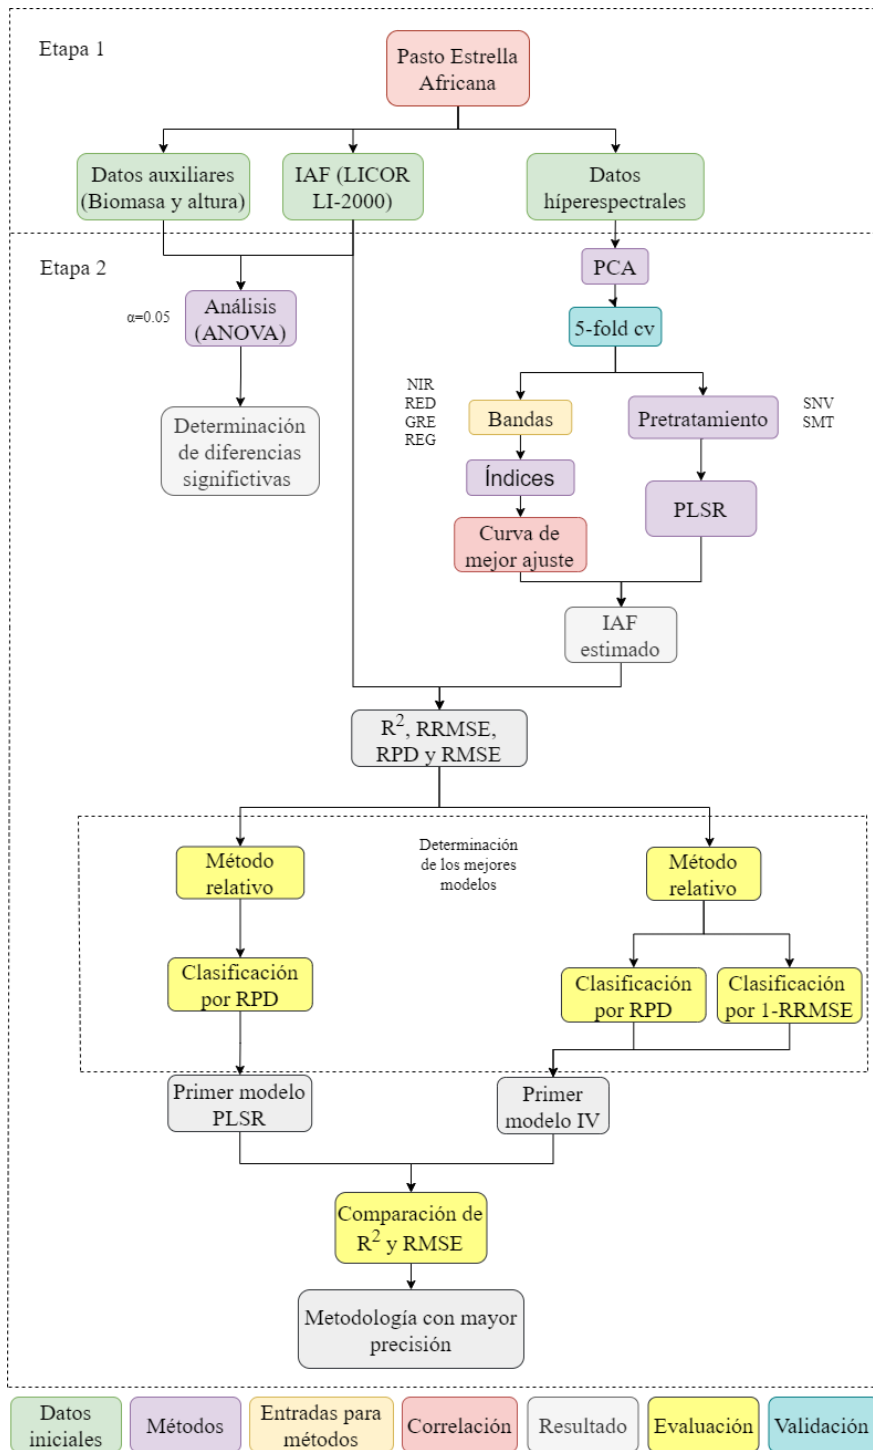
1. Analizar los datos hiperespectrales y auxiliares recolectados en campo para estimar el índice de área foliar en pasto Estrella Africana bajo un sistema de corte y otro de pastoreo.
2. Evaluar dos diferentes metodologías para estimar el índice de área foliar en pasto Estrella Africana comparando sus métricas, determinando la metodología con el mejor rendimiento para el manejo de corte.
3. Evaluar dos diferentes metodologías para estimar el índice de área foliar en pasto Estrella Africana comparando sus métricas, determinando la metodología con el mejor rendimiento para el manejo de pastoreo.

## 4. METODOLOGÍA

### 4.1. Descripción general

En el presente estudio se buscó determinar una metodología para la estimación del IAF en pasto Estrella Africana utilizando datos hiperespectrales. Para ello se desarrollaron tres etapas: 1) recolección de datos de campo y 2) estimación del IAF mediante IV y PLSR utilizando datos hiperespectrales del manejo de corte y 3) estimación del IAF mediante IV y PLSR utilizando datos hiperespectrales del manejo de pastoreo. Esto con el fin de identificar la metodología que presentó la mayor precisión según su valor de  $R^2$  y RMSE. Cabe recalcar que debido a que las etapas 2 y 3 involucran actividades similares, donde su única diferencia son los datos del tipo de manejo utilizados (corte y pastoreo), su descripción metodológica se representó como una sola actividad (Figura 1).

Para la primera etapa, que correspondió a la recolección de datos de campo, se hizo uso de las parcelas experimentales del proyecto 737-C0208 inscrito en la Vicerrectoría de Investigación de la UCR. Este proyecto tuvo como objetivo utilizar los datos hiperespectrales y auxiliares para identificar una metodología para obtener la firma espectral de los forrajes de Estrella Africana y Botón de Oro. Cabe mencionar que se trabajó de manera conjunta con los responsables del proyecto 737-C0208 para la recolección de datos de campo durante un periodo de cuatro meses (junio a octubre de 2022). Para la segunda etapa, se estimó el IAF utilizando dos métodos: IV y PLSR. Estos dos métodos se aplicaron a los datos hiperespectrales, dando un total de dos metodologías por tipo de manejo (corte y pastoreo) a utilizar para la estimación del IAF. En el caso del método de IV, se calcularon el NDVI, MTVI2, RSI, EVI2, ONLI, NDRE y OSAVI, los cuales fueron los que presentaron mayor sensibilidad a las variaciones de IAF en estudio anteriores (Liang et al., 2015; Ma et al., 2022b; Liang et al., 2020a; Feng et al., 2019). Para las estimaciones realizadas con cada una de estas metodologías se llevó a cabo una validación, mediante su comparación con las mediciones de IAF tomadas en campo con el analizador de dosel LICOR LAI-2000. Luego se llevó a cabo una comparación entre los métodos descritos por cada tipo de manejo (corte y pastoreo), donde se determinó la metodología que presentó una mejor precisión según sus valores de  $R^2$  y RMSE.

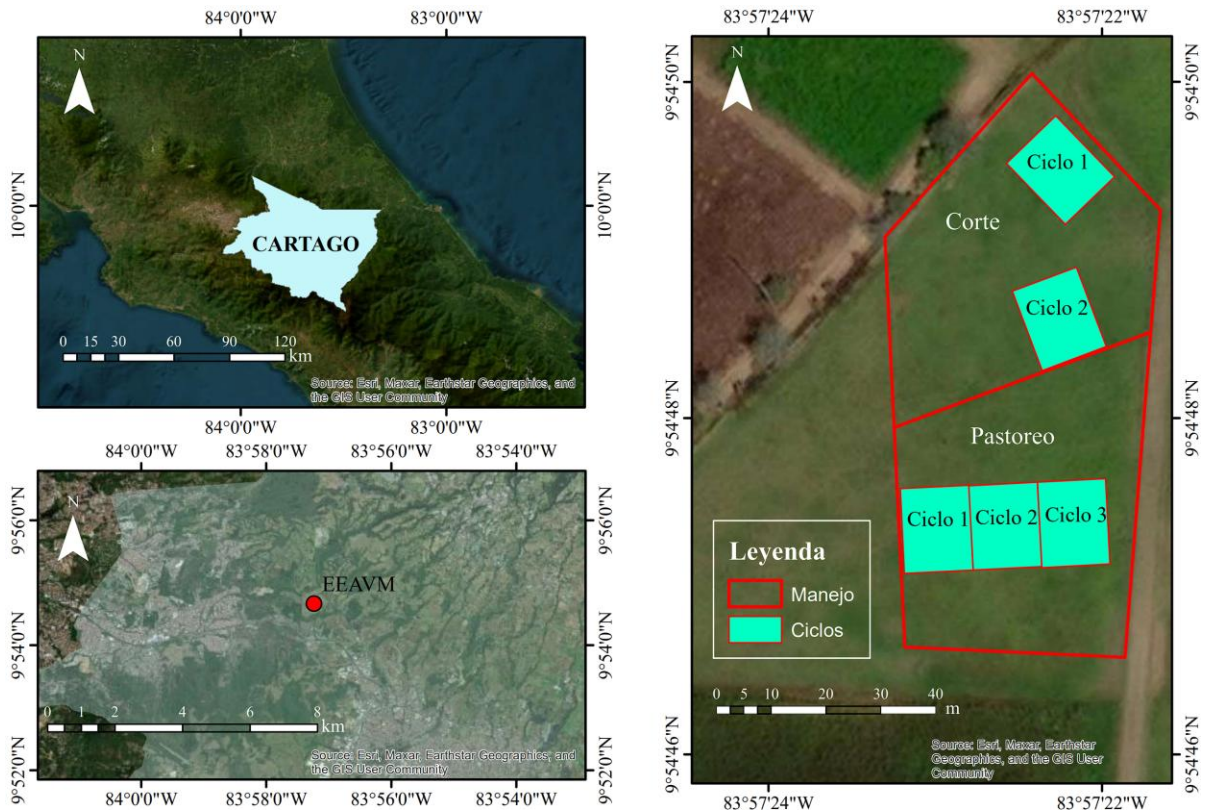


**Figura 1.** Diagrama metodológico.

#### 4.2. Sitio de estudio

El área de estudio fue la EEAVM de la UCR, ubicada en Ochomogo, del distrito de San Rafael, cantón de la Unión de la provincia de Cartago, Costa Rica, con una elevación de 1568 m.s.n.m. Sus precipitaciones rondan los 2000 mm anuales, donde se cuentan con 128 días lluviosos y en promedio, cuenta con temperaturas máximas de 26 °C y mínimas de 15 °C. LA EEAVM se dedica a la investigación y transferencia de conocimientos enfocados en la producción animal. Esta cuenta con ganado lechero, así como con distintos lotes cultivados con forrajes, entre los que se encuentran el Botón de Oro y Estrella Africana.

En la EEAVM se utilizaron las parcelas experimentales del proyecto 737-C0208, inscrito en la Vicerrectoría de Investigación de la UCR, el cual se titula “*Establecimiento de la metodología para la obtención de la firma espectral de especies forrajeras en Costa Rica con enfoque multitemporal*”. Estas parcelas se encontraban en el lote 25 de la EEAVM, donde se contó con una parcela para el manejo de corte y otra para el de pastoreo, estando ambas cultivadas con pasto Estrella Africana y con un tipo de suelo franco arcilloso (Figura 2).

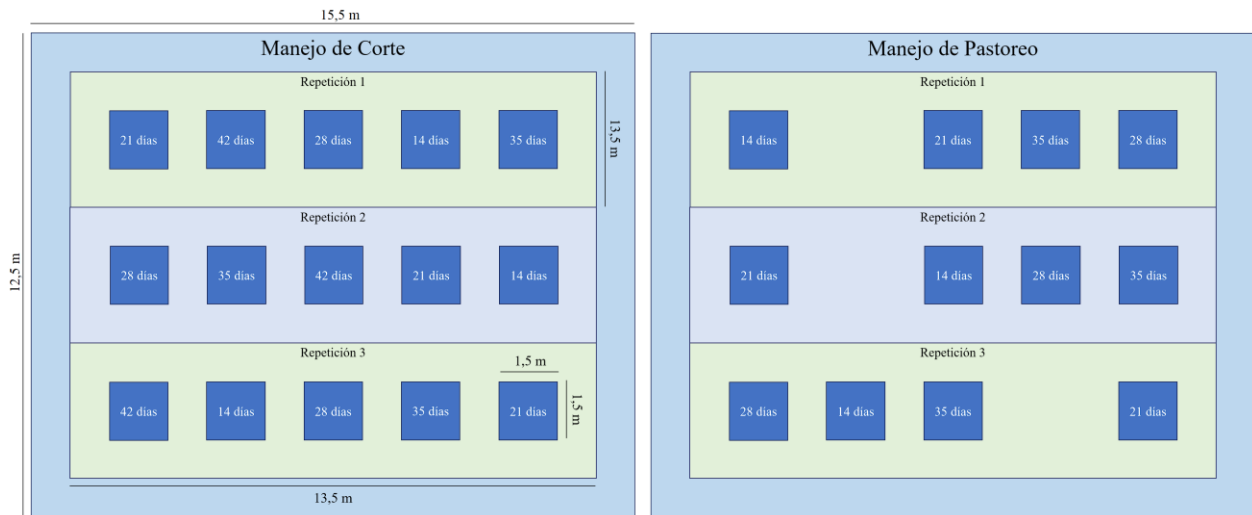


**Figura 2.** Ubicación de las parcelas experimentales de pasto Estrella Africana.

#### 4.2.1. Diseño Experimental

Se utilizó un diseño experimental de bloques completos al azar, con tres repeticiones y un arreglo de tratamientos de parcela dividida, donde cada bloque estaba compuesto por parcelas grandes conformadas por parcelas pequeñas, las cuales a su vez estaban compuestas por subparcelas. Las parcelas grandes ( $193,75 \text{ m}^2$ ) representan, el tipo de manejo del pasto y estas cuentan con tres parcelas pequeñas ( $47,25 \text{ m}^2$ ) las cuales corresponden a las repeticiones y cada parcela pequeña cuenta con cinco subparcelas ( $2,25 \text{ m}^2$ ) las cuales representan cada fecha de muestreo (Figura 3). El área de la subparcela representa una “parcela real” central de  $1,0 \text{ m}^2$  con el fin de considerar el efecto de borde durante las mediciones de espectro. A su vez, estas parcelas grandes se replicaron para cada ciclo de crecimiento, variando la ubicación y el mes.

En el caso del manejo de corte del pasto, se contaron con cinco fechas de muestreo, las cuales fueron 14, 21, 28, 35 y 42 días. Sin embargo, para pastoreo se contó con cuatro fechas, donde se excluyó la medición de 42 días. Esta reducción en las fechas de muestreo para pastoreo fue debido a que en la EEAVM se rota el ganado por los lotes de pastoreo, lo cual limita cuanto puede durar cada ciclo en este manejo. Además, para ambos manejos, la ubicación de cada una de las fechas de muestreo fue determinada de manera aleatoria. Para este diseño, las subparcelas corresponden a las unidades experimentales, siendo la unidad de observación las mediciones espectrales, de IAF y los datos auxiliares.



**Figura 3.** Distribución de las parcelas experimentales para los manejos de corte (izquierda) y pastoreo (derecha).

Para el manejo de corte del pasto se evaluaron dos ciclos de crecimiento, el primer ciclo inició en junio del 2022 y finalizó en julio del 2022 y el segundo ciclo de crecimiento inició en agosto del

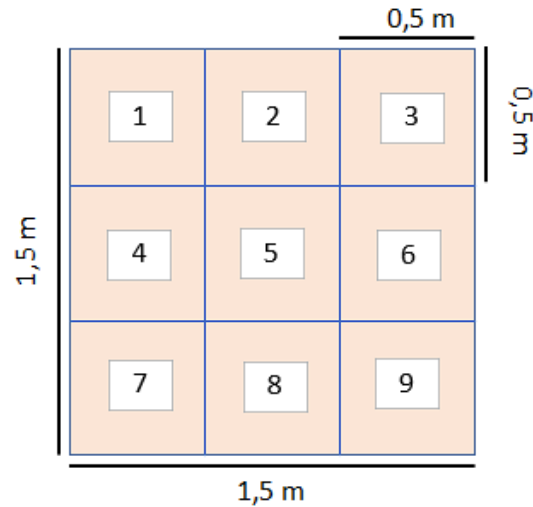
2022 y finalizó en septiembre del mismo año. Por otra parte, para el manejo de pastoreo se evaluaron tres ciclos, el primero iniciando en junio del 2022 y finalizando en julio del 2022, el segundo ciclo de crecimiento fue desde julio hasta agosto del 2022 y el tercer ciclo de crecimiento desde septiembre hasta octubre del mismo año. Las variables independientes corresponden a la edad del pasto, el tipo de manejo y el ciclo de crecimiento del pasto, donde para este último se realizó la toma de datos en una parcela grande ubicada en lugares diferentes para cada ciclo y en meses diferentes. Esto con el fin de agregar mayor aleatoriedad de las propiedades del pasto a los modelos. Por otra parte, los datos hiperespectrales, biomasa seca, la altura del pasto y el IAF fueron las variables dependientes.

Al final de cada ciclo de crecimiento, se llevaron a cabo las labores de pastoreo y corte de manera convencional por la EEAVM, lo cual permitió reiniciar el ciclo de crecimiento del forraje para el inicio del siguiente ciclo. Estas labores se llevaron a cabo una vez finalizadas todas las mediciones, las cuales fueron realizadas en parcelas bajo condiciones de secano, utilizando labores de cosecha y desmalezado manual sobre todo el sitio de estudio.

#### *4.2.2. Recolección de datos*

La recolección de datos hiperespectrales se realizó con un radiospectrómetro de campo ASD Inc. FieldSpec 4 Wide-Res. Este equipo cuenta con un rango espectral de 350-2500 nm con una resolución de 3 nm a infrarrojo cercano visible (VNIR, por sus siglas en inglés) y 30 nm a infrarrojo de onda corta (SWIR, por sus siglas en inglés). Las mediciones se realizaron entre las 10 am y las 2 pm, esto debido a que, para intervalos de tiempo muy largos, los cambios en el ángulo del sol pueden afectar de manera negativa las mediciones hiperespectrales. Esto debido a que cambios en el ángulo del sol generalmente van de la mano con variaciones en los valores de reflectancia (Ma et al., 2020). Además, las mediciones se realizaron a una altura de aproximadamente 0,7 m y a un ángulo de 25°, donde cada medición realizada, representa el promedio de 25 mediciones internamente en el equipo.


Cada subparcela fue dividida en nueve secciones de 0,5 x 0,5 m (Figura 4), donde se realizaron tres mediciones por sección, las cuales fueron promediadas para obtener el espectro de cada subparcela. Además, se calibró el equipo antes de medir cada sección mediante lecturas de reflectancia sobre un Spectralon sin presencia de sombra. Esto debido a que las condiciones de nubosidad en el EEAVM presentaron variaciones en sus condiciones de nubosidad de manera continua, desde cielos despejados hasta la presencia de cúmulos de nubes.



**Figura 4.** Distribución de secciones en subparcelas experimentales para los manejos de pastoreo y corte.

El IAF se midió con un analizador del dosel LICOR LAI-2000, utilizando la cobertura de lente más pequeña sobre el sensor para evitar que el mismo capte otros elementos además del forraje. Para la recolección de datos se subdividió cada subparcela en tres transectos, como se muestra en la Figura 5, donde cada transecto contó con una misma secuencia. Esta secuencia consistió en una medición a 0,5 m sobre el forraje y tres mediciones bajo el forraje, apuntando el sensor siempre hacia arriba. Dicha secuencia fue utilizada para cada transecto sobre las unidades experimentales en conjunto con variaciones en la orientación de la cobertura de la lente por cada transecto. Cabe mencionar que, las mediciones de IAF fueron las primeras en realizarse, debido a que el equipo obtiene mejores resultados cuando el cielo se encuentra nublado, debido a que su funcionamiento se basa en la inversión de la ecuación de Beer-Lambert y bajo el supuesto de que el sensor únicamente recibe radiación difusa (Danner et al., 2015).





**Figura 5.** Metodología de medición del IAF utilizando el Licor LAI-2000 en una subparcela, con mediciones sobre el forraje (color negro) y bajo el forraje (color azul).

La recolección de datos de la biomasa fresca consistió en cosechar el forraje de tres secciones aleatorias por subparcela para luego ser pesada en campo con una balanza. La cosecha se realizó a nivel del suelo de forma manual, utilizando tijeras de jardín y un cuadrante de madera de 0,25 m<sup>2</sup> como guía. La biomasa fresca cosechada fue llevada al laboratorio de bromatología de la EEAVM donde fue analizada para determinar su contenido de materia seca, el cual fue utilizado para calcular la biomasa seca. Para la altura del pasto se realizaron nueve mediciones aleatorias por subparcela (Figura 4), una por sección haciendo uso de una regla de mano. Dichas mediciones fueron promediadas para obtener un solo valor por subparcela.

#### 4.2.3. Factores externos que afectaron la recolección de datos

Durante la recolección de datos, la lluvia y los cambios en la nubosidad fueron factores muy importantes a tomar en consideración debido a su influencia en las mediciones realizadas. En el caso de la lluvia, esta imposibilitaba la recolección de datos debido a los potenciales daños que pudiera generar sobre los equipos. En cuanto a los cambios en nubosidad, estos afectan negativamente la recolección de los datos hiperespectrales, debido a que las variaciones en la luz solar pueden generar errores de calibración y ruidos en las mediciones.

Para algunas fechas de muestreo, la recolección de datos se vio afectada por factores externos los cuales imposibilitaron la toma de datos. A los 28 días de edad del pasto del primer ciclo de crecimiento de ambos tipos de manejos (corte y pastoreo), no fue posible realizar la recolección de datos, debido a que, en esa fecha, 1 de julio de 2022, la tormenta tropical Bonnie y las ondas tropicales #12 y #13 atravesaron el país. En cuanto a la edad del pasto de 42 días del segundo ciclo de crecimiento del manejo de corte, no se pudo realizar la recolección de datos debido a que ese

día, 3 de septiembre de 2022 llovió. Para la edad del pasto de 28 días del tercer ciclo de crecimiento del manejo de pastoreo no fue posible medir el IAF debido a que ese día no pude asistir a recolectar datos.

#### *4.3. Objetivo 1: Análisis de datos hiperespectrales y auxiliares recolectados en campo*

##### *4.3.1. Procesamiento de datos auxiliares y análisis estadístico*

Los datos de IAF y auxiliares fueron procesados de manera que las nueve secciones de cada subparcela fueron promediadas, para cada una de las edades del pasto, tres repeticiones y tipo de manejo (corte o pastoreo). Se utilizó un análisis de varianza, con un nivel de significancia de 0,05 para determinar si existen diferencias significativas entre el IAF, biomasa seca y altura del pasto según el tipo de manejo, ciclo y edad del pasto, así como sus interacciones. Posteriormente, se utilizó la prueba Tukey, con el fin de determinar cuáles de las variables dependientes presentan diferencias significativas, en caso de que existan, para esto se hizo uso del software estadístico R. También se realizaron gráficos de cajas con el fin de demostrar gráficamente la magnitud de la mediana de los grupos de datos analizados.

##### *4.3.2. Preprocesado de datos espectrales*

Los datos espectrales fueron sometidos a un proceso llamado remoción de la brecha (gap remove o splice correction, en inglés), en las longitudes de onda de 1000 nm y 1800 nm, con el fin de compensar los efectos del sensor en estas longitudes de onda. Esta corrección se realizó debido a un desfase que se genera entre los detectores del sensor, causado por diferencias en su sensibilidad (Cardoso-Fernandes et al., 2021). Luego, se realizó una limpieza de los datos espectrales mediante el descarte de mediciones que no cumplieron con los criterios para ser utilizadas. Estos criterios fueron el grado de dispersión y la tendencia que mostraron los datos espectrales. Previo a esta limpieza, se eliminaron mediciones con base en anotaciones realizadas en campo, esto debido a la influencia de factores no deseados como la boñiga, el suelo desnudo y cambios en la irradiancia a la hora de realizar las mediciones. Para esto, se utilizó el software ViewSpec Pro de Malvern Panalytical, adicionalmente se promediaron las firmas para cada subparcela. Además, se realizó la exclusión de los valores de reflectancia superiores a los 1300 nm para cada uno de los espectros, ya que esta región como muestra Moroni et al. (2019), presenta una mayor sensibilidad al contenido de agua, lo cual no es de importancia para esta investigación.

#### *4.4. Objetivo 2 y 3: Estimación de índice de área foliar y evaluación de ambas metodologías*

La estimación del IAF se llevó a cabo utilizando el paquete de software ARTMO, mediante dos diferentes metodologías, con el fin de determinar cuál presenta una mayor precisión comparando sus valores de  $R^2$  y RMSE con respecto al IAF medido con el analizador de dosel. Las dos

metodologías utilizadas fueron: 1) relacionar el IAF con IV y 2) utilizar el modelo PLSR para estimar el IAF utilizando bandas espectrales.

Ambos manejos representan condiciones diferentes por efecto de la influencia de factores externos. Por ejemplo, en el manejo de pastoreo uno de los factores es el ingreso del ganado, y en el de corte, es el ingreso del personal al momento de realizar la cosecha. Por lo tanto, la estimación del IAF para el manejo de corte corresponde al segundo objetivo específico y la del manejo de pastoreo al tercer objetivo. Además, producto de estos factores externos, se esperaba que los métodos de pretratamiento a utilizar para el modelo PLSR, así como las bandas a utilizar para los modelos basados en IV presentaran resultados diferentes según el tipo de manejo, por lo que su análisis se realizó de forma separada.

#### *4.4.1. Análisis de componentes principales*

El uso del PCA ha ido ganando popularidad para reducir la dimensionalidad en conjuntos de datos con una gran cantidad de dimensiones como en imágenes hiperespectrales (García-Allende et al., 2008). Esto debido a que comúnmente el PCA ha sido utilizado en conjuntos de datos con grandes cantidades de variables y presencia de correlación o redundancia entre las variables (Gallagher & Lawrence, 2020). Entre este tipo de datos se encuentran de las mediciones espectrales, ya que generalmente estas presentan cierto grado de correlación en sus variable o bandas espectrales (Gallagher & Lawrence, 2020). Con base en esto se determinó que el PCA puede ser utilizado sobre los datos hiperespectrales, ya que cada espectro utilizado cuenta con 951 variables o bandas espectrales.

Se realizó un PCA a los espectros con el fin de identificar de manera visual, basado en un gráfico de puntuaciones, la presencia de mediciones que se consideraron atípicas en los conjuntos de datos correspondientes a cada tipo de manejo para ser descartadas. Para esto, se partió de un PCA con 10 componentes principales, a partir del cual se determinó la cantidad de componentes principales a utilizar con base en la varianza explicada acumulada de los componentes. Se buscó explicar al menos el 95 % de la varianza de los datos espectrales para cada tipo de manejo, utilizando como mínimo dos componentes principales, para evitar descartar mediciones utilizando como criterio una sola dimensión. En el caso de ambos tipos de manejos (corte y pastoreo), el uso de dos componentes principales permitió explicar el 95 % de la varianza de los datos.

Una vez determinada la cantidad de componentes principales a utilizar (reducción de dimensiones), se realizó el gráfico de puntuaciones para cada tipo de manejo, donde con base en la magnitud de las puntuaciones a lo largo de los componentes principales se determinó la existencia de mediciones atípicas. La implementación de este análisis se llevó a cabo en el lenguaje de programación Python, utilizando la librería scikit-learn (Pedregosa et al., 2011). Originalmente, se contó con 24 y 30 mediciones para el manejo de corte y pastoreo respectivamente, donde cada

medición para cada uno de los tipos de manejo contó con 951 variables, en este caso, longitudes de onda o bandas.

Con base en los gráficos de puntuaciones se descartaron cuatro mediciones para el manejo de corte y tres para el de pastoreo debido a altos valores de reflectancia producto de variaciones en las condiciones ambientales al momento de realizar las mediciones. Luego de descartar las mediciones atípicas, se realizó un nuevo PCA a las 20 mediciones del manejo corte y 27 de pastoreo de forma independiente para verificar que el nuevo clúster de datos sea más uniforme y no se identifiquen más mediciones como atípicas.

#### 4.4.2. Estimación del índice de área foliar utilizando índices de vegetación

Para la estimación del IAF a través de IV se utilizó el rango espectral de las bandas del satélite Sentinel-2 (Tabla 1), con el fin de facilitar la implementación de los modelos resultantes a las imágenes obtenidas por este satélite. Debido a que algunos de los IV utilizados hacen uso de la banda de borde rojo, se utilizaron tres conjuntos de datos ya que el satélite Sentinel-2 cuenta con tres bandas de borde rojo, lo cual dio como resultado un total de seis conjuntos de datos, tres para cada tipo de manejo.

**Tabla 1.** Bandas espectrales y sus rangos a utilizar.

Nombre de la banda	Rango de longitudes de onda (nm)	Numero de banda Sentinel-2
GRE	543-578	Banda 3
RED	650-680	Banda 4
REG 1	698-713	Banda 5
REG 2	733-748	Banda 6
REG 3	773-793	Banda 7
NIR	785-900	Banda 8

GRE: verde, RED: rojo, REG 1: borde rojo 1, REG 2: borde rojo 2, REG 3: borde rojo 3 y NIR: infrarrojo cercano. (Hawrylo & Wezyk, 2018).

Los modelos de predicción basados en IV fueron realizados utilizando la herramienta Spectral Indices Toolbox del software ARTMO, en la cual se agregaron los índices mostrados en la Tabla 2. Para cada uno de estos índices se realizaron regresiones de tipo lineal, exponencial, potencial y polinomial de segundo grado con el fin de determinar la combinación de bandas y tipo de regresión que dé como resultado un mayor  $R^2$  y un menor RMSE (Figura 6a). Los 570.400 modelos mostrados en la Figura 6a se deben a que para cada IV se utilizaron las ecuaciones mostradas en la Tabla 2, para cada una de las longitudes de onda o bandas de datos hiperespectrales mostradas en la Tabla 1, lo cual da como resultado un arreglo factorial. A manera de ejemplo, en la Figura 6b se muestra como a partir de las 30 longitudes de onda de la banda roja y las 115 de la banda

infrarrojo cercano se generan 3450 modelos, producto de la multiplicación de la cantidad de bandas, para cada tipo de regresión utilizada.

En cuanto a la validación de los modelos, se utilizó el método de validación cruzada de k iteraciones, el cual subdivide el conjunto de datos en k partes de igual tamaño de manera aleatoria, de las cuales k-1 partes son utilizadas para el entrenamiento de los modelos. La validación se lleva a cabo con la parte restante, luego, este proceso se repite k veces hasta que todas las partes han sido utilizadas para entrenamiento y validación, donde el resultado final se deriva de la combinación de todas las estimaciones realizadas (Kee et al., 2023). Para este caso, se utilizó un valor de k igual a 5, de manera similar al valor utilizado por He et al. (2020), dividiendo el conjunto de datos en 80 % para el entrenamiento los modelos y el 20 % para la validación en cada iteración.

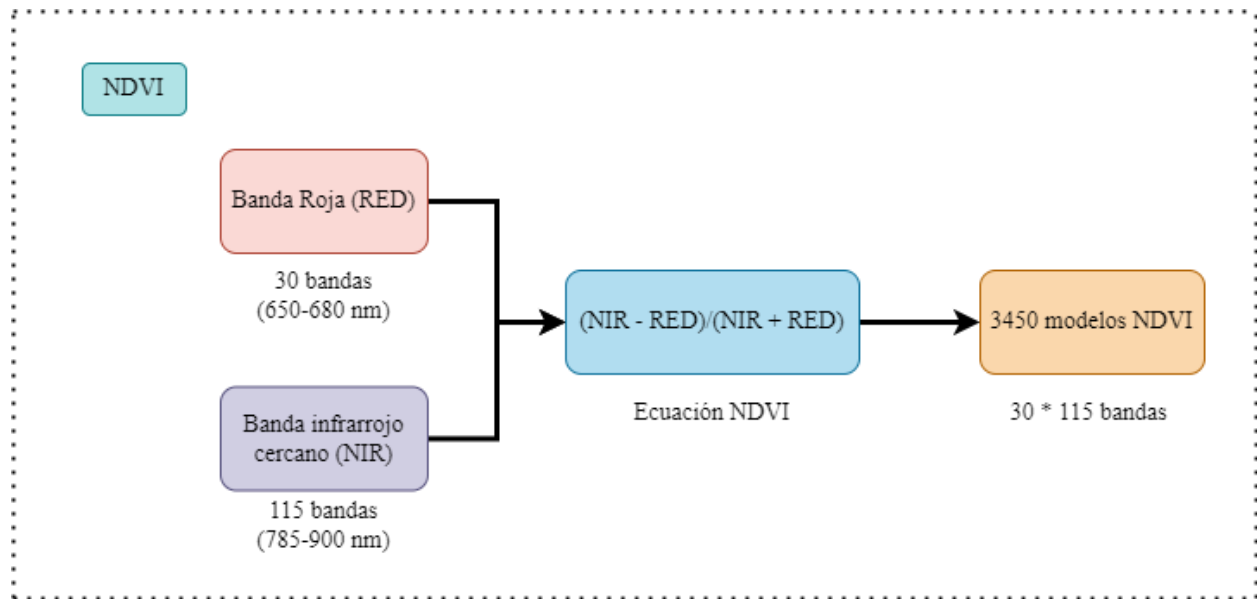
**Tabla 2.** Índices de vegetación utilizados para estimar el IAF según Feng et al. (2019) y Nie et al. (2023).

Índice de Vegetación	Ecuación
NDVI	$\frac{NIR - RED}{NIR + RED}$
MTVI2	$1,5 * \frac{1,2 * (NIR - GRE) - 2,5 * (RED - GRE)}{((2 * NIR + 1)^2 - 6 * NIR + 5 * (RED)^{0,5} - 0,5)^{0,5}}$
EVI2	$2,5 * \frac{NIR - RED}{1 + NIR + 2,4 * RED}$
RSI	$NIR/RED$
OSAVI	$(1 + 0,16) * \frac{NIR - RED}{NIR + RED + 0,16}$
ONLI	$(1 + 0,05) * \frac{0,6 * NIR^2 - rededge}{0,6 * NIR^2 + rededge + 0,05}$
NDRE	$\frac{NIR - rededge}{NIR + rededge}$

NIR: Infrarrojo cercano; RED: Rojo; GREEN: Verde; rededge: Borde rojo



**Figura 6a.** Diagrama de combinaciones para los modelos basados en índices de vegetación.  
 REG 1: borde rojo 1, REG 2: borde rojo 2, REG 3: borde rojo 3.



**Figura 6b.** Combinación de bandas y generación de modelos basados en el IV NDVI.

#### 4.4.3. Estimación del índice de área foliar utilizando el modelo PLSR

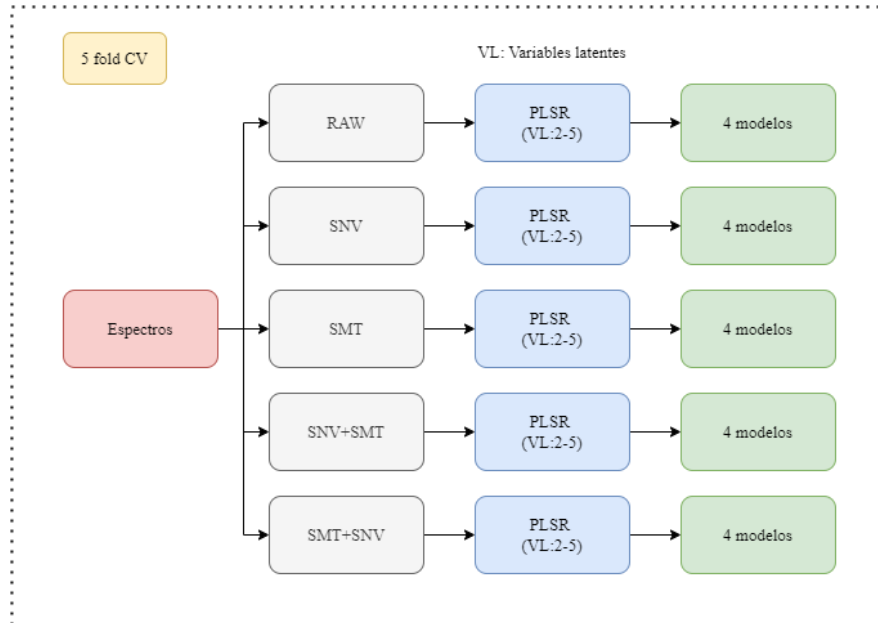
##### 4.4.3.1. Pretratamiento de datos

Para el modelo PLSR se llevó a cabo el pretratamiento de los espectros utilizando el método de variación estándar normalizada (SNV, por sus siglas en inglés) para corregir la dispersión y el método de suavizado de Savitzky-Golay (SMT) para corregir el ruido. Donde ambas correcciones se realizaron para cada espectro u observación de manera independiente. En el caso del método de suavizado, se utilizó un tamaño de ventana de 17 y un ajuste polinomial de segundo grado, de manera similar a Li et al. (2014). Con el fin de determinar el método óptimo de pretratamiento se generaron cuatro conjuntos de datos para cada tipo de manejo: 1) solo SNV; 2) solo SMT; 3) primero SNV y luego SMT y 4) primero SMT y luego SNV. La elaboración de estos conjuntos de datos se realizó en el lenguaje de programación Python, utilizando la librería SciPy, para el método de SMT (Virtanen et al., 2020) y scikit-learn, para el método SNV (Pedregosa et al., 2011).

##### 4.4.3.2. Generación de los modelos

Los modelos se realizaron utilizando la herramienta llamada Machine Learning Regression Algorithms Toolbox del software ARTMO, la cual contiene varios modelos de regresión entre los que se encuentra el modelo PLSR. Para cada uno de los conjuntos de datos con pretratamiento, se probaron de dos a cinco variables latentes en el modelo PLSR, lo que dio como resultado un total de cuatro modelos generados para cada conjunto de datos (Figura 7). Con el fin de determinar la

combinación de variables latentes y conjunto de datos pretratados que permiten obtener los mejores resultados con el modelo (Figura 7). De manera similar a los modelos basados en IV, la validación del modelo se realizó utilizando el método de validación cruzada de k iteraciones, con un valor de k igual a 5 (He et al., 2020).



**Figura 7.** Diagrama de combinaciones para los modelos mínimos cuadrados parciales. RAW: Sin pretratamiento, SNV: Variación estándar normalizada (SNV, por sus siglas en inglés) y SMT: Suavizado.

#### 4.4.4. Determinación y clasificación de los mejores modelos

La determinación de los mejores modelos para cada una de las metodologías (IV y PLSR) y tipo de manejo (corte y pastoreo) se llevó a cabo mediante el método relativo, el cual identifica los mejores modelos de acuerdo con el valor de sus métricas ( $R^2$  y RMSE). Para cada metodología, se contó con un conjunto de modelos, el cual contiene todos los modelos generados según el tipo de manejo. Para la metodología basada en IV, se contó con un conjunto de modelos el cual contenía los primeros 400 modelos generados para los IV EVI2, NDVI, MTVI2, ONLI1, ONLI2, ONLI3, RSI, OSAVI, NDRE1, NDRE2 y NDRE3, con base a su  $R^2$  ordenados descendientemente, dando un total de 4400 modelos por tipo de manejo (corte y pastoreo). Estos mejores 400 modelos por IV están compuestos por los mejores 100 modelos generados para cada tipo de regresión utilizada (lineal, exponencial, polinómica y potencial). Se utilizaron los mejores 100 modelos por tipo de regresión con el fin asegurar la selección de un mejor modelo, ya que no en todos los casos, el mejor modelo en términos de  $R^2$  fue el mejor al considerar el RMSE. En cuanto a la metodología



utilizando el modelo PLSR, se contó con un conjunto de modelos con los 20 modelos generados para cada tipo de manejo.

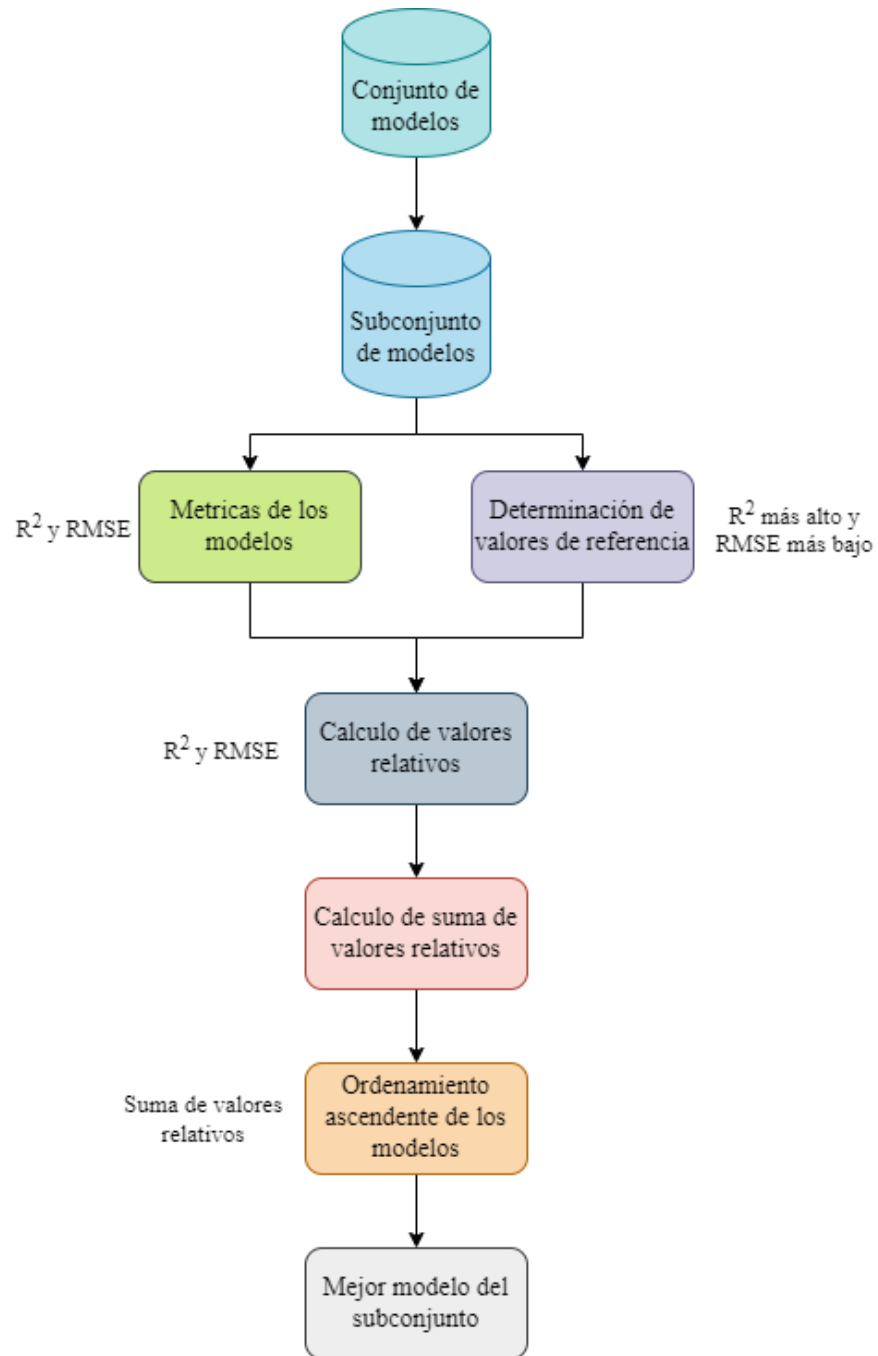
Posteriormente, los conjuntos de modelos fueron divididos en subconjuntos de modelos, para los cuales se determinaron valores de referencia. Para los IV, se generaron 11 subconjuntos, uno para cada índice, siempre discriminado entre tipo de manejo. Para los modelos PLSR, se generaron cinco subconjuntos, uno por cada conjunto de datos (pretratamientos), según el tipo de manejo.

El método relativo, primero determina cual es el valor más alto y bajo de  $R^2$  y RMSE, respectivamente, dentro de cada uno de los subconjuntos, los cuales son llamados valores de referencia. Luego, como se muestra en la Figura 8, utilizando estos valores de referencia se calculan valores relativos de  $R^2$  y RMSE para cada uno de los modelos del subconjunto, utilizando las ecuaciones 5 y 6, respectivamente. Una vez calculados los valores relativos de  $R^2$  y RMSE para cada modelo, se suman ambos valores, esto debido a que los valores relativos representan que tanto se aleja cada modelo de los valores de referencia, lo que significa que los valores relativos más pequeños se asocian a un mejor modelo. Con base en esto, se puede considerar que el modelo con el menor valor de la suma de sus valores relativos es el mejor. Seguidamente, se ordenaron los modelos de manera ascendente según su valor de suma de relativos y se consideró el modelo en la primera posición como el mejor. Este procedimiento se realizó de forma independiente para cada uno de los subconjuntos de ambas metodologías, según el tipo de manejo.

Este método fue inspirado en la metodología seguida por Liang et al. (2015), para determinar los mejores modelos basados en IV con base en el valor de la menor suma de rangos o posiciones de los modelos tomando en consideración dos puntos de referencia. Donde en el caso de Liang et al. (2015), los puntos de referencia fueron los valores de RMSE obtenidos en dos conjuntos de datos y en el caso de esta investigación los valores relativos de  $R^2$  y RMSE.

$$R^2_{relativo} = 1 - \frac{R^2}{R^2_{maximo}} \quad (5)$$

$$RMSE_{relativo} = \frac{RMSE}{RMSE_{minimo}} - 1 \quad (6)$$



**Figura 8.** Método relativo para la determinación de los mejores modelos.

Luego de determinar los modelos con la menor suma de valores relativos correspondientes a cada subconjunto y tipo de manejo, se llevó a cabo un proceso de clasificación utilizando dos métricas de forma independiente. Las métricas utilizadas fueron el 1-RRMSE y el RPD, para las cuales, un valor más alto se asocia con un mejor modelo. Debido a esto, el proceso de clasificación consistió en ordenar de manera descendente los mejores modelos de cada subconjunto con base en su valor de RPD y 1-RRMSE de forma separada para luego comparar sus resultados y determinar cuál tipo de clasificación es más confiable.

## **5. RESULTADOS Y DISCUSIÓN**

### *5.1. Objetivo 1: Análisis de datos hiperespectrales y auxiliares recolectados en campo*

#### *5.1.1. Análisis de datos auxiliares*

Para esta investigación, las variables independientes son el tipo de manejo, el ciclo de crecimiento y la edad del pasto. Por otra parte, las variables dependientes son la biomasa seca, la altura del pasto y el IAF. Con base en lo anterior, se buscó determinar si existen diferencias significativas entre el ciclo de crecimiento, tipo de manejo, edad del pasto y sus interacciones, para cada una de las variables dependientes. Para esto, se realizó un análisis de varianza y la prueba Tukey. Debido a esto, esta sección será discutida separando las variables dependientes, las cuales fueron analizadas por subparcela.

Previamente, se realizó la prueba de normalidad utilizando el método de Kolmogorov-Smirnov (55 muestras), mediante la cual se determinó que el IAF ( $p=0,9930$ ), biomasa seca ( $p=0,4453$ ) y altura del pasto ( $p=0,5381$ ) siguen una distribución normal (Tabla A1). En general, los resultados del análisis de varianza de las tres variables dependientes se muestran en la Tabla 3. Se observa que al considerar únicamente el ciclo de crecimiento las tres variables dependientes mostraron diferencias significativas ( $p<0,05$ ), lo cual es de esperarse ya que todos los ciclos de crecimiento fueron llevados a cabo en momentos diferentes del año. En cuanto al tipo de manejo, únicamente el IAF y la biomasa seca fueron significativamente diferentes ( $p<0,05$ ). En el caso de la edad del pasto, únicamente la altura del pasto mostró diferencias significativas ( $p<0,05$ ).

Al considerar las interacciones entre la edad del pasto con el ciclo de crecimiento, se observa que todas las variables dependientes presentan diferencias significativas. Sin embargo, para la interacción de la edad del pasto con el tipo de manejo, los resultados fueron totalmente opuestos a los mencionados para la interacción con el ciclo de crecimiento. Con base en estos resultados se puede intuir que el ciclo tiene un efecto más significativo sobre todas las variables al tomar en consideración la edad del pasto, en comparación con el tipo de manejo. A continuación, se discutirán en más detalle estos resultados enfocados en cada variable.

**Tabla 3.** Resultados del análisis de varianza, con los valores de p para cada variable dependiente según cada una de las interacciones.


Variable	Ciclo de crecimiento	Tipo de manejo	Edad del pasto	Edad del pasto: Ciclo de crecimiento	Edad del pasto: Tipo de manejo
IAF	1,789E-08*	0,005*	0,469	0,021*	0,099
Biomasa seca	3,033E-04*	0,002*	0,113	0,046*	0,190
Altura del pasto	1,318E-06*	0,671	9,490E-05*	0,002*	0,438

\* Presenta diferencias significativas para un alfa de 0,05.

#### 5.1.1.1. Índice de área foliar (IAF)

En la Figura 9, se observan diferencias en las medianas del IAF entre los ciclos de crecimiento del manejo de corte, donde se aprecia que para el segundo ciclo de crecimiento se dio una reducción en los valores del IAF. Además, al observar los resultados de la prueba Tukey (Tabla 4), estos indican que existen diferencias significativas entre ambos ciclos de corte ( $p < 0,0001$ ). Por otra parte, en el caso del manejo por pastoreo, las medianas de los valores de IAF indican que se da un aumento gradual del IAF en el tiempo según el ciclo de crecimiento (Figura 9). Sin embargo, según la prueba de Tukey, únicamente el primer ciclo de crecimiento del manejo de pastoreo es significativamente diferente con respecto a los ciclos 2 ( $p = 0,0004$ ) y 3 ( $p = 0,0001$ ) (Tabla 4).

Para ambos manejos, se observa que el primer ciclo de crecimiento de cada tipo de manejo es significativamente diferente de los demás ciclos (Tabla 4). Esto puede estar relacionado con la influencia de la tormenta tropical Bonnie y las ondas tropicales #12 y #13 que atravesaron el país el 1 de julio de 2022, durante el primer ciclo de crecimiento del pasto. Además, es importante considerar que el cambio de ciclo de crecimiento implica una ubicación diferente dentro de la parcela experimental, lo cual puede generar variaciones en el desarrollo del pasto debido a la disposición de los nutrientes en el suelo.



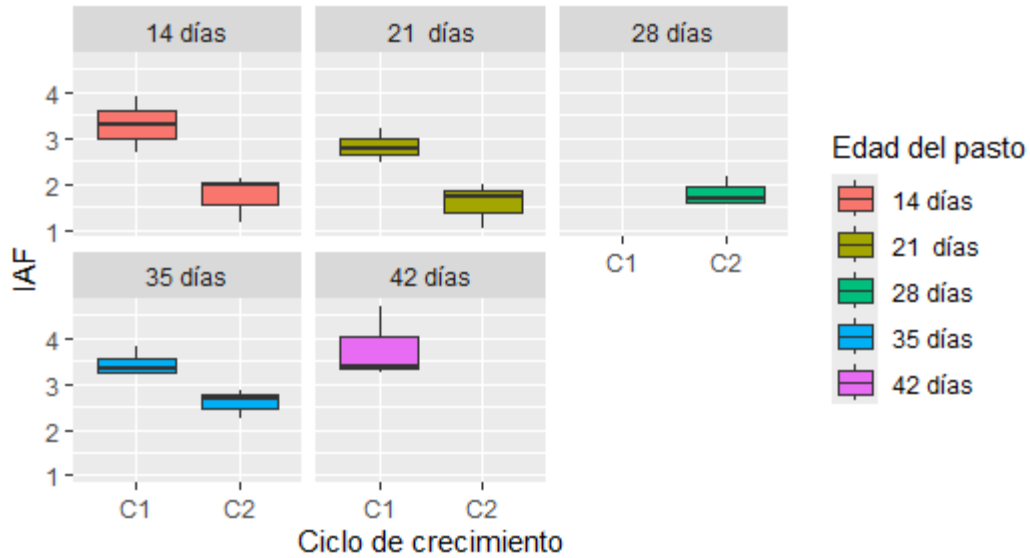
**Figura 9.** Gráfico de cajas de IAF para ambos tipos de manejos (corte y pastoreo) con sus respectivos ciclos de crecimiento.

**Tabla 4.** Resultados de la prueba Tukey para el IAF según los ciclos de crecimiento.


Ciclo de crecimiento	IAF	Tukey
P3	3,63 ± 0,75	A
P2	3,38 ± 0,70	A
C1	3,33 ± 0,59	A
P1	2,21 ± 0,68	B
C2	1,94 ± 0,54	B

C: Corte, P: Pastoreo. Medias con una letra común no son significativamente diferentes ( $p > 0,05$ ).

Considerando la interacción entre el ciclo de crecimiento y la edad del pasto (Figura 10), para todas las edades se alcanzaron los valores más altos de IAF durante el primer ciclo para el manejo de corte, a excepción de las edades de 28 y 42 días, ya que solo se cuenta con los valores de un ciclo. Según los resultados de la prueba Tukey, ninguna edad es significativamente diferente entre ambos ciclos de crecimiento para este tipo de manejo. Al evaluar la misma interacción para el manejo de pastoreo, se observa una tendencia similar a la mostrada en la Figura 9 para las edades de 14 y 35 días (Figura 11). En cuanto a la edad de 21 días, se alcanzó el valor más alto de IAF durante el segundo ciclo de crecimiento y para la edad de 28 días solo se contó con una medición (Figura 11). Para este manejo, según la prueba Tukey respecto a la edad de 35 días, sí existen diferencias significativas entre el primer y tercer ciclo de crecimiento ( $p = 0,0001$ ) (Tabla 5).



**Figura 10.** Gráfico de cajas de IAF para cada ciclo de crecimiento del manejo de corte con sus respectivas edades del pasto. C: Corte.



**Figura 11.** Gráfico de cajas de IAF para cada ciclo de crecimiento del manejo de pastoreo con sus respectivas edades del pasto. P: Pastoreo.

**Tabla 5.** Resultados de la prueba Tukey para el IAF según el ciclo de crecimiento y la edad del pasto.


Ciclo de crecimiento	Edad de pasto	IAF	Tukey
P3	35 días	4,37 ± 0,347	A
C1	42 días	3,76 ± 0,782	A B
P2	28 días	3,69 ± 0,482	A B
P2	21 días	3,69 ± 1,02	A B
C1	35 días	3,44 ± 0,329	A B C
P3	14 días	3,36 ± 0,552	A B C
C1	14 días	3,29 ± 0,615	A B C D
P2	14 días	3,25 ± 0,824	A B C D
P3	21 días	3,16 ± 0,743	A B C D
P2	35 días	2,87 ± 0,066	A B C D
C1	21 días	2,82 ± 0,367	A B C D
C2	35 días	2,6 ± 0,301	B C D
P1	14 días	2,57 ± 0,454	B C D
P1	21 días	2,48 ± 0,621	B C D
C2	28 días	1,8 ± 0,335	C D
C2	14 días	1,75 ± 0,507	C D
C2	21 días	1,59 ± 0,502	D
P1	35 días	1,57 ± 0,598	D

C: Corte, P: Pastoreo. Medias con una letra común no son significativamente diferentes ( $p>0,05$ ).

Para ambos tipos de manejo, se observó que, el IAF no muestra una tendencia a aumentar conforme se aumenta la edad del pasto. En cuanto al manejo de corte, este presentó una tendencia a reducir el valor de su IAF durante las primeras edades, para luego mostrar una tendencia creciente durante las últimas dos edades en ambos ciclos de crecimiento (Figura 10). Al enfocarse en el manejo de pastoreo, este presentó aumentos en el IAF al aumentar la edad para los primeros dos ciclos de crecimiento, seguido de una reducción en su valor de IAF para la última edad de 35 días. Para el tercer ciclo de crecimiento de este tipo de manejo, el IAF tuvo una reducción durante la edad de 21 días, seguido de un aumento para la edad de 35 días. Estos comportamientos tan variados pueden ser producto de varios factores tanto ambientales como el propio efecto del suelo, ya que como se mencionó anteriormente, la precipitación puede ser un posible responsable de este comportamiento, así como la distribución de nutrientes en el suelo.

Al analizar las edades del pasto según el tipo de manejo, se observan diferencias en las medianas del IAF para el manejo de corte, donde para las edades de 28 y 42 días se alcanzaron los valores

mínimos (1,69) y máximos (3,37) de IAF respectivamente para este manejo (Figura 12). Para el manejo de pastoreo, se observa que de forma general los valores de IAF para todas las edades se encuentran en un rango similar, a excepción de la edad de 28 días, la cual para este manejo representa el valor máximo (3,74) (Figura 12). En cuanto a los resultados obtenidos por la prueba Tukey, ninguna edad presenta diferencias significativas ( $p > 0,05$ ) respecto a las demás en el caso de ambos tipos de manejos. Cabe mencionar que para la edad del pasto de 28 días en ambos tipos de manejos y 42 días del manejo de corte únicamente se cuenta con los datos del segundo ciclo de crecimiento, debido a los factores externos mencionados en la sección 4.2.3.



**Figura 12.** Gráfico de cajas de IAF para cada ciclo del manejo de corte con sus respectivas edades del pasto.

De manera general, los valores de IAF medidos en esta investigación son superiores a los presentados por otros autores, como Coto y Rojas (2021), quienes registraron un valor máximo de IAF de 2,44 para pasto Estrella Africana bajo un manejo de pastoreo. A pesar de que en el estudio realizado por estos autores no se menciona explícitamente la edad del pasto correspondiente a ese valor de IAF, se observa que es inferior a la mayoría de las mediciones realizadas para ambos tipos de manejo (Tabla 5). A pesar de que el estudio de Coto y Rojas (2021) también fue realizado en la EEAVM, esta diferencia en los valores reportados de IAF puede ser debido a que fue realizado en lotes diferentes, ya que los cambios en la zona de estudio pueden resultar en valores diferentes. Esto también se observa en la Figura 9, donde se muestra como para cada ciclo de crecimiento se registraron valores diferentes de IAF, debido a que cada ciclo se llevó a cabo en una ubicación diferente.



Otros estudios realizados en otros tipos de pastos como el de Li et al. (2016), obtuvieron valores máximos y mínimos de IAF en zonas cubiertas principalmente por una mezcla de *Leymus chinensis* y *Stipa* de 3,22 y 0,88 respectivamente para un manejo de corte. Por otra parte, para el manejo de pastoreo obtuvieron valores máximos y mínimos de 2,73 y 0,61 durante su periodo de muestreo. Para ambos tipos de manejo, los valores de IAF mencionados son inferiores a los obtenidos en esta investigación, donde para el manejo de corte el rango de IAF fue de 1,03-4,66 y para pastoreo de 1,09-4,77. Estas diferencias en el IAF puede ser debido al tipo de pasto, ya que en dicho estudio se llevaron a cabo ciclos de crecimiento de 47 y 52 días, lo cual debería dar lugar a un pasto bastante desarrollado. Otra posible causa puede ser que a diferencia del pasto Estrella Africana, estos otros pastos son C3, lo cual afecta su eficiencia fotosintética. De manera similar, He y Guo (2006) reportaron rangos de IAF desde los 0,44 hasta los 3,85, para una combinación de pastos C3, entre los que se encuentran el *Agropyron smithii*, *Bouteloua gracilis*, *Koeleria gracilis* y *Stipa comata*, lo cual parece reafirmar que los pastos C3 tienden a presentar valores inferiores de IAF en comparación con los C4 como el Estrella Africana.


#### 5.1.1.2. Biomasa seca

Para el manejo de corte, ambos ciclos de crecimiento alcanzaron valores de biomasa seca inferiores a las 5,11ton/ha obtenidas por Salazar (2007) para Estrella Africana en el cantón de San Carlos, siendo el primer ciclo de crecimiento el que presentó la mayor producción de biomasa seca (Tabla 6 y Figura 13). Además, los resultados de la prueba Tukey (Tabla 6), indican que sí existen diferencias significativas entre ambos ciclos de crecimiento ( $p= 0,0012$ ) del manejo de corte. En cuanto al manejo de pastoreo, la mayor producción de biomasa seca se dio durante el tercer ciclo de crecimiento al tomar en consideración la mediana de cada ciclo (Figura 13), alcanzando un valor de 4,46 ton/ha, el cual es inferior al reportado por Salazar (2007). Los resultados de la prueba Tukey (Tabla 6), sugieren que para este manejo no existen diferencias significativas entre los ciclos de crecimiento de este tipo de manejo.

**Tabla 6.** Resultados de la prueba de Tukey para la biomasa seca según el ciclo de crecimiento.


Ciclo de crecimiento	Biomasa seca (ton/ha)	Tukey
P3	4,29 ± 0,971	A
P2	3,99 ± 0,970	A
C1	3,82 ± 1,32	A
P1	3,3 ± 1,19	A B
C2	2,22 ± 0,630	B

C: Corte, P: Pastoreo. Medias con una letra común no son significativamente diferentes ( $p>0,05$ ).



**Figura 13.** Gráfico de cajas de la biomasa para ambos tipos de manejos con sus respectivos ciclos de crecimiento.

Al tomar en consideración la edad del pasto para el manejo de corte, la edad de 28 días fue la que presentó la menor producción de biomasa seca, con valores de 1,72 ton/ha, en cambio, para la edad de 42 días se presentó la mayor producción, alcanzando las 4 ton/ha (Figura 14). Analizando el manejo de pastoreo, la producción de biomasa seca alcanzó su valor más alto de 5 ton/ha a los 28 días, mientras que su valor más bajo, de 3,03 ton/ha se dio a los 14 días de edad del pasto (Figura 14). Con base en los resultados mencionados anteriormente, la producción de biomasa seca del manejo de pastoreo se encuentra más cerca de las 5,11 ton/ha de biomasa seca obtenidas por Salazar (2007) para el mismo tipo de manejo y edad del pasto de 28 días. Con respecto a los resultados de la prueba Tukey, no existen diferencias significativas entre las edades para ambos tipos de manejo.




**Figura 14.** Gráfico de cajas de la biomasa para los manejos de corte y pastoreo con sus respectivas edades del pasto.

En la Figura 15 se muestra que para la edad de 14 y 35 días se logró una mayor producción de biomasa seca durante el primer ciclo de crecimiento del manejo de corte, siendo el resultado opuesto para la edad de 28 días. Según la prueba Tukey, únicamente la edad de 35 días presenta diferencias significativas entre los ciclos ( $p=0,0126$ ) (Tabla 7). En pastoreo, las edades de 14 y 21 días muestran una tendencia similar a la mostrada en la Figura 13 para este manejo, donde para los 35 días se obtuvo el valor más bajo de biomasa seca durante el segundo ciclo de crecimiento en lugar del primero (Figura 16). En cuanto a los resultados de la prueba Tukey, no existen diferencias significativas entre ninguna de las edades para este tipo de manejo (Tabla 7).

Ferrufino et al. (2022), reportaron una tendencia similar la obtenida en esta investigación respecto a la producción de biomasa seca, donde existe una tendencia a aumentar la biomasa seca con el paso de las semanas, a excepción de una edad del pasto, 21 días en su estudio y 28 días en este. En dicho estudio, se reportaron valores de biomasa seca de 4,04; 3,26; 4,06 y 6,14 ton/ha para las edades de 14, 21, 28 y 35 días, los cuales son superiores a los 2,06; 2,60; 1,72 y 3,18 ton/ha obtenidos en esta investigación para las mismas edades del pasto bajo el manejo de corte. La diferencia en la producción de biomasa seca puede ser debido a la diferencia en las fechas de muestreo, ya que para esta investigación los muestreos se realizaron desde junio hasta octubre de 2022, en cambio en dicho estudio se realizó de agosto-diciembre de 2018.

Por otra parte, Nuñez-Arroyo et al. (2022), evaluaron la producción de biomasa seca para diferentes tipos de forrajes, donde el Kikuyo, Ryegrass, Estrella Africana, Mombaza y Toledo, obtuvieron una producción de 0,81; 2,77; 3,27; 4,47 y 2,92 ton/ha a los 42 días de edad durante la época lluviosa (septiembre a octubre de 2018). La zona de estudio del Kikuyo y el Ryegrass fue en Sarapiquí, para la Estrella Africana fue Barva de Heredia y para el Mombaza y Toledo fue Sabanilla de Alajuela. Al comparar estos valores con los obtenidos en esta investigación a la edad más cercana de cada tipo de manejo, únicamente el Mombaza presentó una mayor producción de biomasa seca, al compararlo con los 4,24 y 4,12 ton/ha obtenidos a los 42 días del manejo de corte y 35 días para el de pastoreo. En este caso, las diferencias en cuanto a la producción de biomasa seca pueden ser debido a las características de la zona, ya que, por un lado, el Mombaza y Estrella Africana son cultivo C4, por lo que las temperaturas más altas de Sarapiquí (29-30 °C) pueden ser las responsables de las diferencias.

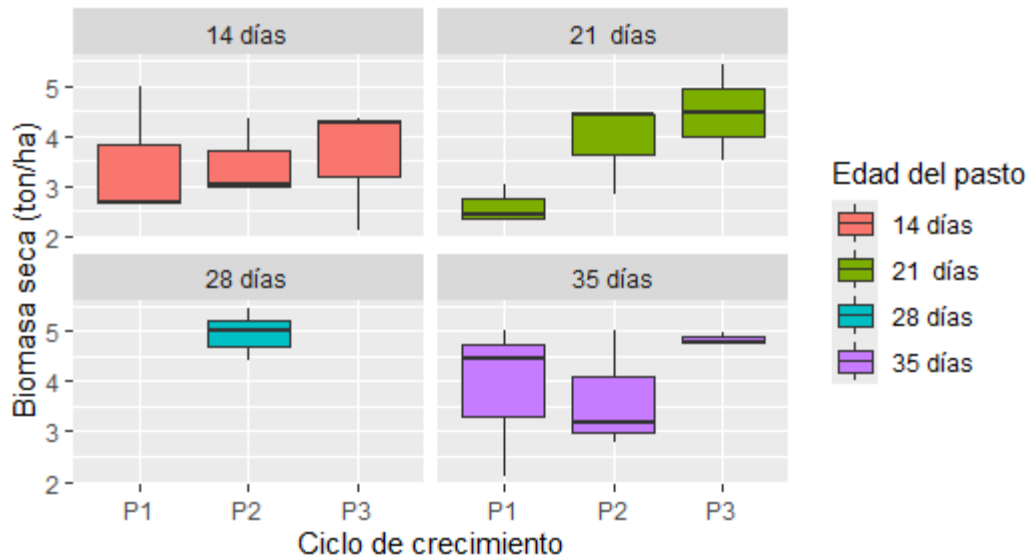


**Figura 15.** Gráfico de cajas de la biomasa seca para cada ciclo de crecimiento del manejo de corte con sus respectivas edades del pasto. C: Corte.

**Tabla 7.** Resultados de la prueba Tukey para la biomasa seca según el ciclo de crecimiento y la edad del pasto.

<b>Ciclo de crecimiento</b>	<b>Edad de pasto</b>	<b>Biomasa seca (ton/ha)</b>	<b>Tukey</b>
C1	35 días	5,2 ± 1,06	A
P2	28 días	4,95 ± 0,523	A
P3	35 días	4,84 ± 0,13	A B
P3	21 días	4,46 ± 0,95	A B
C1	42 días	4,24 ± 0,913	A B
P2	21 días	3,9 ± 0,906	A B
P1	35 días	3,87 ± 1,55	A B
P2	35 días	3,65 ± 1,19	A B
P3	14 días	3,57 ± 1,25	A B
P2	14 días	3,44 ± 0,789	A B
P1	14 días	3,44 ± 1,35	A B
C1	14 días	3,13 ± 1,15	A B
C2	21 días	2,98 ± 0,859	A B
C1	21 días	2,72 ± 0,819	A B
P1	21 días	2,59 ± 0,389	A B
C2	35 días	2,09 ± 0,387	B
C2	14 días	1,99 ± 0,142	B
C2	28 días	1,81 ± 0,248	B

C: Corte, P: Pastoreo. Medias con una letra común no son significativamente diferentes ( $p > 0,05$ ).



**Figura 16.** Gráfico de cajas de la biomasa seca para cada ciclo de crecimiento del manejo de pastoreo con sus respectivas edades del pasto. P: Pastoreo.

De manera similar al IAF, la biomasa seca no tuvo una tendencia a aumentar conforme aumentó la edad. Considerando el manejo de corte, se dio una disminución en la biomasa seca para la edad de 21 días seguido de un aumento para la edad de 35 días y una reducción para la edad de 42 días del primer ciclo de crecimiento, de acuerdo con el valor de las medianas (Figura 15). Para el segundo ciclo de este tipo de manejo si se observa una tendencia creciente durante las primeras dos edades, seguido de una disminución para la edad de 35 días. Con respecto al manejo de pastoreo, únicamente el tercer ciclo de crecimiento presentó aumentos en la biomasa seca al aumentar la edad del pasto (Figura 16).

Estos resultados pueden ser producto de la influencia de diferentes factores sobre el pasto, como las condiciones ambientales, así como la disponibilidad y distribución de los nutrientes en el suelo. En cuanto a las condiciones ambientales, de manera general, para el manejo de corte se contó con una radiación y precipitación acumulada mayor en comparación con el manejo de pastoreo (Tabla 8); sin embargo, se obtuvieron valores más altos de biomasa seca en el manejo de pastoreo (Figura 14). Esto sugiere que, además del efecto que pueden tener las condiciones ambientales sobre el pasto, la nutrición de este es un factor con mayor importancia para la producción de biomasa seca. Esto debido a que, para el manejo de pastoreo, se cuenta con el ingreso de nutrientes como el nitrógeno, potasio y fósforo a través de la boñiga (CNAT, 2015), los cuales son los nutrientes más demandados por los pastos para su desarrollo (Pezo y García, 2018). La falta de este ingreso de

nutrientes en el manejo de corte puede ser la razón por la cual se observa una menor producción y mayor variabilidad en la biomasa seca para este tipo de manejo.

**Tabla 8.** Radiación global total acumulada, precipitación acumulada y temperatura promedio por ciclo de crecimiento para los manejos de corte y pastoreo.

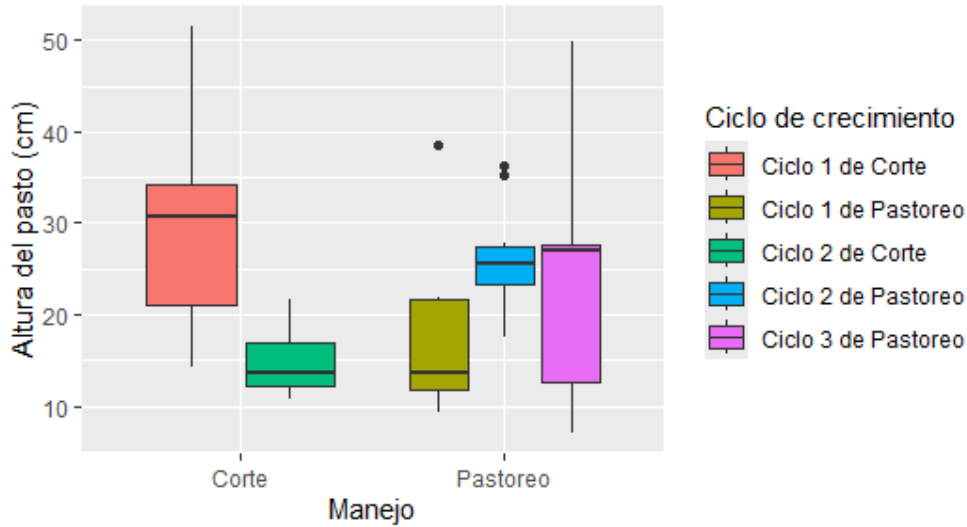
Variable	Manejo	
	Corte	Pastoreo
*Radiación (MJ/m <sup>2</sup> )	560,65	510,6
**Precipitación acumulada (mm)	378,30	311,50
**Temperatura (°C)	17,50	17,69

\*: Obtenido de la estación meteorológica número 84181 del Instituto Meteorológico nacional ubicada en Iztará.

\*\* : Obtenido de la estación meteorológica número 84249 del Instituto Meteorológico nacional ubicada en la EEAVM.

### 5.1.1.3. Altura del pasto

Con respecto al manejo de corte, se registraron los valores más altos de altura del pasto durante el primer ciclo de crecimiento, según el valor de la mediana (30,8 cm) (Figura 17). De acuerdo con los resultados de la prueba Tukey (Tabla 9), ambos ciclos de crecimiento son significativamente diferentes ( $p < 0,0001$ ) para este tipo de manejo. En cuanto al manejo de pastoreo, la mayor altura del pasto se alcanzó durante el tercer ciclo de crecimiento, con 27 cm de acuerdo con el valor de la mediana mostrada en la Figura 17. Por otra parte, durante el primer ciclo de crecimiento se obtuvo el menor valor de altura del pasto, de 13,5 cm (Figura 17). Para este tipo de manejo, los resultados de la prueba Tukey indican que únicamente el primer y segundo ciclos de crecimiento son significativamente diferentes ( $p = 0,0227$ ) (Tabla 9).



**Figura 17.** Gráfico de cajas de la altura del pasto para ambos tipos de manejos con sus respectivos ciclos de crecimiento.

**Tabla 9.** Resultados de la prueba de Tukey para la altura del pasto según el ciclo de crecimiento.

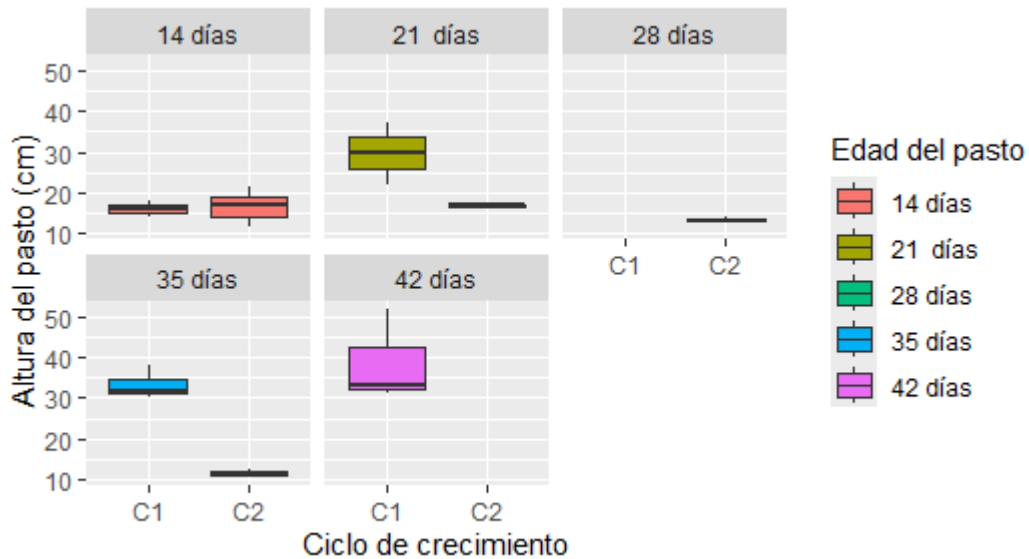
Ciclo de crecimiento	Altura del pasto (cm)	Tukey
C1	29,5 ± 10,6	A
P2	25,9 ± 5,44	A
P3	24 ± 12,7	A B
P1	17,4 ± 9,10	B C
C2	14,7 ± 3,22	C

C: Corte, P: Pastoreo. Medias con una letra común no son significativamente diferentes ( $p > 0,05$ ).


La interacción entre la edad del pasto y el ciclo de crecimiento indica que, para las edades de 21 y 35 días, se obtuvo la mayor altura del pasto durante el primer ciclo de crecimiento del manejo de corte, caso contrario para la edad de 14 días (Figura 18). Para el manejo de pastoreo, se logró obtener el valor más alto y bajo de altura del pasto durante el segundo y primer ciclo de crecimiento, respectivamente para las edades de 14 y 35 días (Figura 19). Respecto a la edad de 21 días, se dio un aumento gradual de los valores de altura al cambiar de ciclo, según el valor de las medianas (Figura 19). En cuanto a la prueba Tukey, esta dio como resultado que no existen diferencias significativas al comparar las edades del pasto entre los ciclos de crecimiento para ambos tipos de manejo (corte y pastoreo).



Al comparar las edades del pasto, se observa que para el manejo de corte los valores de altura del pasto aumentaron de acuerdo con la edad, a excepción de la edad de 28 días (Figura 20). Para este mismo tipo de manejo, se lograron los valores de altura del pasto más altos, de 33,1 cm a los 42 días y los más bajos a los 28 días, con 13 cm, de acuerdo con el valor de las medianas (Figura 20). Al comparar las alturas del pasto para este tipo de manejo, los resultados de la prueba Tukey indican que las edades del pasto de 14 y 28 días son significativamente diferentes con respecto a la edad de 42 días del manejo de corte ( $p < 0,05$ ) (Tabla 10).




**Figura 18.** Gráfico de cajas de la altura del pasto para cada ciclo de crecimiento del manejo de corte con sus respectivas edades del pasto. C: Corte.



**Figura 19.** Gráfico de cajas de la altura del pasto para cada ciclo de crecimiento del manejo de pastoreo con sus respectivas edades del pasto. P: Pastoreo.

Los valores de altura del pasto para el manejo de pastoreo alcanzaron máximos y mínimos de 27,4 y 12,3 cm, a los 35 y 14 días de edad, respectivamente (Figura 20). Comparando los valores de altura del pasto, los resultados de la prueba Tukey muestran que ninguna edad presenta diferencias significativas respecto a las otras para este tipo de manejo ( $p > 0,05$ ) (Tabla 10). Los resultados de ambos tipos de manejo pueden compartir su origen con lo explicado en la sección correspondiente a la biomasa seca, ya que con base en las Figuras 13 y 17 se observa que ambas variables muestran una tendencia similar, lo cual sugiere que se ven afectadas por los mismos factores.

Además, al comparar los valores de altura del pasto con los reportados en otros estudios como el de Jiménez (2023), quienes realizaron mediciones de altura en pasto Estrella Africana bajo 4 tratamientos de fertilización. A pesar de esto, los valores de altura reportados por el autor son inferiores a los obtenidos en esta investigación. Esto debido a que en dicho estudio se reporta un valor máximo de altura del pasto de 28,1 cm a los 49 días de edad, en cambio, como se muestra en la Tabla 10, se obtuvieron valores mayores al considerar las edades de 35 y 42 días de los manejos de pastoreo y corte, respectivamente. Esto puede ser debido a diferencias en las condiciones ambientales y de las propiedades del suelo, ya que se trata de un estudio realizado en Colombia. Por otra parte, Luna (2019), obtuvieron valores de altura del pasto superiores a los presentados en la Tabla 10, reportando valores de 18,7; 24,5 y 30,8 cm a los 14, 21 y 28 días de edad. Con base en estos dos estudios es posible suponer que los valores reportados en esta investigación se encuentran dentro del rango de valores reportados.



**Figura 20.** Gráfico de cajas de la altura del pasto para los manejos de corte y pastoreo con sus respectivas edades del pasto.

**Tabla 10.** Resultados de la prueba Tukey para la altura de forraje según el tipo de manejo y la edad del pasto.

Tipo de manejo	Edad de pasto	Altura del pasto (cm)	Tukey
Corte	42 días	38,6 ± 11,2	A
Pastoreo	35 días	28,2 ± 5,75	A B
Pastoreo	28 días	26,4 ± 0,816	A B
Pastoreo	21 días	23,8 ± 11,2	A B
Corte	21 días	23,4 ± 8,45	A B
Corte	35 días	22,4 ± 12,2	A B
Corte	14 días	16,5 ± 3,34	B
Pastoreo	14 días	15,2 ± 8,49	B
Corte	28 días	13,3 ± 0,675	B

Medias con una letra común no son significativamente diferentes ( $p > 0,05$ ).

#### 5.1.4. IAF y biomasa seca

Según lo mostrado en la Tabla 3, la biomasa seca y el IAF no presentan diferencias significativas al considerar la edad del pasto, lo cual no es un comportamiento esperado, ya que lo normal sería que si existan diferencias en ambas variables dependientes al cambiar la edad del pasto. Esto

posiblemente se debe al efecto de otros factores como la influencia del clima en el pasto y las propiedades del suelo.

Los pastos suelen experimentar cambios en su rendimiento producto de variaciones en las condiciones climáticas como la temperatura, la radiación solar y las precipitaciones. La radiación solar se encuentra fuertemente ligada a procesos fisiológicos relacionados con el crecimiento de los pastos durante su desarrollo, donde la conversión de la energía solar a biomasa se encuentra relacionada con la actividad fotosintética la cual varía en función de la energía disponible (Del pozo, 2000).

Según Del pozo (2000), el rango de temperatura óptimo fotosintético para gramíneas tropicales va desde 35-39 °C, donde en algunas especies, ocurren efectos negativos en su crecimiento a los 20 °C que generan un déficit energético en el pasto producto de reducciones en la tasa respiratoria. En el caso de las precipitaciones, estas pueden inducir un estado de estrés en el pasto si se da un exceso o un déficit. Su exceso provoca una modificación en la distribución y producción de biomasa en el pasto, así como su tasa de crecimiento, sin embargo, su déficit provoca una reducción del área foliar, así como una modificación entre la partición de biomasa aérea y radical (Del pozo, 2000).

Al comparar el comportamiento del IAF y biomasa como se muestra en el apéndice A, se observa que no existe una clara relación con respecto a las variables climáticas. Para ambos manejos se observa un comportamiento irregular, donde en algunos casos se aprecian reducciones en los valores de IAF y biomasa al aumentar la edad del pasto. Esto sugiere que además de las variables climáticas, otros factores tuvieron efecto sobre la velocidad de crecimiento del pasto, como lo puede ser el suelo. De manera general, la EEAVM cuenta con suelos del tipo andisol (Coto y Rojas, 2022), los cuales, suelen presentar una alta productividad de manera natural (INTA, 2015). Variaciones en las propiedades nutricionales del suelo pueden ser la razón por la cual, en el manejo de corte, específicamente, no se observa una clara tendencia a aumentar el IAF y la biomasa al aumentar la edad del pasto. Sin embargo, no se realizaron análisis de laboratorio de las propiedades nutricionales del suelo para confirmar dicho supuesto.

Esto se muestra de una forma más clara en las Figuras 21, 22 y 23, donde se observa cómo se distribuyen los valores de IAF y biomasa para ambos manejos permitiendo identificar que existen regiones de las parcelas que cuentan con mejores condiciones para el desarrollo del pasto. Para el manejo de corte, los valores más altos de IAF (2,93-3,74: color cian y 3,74-4,77: color azul) se concentran en el extremo norte de la parcela experimental, de manera similar, en la misma región se encuentran los mayores valores de biomasa (3,63-4,77 ton/ha: color cian y 4,77-5,82 ton/ha: color azul) (Figura 21). En el caso del manejo de pastoreo, los valores más altos de IAF y biomasa, representados por los mismos intervalos mencionados anteriormente estuvieron concentrados en la región central y oeste de la zona de estudio (Figuras 22 y 23).

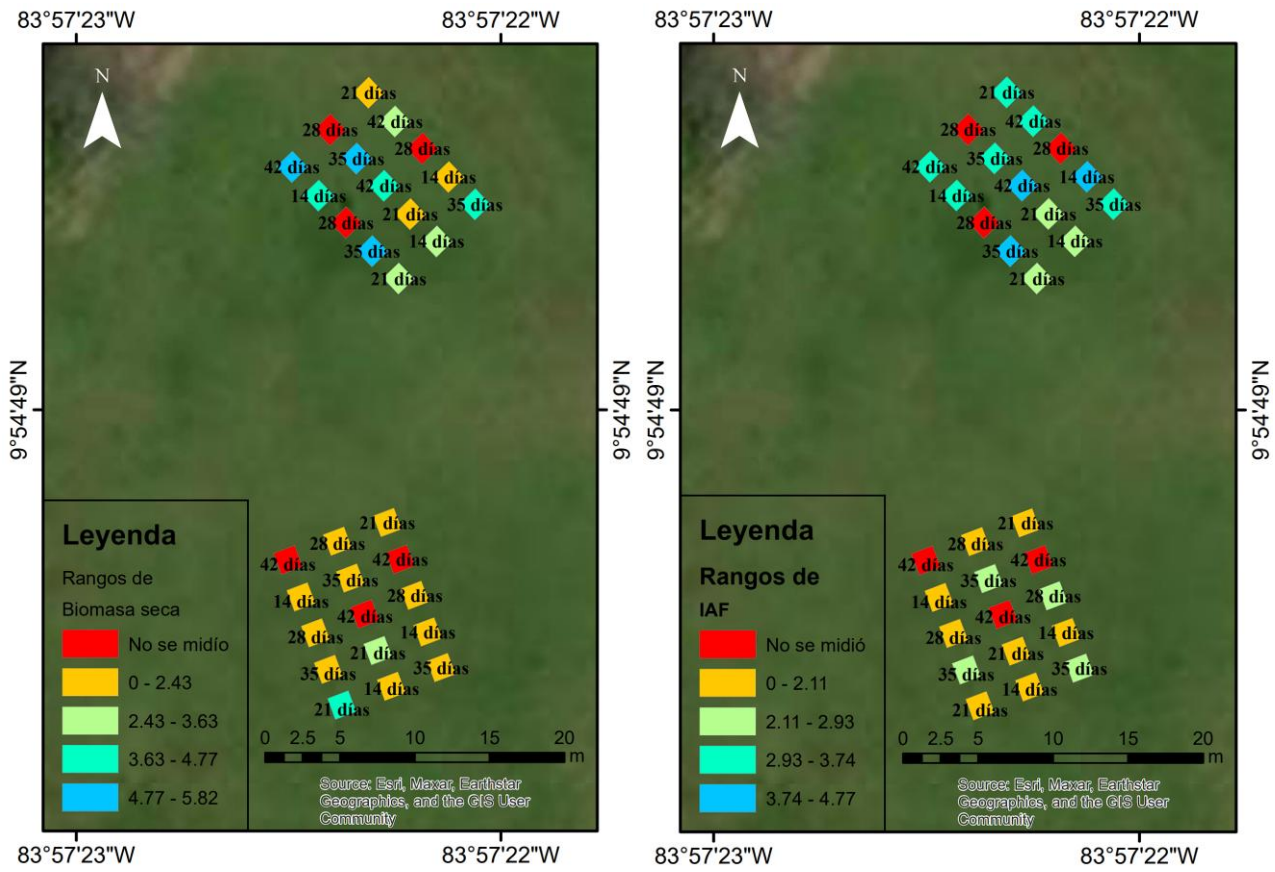


Figura 21. Distribución de valores de biomasa e IAF para ambos ciclos de crecimiento de corte.

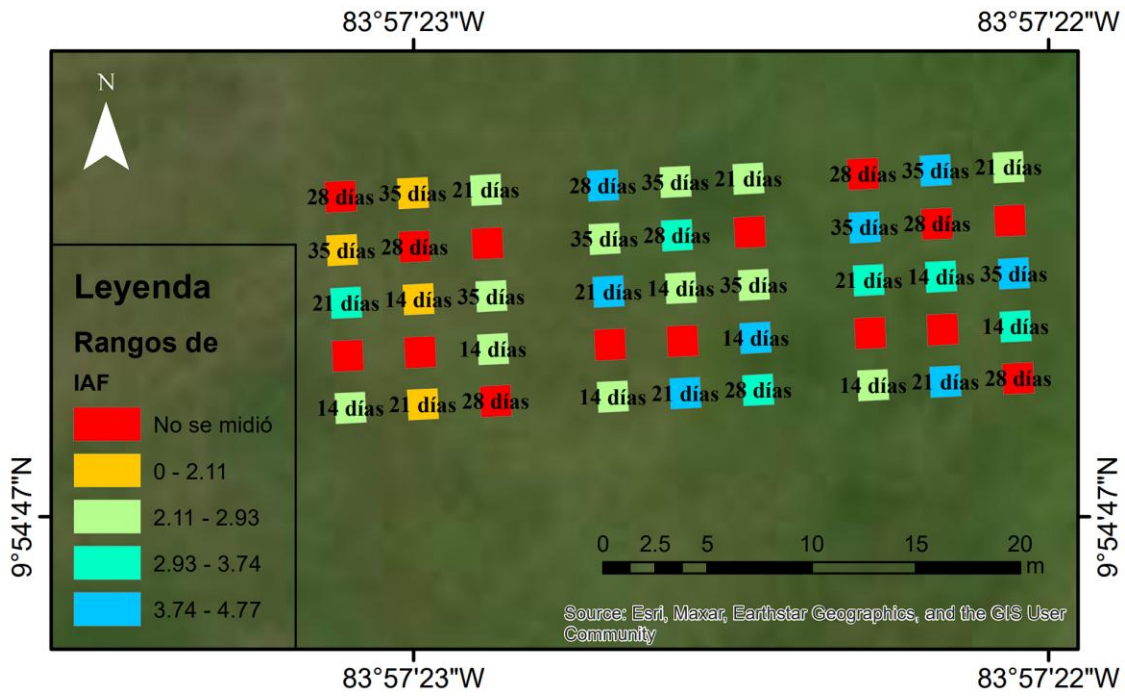


Figura 22. Distribución de valores de IAF para los tres ciclos de crecimiento de pastoreo.




Figura 23. Distribución de valores de biomasa para los tres ciclos de crecimiento de pastoreo.

En el caso del manejo por pastoreo también se observa un comportamiento similar, sin embargo, para este caso se trata de un comportamiento esperado, ya que al ingresar el ganado en la parcela este genera un grado de compactación en el suelo, el cual provoca el crecimiento desigual del pasto. Otro factor por considerar con influencia en el crecimiento del pasto es la boñiga, la cual puede agregar al suelo nutrientes como nitrógeno, potasio y fósforo, los cuales son de importancia para el crecimiento del pasto (CNAT, 2015).

### *5.1.2. Análisis de datos hiperespectrales*

Para esta sección, se analizaron los datos hiperespectrales correspondientes a cada manejo de forma independiente, debido a que con base en los resultados del análisis de varianza (Tabla 3), el IAF es significativamente diferente al tomar en consideración el tipo de manejo. Como parte de este análisis, primero se llevó a cabo el descarte de mediciones, seguido de la remoción de la brecha y finalizando con el promediado de las mediciones resultantes.

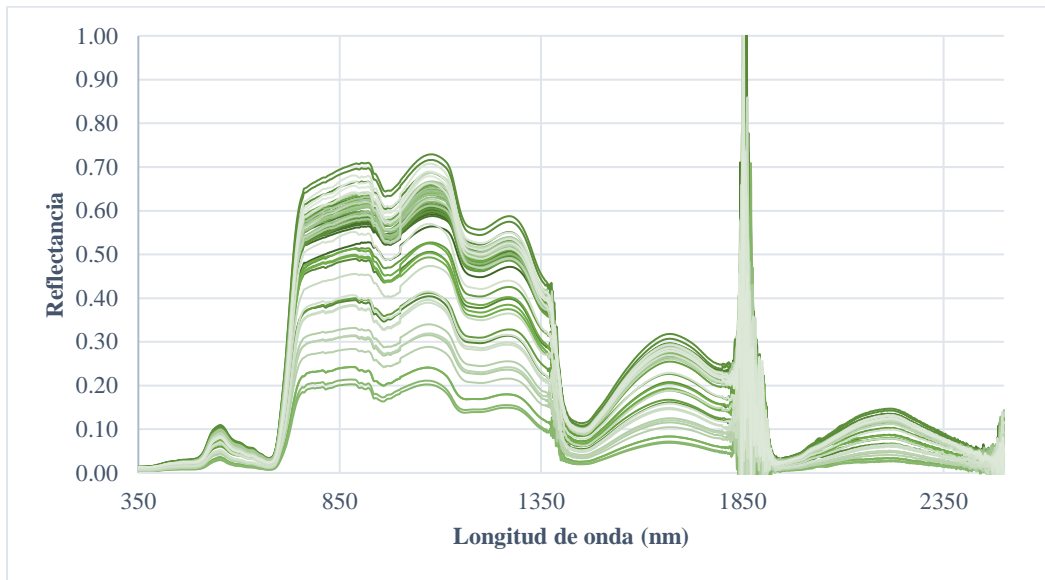
A manera de ejemplo, en la Figura 24 se muestran todas las mediciones espectrales correspondientes a la edad del pasto de 42 días para el primer ciclo de crecimiento del manejo de corte, antes de aplicada la remoción de la brecha (gap remove, en inglés). En esta figura se observa que existe una dispersión entre las mediciones en la región NIR del espectro, la cual va desde los 700 hasta los 1200 nm. La dispersión en la región NIR del espectro suele estar relacionado con la estructura celular de las plantas, así como la interacción de la luz con componentes celulares como el almidón, aceites y proteínas (Kuska et al., 2018). Por esta razón, las estructuras vegetales como las hojas son las que mayor influencia tiene en la reflectancia dentro de esta región (Kuska et al., 2018).

El descarte de mediciones se llevó a cabo con base en la dispersión y tendencia de los espectros, principalmente en la región NIR. Para esto, primero se buscó identificar el rango de reflectancia en el que se encontraban la mayor cantidad de los espectros y luego se descartaron los espectros que estuvieran fuera de ese rango. Como se observa en la Figura 25, para la edad de 42 días del primer ciclo de crecimiento del manejo de corte, el rango de reflectancia seleccionado fue de 0,45-0,7 utilizando como referencia la longitud de onda de 850 nm.

La longitud de onda de referencia (850 nm) utilizada para este ejemplo fue seleccionada ya que se encuentra dentro de la región NIR del espectro, donde generalmente se observan los efectos multiplicativos de la dispersión lo cual permite identificar fácilmente donde se agrupan la mayoría de los espectros. Además, si bien para este ejemplo se utilizó la longitud de onda de 850 nm, eso no quiere decir que se haya utilizado la misma para todas las demás mediciones, debido a que los espectros no son iguales. Alternativamente, se podría utilizar un rango de longitudes de onda para definir el rango de valores de reflectancia a utilizar para el descarte de las mediciones. Finalizando con el descarte de mediciones, también se excluyeron mediciones debido a la presencia de


elementos y factores no deseados, por ejemplo, la boñiga, suelo desnudo y variaciones en la luminosidad debido a cambios en la nubosidad, los cuales podrían agregar ruido a los espectros.

El proceso de remoción de la brecha se realizó utilizando la función `rmgap` del paquete de R llamado `rchemo`. Esta se encargó de remover la brecha mediante el ajuste de un modelo lineal, permitiendo cuantificar cuanto se deben corregir los valores de reflectancia para eliminar la brecha. Una vez aplicado el descarte de las mediciones y la remoción de la brecha, se realizó el promediado de los espectros, dando como resultado lo mostrado en la Figura 26.

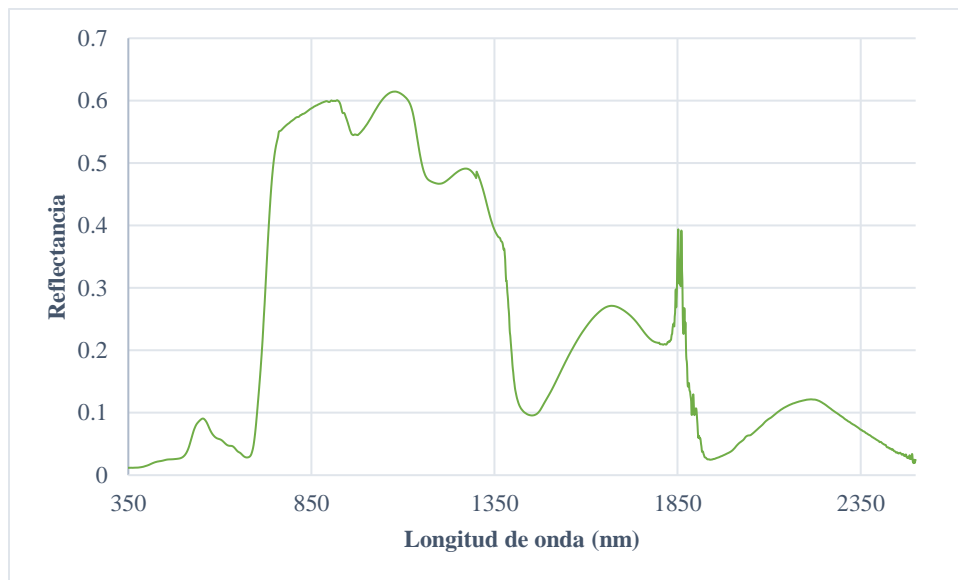


**Figura 24.** Espectros iniciales para la edad del pasto de 42 días del manejo de corte.






**Figura 25.** Espectros para la edad del pasto de 42 días del manejo de corte luego de excluir mediciones y aplicar la remoción de la brecha.



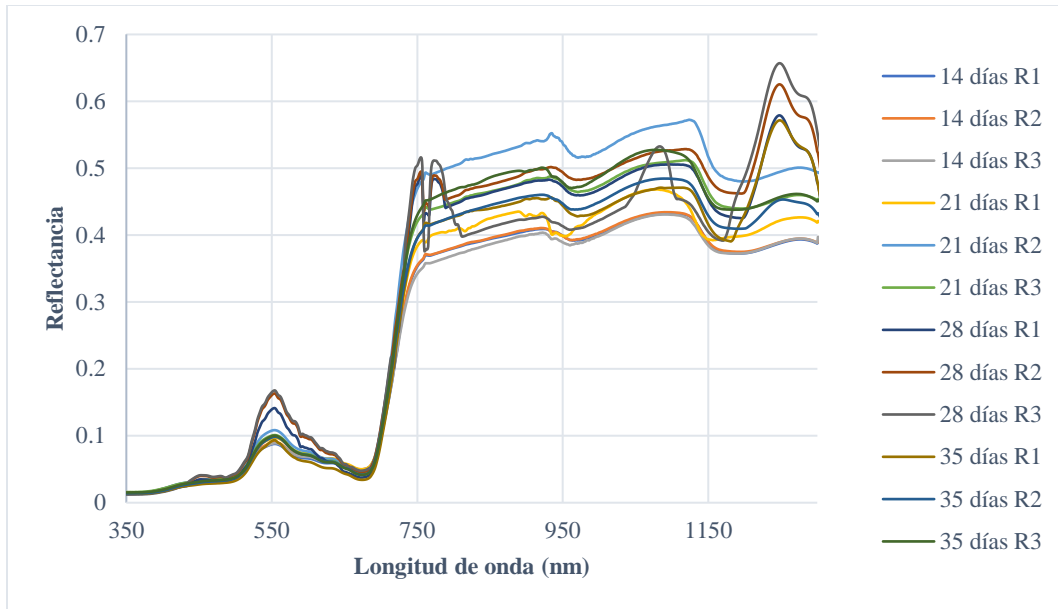
**Figura 26.** Espectro promedio final para la edad del pasto de 42 días del manejo de corte.

Los espectros promedio correspondientes al manejo de corte, una vez aplicados los procesos de descarte, remoción de la brecha y promediado para cada una de las edades del pasto se muestran en las Figuras 27 y 28, para el ciclo de crecimiento 1 y 2 respectivamente. En el caso de ambos

ciclos de crecimiento, se observa que se da un aumento gradual en los valores de reflectancia, sin embargo, este aumento no se da al aumentar la edad del pasto en todos los casos, lo cual refuerza lo mencionado anteriormente respecto a que para este manejo no se contó con una distribución de pasto uniforme.

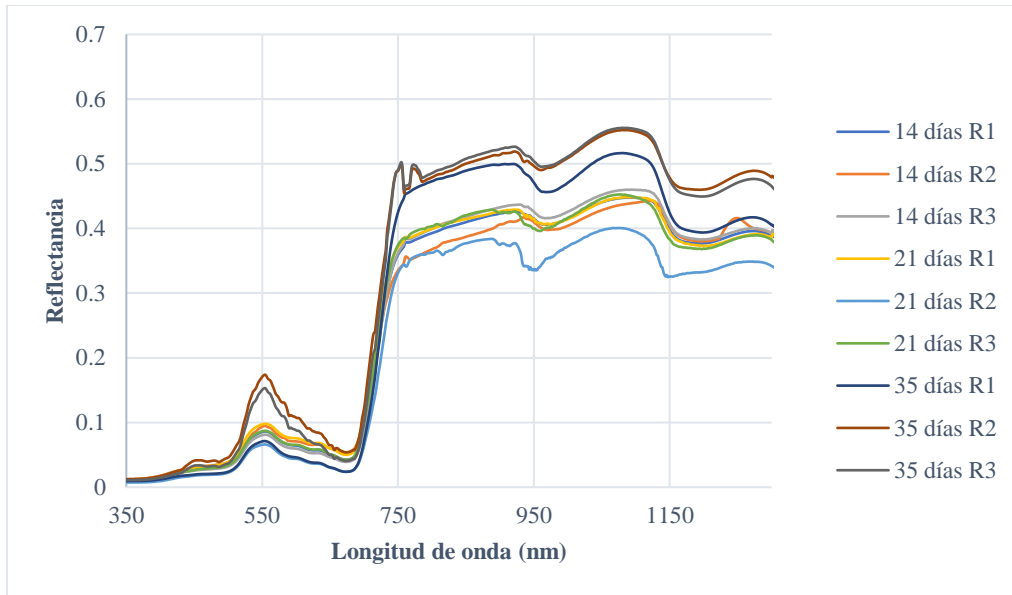


**Figura 27.** Espectros para el primer ciclo de crecimiento del manejo de corte.




**Figura 28.** Espectros para segundo ciclo de crecimiento del manejo de corte.

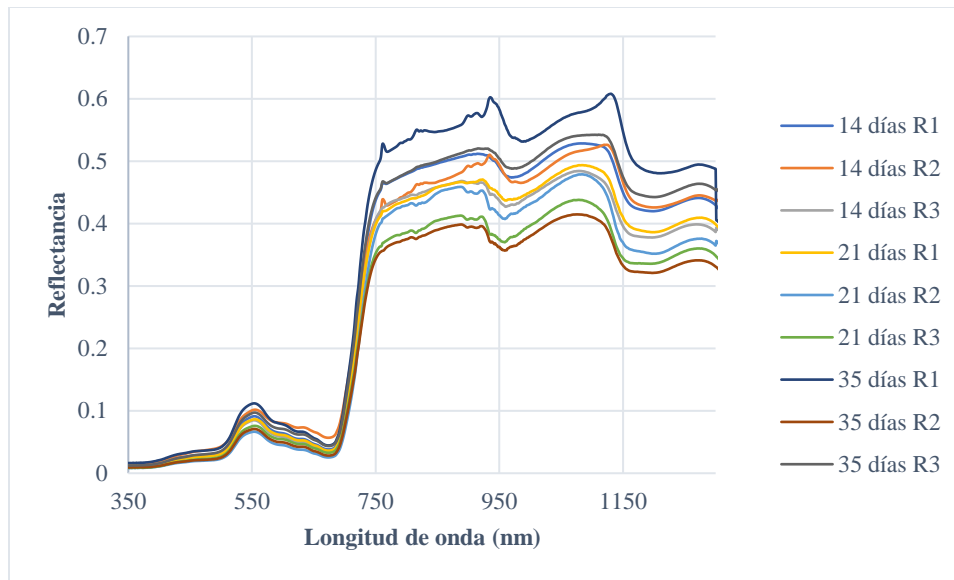
En cuanto a los ciclos de crecimiento del manejo de pastoreo, se observa un comportamiento similar al mostrado para el manejo de corte, como indican las Figuras 29, 30 y 31. Donde en algunos casos al aumentar la edad del pasto se obtuvieron valores mayores de reflectancia en la región NIR, la cual presenta mayor sensibilidad a los cambios en la estructura celular de las plantas.



**Figura 29.** Espectros para primer ciclo de crecimiento del manejo de pastoreo.



**Figura 30.** Espectros para segundo ciclo de crecimiento del manejo de pastoreo.



**Figura 31.** Espectros para tercer ciclo de crecimiento del manejo de pastoreo.

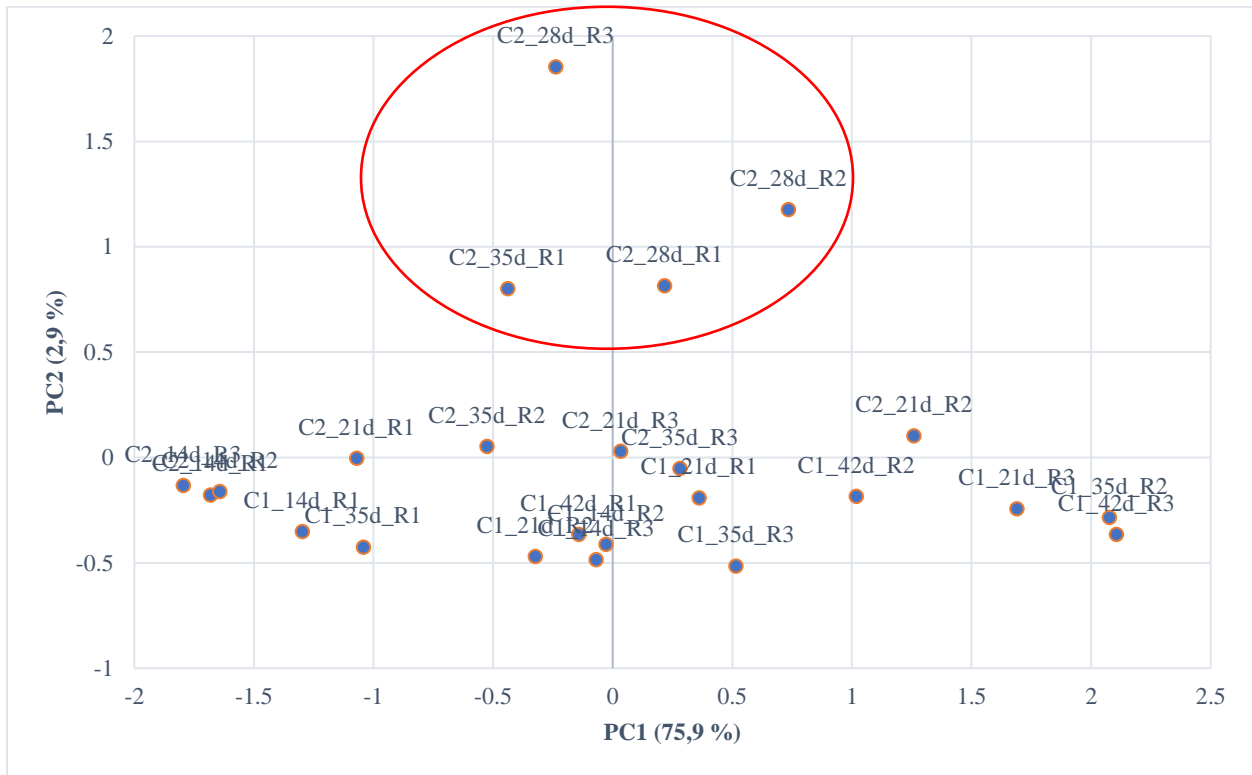
## 5.2. Objetivo 2 y 3: Estimación de índice de área foliar y determinación de la metodología más precisa

### 5.2.1. Análisis de componentes principales

La nomenclatura utilizada para identificar los espectros consistió en una combinación del ciclo de crecimiento y el tipo de manejo. De manera que, para los ciclos de crecimiento del manejo de corte se utilizó la nomenclatura “C1” y “C2” para el primer y segundo ciclo, respectivamente. En el caso de la edad del pasto y las repeticiones se utilizó la letra “d” y “R”, respectivamente. A manera de ejemplo, el espectro “C2\_42d\_R3” corresponde a la tercera repetición de la medición de 42 días (edad del pasto), durante el segundo ciclo de crecimiento del manejo de corte.


En la Figura 32, se muestran graficadas las puntuaciones de los dos primeros componentes principales de los espectros del manejo de corte, incluyendo todos los ciclos de crecimiento y edades del pasto. Donde basado en el segundo componente principal (PC2), se puede observar que las tres repeticiones de la edad del pasto de día 28 del segundo ciclo de crecimiento del manejo de corte se presentan como espectros atípicos. Esto debido a que los valores de sus puntuaciones en el componente PC2 son distintos a los del clúster de datos a lo largo de este componente. Por esta razón estos espectros fueron excluidos del conjunto de datos para mejorar la uniformidad del modelo. Además, la primera repetición de la edad del pasto de 35 días del segundo ciclo del manejo de corte, también se consideró como un espectro atípico. Estos resultados también se observan en

la Figura 28, donde alrededor de la longitud de onda de 1250 nm se da un aumento abrupto en los valores de reflectancia, lo cual permite confirmar que se tratan de espectros atípicos.




**Figura 32.** Puntuaciones de los componentes PC1 y PC2 del PCA realizado al conjunto de datos del manejo de corte antes de excluir mediciones. Las mediciones atípicas se resaltan con una elipse roja.

Luego de descartar los espectros C2\_28d\_R1, C2\_28d\_R2, C2\_28d\_R3 y C2\_35d\_R1, se realizó nuevamente un PCA sobre los demás espectros del manejo de corte y se realizó el gráfico de puntuaciones mostrado en la Figura 33. Con base en este gráfico se puede observar que los espectros se encuentran distribuidos de manera más uniforme a lo largo de ambos componentes principales, donde en este caso, el primer componente principal (PC1) logra explicar hasta un 95,4 % de la varianza y el componente PC2 el 3,9 %. Tomando en consideración la distribución de las mediciones espectrales únicamente sobre el componente PC2, se puede intuir que espectros como el C2\_21d\_R2 pueden ser posiblemente atípicos. Sin embargo, debido al valor de su puntuación sobre el componente PC2 y la varianza explicada por este componente no se considera que su influencia sobre el resto de los espectros sea significativa.



**Figura 33.** Puntuaciones de los componentes PC1 y PC2 del PCA realizado al conjunto de datos del manejo de corte luego de excluir mediciones.

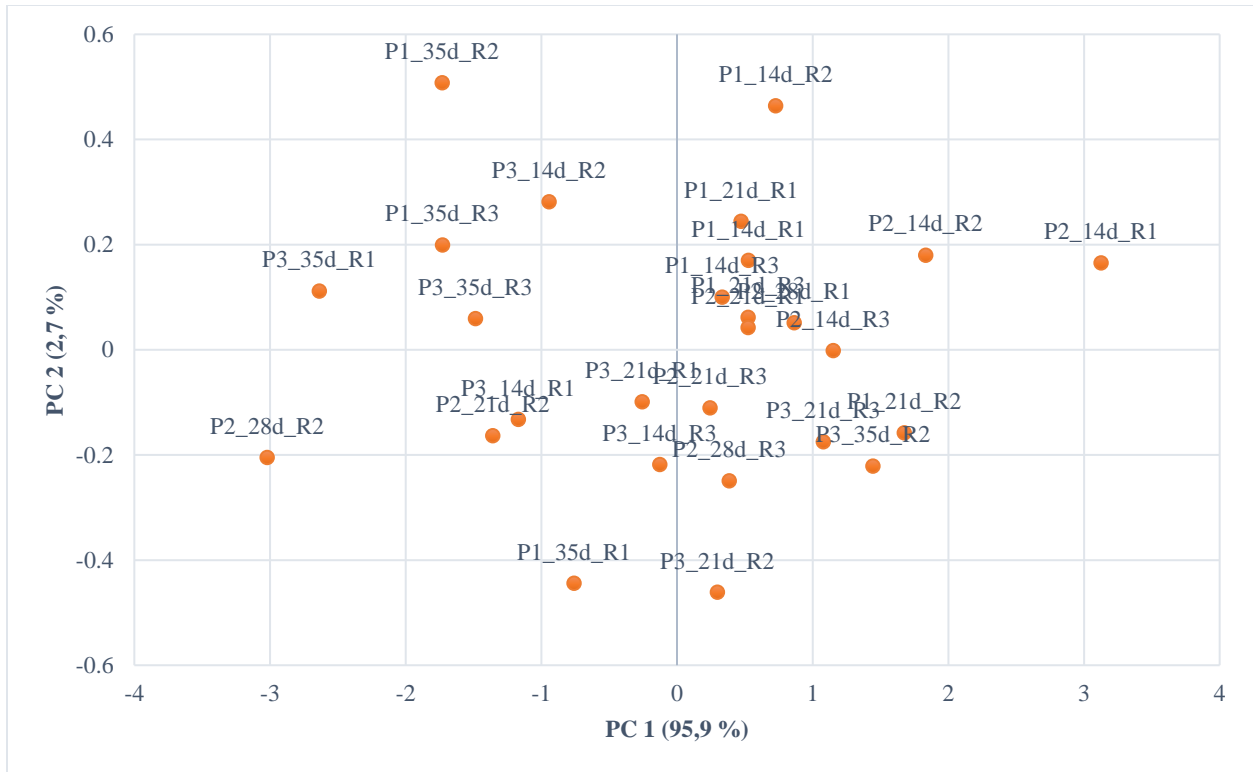
En el caso del manejo de pastoreo, ocurre algo similar a lo observado en el manejo de corte, donde al graficar las puntuaciones de los componentes PC1 y PC2, se cuenta con espectros que se pueden considerar atípicos, basado en la magnitud de sus puntuaciones en el componente PC2 (Figura 34). En este caso, los espectros P2\_35d\_R1, P2\_35d\_R2 y P2\_35d\_R3 fueron considerados como atípicos debido a la magnitud de sus puntuaciones a lo largo del componente PC2 y a sus valores de reflectancia, según se muestra en la Figura 30. Donde aproximadamente en la longitud de onda de 1250 nm se da un aumento en la reflectancia en las tres repeticiones del día 35 del segundo ciclo de crecimiento del manejo de pastoreo.



**Figura 34.** Puntuaciones de los componentes PC1 y PC2 del PCA realizado al conjunto de datos del manejo de pastoreo antes de excluir mediciones. Las mediciones atípicas se resaltan con una elipse roja.

En la Figura 35, se muestran las puntuaciones de los componentes PC1 y PC2 luego de excluir las repeticiones del día 35 de segundo ciclo de crecimiento del manejo de pastoreo. Se observa que la magnitud de todas las puntuaciones se encuentra en un rango similar. Además, de manera similar a lo sucedido para el manejo de corte, luego de excluir los espectros atípicos se obtuvo un aumento en la varianza explicada por el componente PC1, logrando explicar el 95,9 %. Todos los espectros excluidos fueron tomados el mismo día, a excepción del C2\_35d\_R1, concretamente el 19 de agosto de 2022, por lo que se puede asumir que estos espectros fueron afectados por la misma razón. El aumento en la reflectancia observado en las Figuras 22 y 24 puede ser debido a un error de calibración, producto de cambios repentinos en las condiciones de nubosidad.





**Figura 35.** Puntuaciones de los componentes PC1 y PC2 del PCA realizado al conjunto de datos del manejo de pastoreo luego de excluir mediciones.

### 5.2.2. Estimación del índice de área foliar utilizando índices de vegetación

Producto de la cantidad de modelos generados, surge la necesidad de utilizar algún método para determinar los mejores modelos correspondientes a cada IV y tipo de manejo. Para esto, se utilizó el método relativo, el cual utiliza valores relativos que representan que tanto se aleja el  $R^2$  y RMSE de cada modelo, del mayor y menor valor de  $R^2$  y RMSE en todo un subconjunto. Este método parte de un conjunto de modelos, el cual contiene todos los modelos generados para un tipo específico de manejo (corte y pastoreo), incluyendo todos los IV y tipos de regresión utilizados (lineal, exponencial, potencial y polinómica de segundo grado). A partir del conjunto de modelos, se generaron 11 subconjuntos, uno para cada IV, a excepción del NDRE y ONLI, los cuales contaron con 3 subconjuntos cada uno, debido a que ambos utilizan las 3 bandas de borde rojo.

### 5.2.2.1. Manejo de corte

Para la primera parte del método relativo, se determinaron los valores de referencia (Tabla 11). Con base en estos valores de referencia, para los subconjuntos del manejo de corte se obtuvo que el IV NDRE2 es el que alcanzó el valor más alto y bajo de  $R^2$  (0,6812) y RMSE (0,5088), respectivamente. De acuerdo con los valores de referencia (Tabla 11), se calcularon los valores relativos de  $R^2$  y RMSE para cada modelo de cada subconjunto, para luego calcular la suma de estos valores relativos para cada uno de los modelos. Debido a que para este método se consideró que un buen modelo es aquel que posee los valores relativos más bajos, el menor valor de la suma de estos valores relativos debería corresponder al mejor modelo del subconjunto. Con base en esto, se ordenó cada uno de los subconjuntos de forma ascendente, de acuerdo con su valor de suma de relativos, para luego seleccionar el primer modelo.

**Tabla 11.** Valores de referencia de cada subconjunto determinados con el método relativo para los manejos de corte y pastoreo.

Corte			Pastoreo		
IV	$R^2$	RMSE	IV	$R^2$	RMSE
EVI2	0,2140	0,8282	EVI2	0,1755	0,9810
NDVI	0,4077	0,6993	NDVI	0,1777	0,9658
MTVI2	0,2678	0,7946	MTVI2	0,2210	0,9900
ONLI1	0,3631	0,5961	ONLI1	0,1996	0,9975
ONLI2	0,2099	0,8241	ONLI2	0,2039	0,9819
ONLI3	0,0988	0,9101	ONLI3	0,1574	0,9780
OSAVI	0,3071	0,7641	OSAVI	0,1636	0,9901
RSI	0,3627	0,7335	RSI	0,2267	0,9157
NDRE1	0,4468	0,6716	NDRE1	0,2083	1,0231
NDRE2	0,6812	0,5088	NDRE2	0,3356	0,8884
NDRE3	0,4378	0,7110	NDRE3	0,1914	0,8372

ONLI 1: Conjunto de datos de borde rojo 1, ONLI 2: Conjunto de datos de borde rojo 2, ONLI 3:

Conjunto de datos de borde rojo 3, NDRE 1: Conjunto de datos de borde rojo 1, NDRE 2:

Conjunto de datos de borde rojo 2, NDRE 3: Conjunto de datos de borde rojo 3.

Luego de aplicar el método relativo para este tipo de manejo, se obtuvo que para el IV EVI2, fue posible minimizar la suma de valores relativos al utilizar una regresión potencial, para la cual se obtuvo un  $R^2$  de 0,2140 y un RMSE de 0,8447 (Tabla B23). En cuanto a los modelos basados en el IV MTVI2, el uso de una regresión potencial permitió obtener las métricas de 0,2674 en el caso del  $R^2$  y 0,8050 para el RMSE (Tabla B24). Al considerar el IV NDVI, la regresión de tipo lineal fue la que permitió minimizar la suma de valores relativos para este IV, con un  $R^2$  de 0,4077 y un

RMSE de 0,6993 (Tabla B25). Para el IV ONLI1, fue posible alcanzar un  $R^2$  de 0,3391 y un RMSE de 0,5961 al utilizar una regresión potencial (Tabla B26). Por otra parte, para el ONLI2 se lograron métricas de 0,2099 para el  $R^2$  y 0,8241 para el RMSE por medio de una regresión de tipo lineal (Tabla B27).

En este aspecto, el ONLI3 alcanzó métricas de hasta 0,0988 para el  $R^2$  y 0,9108 para el RMSE, al utilizar una regresión de tipo polinómica de segundo grado (Tabla B28). Para el IV OSAVI, se obtuvieron mejores resultados al utilizar una regresión de tipo lineal, logrando un  $R^2$  de 0,3067 y un RMSE de 0,7641 (Tabla B29). En cuanto al RSI, el mejor modelo presentó las métricas de 0,3627 como valor de  $R^2$  y 0,7472 en el caso del RMSE (Tabla B30). Para el IV NDRE1 al utilizar una regresión lineal, se obtuvieron valores de  $R^2$  de hasta 0,4468 y RMSE de 0,6716 (Tabla B31). Finalmente, al utilizar una regresión de tipo polinómica de segundo grado fue posible minimizar la suma de valores relativos para los IV NDRE2 ( $R^2=0,6812$ , RMSE=0,5089) y NDRE3 ( $R^2=0,3756$ , RMSE=0,7110) (Tablas B32 y B33).

Con base en los resultados del método relativo para cada subconjunto del manejo de corte, se observa que los tipos de regresión más comunes fueron la potencial y la lineal, ambas utilizadas en cuatro modelos (Tabla 12). Lo cual es algo visto en estudio previos como el de Liang et al. (2015), donde modelos basados en regresiones de tipo lineal y potencial permitieron obtener buenos resultados. De manera opuesta, para ninguno de los subconjuntos, el uso de una regresión exponencial permitió obtener buenos resultados.

Al comparar los modelos determinados mediante el método relativo para el manejo de corte, se observa que el modelo basado en el IV NDRE2 puede ser considerado el mejor modelo (Tabla 12), ya que es el que presenta el valor más alto y bajo de  $R^2$  y RMSE respectivamente. Con base en los resultados del método relativo, se probaron dos tipos de clasificación, una con base en el RPD, el cual es la relación entre la desviación estándar de los datos medidos entre el RMSE de cada modelo y el 1-RRMSE.

**Tabla 12.** Modelos determinados con el método relativo para todos los subconjuntos de manejo de corte.

<b>IV</b>	<b>Regresión</b>	<b>Bandas (nm)</b>	<b>RMSE</b>	<b>R<sup>2</sup></b>	<b>Suma de relativos</b>
EVI2	Potencial	865;650	0,8447	0,2140	0,0199
MTVI2	Potencial	650;871;578	0,8050	0,2674	0,0000
NDVI	Lineal	650;900	0,6993	0,4077	0,0146
ONLI1	Potencial	873;701	0,5961	0,3391	0,0661
ONLI2	Lineal	865;733	0,8241	0,2099	0,0000
ONLI3	Polinómica	816;773	0,9108	0,0988	0,0008
OSAVI	Lineal	900;650	0,7641	0,3067	0,0013
RSI	Potencial	900;680	0,7472	0,3627	0,0187
NDRE1	Lineal	900;713	0,6716	0,4468	0,0000
NDRE2	Polinómica	833;742	0,5089	0,6812	0,0002
NDRE3	Polinómica	786;773	0,7110	0,3756	0,1421

ONLI 1: Conjunto de datos de borde rojo 1, ONLI 2: Conjunto de datos de borde rojo 2, ONLI 3: Conjunto de datos de borde rojo 3, NDRE 1: Conjunto de datos de borde rojo 1, NDRE 2: Conjunto de datos de borde rojo 2, NDRE 3: Conjunto de datos de borde rojo 3.

En la Tabla 13 se muestran los resultados de la clasificación realizada con el RPD y 1-RRMSE, sobre los resultados del método relativo para el manejo de corte, en la cual se observa que, para ambos tipos de clasificación, los resultados fueron los mismos. Luego de clasificados los modelos del manejo de corte, se determinó que el mejor modelo fue el basado en el IV NDRE2, alcanzando un valor de R<sup>2</sup> de 0,6812 y un RMSE de 0.5089 y que el peor modelo fue el ONLI3 con un R<sup>2</sup> de 0,0988 y un RMSE de 0,9108 (Tabla 14).

**Tabla 13.** Comparación entre los tipos de clasificación de los modelos basados en IV para el manejo de corte.

Clasificación por RPD				Clasificación por 1-RRMSE			
IV	RMSE	R <sup>2</sup>	RPD	IV	RMSE	R <sup>2</sup>	1-RRMSE
NDRE2	0,5089	0,6812	1,8113	NDRE2	0,5089	0,6812	0,8151
ONLI1	0,5961	0,3391	1,5464	ONLI1	0,5961	0,3391	0,7835
NDRE1	0,6716	0,4468	1,3725	NDRE1	0,6716	0,4468	0,7560
NDVI	0,6993	0,4077	1,3182	NDVI	0,6993	0,4077	0,7460
NDRE3	0,7110	0,3756	1,2965	NDRE3	0,7110	0,3756	0,7417
RSI	0,7472	0,3627	1,2337	RSI	0,7472	0,3627	0,7286
OSAVI	0,7641	0,3067	1,2064	OSAVI	0,7641	0,3067	0,7224
MTVI2	0,8050	0,2674	1,1451	MTVI2	0,8050	0,2674	0,7076
ONLI2	0,8241	0,2099	1,1185	ONLI2	0,8241	0,2099	0,7007
EVI2	0,8447	0,2140	1,0913	EVI2	0,8447	0,2140	0,6932
ONLI3	0,9108	0,0988	1,0121	ONLI3	0,9108	0,0988	0,6692


ONLI 1: Conjunto de datos de borde rojo 1, ONLI 2: Conjunto de datos de borde rojo 2, ONLI 3: Conjunto de datos de borde rojo 3, NDRE 1: Conjunto de datos de borde rojo 1, NDRE 2: Conjunto de datos de borde rojo 2, NDRE 3: Conjunto de datos de borde rojo 3.

**Tabla 14.** Clasificación de los modelos basados en índices para el manejo de corte.


IV	Bandas (nm)	RMSE	R <sup>2</sup>	Regresión
NDRE2	833;742	0,5089	0,6812	$Y=-1806,83*X^2+386,92*X-17,08$
ONLI1	873;701	0,5961	0,3391	$Y=3,85*X^{0,14}$
NDRE1	900;713	0,6716	0,4468	$Y=14,12*X-3,92$
NDVI	650;900	0,6993	0,4077	$Y=13,86*X-8,79$
NDRE3	786;773	0,7110	0,3756	$Y=-53771,60*X^2+1253,07*X-2,92$
RSI	900;680	0,7472	0,3627	$Y=0,29*X^{0,83}$
OSAVI	900;650	0,7641	0,3067	$Y=11,22*X-5,57$
MTVI2	650;871;578	0,8050	0,2674	$Y=5,36*X^{1,85}$
ONLI2	865;733	0,8241	0,2099	$Y=10,12*X+6,80$
EVI2	865;650	0,8447	0,2140	$Y=5,60*X^{2,02}$
ONLI3	816;773	0,9108	0,0988	$Y=-182,31*X^2-179,45*X-40,88$

ONLI 1: Conjunto de datos de borde rojo 1, ONLI 2: Conjunto de datos de borde rojo 2, ONLI 3: Conjunto de datos de borde rojo 3, NDRE 1: Conjunto de datos de borde rojo 1, NDRE 2: Conjunto de datos de borde rojo 2, NDRE 3: Conjunto de datos de borde rojo 3.

Comparando de manera visual el ajuste de los dos primeros modelos para el manejo de corte (Figuras 36 y 37), se puede asumir que estos modelos son similares entre sí, en cuanto a su capacidad para predecir o estimar los valores de IAF medidos en campo. Al analizar más a profundidad los resultados de cada uno de estos modelos, se obtiene que el valor de la suma cuadrada de sus residuos es de 7,88 para el IV ONLI1 y 4,34 para el NDRE2. Con base en estos valores se puede decir que el modelo basado en el NDRE2 es el que mejor se ajusta a los valores de IAF, lo cual también se observa en la Tabla 14, donde este modelo presenta el mayor valor de  $R^2$ . Además, en términos de minimizar el error en las estimaciones de IAF, el modelo basado en el IV NDRE2 es el más apto.



**Figura 36.** Distribución de los valores medidos y estimados de IAF para el índice NDRE2 para el manejo de corte, con su línea de tendencia lineal (línea punteada).



**Figura 37.** Distribución de los valores medidos y estimados de IAF para el índice ONLI1 para el manejo de corte, con su línea de tendencia lineal (línea punteada).

#### 5.2.2.2. Manejo de pastoreo

De acuerdo con los valores de referencia del método relativo para los subconjuntos del manejo de pastoreo (Tabla 11), el IV NDRE2 fue el que alcanzó el valor más alto de  $R^2$  con un 0,3356 y el NDRE3 el RMSE más bajo con un 0,8372. Posteriormente, se calcularon los valores relativos de  $R^2$  y RMSE para cada uno de los modelos de cada subconjunto del manejo de pastoreo.

Los resultados de este método para el manejo de pastoreo muestran que para el IV EVI2, el uso de una regresión de tipo exponencial permitió obtener un valor de  $R^2$  de 0,1755 y un RMSE de 1,0079 (Tabla B34). De manera similar, el NDVI también hizo uso de una regresión de tipo exponencial para obtener las métricas de 0,1777 y 1,0426 para el  $R^2$  y RMSE respectivamente (Tabla B35). Este tipo de regresión exponencial también permitió minimizar la suma de los valores relativos al utilizar el IV ONLI2, donde se obtuvo un valor de  $R^2$  de 0,2039 y un RMSE de 1,0161 (Tabla B36). De igual manera, para el ONLI 3 la regresión de tipo exponencial fue la que permitió obtener un valor de  $R^2$  de 0,1574 y un RMSE de 1,0041 (Tabla B37).

En cuanto al OSAVI, se obtuvieron valores de  $R^2$  de 0,1636 y RMSE de 1,0186 al utilizar una regresión de tipo exponencial (Tabla B38). Por otro lado, el MTVI2 presentó valores de  $R^2$  y RMSE de 0,2110 y 0,9901 respectivamente al utilizar una regresión de tipo lineal (Tabla B39). De forma similar, la regresión de tipo lineal permitió minimizar la suma de valores relativos para el IV RSI, alcanzando un  $R^2$  de 0,2220 y un RMSE de 1,0470 (Tabla B40). En el caso del IV ONLI1,

el uso de una regresión de potencial permitió obtener un valor de  $R^2$  de 0,1996 y un RMSE de 1,0542 (Tabla B41). Al considerar el IV NDRE1, al utilizar una regresión de tipo exponencial, se alcanzaron valores de  $R^2$  de hasta 0,2083 y RMSE de 1,0633 (Tabla B42). Por otra parte, el uso de una regresión potencial logro minimizar la suma de valores relativos al utilizar los IV NDRE2 ( $R^2=0,3354$ ,  $RMSE=1,1094$ ) y NDRE3 ( $R^2=0,1914$ ,  $RMSE=0,8597$ ) (Tabla B43 y B44).

En el caso de este tipo de manejo, al tomar en consideración todos los subconjuntos, los modelos determinados con el método relativo utilizaron mayoritariamente una regresión de tipo exponencial (Tabla 15). Lo cual coincide con los resultados obtenidos por Wang et al. (2019), incluso para el IV NDRE (NDRE1, según la Tabla 15), el cual también fue utilizado por estos autores. Por otra parte, la regresión polinómica de segundo grado fue sin discusión la que dio resultados inferiores para este manejo, ya que según se muestra en la Tabla 15, ninguno de los modelos seleccionados utilizó este tipo de regresión.

**Tabla 15.** Modelos determinados con el método relativo para todos los subconjuntos de manejo de pastoreo.

IV	Regresión	Bandas (nm)	RMSE	$R^2$	Suma de relativos
EVI2	Exponencial	859;656	1,0079	0,1755	0,0274
MTVI2	Lineal	656;877;578	0,9901	0,2210	0,0001
NDVI	Exponencial	656;886	1,0426	0,1777	0,0795
ONLI1	Potencial	805;712	1,0542	0,1996	0,0568
ONLI2	Exponencial	865;733	1,0161	0,2039	0,0348
ONLI3	Exponencial	807;789	1,0041	0,1574	0,0267
OSAVI	Exponencial	865;656	1,0186	0,1636	0,0288
RSI	Lineal	866;656	1,0470	0,2220	0,1641
NDRE1	Exponencial	876;701	1,0633	0,2083	0,0393
NDRE2	Potencial	882;733	1,1094	0,3354	0,2494
NDRE3	Potencial	816;780	0,8597	0,1914	0,0269

ONLI 1: Conjunto de datos de borde rojo 1, ONLI 2: Conjunto de datos de borde rojo 2, ONLI 3:

Conjunto de datos de borde rojo 3, NDRE 1: Conjunto de datos de borde rojo 1, NDRE 2:

Conjunto de datos de borde rojo 2, NDRE 3: Conjunto de datos de borde rojo 3.

De manera similar al manejo de corte, se llevó a cabo una clasificación de los modelos determinados por el método relativo, donde ambos tipos de clasificación también ordenaron los modelos generados de la misma manera para el manejo de pastoreo (Tabla 16). De acuerdo con estos resultados, ambos tipos de clasificación son equivalentes, por lo cual cualquiera de ellos puede ser utilizado. Con base en esta clasificación de los modelos, para el manejo de pastoreo, el



primer modelo fue el basado en el IV NDRE3, con un valor de  $R^2$  de 0,1914 y un RMSE de 0,8597, por otro lado, el último modelo fue el NDRE2, con un  $R^2$  de 0,3354 y un RMSE de 1,1094 (Tabla 17).

**Tabla 16.** Comparación entre los tipos de clasificación de los modelos basados en IV para el manejo de pastoreo.

Clasificación por RPD				Clasificación por 1-RRMSE			
IV	RMSE	$R^2$	RPD	IV	RMSE	$R^2$	1-RRMSE
NDRE3	0,8597	0,1914	1,1167	NDRE3	0,8597	0,1914	0,7251
MTVI2	0,9901	0,2210	0,9696	MTVI2	0,9901	0,2210	0,6834
ONLI3	1,0041	0,1574	0,9561	ONLI3	1,0041	0,1574	0,6790
EVI2	1,0079	0,1755	0,9525	EVI2	1,0079	0,1755	0,6778
ONLI2	1,0161	0,2039	0,9448	ONLI2	1,0161	0,2039	0,6751
OSAVI	1,0186	0,1636	0,9425	OSAVI	1,0186	0,1636	0,6743
NDVI	1,0426	0,1777	0,9208	NDVI	1,0426	0,1777	0,6667
RSI	1,0470	0,2220	0,9169	RSI	1,0470	0,2220	0,6653
ONLI1	1,0542	0,1996	0,9107	ONLI1	1,0542	0,1996	0,6629
NDRE1	1,0633	0,2083	0,9029	NDRE1	1,0633	0,2083	0,6600
NDRE2	1,1094	0,3354	0,8654	NDRE2	1,1094	0,3354	0,6453


ONLI 1: Conjunto de datos de borde rojo 1, ONLI 2: Conjunto de datos de borde rojo 2, ONLI 3: Conjunto de datos de borde rojo 3, NDRE 1: Conjunto de datos de borde rojo 1, NDRE 2: Conjunto de datos de borde rojo 2, NDRE 3: Conjunto de datos de borde rojo 3.

**Tabla 17.** Clasificación de los modelos basados en índices para el manejo de pastoreo.

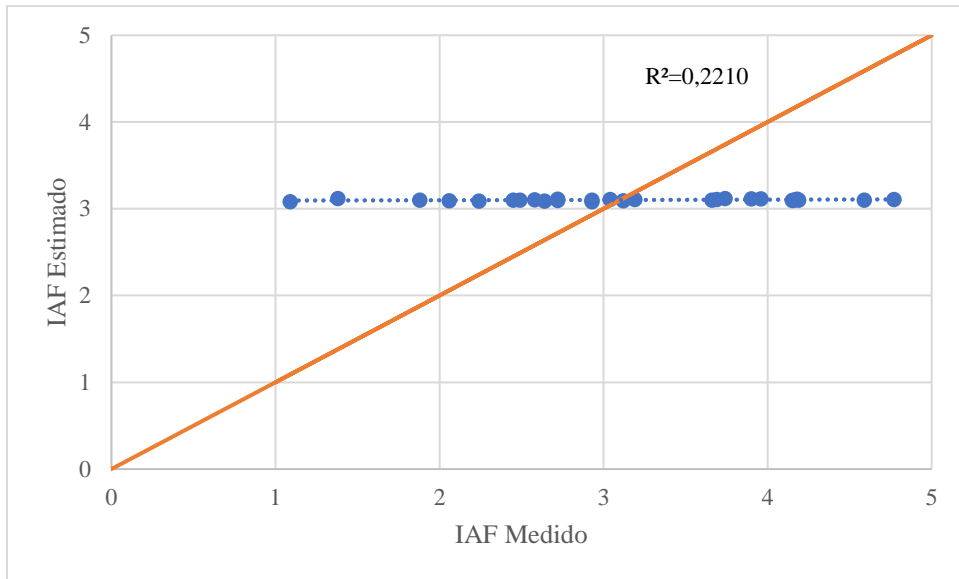
<b>IV</b>	<b>Bandas (nm)</b>	<b>RMSE</b>	<b>R<sup>2</sup></b>	<b>Regresión</b>
NDRE3	816;780	0,8597	0,1914	$Y=6,45*X^{0,16}$
MTVI2	656;877;578	0,9901	0,2210	$Y=0,15*X+3,03$
ONLI3	807;789	1,0041	0,1574	$Y=3,46+\exp(0,27*X)$
EVI2	859;656	1,0079	0,1755	$Y=2,59+\exp(0,20*X)$
ONLI2	865;733	1,0161	0,2039	$Y=3,42+\exp(0,34*X)$
OSAVI	865;656	1,0186	0,1636	$Y=2,21+\exp(0,40*X)$
NDVI	656;886	1,0426	0,1777	$Y=1,81+\exp(0,59*X)$
RSI	866;656	1,0470	0,2220	$Y=0,01*X+3,06$
ONLI1	805;712	1,0542	0,1996	$Y=2,81*X^{0,02}$
NDRE1	876;701	1,0633	0,2083	$Y=1,91+\exp(0,67*X)$
NDRE2	882;733	1,1094	0,3354	$Y=4,62*X^{0,25}$

ONLI 1: Conjunto de datos de borde rojo 1, ONLI 2: Conjunto de datos de borde rojo 2, ONLI 3: Conjunto de datos de borde rojo 3, NDRE 1: Conjunto de datos de borde rojo 1, NDRE 2: Conjunto de datos de borde rojo 2, NDRE 3: Conjunto de datos de borde rojo 3.

En cuanto al manejo de pastoreo, los valores de la suma cuadrada de los residuos fueron de 17,88 para el modelo basado en el IV NDRE3 y 23,82 para el MTVI2. Al considerar estos valores se puede decir que en este caso el modelo superior para estimar el IAF fue el basado en el IV NDRE3, lo cual también se observa gráficamente de acuerdo con la orientación de la línea de tendencia (línea punteada) (Figuras 38 y 39). Para este manejo, con base en el valor del RPD (Tabla 15), el primer modelo también fue el mencionado anteriormente, por lo que en este caso se confirma que el modelo basado en IV NDRE3 fue relativamente mejor en comparación con los demás para este tipo de manejo. Sin embargo, se debe tomar en consideración que a pesar de que el modelo basado en el IV NDRE3 fue el primero en términos de RPD, sus resultados siguen siendo poco precisos, por lo que para el manejo de pastoreo no es recomendable utilizar este modelo para predecir el IAF.



**Figura 38.** Distribución de los valores medidos y estimados de IAF para el índice NDRE3 para el manejo de pastoreo, con su línea de tendencia lineal (línea punteada).



**Figura 39.** Distribución de los valores medidos y estimados de IAF para el índice MTVI2 para el manejo de pastoreo, con su línea de tendencia lineal (línea punteada).


### 5.2.2.3. Análisis de ambos tipos de manejo

Previo a utilizar el método relativo, de manera general, para el manejo de corte, el tipo de regresión potencial fue la que presentó los valores de  $R^2$  más altos para la mayoría de los IV estudiados, siendo la polinómica de segundo grado la que dio los valores más bajos. Para el manejo de pastoreo, la regresión de tipo exponencial fue la que permitió alcanzar los valores de  $R^2$  más altos en la mayoría de los casos y la polinómica de segundo grado la que dio los más bajos. Esto sugiere que, además del IV utilizado, el tipo de regresión juega un papel fundamental a la hora de generar este tipo de modelos. Lo cual no se trata de un caso aislado, ya que, según los resultados obtenidos por diferentes autores, diferentes tipos de regresión han permitido alcanzar los mejores resultados, incluso para un mismo tipo de cultivo.

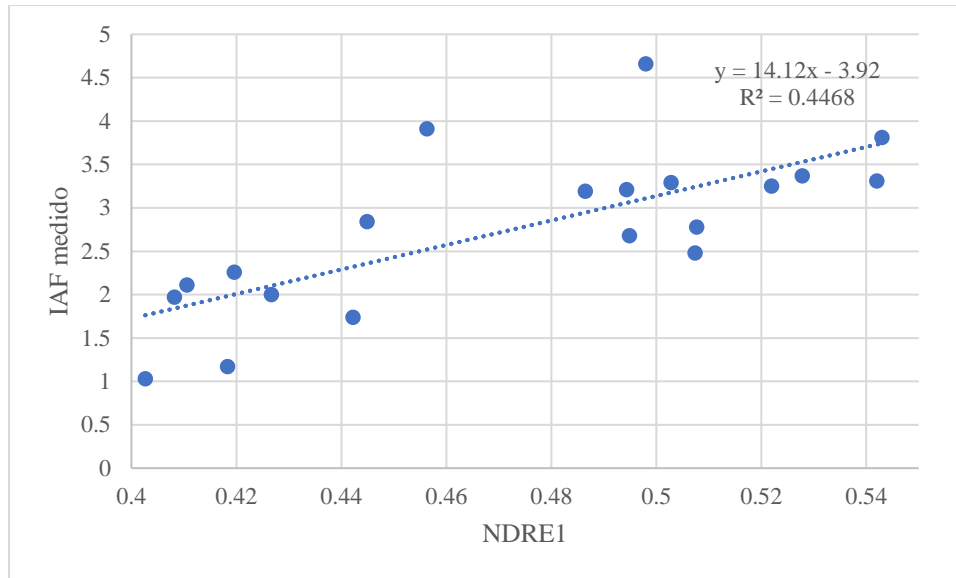
Entre estos autores se encuentra Wang et al. (2019), cuyos resultados muestran que el uso de un tipo de regresión exponencial les permitió obtener los mejores resultados al estimar el IAF en arroz, utilizando IV como el NDRE, GNDVI y CIRE, alcanzando  $R^2$  y RMSE de hasta 0,74 y 1,46 respectivamente. Por otra parte, Dong et al. (2020), obtuvieron los mejores resultados en términos de  $R^2$  (0,93) al utilizar una regresión de tipo polinómica de segundo grado para el IV NDRE al estimar el IAF, en cultivos como maíz, avena, soya y trigo. Con base en los resultados de Nie et al. (2023), se observa que para diferentes cultivos se obtienen diferentes valores de  $R^2$  y RMSE al utilizar un mismo IV para estimar el IAF mediante el ajuste de un modelo lineal para trigo, algodón y maíz. Con base en esto, es posible inferir que el rendimiento de los modelos varía en función de los IV, tipo de regresión y tipo de cultivo.

Con base en los resultados de la clasificación de los modelos mostrados en las Tablas 16 y 17, se puede intuir que la banda de borde rojo a utilizar tiene un efecto considerable sobre la capacidad de un modelo para estimar el IAF, como es en el caso de los modelos basados en el IV ONLI. Para el manejo de corte, se obtuvieron buenos resultados ( $R^2=0,3391$ ,  $RMSE=0,5961$ ) al utilizar conjunto de datos de borde rojo 1 (698-713 nm) en comparación al utilizar el de borde rojo 3 (773-793 nm) ( $R^2=0,0988$ ,  $RMSE=0,9108$ ). Por otra parte, para el manejo de pastoreo se obtuvieron mejores resultados ( $R^2=0,1574$ ,  $RMSE=1,0041$ ) con este IV al utilizar el conjunto de datos de borde rojo 3 e inferiores ( $R^2=0,1996$ ,  $RMSE=1,0542$ ) al utilizar el de borde rojo 1. El IV NDRE también hace uso de la banda de borde rojo, sin embargo, para el manejo de corte el uso de la banda de borde rojo 2 (733-748 nm) fue la que permitió obtener los mejores resultados ( $R^2=0,6812$ ,  $RMSE=0,5089$ ) y la de borde rojo 3 la que presentó las menores métricas ( $R^2=0,3756$ ,  $RMSE=0,7110$ ). En cuanto al manejo de pastoreo, se obtuvieron métricas de hasta 0,1914 para el  $R^2$  y 0,8597 para el RMSE en el mejor de los casos y un  $R^2$  de 0,3354 y un RMSE de 1,1094 en el peor, al utilizar las bandas de borde rojo 3 y 2, respectivamente. De acuerdo con estos resultados, la banda de borde rojo que permite obtener mejores resultados no solo varía en función del tipo de manejo, sino que también depende del IV a utilizar.

Al representar de manera grafica la relación entre los valores de un IV y el IAF medido, podría ser posible identificar o descartar tipos de regresión que permitan obtener mejores resultados a la hora de estimar el IAF. Para el manejo de corte, la relación entre el IAF medido y el IV NDRE2 (Figura 40), parece indicar que es posible identificar levemente que la relación entre ambas variables puede ser definida por una regresión potencial o polinómica de segundo grado, de acuerdo con la distribución de los datos. Por otro lado, al graficar la relación entre el IAF medido y el IV NDRE1 (Figura 41), es posible intuir que los datos siguen una relación lineal o inclusive polinómica de segundo grado.

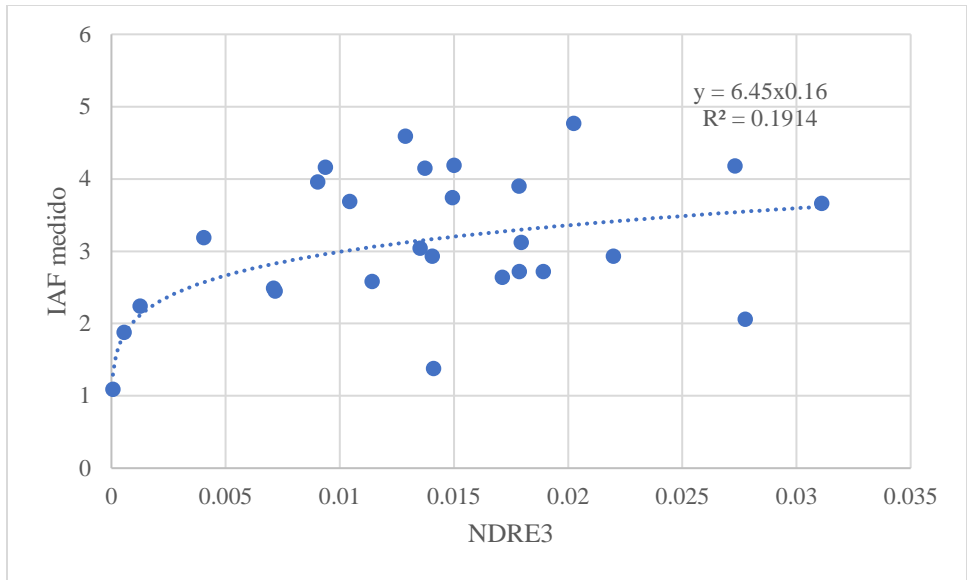


**Figura 40.** Relación entre el IAF medido y el IV NDRE2 para el manejo de corte.




**Figura 41.** Relación entre el IAF medido y el IV NDRE1 para el manejo de corte.

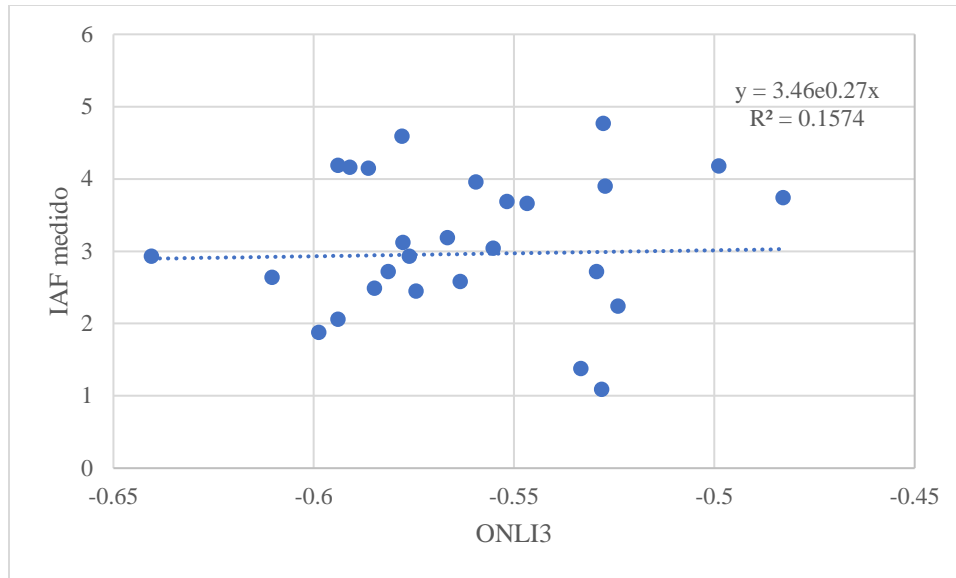
Según los resultados mostrados en la Tabla 14, el IV NDRE2 presentó una relación polinomial de segundo grado con el IAF, la cual le permitió alcanzar las mejores métricas para el manejo de corte y en el caso del IV NDRE1 fue una de tipo lineal. En el caso del manejo de pastoreo, la relación entre el IV NDRE3 y el IAF medido (Figura 42) podría considerarse lineal, polinómica o potencial. Para los IV MTVI2 y ONLI3, resulta complicado identificar algún tipo de relación que permita obtener un buen ajuste (Figuras 43 y 44). Como base en los resultados de la Tabla 17, para este tipo de manejo, para el IV NDRE3, una relación potencial fue determinada como la óptima y para el MTVI2 y ONLI3, una relación lineal y potencial respectivamente.



**Figura 42.** Relación entre el IAF medido y el IV NDRE3 para el manejo de pastoreo.



**Figura 43.** Relación entre el IAF medido y el IV MTVI2 para el manejo de pastoreo.



**Figura 44.** Relación entre el IAF medido y el IV ONLI3 para el manejo de pastoreo.

Esto podría sugerir que, la elaboración de este tipo de gráficos de dispersión (Figuras 40, 41, 42, 43 y 44), podrían ser utilizados como un tipo el análisis exploratorio para identificar los tipos de regresión se podrían utilizar para cada IV, sin embargo, no se puede garantizar identificar el tipo de regresión óptimo de esta forma. Por otra parte, se debe tomar en consideración que los gráficos de dispersión mostrados fueron generados utilizando la mejor combinación de bandas para cada IV (Tablas 14 y 17), en inclusive de esta forma no fue posible identificar fácilmente el tipo de regresión que mejor se ajusta a cada IV, por lo que en casos que involucran combinaciones de bandas puede no ser un buen abordaje.

### 5.2.3. Estimación del índice de área foliar utilizando el modelo PLSR

La construcción de los modelos PLSR se realizó a partir de los espectros. Para ello, se generaron cinco conjuntos de datos, uno corresponde a los datos originales y los otros cuatro a uno por cada pretratamiento: 1) variación estándar normalizada (SNV, por sus siglas en ingles), 2) suavizado basado en el método de Savitzky-Golay (SMT) y las combinaciones de esto dos métodos, 3) SNV primero con SMT luego (SNV+SMT) y 4) SMT primero con SNV luego (SMT+SNV).

Para cada uno de estos conjuntos de datos se probaron de dos a cinco variables latentes en el modelo PLSR, con el fin de determinar la combinación que permita alcanzar los mejores resultados. Esta combinación con los mejores resultados fue determinada utilizando el método relativo mencionado en la sección correspondiente a los modelos generados a partir de IV, debido a su capacidad para maximizar los valores de  $R^2$  y minimizar los de RMSE.



### 5.2.3.1 Manejo de corte

Al analizar únicamente el manejo de corte, el uso de 2 variables latentes el que presentó mejores resultados para el conjunto de datos sin tratamiento ( $R^2=0,3373$  y  $RMSE=0,7551$ ), siendo el uso de 5 variables latentes el menos favorable ( $R^2=0,0636$  y  $RMSE=1,2189$ ) (Tabla B45). De manera similar, el uso de 2 variables latentes dio como resultado un  $R^2$  de hasta 0,3373 y un  $RMSE$  de 0,7550 al utilizar el conjunto de datos SMT, en cambio, el uso de 5 variables latentes aumentó el valor del  $RMSE$  (1,2196) y redujo el  $R^2$  (0,0627) (Tabla B46).


Utilizando 3 variables latentes fue posible obtener mejores métricas para el conjunto de datos SNV ( $R^2=0,4147$  y  $RMSE=0,7045$ ) sin embargo, el uso de 5 variables latentes continúa dando resultados inferiores en términos de  $R^2$  (0,2444) y  $RMSE$  (0,8501) (Tabla B47). En cuanto a las combinaciones, en ambos casos se alcanzaron mejores resultados al utilizar 3 variables latentes, siendo el SNV+SMT el que presentó resultados superiores, con un  $R^2$  de 0,4141 y un  $RMSE$  de 0,7049, en comparación con los de la otra combinación ( $R^2=0,4136$  y  $RMSE=0,7052$ ) (Tabla B48 y B49). De la misma forma, al utilizar 5 variables latentes se obtuvieron resultados inferiores, donde la combinación SMT+SNV alcanzó mejores métricas ( $R^2=0,2445$  y  $RMSE=0,8499$ ) en comparación con la combinación SNV+SMT ( $R^2=0,2440$  y  $RMSE=0,850$ ) (Tabla B48 y B49).

Al comparar los modelos para cada uno de los pretratamientos se observa que, en primer lugar, en términos del valor del RPD, se encuentra el modelo generado con el pretratamiento SNV (Tabla 18) sobre los datos del manejo de corte. Los resultados obtenidos utilizando el conjunto de datos SNV pueden ser debido a que, para este caso en concreto, se logró reducir la dispersión en los espectros de forma efectiva y con muy pocas variaciones a lo largo del espectro, siendo alrededor de los 950 nm y 1250 nm donde se observaron variaciones (Figura 45).

**Tabla 18.** Métricas de los modelos PLSR para estimar IAF para cada uno de los métodos de pretratamiento del manejo de corte.

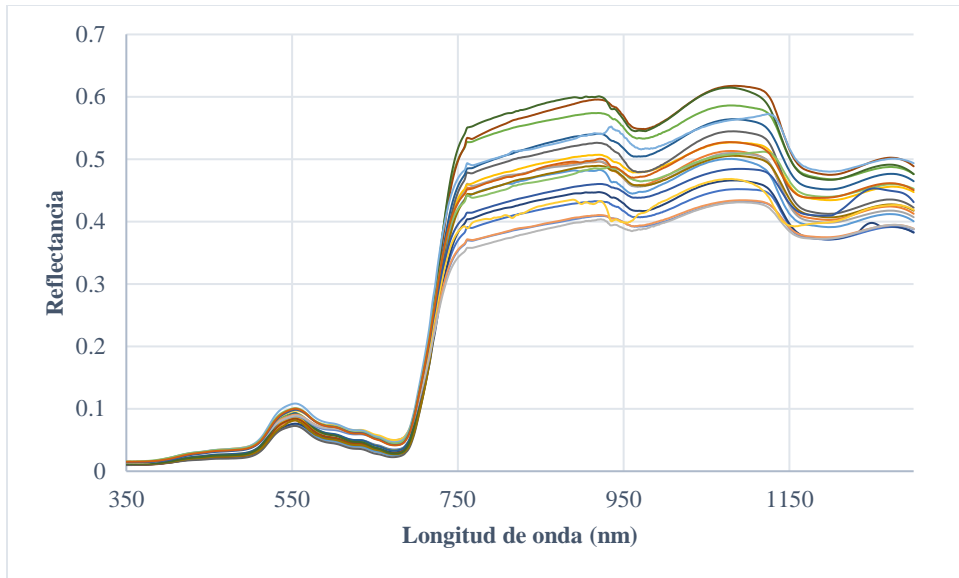
Pretratamiento	VARIABLES latentes	RMSE	$R^2$	RPD
SNV	3	0,7045	0,4147	1,3084
SNV+SMT	3	0,7049	0,4141	1,3076
SMT+SNV	3	0,7052	0,4136	1,3071
SMT	2	0,7550	0,3373	1,2209
RAW	2	0,7551	0,3373	1,2208

SNV: Variación estándar normalizada, SMT: Suavizado y RAW: datos sin tratamiento.

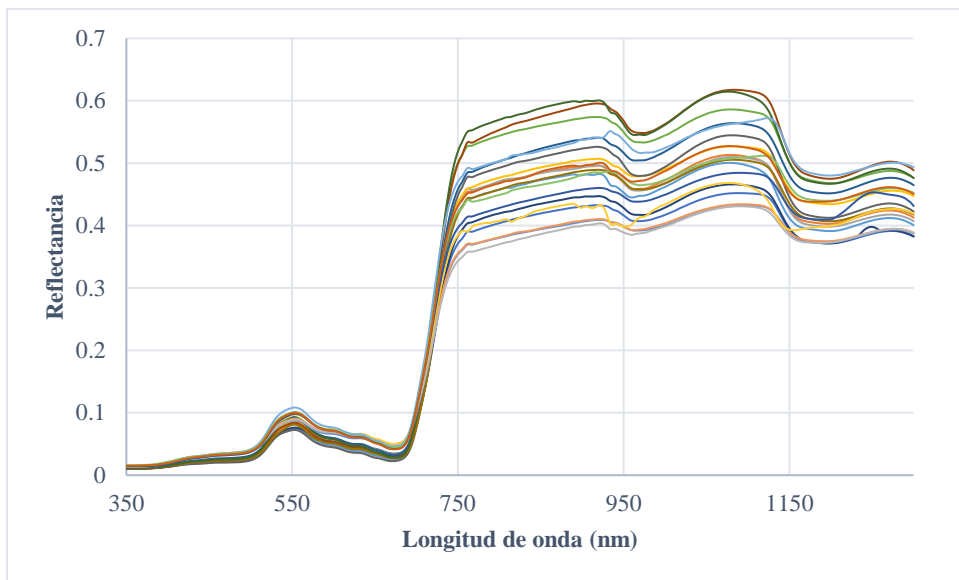


**Figura 45.** Espectros de todos los ciclos de crecimiento del manejo de corte tratados con el método de variación estándar normalizada (SNV).

Respecto a los resultados al utilizar únicamente el método SMT, se observa que sus resultados no fueron los más prometedores, siendo prácticamente los mismo que al no aplicar ningún tipo de pretratamiento (Tabla 18). El motivo de estos resultados puede estar relacionado con el hecho que los espectros estudiados no se caracterizaron por la presencia de ruidos, razón por la cual este método utilizado para la eliminación de ruidos (SMT) no supuso una mejora en los resultados. Además, al comparar los espectros sin tratamiento y luego de aplicado el SMT, se observa que prácticamente no existen diferencias entre ambos conjuntos de datos (Figura 46 y 47).

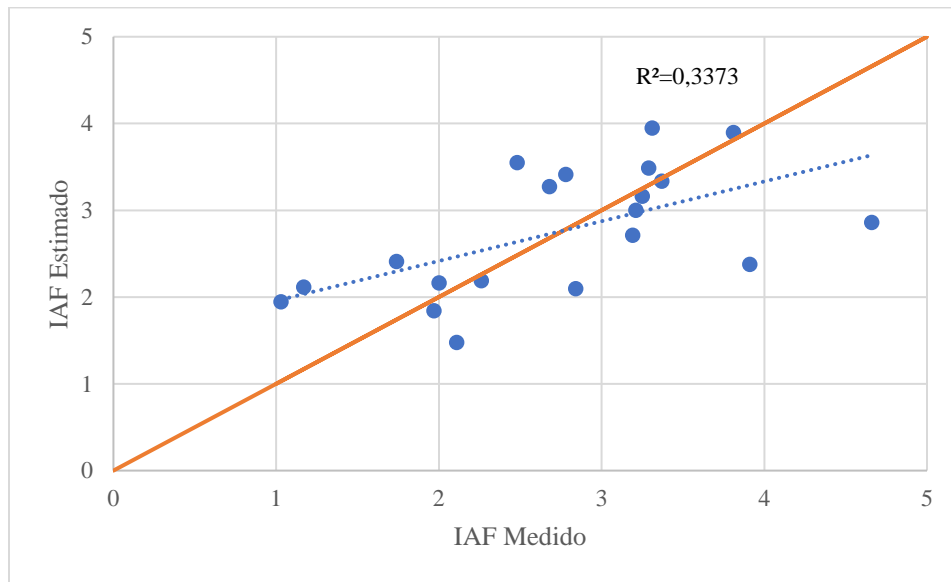


**Figura 46.** Espectros de todos los ciclos de crecimiento del manejo de corte sin tratamiento (RAW).




**Figura 47.** Espectros de todos los ciclos de crecimiento del manejo de corte tratados con el método de suavizado (SMT).


La relación entre los valores de IAF medidos y estimados de los modelos PLSR para el manejo de corte (Tabla 18), se muestran en las Figuras 48, 49, 50, 51 y 52. En las cuales, de acuerdo con la línea de tendencia (línea punteada) los modelos con mejor ajuste son los que utilizaron los conjuntos de datos SNV, SNV+SMT y SMT+SNV. Esto debido a que la línea de tendencia se asemeja más a la línea de tendencia ideal (línea naranja), para un modelo capaz de estimar con precisión los datos medidos. Esto se ve respaldado por los valores de la suma cuadrada de los residuos, siendo el modelo generado con el conjunto de datos SNV el que presentó el valor más bajo (9,92), seguido del SNV+SMT (9,93) y el SMT+SNV (9,94). De acuerdo con esto, se valida la selección del modelo basado en el conjunto de datos SNV, con 3 variables latentes como el modelo PLSR más confiable para el manejo de corte, según se muestra en la Tabla 18.




**Figura 48.** Distribución de los valores medidos y estimados de IAF para el mejor modelo PLSR generado con el conjunto de datos sin tratamiento (RAW) del manejo de corte, con su línea de tendencia lineal (línea punteada).




**Figura 49.** Distribución de los valores medidos y estimados de IAF para el mejor modelo PLSR generado con el conjunto de datos suavizado (SMT) del manejo de corte, con su línea de tendencia lineal (línea punteada).



**Figura 50.** Distribución de los valores medidos y estimados de IAF para el mejor modelo PLSR generado con el conjunto de datos con combinación de métodos (SMT+SNV) del manejo de corte, con su línea de tendencia lineal (línea punteada).



**Figura 51.** Distribución de los valores medidos y estimados de IAF para el mejor modelo PLSR generado con el conjunto de datos tratados con la variación estándar normalizada (SNV) del manejo de corte, con su línea de tendencia lineal (línea punteada).



**Figura 52.** Distribución de los valores medidos y estimados de IAF para el mejor modelo PLSR generado con el conjunto de datos con combinación de métodos (SNV+SMT) del manejo de corte, con su línea de tendencia lineal (línea punteada).

### 5.2.3.2. Manejo de pastoreo

Al analizar los resultados de los modelos PLSR generados con el conjunto de datos sin tratamiento del manejo de pastoreo, se observa que se obtuvieron valores de  $R^2$  entre 0,1769 a 0,0600, con RMSE de entre 1,0837 a 0,8772 (Tabla B50). Para este conjunto de datos, el uso de 3 variables latentes permitió alcanzar valores de  $R^2$  de 0,1769 y un RMSE de 0,8772 (Tabla B50). Utilizando el conjunto de datos SMT se puede intuir que 3 es el número óptimo de variables latentes, ya que al comparar las métricas de los modelos (Tabla B51), al aumentar o reducir el número de variables latente se reduce drásticamente el valor del  $R^2$  y aumentan los valores de RMSE. Con base a esto, el mayor valor de  $R^2$  (0,1764) y menor RMSE (0,8775) se obtuvo para este conjunto de datos al seleccionar 3 variables latentes.


Para el modelo PLSR generado con el conjunto de datos SNV, se obtuvieron valores de  $R^2$  de 0,0908 y un RMSE de 0,9191 al utilizar 2 variables latentes, a diferencia del modelo generado con 4 variables latentes cuyo valor de  $R^2$  fue de 0,0639 y su RMSE de 1,0313 (Tabla B52). Para ambas combinaciones, los modelos generados con 2 variables latentes fueron los que presentaron mejores resultados ( $R^2=0,0905$  y  $RMSE=0,9192$ ) para el conjunto de datos SMT+SNV, en comparación con el SNV+SMT ( $R^2=0,0904$  y  $RMSE=0,9194$ ) (Tabla B53 y B54). En el caso del conjunto SNV+SMT el uso de 3 variables latentes alcanzó los valores más bajos de  $R^2$  y RMSE de 0,0671 y 1,0636, respectivamente (Tabla B54). De manera similar, la combinación SMT+SNV obtuvo resultados inferiores con un  $R^2$  de 0,0633 y un RMSE de 1,0297 al generar un modelo con 4 variables latentes (Tabla B53).

Los modelos determinados con el método relativo para este tipo de manejo, correspondientes a cada uno de los conjuntos de datos presentaron valores de RPD de entre 1,0442, hasta 1,0944. Con base en el valor del RPD, se puede considerar que la combinación entre el conjunto de datos sin tratamiento y el uso de un modelo con 3 variables latentes fue el que se colocó en el primer lugar de la clasificación, con valores de  $R^2$  de 0,1769 y RMSE de 0,8772 (Tabla 19). Los resultados del conjunto de datos SMT fueron de mejores y casi idénticos a los mostrados por el conjunto de datos sin tratamiento. Esto puede ser debido a que este método se encarga de reducir el ruido en los espectros, sin embargo, como se observa en las Figuras 53 y 54, el cambio en los espectros es prácticamente nulo, lo cual se ve reflejado en las métricas. Respecto al método SNV, aparentemente esta transformación en los conjuntos de datos no fue la óptima para el manejo de pastoreo, ya que el valor de sus métricas fue inferior en comparación con el SMT.

**Tabla 19.** Métricas de los modelos PLSR para estimar IAF para cada uno de los métodos de pretratamiento del manejo de pastoreo.


Pretratamiento	Variables latentes	RMSE	R <sup>2</sup>	RPD
RAW	3	0,8772	0,1769	1,0944
SMT	3	0,8775	0,1764	1,0941
SNV	2	0,9191	0,0908	1,0445
SMT+SNV	2	0,9192	0,0905	1,0444
SNV+SMT	2	0,9194	0,0904	1,0442

SNV: Variación estándar normalizada, SMT: Suavizado y RAW: datos sin tratamiento.




**Figura 53.** Espectros de todos los ciclos de crecimiento del manejo de pastoreo sin tratamiento (RAW).



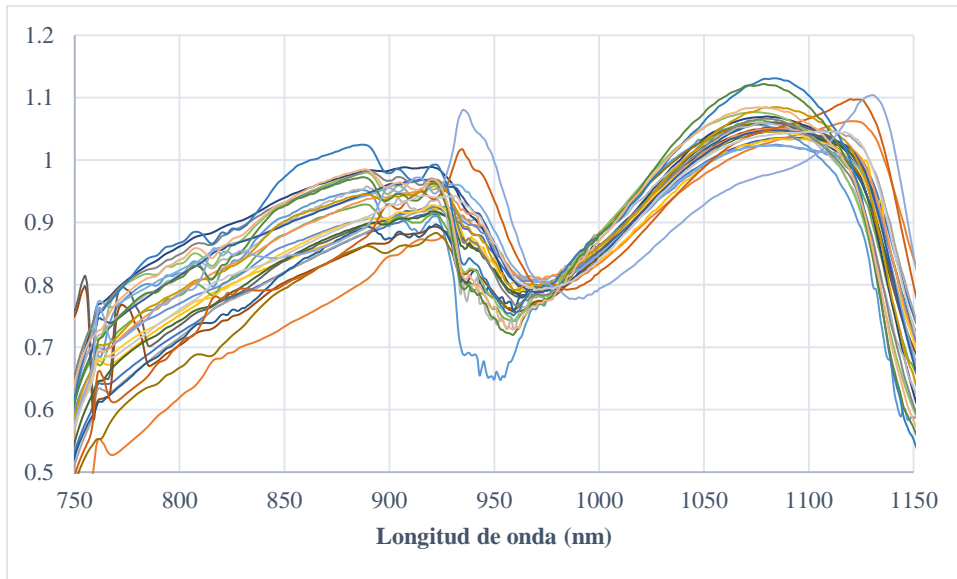


**Figura 54.** Espectros de todos los ciclos de crecimiento del manejo de pastoreo tratados con el método de suavizado (SMT).

Visualizando los espectros del conjunto de datos SNV (Figura 55), se aprecian las posibles causas de estos resultados, ya que para este tipo de manejo si existe una gran cantidad de variaciones a lo largo del espectro, a diferencia de lo observado para el manejo de corte (Figura 40). Al realizar un acercamiento sobre los espectros, se pueden ver a mayor detalle estas variaciones (750 nm a 1150 nm) las cuales pueden ser las responsables de los resultados del manejo de pastoreo (Figura 56). Estas variaciones pueden ser producto de picos o ruidos en los espectros en longitudes de onda específicas. Las cuales terminan afectando a todo el espectro luego de aplicado este método, debido a que la transformación de los espectros se lleva a cabo con base en el promedio y desviación estándar de todo el espectro (Roger et al., 2022). Esto también se ve en las combinaciones, donde sin importar el orden en que se aplique el método SNV, las métricas y el valor de RPD no presentan grandes diferencias (Tabla 19), lo cual a la vez sugiere que el método SNV tiene un efecto más significativo sobre los espectros que el método SMT.




**Figura 55.** Espectros de todos los ciclos de crecimiento del manejo de pastoreo tratados con el método de variación estándar normalizada (SNV).




**Figura 56.** Espectros de todos los ciclos de crecimiento del manejo de pastoreo tratados con el método de variación estándar normalizada (SNV), para el intervalo de 750-1150 nm.

En lo que se refiere al manejo de pastoreo, de acuerdo con la relación entre el IAF medido y estimado mostrado en las Figuras 57, 58, 59, 60 y 61, los modelos PLSR con mejor ajuste fueron


los que utilizaron el conjunto de datos SMT y sin tratamiento de acuerdo con su línea de tendencia. Tomando en consideración la suma cuadrada de los residuos para cada modelo, se puede considerar el modelo basado en el conjunto de datos sin tratamiento como el más apto (20,77), siendo el segundo mejor el que utilizó el conjunto SMT (20,79). En el caso de los demás conjuntos, sus valores fueron 22,80 para el SNV, 22,81 para el SMT+SNV y 22,82 para el SNV+SMT. Ordenando los modelos de acuerdo con su valor de la suma cuadrada de los residuos, se obtiene el mismo orden mostrado en la Tabla 19, lo cual permite validar esta clasificación.




**Figura 57.** Distribución de los valores medidos y estimados de IAF para el mejor modelo PLSR generado con el conjunto de datos sin tratamiento (RAW) del manejo de pastoreo, con su línea de tendencia lineal (línea punteada).



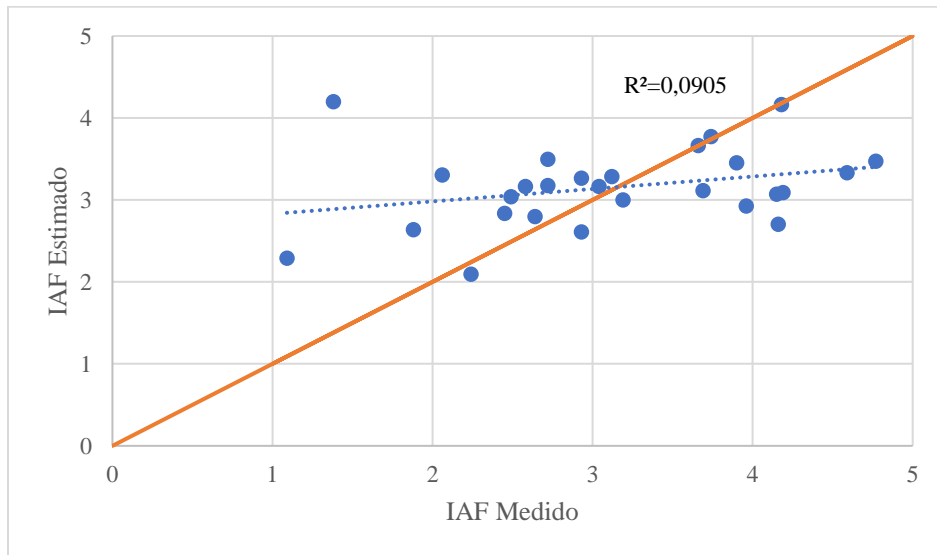
**Figura 58.** Distribución de los valores medidos y estimados de IAF para el mejor modelo PLSR generado con el conjunto de datos tratados con la variación estándar normalizada (SNV) del manejo de pastoreo, con su línea de tendencia lineal (línea punteada).



**Figura 59.** Distribución de los valores medidos y estimados de IAF para el mejor modelo PLSR generado con el conjunto de datos suavizado (SMT) del manejo de pastoreo, con su línea de tendencia lineal (línea punteada).



**Figura 60.** Distribución de los valores medidos y estimados de IAF para el mejor modelo PLSR generado con el conjunto de datos con combinación de métodos (SNV+SMT) del manejo de pastoreo, con su línea de tendencia lineal (línea punteada).



**Figura 61.** Distribución de los valores medidos y estimados de IAF para el mejor modelo PLSR generado con el conjunto de datos con combinación de métodos (SMT+SNV) del manejo de pastoreo, con su línea de tendencia lineal (línea punteada).

### *5.2.3.3. Análisis de ambos tipos de manejo del pasto*

Los resultados obtenidos por los modelos PLSR generados para ambos tipos de manejo no presentaron las métricas esperadas, ya que al comparar con modelos PLSR generados por otros autores, se obtuvieron valores de  $R^2$  y RMSE más bajos al estimar el IAF. Entre estos se encuentran Darvishzadeh et al. (2008), quienes obtuvieron valores de  $R^2$  y RMSE de 0,65 y 0,32 respectivamente, utilizando un modelo PLSR con 4 variables latentes, a partir de datos hiperespectrales suavizados con el método de Savitzky-Golay (tamaño de ventana=15) en pastizales. Nie et al. (2023), obtuvieron buenos resultados al estimar el IAF mediante el modelo PLSR en trigo ( $R^2=0,76$  y  $RMSE=0,86$ ), algodón ( $R^2=0,91$  y  $RMSE=0,45$ ) y maíz ( $R^2=0,86$  y  $RMSE=0,71$ ). Por otra parte, Li et al. (2014), lograron obtener valores de  $R^2$  y RMSE de hasta 0,88 y 0,94 respectivamente al utilizar un modelo PLSR para estimar el IAF en trigo invernal utilizando datos hiperespectrales suavizados utilizando el método de Savitzky-Golay (tamaño de ventana=17). Según lo mostrado por Ma et al. (2022b), para trigo de invierno lograron generar un modelo PLSR para predecir el IAF el cual presentó un  $R^2$  de 0,67 y un RMSE de 0,80. Por otra parte, Kanning et al. (2018), obtuvieron  $R^2$  y RMSE de 0,79 y 0,18 respectivamente, al estimar IAF en un cultivo de trigo. Con base en esto se puede decir que el modelo PLSR si es apto para estimar el IAF de forma efectiva. Sin embargo, los modelos generados a través de esta investigación presentaron valores de  $R^2$  y RMSE inferiores a los requeridos para estimar de forma precisa el IAF.

### *5.2.4. Comparación de resultados de la metodología basada en IV y PLSR para ambos tipos de manejo de pasto*

En la Tabla 20 se observa que, de acuerdo con los modelos generados con las metodologías utilizadas, el uso de IV permitió obtener los mejores resultados para el manejo de corte, presentando valores de  $R^2$  de hasta 0,6812 y un RMSE de 0,5089. En comparación, el mejor modelo PLSR para este tipo de manejo presentó valores de  $R^2$  39,12 % inferiores y un RMSE 38,43 % superior al alcanzado por el mejor modelo de la metodología basada en IV utilizando el NDRE2 (Tabla 20).

Por otra parte, en cuanto al manejo de pastoreo, la mejor metodología fue la basada en IV, utilizando el NDRE con la banda de borde rojo 3, la que dio como resultado un  $R^2$  de 0,1914 y un RMSE de 0,8597 (Tabla 20). Para este manejo, el modelo PLSR presentó métricas similares a las del modelo basado en el IV NDRE3, siendo en este caso, un 7,57 % inferior y 2,04 % superior en términos de  $R^2$  y RMSE respectivamente (Tabla 20).

**Tabla 20.** Mejores modelos para estimar el IAF generados con cada metodología según el tipo de manejo.

Modelo	Corte		Modelo	Pastoreo	
	RMSE	R <sup>2</sup>		RMSE	R <sup>2</sup>
IV(NDRE2)	0,5089	0,6812	IV(NDRE3)	0,8597	0,1914
PLSR(SNV)	0,7045	0,4147	PLSR(RAW)	0,8772	0,1769

NDRE2: NDRE utilizando el borde rojo 2, NDRE3: NDRE utilizando el borde rojo 3, SNV: Variación estándar normalizada y RAW: datos sin pretratamiento.

Para ambos manejos, se determinó que la mejor metodología para estimar el IAF fue la basada en IV, utilizando concretamente el NDRE, mediante el cual fue posible identificar que la banda de borde rojo es sensible a variaciones en el IAF. El hecho de que esta metodología fue la que mejores resultados presentó para ambos manejos puede ser debido a varios factores. La banda de borde rojo se caracteriza por su estrecha relación con propiedades físicas y químicas de la vegetación, debido a que los valores de reflectancia tienden a aumentar rápidamente dentro de esta banda (Kang et al., 2021). También, se trata de una zona de transición, entre los bajos valores de reflectancia producto de la absorción de clorofila en la banda roja y los altos valores de reflectancia en la región de infrarrojo cercano, relacionados con las propiedades estructurales de las plantas (Moroni et al., 2019). Por una parte, algunos IV han sido desarrollados para mitigar los efectos de la influencia del suelo y la atmosfera, además, no hacen uso de todo el espectro, ya que son calculados utilizando rangos de bandas específicos, sensibles al estrés y el desarrollo de las plantas (Moroni et al., 2019). Debido a esto se puede considerar que el uso de IV permite generar modelos utilizando información más específica del pasto en este caso.

De acuerdo con investigaciones previas realizadas por otros autores, de manera general el modelo PLSR tiende a presentar mejores resultados que los modelos basados en IV. Entre estos autores se encuentran Wang et al. (2018), cuyos resultados indican que sus modelos PLSR presentaron mejores resultados en comparación con los basados en el IV NDVI, alcanzando valores de R<sup>2</sup> de 0,64 y un RMSE de 0,96 en un cultivo de arroz. En el caso de Darvishzadeh et al. (2008), también realizaron una comparación entre tipos de modelos, donde los resultados del mejor modelo basado en IV (R<sup>2</sup>=0,64, RMSE=0,33), fueron similares a los del mejor modelo PLSR (R<sup>2</sup>=0,65, RMSE=0,32), siendo este último ligeramente superior para pastizales.

Un factor importante que tomar en consideración a la hora de generar modelos PLSR es el tipo de pretratamiento de los datos espectrales, donde en estudios como el de Wang et al. (2018), el uso de la primera derivada sobre la reflectancia permitió obtener los mejores resultados. Esto también se muestra en la Tabla 20, ya que se observa que el tipo de pretratamiento tiene un efecto sobre los resultados obtenidos con los modelos PLSR, siendo el SNV y los datos originales los que mejores

resultados dieron para los manejos de corte y pastoreo, respectivamente. Esto, junto con los resultados obtenidos por otros autores, sugiere que los modelos obtenidos cuentan con un margen de mejora, para el cual se deben explorar otros tipos de pretratamientos.

Es importante considerar que a pesar de que se generaron los modelos de ambas metodologías para el manejo de pastoreo, estos no pueden ser utilizados, ya que presentan valores de  $R^2$  muy bajos, inferiores a 0,20, lo cual hace que sus predicciones no sean confiables. Esto puede ser debido a las condiciones de la zona de estudio, ya que el ingreso del ganado en la parcela puede generar una alta variabilidad en las condiciones del pasto, ya que estos animales no realizan el pastoreo de forma homogénea. Por otra parte, vale la pena considerar que los resultados pueden ser debido al tipo de vegetación, ya que los estudios similares se suelen realizar en cultivos como el trigo o el arroz, los cuales son muy diferentes estructuralmente del pasto Estrella Africana.



## 6. CONCLUSIONES

- El índice de área foliar y la biomasa seca no fueron significativamente diferente al tomar en consideración la edad del pasto, lo cual puede estar relacionado con las propiedades del pasto del suelo de las subparcelas muestreadas y las condiciones climáticas.
- La altura del pasto fue significativamente diferente respecto a la edad del pasto, caso contrario al considerar el tipo de manejo.
- Los datos espectrales del manejo de pastoreo presentaron más variabilidad en comparación con los del manejo de corte, lo cual puede estar relacionado con el efecto que genera el ganado sobre el suelo y el pasto al pastorear.
- Para el manejo de pastoreo, el mejor modelo basado en índices de vegetación y PLSR presentaron resultados similares, con mejores métricas de hasta 0,1914 para el  $R^2$  y 0,8597 para el RMSE al utilizar el IV NDRE con la banda de borde rojo 3, sin embargo, ninguno de los modelos de este tipo de manejo fue preciso, por lo que no se recomienda el uso de ninguno.
- El modelo basado en el índice de vegetación NDRE, utilizando el conjunto de datos de borde rojo 2, permitió obtener un  $R^2$  de 0,6812 y un RMSE de 0,5089, lo cual resultó en el mejor modelo de todos los modelos analizados para estimar el IAF en las parcelas de corte de la EEAVM.
- La banda de borde rojo presentó una influencia considerable sobre la capacidad de los modelos basados en índices de vegetación para predecir el índice de área foliar, permitiendo alcanzar un valor de  $R^2$  67,1 % superior y un RMSE 27,2 % inferior (NDRE) con respecto al mejor índice que no hace uso de la banda de borde rojo (NDVI) para el manejo de corte.
- La selección de la banda de borde rojo se vio influenciada por el tipo de manejo. En el caso del manejo de corte la banda REG 2 fue la que presentó los mejores resultados ( $R^2=0,6812$ ,  $RMSE=0,5089$ ) y el caso del manejo de pastoreo fue la banda REG 3 ( $R^2=0,1914$ ,  $RMSE=0,8597$ ).
- De manera general, las regresiones de tipo potencial y exponencial permitieron obtener los mejores resultados para los modelos de los manejos de corte y pastoreo, respectivamente.
- Con base en la clasificación de los mejores modelos basados en IV para ambos tipos de manejos (corte y pastoreo), es posible utilizar solamente el RPD o el 1-RRMSE, ya que ambas métricas ordenaron los modelos de la misma manera.
- Para ambos tipos de manejo (corte y pastoreo), de manera general el uso de 3 variables latentes permitió alcanzar los mejores resultados.
- La combinación entre el conjunto de datos con el pretratamiento SNV y 3 variables latentes permitió alcanzar los mejores resultados para el manejo de corte, con un  $R^2$  de 0,4147 y un RMSE de 0,7045.

- El uso de algún pretratamiento permitió mejorar los resultados de los modelos PLSR del manejo del corte en comparación con el conjunto de datos sin pretratamiento (RAW), caso contrario para el manejo de pastoreo.
- Para el manejo de pastoreo, el uso del conjunto de datos sin pretratamiento fue el que obtuvo la menor suma de valores relativos al combinarse con 3 variables latentes, dando como resultado un  $R^2$  de 0,1769 y un RMSE de 0,8772, donde una vez más, no se recomienda el uso de este modelo para estimar el IAF debido a su baja precisión.
- Las metodologías basadas en índices de vegetación y PLSR presentaron mejores resultados al estimar el índice de área foliar utilizando el conjunto de datos del manejo de corte con valores de  $R^2$  de 0,6812 y 0,4147 y RMSE de 0,5089 y 0,7045 respectivamente.
- Los resultados inferiores obtenidos para el manejo de pastoreo al utilizar el pretratamiento SNV puede ser debido a que este método utiliza el promedio y la desviación estándar de todo el espectro para realizar la transformación, lo cual lo hace sensible a ruidos a lo largo del espectro.
- De manera general, el método de pretratamiento SNV tiene un efecto más significativo sobre los resultados del modelo en comparación con el SMT, inclusive a la hora de combinar pretratamientos para ambos tipos de manejo (corte y pastoreo).

## 7. RECOMENDACIONES

- En esta investigación se utilizaron dos diferentes metodologías para predecir el índice de área foliar, IV y PSR, sin embargo, el uso de otros modelos basados en machine learning como el Random Forest o redes neuronales podrían permitir alcanzar mejores resultados, según se muestra en estudios como el de Wang et al. (2018) y Liang et al. (2015).
- La selección del método de validación cruzada puede tener un efecto significativo en la capacidad de los modelos para predecir, por lo cual explorar diferentes tipos de validación cruzada podría ser una estrategia por considerar en busca de mejorar la calibración del modelo.
- Considerar la evaluación de más ciclos de crecimiento para ambos tipos de manejo, con el fin de obtener una mayor cantidad de datos, lo cual permita generar modelos más robustos, capaces de predecir de forma más precisa el IAF gracias a una mejor abstracción del patrón de crecimiento del pasto Estrella Africana bajo las condiciones de la EEAVM.
- Los métodos de pretratamiento utilizando datos hiperespectrales juegan un papel crucial a la hora de modelar, por lo que se requiere explorar más a fondo otros tipos de métodos con el fin de identificar el que mejor se ajuste cada situación en particular.
- Con base en la baja precisión de los modelos generados por ambas metodologías para el manejo de pastoreo y en lo ampliamente utilizado que es este tipo de manejo en Costa Rica, se recomienda investigar más a profundidad este tipo de manejo con el fin de determinar

los puntos clave que permitan mejorar la capacidad de predicción de los modelos a la hora de predecir el IAF.

## 8. REFERENCIAS

- Berger, K., Atzberger, C., Danner, M., D'Urso, G., Mauser, W., Vuolo, F. & Hank, T. (2018). Evaluation of the prosail model capabilities for future hyperspectral model environments: A Review Study. *Remote Sensing*, 10(1), 85. <https://doi.org/10.3390/rs10010085>
- Cardoso-Fernandes, J., Silva, J., Días, F., Lima, A., Teodoro, A., Barrès, O., Cauzid, J., Perrotta, M., Roda-Robles, E. & Ribeiro, M. (2021). Tools for Remote Exploration: A Lithium (Li) Dedicated Spectral Library of the Fregeneda–Almendra Aplite–Pegmatite Field. *Data*, 6(33). <https://doi.org/10.3390/data6030033>
- Casa, R., Varella, H., Buis, S., Guérif, M., De Solan, B. & Baret, F. (2012). Forcing a wheat crop model with LAI data to access agronomic variables: Evaluation of the impact of model and LAI uncertainties and comparison with an empirical approach. *European Journal of Agronomy*, 37(1), 1-10. <https://doi.org/10.1016/j.eja.2011.09.004>
- CNAT. (2015). Hoja de Datos: Estiércol en sistemas de producción orgánica. <https://www.ams.usda.gov/sites/default/files/media/FINAL%20Esti%C3%A9rcol%20en%20Sistemas%20de%20Produccion%20Organica.pdf>
- Coto, A. & Rojas, A. (2022). Comparativa multi e hiperespectral del pasto *Cynodos nlemfuensis* bajo condiciones tropicales y de pastoreo con ganado lechero. *Ingeniería*, 32(1), 1-18. <https://doi.org/10.15517/ri.v32i1.46129>
- Danner, M., Locherer, M., Hank, T. & Richter, K. (2015). Measuring Leaf Area Index (LAI) with the LI-Cor LAI 2200C or LAI-2200 (+2200Clear Kit) – theory, measurement, problems, interpretation. (EnMAP Field Guides Technical Report), Potsdam : GFZ Data Services, 24 p. <https://doi.org/10.2312/enmap.2015.009>
- Darvishzadeh, R., Skidmore, A., Schlerf, M., Atzberger, C., Corsi, F. & Cho, M. (2008). LAI and chlorophyll estimation for a heterogeneous grassland using hyperspectral measurements. *ISPRS Journal of Photogrammetry & Remote Sensing*, 63(2008), 409-426. <http://dx.doi.org/10.1016/j.isprsjprs.2008.01.001>
- Darvishzadeh, R., Wang, T., Skidmore, A., Vrieling, A., O'Connor, B., Gara, T., Ens, B. & Paganini, M. (2019). Analysis of Sentinel-2 and Rapideye for retrieval of leaf area index in a Saltmarsh using a radiative transfer model. *Remote Sensing*, 11(6), 671. <https://doi.org/10.3390/rs11060671>
- Del Pozo, P. (2000). Bases ecofisiológicas para el manejo de los pastos tropicales. *PASTOS*, 32(2), 109-137. <http://polired.upm.es/index.php/pastos/article/view/1314/1318>

- Din, M., Zheng, W., Rashid, M., Wang, S. & Shi, Z. (2017). Evaluating hyperspectral vegetation indices for leaf area index estimation of oryza sativa l. at diverse phenological stages. *Frontiers in Plant Science*, 8. <https://doi.org/10.3389/fpls.2017.00820>
- Dong, T., Liu, J., Qian, B., He, L., Liu, J., Wang, R., Jing, Q., Champagne, C., McNair, H., Powers, J., Shi, Y., Chen, J. & Shang, J. (2020). Estimating crop biomass using leaf area index derived from Landsat 8 and Sentinel-2 data. *ISPRS Journal of Photogrammetry and Remote Sensing*, 168, 236-250. <https://doi.org/10.1016/j.isprsjprs.2020.08.003>
- Dong, T., Liu, J., Qian, B., Zhao, T., Jing, Q., Geng, X., Wang, J., Huffman, T. & Shang, J. (2016). Estimating winter wheat biomass by assimilating leaf area index derived from fusion of Landsat-8 and MODIS data. *International Journal of Applied Earth Observation and Geoinformation*, 49, 63-74. <https://doi.org/10.1016/j.jag.2016.02.001>
- Du, L., Yang, H., Song, X. et al. Estimating leaf area index of maize using UAV-based digital imagery and machine learning methods. *Sci Rep*, 12(15937). <https://doi.org/10.1038/s41598-022-20299-0>
- Duchemin, B., Maisongrande, P., Boulet, G. & Benhadj, I. (2008). A simple algorithm for yield estimates: Evaluation for semi-arid irrigated winter wheat monitored with green leaf area index. *Environmental Modelling & Software*, 23(7), 876-892. <https://doi.org/10.1016/j.envsoft.2007.10.003>
- Fang, H., Baret, F., Plummer, S. & Schaepman-Strub, G. (2019). An overview of global leaf area index (LAI): methods, products, validation, and applications, *Reviews of Geophysics*, 57(3), 739-799. <https://doi.org/10.1029/2018RG000608>
- Feng, H., Yang, F., Yang, G. & Pei, H. (2016). Hyperspectral Estimation of Leaf Area Index of Winter Wheat Based on Akaike's Information Criterion. 10th International Conference on Computer and Computing Technologies in Agriculture (CCTA), Dongying, China. pp.528-537, 10.1007/978-3-030-06155-5\_54. hal-02179990
- Feng, W., Wu, Y., He, L., Ren, X., Wang, Y., Huo, G., Wang, Y., Liu, W. & Guo, T. (2019). An optimized non-linear vegetation index for estimating leaf area index in winter wheat. *Precision Agriculture*, 20, 1157-1176. <https://doi.org/10.1007/s11119-019-09648-8>
- Ferrufino, A., Mora-Valverde, D. & Villalobos-Villalobos, L. (2022). Biomasa y bromatología del pasto Estrella Africana (*Cynodon nlemfuensis Vanderyst*) con cinco edades de rebrote. *Agronomía Mesoamericana*. 33(2), 47746. doi:10.15517/am.v33i2.47746
- Gallagher, N.B. & Lawrence, L. (2020). Introduction to hyperspectral and multivariate image analysis and principal components analysis for multivariate images. <https://eigenvector.com/wp-content/uploads/2020/12/IntroHSIandMIA.pdf>

- Gambardella, C., Parente, R., Ciambrone, A. & Casbarra, M. (2021). A principal components analysis-based method for the detection of cannabis plants using representation data by remote sensing. *Data*, 6(10), 108. <https://doi.org/10.3390/data6100108>
- Garcia-Allende, P., Conde, O., Amado, M., Quintela, A., Lopez-Higuera, J. (2008). hyperspectral data processing algorithm combining principal component analysis and K nearest neighbours. Proc. SPIE 6966, Algorithms and Technologies for Multispectral, Hyperspectral, and Ultraspectral Imagery XIV, 69660H. <https://doi.org/10.1117/12.770298>
- Guo, X., Wang, M., Jia, M. & Wang, W. (2021). Estimating mangrove leaf area index based on red-edge vegetation indices: A comparison among UAV, WorldView-2 and Sentinel-2 imagery. *International Journal of Applied Earth Observation and Geoinformation*, 103. <https://doi.org/10.1016/j.jag.2021.102493>
- Haboudane, D., Miller, J., Pattey, E., Zarco-Tejada, P. & Strachan, I. (2004). Hyperspectral vegetation indices and novel algorithms for predicting green LAI of crop canopies: Modeling and validation in the context of precision agriculture. *Remote Sensing of Environment*. 90(3), 337-353. <https://doi.org/10.1016/j.rse.2003.12.013>
- Hawrylo, P. & Wezyk, P. (2018). Predicting growing stock volume of scots pine stands using Sentinel-2 satellite imagery and airborne image-derived point clouds. *Forests*, 9(5), 274. <http://dx.doi.org/10.3390/f9050274>
- He, L., Ren, X., Wang, Y., Liu, B., Zhang, H., Liu, W., Feng, W. & Guo, T. (2020). Comparing methods for estimating leaf area index by multi-angular remote sensing in winter wheat. *Science Reports*, 10(1). <http://doi.org/10.1038/s41598-020-70951-w>
- He, Y. & Guo, X. (2006). Leaf area index estimation using remotely sensed data for Grasslands National Park. *Prairie Perspectives*. 9(1):105-117. <https://tspace.library.utoronto.ca/handle/1807/69335>
- Hennessy, A., Clarke, K. & Lewis, M. (2020). Hyperspectral classification of plants: a review of waveband selection generalizability, *Remote Sensing*, 12(1), 113. <https://doi.org/10.3390/rs12010113>
- Holland, S.M. (2019). Principal component analysis (PCA). Department of Geology, University of Georgia, Greece. <http://stratigrafia.org/8370/handouts/pcaTutorial.pdf>
- INTA. (2015). Suelos de Costa Rica orden andisol, *Boletín técnico*, 8. <https://www.mag.go.cr/bibliotecavirtual/Av-1828.PDF>

- Jiang, Z., Huete, A., Didan, K. & Miura, T. (2008). Development of a two-band enhanced vegetation index without a blue band. *Remote Sensing of Environment*. 112(10), 3833-3845. <https://doi.org/10.1016/j.rse.2008.06.006>
- Jimenez, N. (2023). Evaluación de alternativas de fertilización orgánica en pasto Estrella Africana (*Cynodon plectostachyus*). San José de Calcuta: Universidad Francisco de Paula Santander. [https://repositorioinstitucional.ufps.edu.co/xmlui/bitstream/handle/20.500.14167/4056/Trabajo\\_de\\_grado.pdf?sequence=1&isAllowed=y](https://repositorioinstitucional.ufps.edu.co/xmlui/bitstream/handle/20.500.14167/4056/Trabajo_de_grado.pdf?sequence=1&isAllowed=y)
- Jin, X., Li, Z., Feng, H., Ren, Z. & Li, S. (2020). Deep neural network algorithm for estimating maize biomass based on simulated Sentinel 2A vegetation indices and leaf area index. *The Crop Journal*, 8(1), 87-97. <https://doi.org/10.1016/j.cj.2019.06.005>
- Kang, Y., Meng, Q., Liu, M., Zou, Y. & Wang, X. (2021). Crop Classification Based on Red Edge Features Analysis of GF-6 WFV Data. *Sensors*, 21(13), 4328. <https://doi.org/10.3390/s21134328>
- Kanning, M., Kühling, I., Trautz, D. & Jarmer, T. (2018). High-resolution UAV-based hyperspectral imagery for lai and chlorophyll estimations from wheat for yield prediction. *Remote Sens.* 10(12), 2000. <https://doi.org/10.3390/rs10122000>
- Kee, E., Chong, J., Choong, Z. & Lau, M. (2023). A Comparative Analysis of Cross-Validation Techniques for a Smart and Lean Pick-and-Place Solution with Deep Learning. *Electronics*, 12(11), 2371. <https://doi.org/10.3390/electronics12112371>
- Kganyago, M., Mhangara, P. & Adjorlolo, C. (2021). Estimating Crop Biophysical Parameters Using Machine Learning Algorithms and Sentinel-2 Imagery. *Remote Sensing*, 13(21), 4314. <https://doi.org/10.3390/rs13214314>
- Kuska, M., Behmann, J. & Mahlein, A. (2018). Potential of hyperspectral imaging to detect and identify the impact of chemical warfare compounds on plant tissue. *Pure and Applied Chemistry*, 90(10), 1615-1624. <https://doi.org/10.1515/pac-2018-0102>
- Li, X., Zhang, Y., Bao, Y., Luo, J., Jin, X., Xu, X., Song, X. & Yang, G. (2014). Exploring the Best Hyperspectral Features for LAI Estimation Using Partial Least Squares Regression. *Remote Sensing*, 6(7), 6221-6241. <https://doi.org/10.3390/rs6076221>
- Li, Z., Wang, J., Tang, H., Huang, C., Yang, F., Chen, B., Wang, X., Xin, X. & Ge, Y. (2016). Predicting Grassland Leaf Area Index in the Meadow Steppes of Northern China: A Comparative Study of Regression Approaches and Hybrid Geostatistical Methods. *Remote Sensing*. 8(8), 632. <https://doi.org/10.3390/rs8080632>

- Liang, L., Di, L., Zhang, L., Deng, M., Qin, Z., Zhao, S. & Lin, H. (2015). Estimation of crop LAI using hyperspectral vegetation indices and a hybrid inversion method. *Remote sensing of environment*, 165, 123-134. <https://doi.org/10.1016/j.rse.2015.04.032>
- Liang, L., Geng, D., Tan, J., Qiu, S., Di, L., Wang, S., Xu, L., Wang, L., Kang, J. & Li, L. (2020a). Estimating crop LAI using spectral feature extraction and the hybrid inversion method. *Remote Sens*, 12(1), 3534. <https://doi.org/10.3390/rs12213534>
- Liang, L., Huang, T., Di, L., Geng, D., Yan, J., Wang, S., Wang, L., Li, L., Chen, B. & Kang, J. (2020b). Influence of different bandwidths on LAI estimation using vegetation indices. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 13, 1494-1502. <https://doi.org/10.1109/JSTARS.2020.2984608>
- Liu, Y., Liu, Y., Chen, Y., Zhang, Y., Shi, T., Wang, J., Hong, Y., Fei, T. & Zhang, Y. (2019). The Influence of Spectral Pretreatment on the Selection of Representative Calibration Samples for Soil Organic Matter Estimation Using Vis-NIR Reflectance Spectroscopy. *Remote Sens*, 11(4), 450. <https://doi.org/10.3390/rs11040450>
- Liu, Z., Ju, H., Ma, Q., Sun, C., Lv, Y., Liu, K., Wu, T. & Cheng, M. (2024). Rice Yield Estimation Using Multi-Temporal Remote Sensing Data and Machine Learning: A Case Study of Jiangsu, China. *Agriculture*, 14(4), 638. <https://doi.org/10.3390/agriculture14040638>
- Luna, A. (2019). Determinación de la edad óptima de pastoreo para la estrella Africana (*Cynodon plectostachyus*) en el sistema lechero de la Granja experimental Universidad Francisco de Paula Santander Ocaña. San José de Calcuta: Universidad Francisco de Paula Santander. <https://repositorio.ufps.edu.co/bitstream/handle/ufps/4369/1630463.pdf?sequence=1&isAllowed=y>
- Ma, J., Wang, L. & Chen, P. (2022b). Comparing Different Methods for Wheat LAI Inversion Based on Hyperspectral Data. *Agriculture*, 12(9), 1353. <https://doi.org/10.3390/agriculture12091353>
- Ma, X., Huete, A., Nguyen Tran, N., Bi, J., Gao, S. & Zeng, Y. (2020). Sun-Angle Effects on Remote-Sensing Phenology Observed and Modelled Using Himawari-8. *Remote Sensing*, 12(8), 1339. <https://doi.org/10.3390/rs12081339>
- Ma, Y., Zhang, Q., Yi, X., Ma, L., Zhang, L., Huang, C., Zhang, Z. & Lv, X. (2022a). Estimation of cotton leaf area index (LAI) based on spectral transformation and vegetation index. *Remote Sensing*, 14(1), 136. <https://doi.org/10.3390/rs14010136>



- Mai, T. (14 de octubre de 2012). Que son sensores pasivos y activos. NASA. [https://www.nasa.gov/directorates/heo/scan/communications/outreach/funfacts/txt\\_passive\\_active.html](https://www.nasa.gov/directorates/heo/scan/communications/outreach/funfacts/txt_passive_active.html)
- Mananze, S., Pôças, I. & Cunha, M. (2018). Retrieval of maize leaf area index using hyperspectral and multispectral data. *Remote Sensing*, 10(12), 1942. <https://doi.org/10.3390/rs10121942>
- Moroni, M., Porti, M. & Piro, P (2019). Design of a remote-controlled platform for green roof plants monitoring via hyperspectral sensors. *Water*, 11(7), 1368. <https://doi.org/10.3390/w11071368>
- Nie, C., Shi, L., Li, Z., Xu, X., Yin, D., Li, S. & Jin, X. (2023). A comparison of methods to estimate leaf area index using either crop-specific or generic proximal hyperspectral datasets. *European Journal of Agronomy*. 142, 126664. <https://doi-org.ezproxy.sibdi.ucr.ac.cr/10.1016/j.eja.2022.126664>
- Núñez-Arroyo, J., Jiménez-Castro, J., Tobía-Rivero, C., Arias-Gamboa, L., Jiménez-Alfaro, E. & Padilla-Fallas, J. (2022). Efecto de la edad de rebrote y época del año sobre la biomasa y calidad bromatológica en gramíneas utilizadas en tres zonas agroclimáticas de Costa Rica (I PARTE). *Nutrición Animal Tropical*. 16(1), 31-52. <https://doi.org/10.15517/nat.v16i1.50370>
- Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., Blondel, M., Prettenhofer, P., Weiss, R., Dubourg, V., Vanderplas, J., Passos, A., Cournapeau, D., Brucher, M., Perrot, M. & Duchesnay, É. (2011). Scikit-learn: Machine learning in Python. *JMLR*, 12(85), 2825-2830. <https://jmlr.csail.mit.edu/papers/volume12/pedregosa11a/pedregosa11a.pdf>
- Pezo, D. & García, F. (2018). Uso eficiente de fertilizantes en pasturas. CATIE, Turrialba Costa Rica. [https://repositorio.catie.ac.cr/bitstream/handle/11554/9227/Uso\\_eficiente\\_de\\_fertilizantes\\_en\\_pasturas.pdf](https://repositorio.catie.ac.cr/bitstream/handle/11554/9227/Uso_eficiente_de_fertilizantes_en_pasturas.pdf) (consultado 22 mayo de 2024).
- Roger, J., Mallet, A. & Marini, F. (2022). Preprocessing NIR spectra for Aquaphotomics. *Molecules*. 27(20), 6795. <https://doi.org/10.3390/molecules27206795>
- Tao, H., Feng, H., Xu, L., Miao, M., Long, H., Yue, J., Li, Z., Yang, G., Yang, X. & Fan, L. (2020). Estimation of crop growth parameters using uav-based hyperspectral remote sensing data. *Sensors*, 20(5), 1296. <https://doi.org/10.3390/s20051296>
- Tunca, E., Selim Köksal, E, Öztürk, E, Akay, H. & Çetin Taner, S. (2024). Accurate leaf area index estimation in sorghum using high-resolution UAV data and machine learning models.

- Verrelst, J., Rivera, J., Veroustrate, F., Muñoz, J., Clevers, J., Camps, G. & Moreno, J. (2015). Experimental Sentinel-2 LAI estimation using parametric, non-parametric and physical retrieval methods—A comparison. *ISPRS Journal of Photogrammetry and Remote Sensing*, 108, 260-272. <https://doi.org/10.1016/j.isprsjprs.2015.04.013>
- Villalobos, L. & Arce, J. (2014). Evaluación agronómica y nutricional del pasto estrella africana (*Cynodon nlemfuensis*) En la zona de Monteverde, Puntarenas, Costa Rica. II. Valor nutricional. *Agronomía Costarricense*, 38(1), 135-145. [https://www.scielo.sa.cr/scielo.php?script=sci\\_arttext&pid=S0377-94242014000100008](https://www.scielo.sa.cr/scielo.php?script=sci_arttext&pid=S0377-94242014000100008)
- Villalobos, L. & Arce, J. (2014). Evaluación agronómica y nutricional del pasto estrella africana (*Cynodon nlemfuensis*) En la zona de Monteverde, Puntarenas, Costa Rica. II. Valor nutricional. *Agronomía Costarricense*, 38(1), 135-145. [https://www.scielo.sa.cr/scielo.php?script=sci\\_arttext&pid=S0377-94242014000100008](https://www.scielo.sa.cr/scielo.php?script=sci_arttext&pid=S0377-94242014000100008)
- Virtanen, P., Commers, R., Oliphant, T., Haberland, M., Reddy, T., Cournapeau, D., Burovski, E., Peterson, P., Weckesser, W., Bright, J., Van der Walt, S., Brett, M., Wilson, J., Millman, K., Mayorov, N., Nelson, A., Jones, E., Kern, R., Larson, E., Carey, C., Polat, İ., Feng, Y., Moore, E., VanderPlas, J., Laxalde, D., Perktold, J., Cimrman, R., Henriksen, I., Quintero, E., Harris, C., Archibald, A., Ribeiro, A., Pedregosa, F., van Mulbergt, P. & SciPy 1.0 contributors. (2020). SciPy 1.0: Fundamental algorithms for scientific computing in Python. *Nature Methods*, 17(3), 261-272. <https://doi.org/10.1038/s41592-019-0686-2>
- Wang, L., Chang, Q., Yang, J., Zhang, X. & Li, F. (2018). Estimation of paddy rice leaf area index using machine learning methods based on hyperspectral data from multi-year experiments. *PLoS One*, 13(12), e0207624. <https://doi.org/10.1371/journal.pone.0207624>
- Wang, Y., Zhang, K., Tang, C., Cao, Q., Tian, Y., Zhu, Y., Cao, W. & Liu, X. (2019). Estimation of Rice Growth Parameters Based on Linear Mixed-Effect Model Using Multispectral Images from Fixed-Wing Unmanned Aerial Vehicles. *Remote Sens*, 11(11), 1371. <https://doi.org/10.3390/rs11111371>
- Xie, Q., Huang, W., Dash, J., Song, X., Huang, L., Zhao, J. & Wang, R. (2015). Evaluating the potential of vegetation indices for winter wheat LAI estimation under different fertilization and water conditions. *Advances in Space Research*. 56(11), 2365-2373. <https://doi.org/10.1016/j.asr.2015.09.022>


- Xu, J., Quackenbush, L., Volk, T. & Im, J. (2020). Forest and Crop Leaf Area Index Estimation Using Remote Sensing: Research Trends and Future Directions. *Remote Sensing*, 12(18), 2934. <https://doi.org/10.3390/rs12182934>
- Yin, G., Li, J., Liu, Q., Fan, W., Xu, B., Zeng, Y. & Zhao, J. (2015). Regional leaf area index retrieval based on remote sensing: the role of radiative transfer model selection. *Remote Sensing*, 7(4), 4604-4625. <https://doi.org/10.3390/rs70404604>
- Zhang, J. & Mouazen, A. (2023). Fractional-order Savitzky–Golay filter for pre-treatment of on-line vis–NIR spectra to predict phosphorus in soil. *Infrared Physics & Technology*. 131, 104720. <https://doi.org/10.1016/j.infrared.2023.104720>
- Zhang, J., Cheng, T., Guo, W., Xu, X., Qiao, H., Xie, Y. & Ma, X. (2021). Leaf area index estimation model for UAV image hyperspectral data based on wavelength variable selection and machine learning methods. *Plant Methods*, 17(49). <https://doi.org/10.1186/s13007-021-00750-5>
- Zhang, Y., Huang, J., Huang, H., Li, Y., Jin, Y., Guo, H., Feng, Q. & Zhao, Y. (2022). Grassland aboveground biomass estimation through assimilating remote sensing data into a grass simulation model. *Remote Sensing*, 14(13), 3194. <https://doi.org/10.3390/rs14133194>

## **9. APÉNDICE A: OBJETIVO ESPECÍFICO 1**

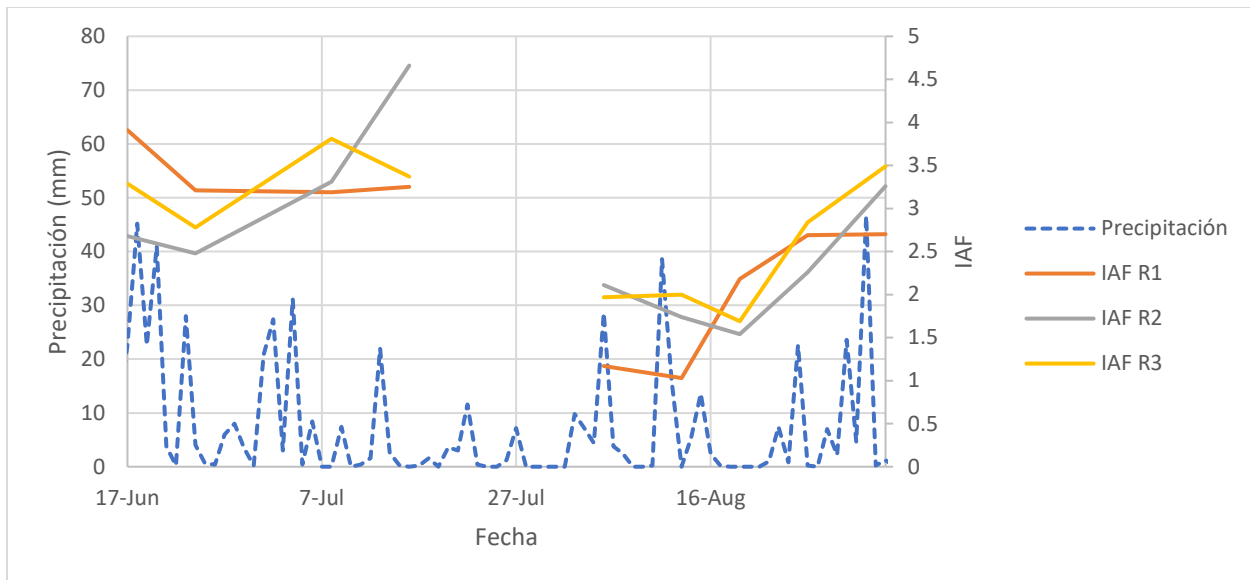
**Tabla A.** Resultados de la prueba de normalidad para los datos de ambos manejos utilizando la prueba de Kolmogorov-Smirnov.

Variable	Valor p
IAF	0,9930
Biomasa seca	0,4453
Altura del pasto	0,5381


$\alpha = 0,05$




**Figura A. 1.** Contraste entre la tendencia del IAF y la radiación solar diaria para el manejo de corte.




**Figura A. 2.** Contraste entre la tendencia del IAF y la precipitación diaria para el manejo de corte.




**Figura A. 3.** Contraste entre la tendencia del IAF y la temperatura promedio diaria para el manejo de corte.



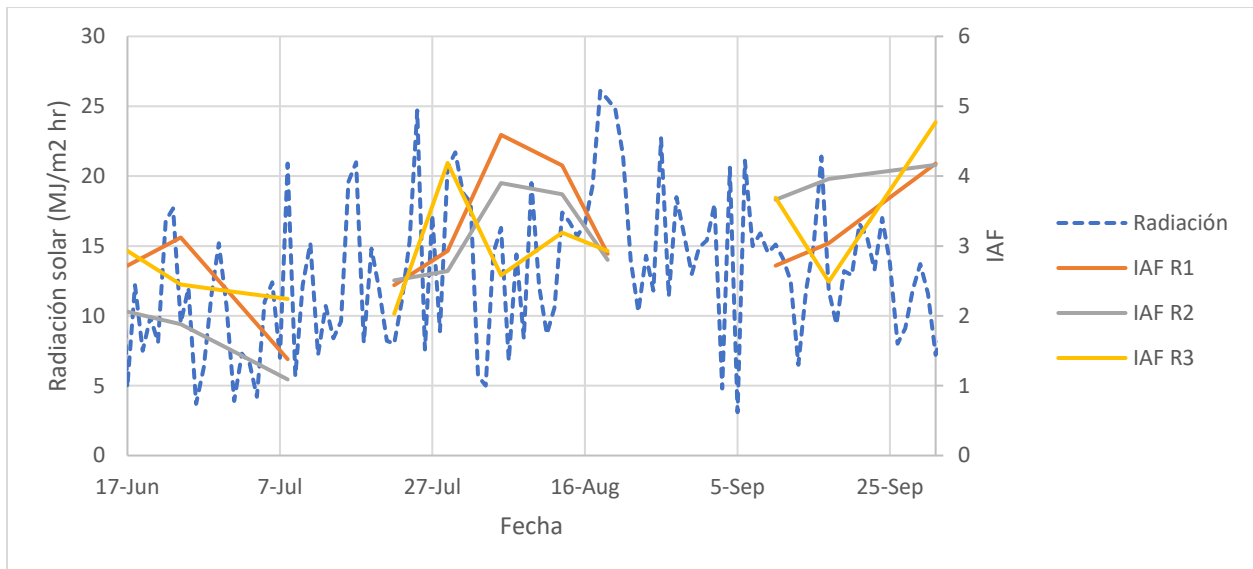
**Figura A. 4.** Contraste entre la tendencia de la biomasa y la radiación solar diaria para el manejo de corte.



**Figura A. 5.** Contraste entre la tendencia de la biomasa y la precipitación diaria para el manejo de corte.




**Figura A. 6.** Contraste entre la tendencia de la biomasa y la temperatura promedio diaria para el manejo de corte.




**Figura A. 7.** Contraste entre la tendencia del IAF y la radiación solar diaria para el manejo de pastoreo.






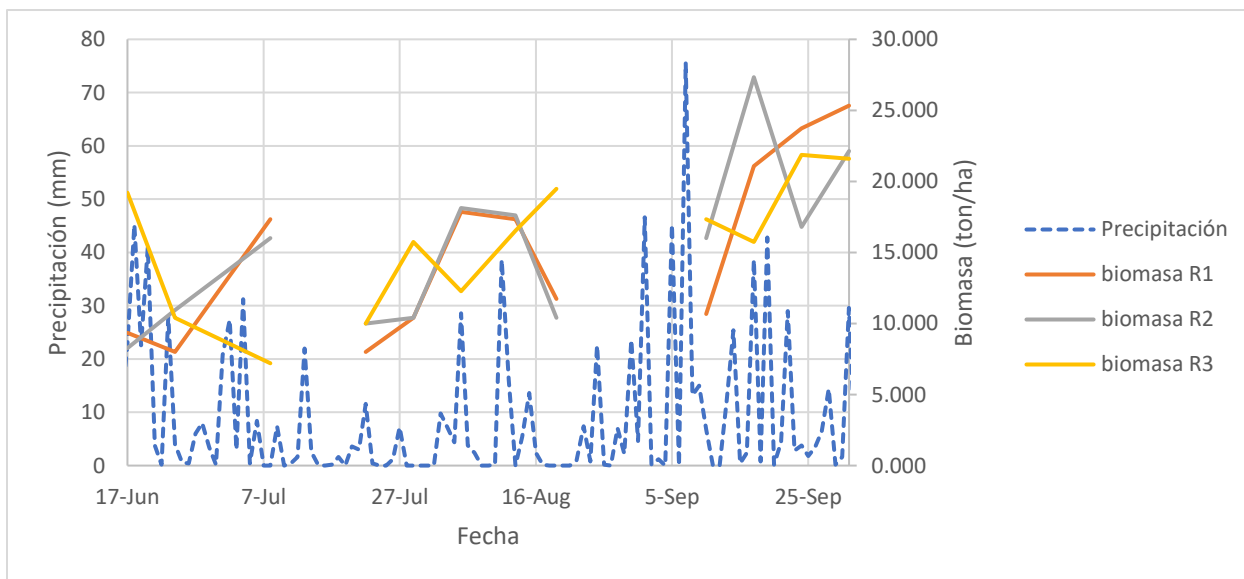
**Figura A. 8.** Contraste entre la tendencia del IAF y la precipitación diaria para el manejo de pastoreo.




**Figura A. 9.** Contraste entre la tendencia del IAF y la temperatura promedio diaria para el manejo de pastoreo.



**Figura A. 10.** Contraste entre la tendencia de la biomasa y la radiación solar diaria para el manejo de pastoreo.



**Figura A. 11.** Contraste entre la tendencia de la biomasa y la precipitación diaria para el manejo de pastoreo.



**Figura A. 12.** Contraste entre la tendencia de la biomasa y la temperatura promedio diaria para el manejo de pastoreo.

## **10. APÉNDICE B: OBJETIVOS ESPECÍFICOS 2 Y 3**

**Tabla B1.** Primeros 5 modelos por tipo de regresión según su  $R^2$  para el subconjunto del índice EVI2 para el manejo de corte.

<b>IV</b>	<b>Regresión</b>	<b>Bandas (nm)</b>	<b>RMSE</b>	<b><math>R^2</math></b>	<b>RRMSE</b>
EVI2	Potencial	865;650;	0,8447	0,2140	30,6819
EVI2	Potencial	866;650;	0,8447	0,2140	30,6813
EVI2	Potencial	867;650;	0,8447	0,2140	30,6826
EVI2	Potencial	868;650;	0,8448	0,2139	30,6867
EVI2	Potencial	870;650;	0,8449	0,2138	30,6901
EVI2	Lineal	865;650;	0,8283	0,2062	30,0858
EVI2	Lineal	866;650;	0,8283	0,2062	30,0863
EVI2	Lineal	867;650;	0,8283	0,2062	30,0868
EVI2	Lineal	868;650;	0,8283	0,2061	30,0888
EVI2	Lineal	870;650;	0,8284	0,2060	30,0906
EVI2	Exponencial	865;650;	0,8549	0,2042	31,0539
EVI2	Exponencial	866;650;	0,8549	0,2042	31,0543
EVI2	Exponencial	867;650;	0,8550	0,2041	31,0556
EVI2	Exponencial	870;650;	0,8551	0,2041	31,0597
EVI2	Exponencial	868;650;	0,8551	0,2040	31,0612
EVI2	Polinómica	871;650;	0,8542	0,1837	31,0270
EVI2	Polinómica	870;650;	0,8543	0,1836	31,0298
EVI2	Polinómica	872;650;	0,8542	0,1836	31,0290
EVI2	Polinómica	868;650;	0,8544	0,1835	31,0355
EVI2	Polinómica	865;650;	0,8546	0,1834	31,0426

**Tabla B2.** Primeros 5 modelos por tipo de regresión según su  $R^2$  para el subconjunto del índice MTVI2 para el manejo de corte.

<b>IV</b>	<b>Regresión</b>	<b>Bandas (nm)</b>	<b>RMSE</b>	<b><math>R^2</math></b>	<b>RRMSE</b>
MTVI2	Potencial	650;900;578;	0,8066	0,2678	29,2987
MTVI2	Potencial	650;899;578;	0,8066	0,2677	29,2979
MTVI2	Potencial	651;899;578;	0,8065	0,2677	29,2964
MTVI2	Potencial	651;900;578;	0,8066	0,2677	29,2981
MTVI2	Potencial	650;898;578;	0,8066	0,2676	29,2987
MTVI2	Lineal	650;899;578;	0,7946	0,2596	28,8617
MTVI2	Lineal	650;900;578;	0,7946	0,2596	28,8632
MTVI2	Lineal	651;899;578;	0,7947	0,2595	28,8650
MTVI2	Lineal	651;900;578;	0,7947	0,2595	28,8660
MTVI2	Lineal	650;898;578;	0,7947	0,2594	28,8663
MTVI2	Exponencial	650;885;578;	0,8149	0,2580	29,6022
MTVI2	Exponencial	650;871;578;	0,8148	0,2579	29,5972
MTVI2	Exponencial	650;873;578;	0,8148	0,2579	29,5950
MTVI2	Exponencial	650;879;578;	0,8149	0,2579	29,5992
MTVI2	Exponencial	650;883;578;	0,8149	0,2579	29,6016
MTVI2	Polinómica	650;885;578;	0,8386	0,2086	30,4629
MTVI2	Polinómica	650;882;578;	0,8388	0,2085	30,4672
MTVI2	Polinómica	650;883;578;	0,8387	0,2085	30,4657
MTVI2	Polinómica	650;886;578;	0,8387	0,2085	30,4631
MTVI2	Polinómica	650;879;578;	0,8389	0,2084	30,4736

**Tabla B3.** Primeros 5 modelos por tipo de regresión según su  $R^2$  para el subconjunto del índice ONLI1 para el manejo de corte.

<b>IV</b>	<b>Regresión</b>	<b>Bandas (nm)</b>	<b>RMSE</b>	<b>R<sup>2</sup></b>	<b>RRMSE</b>
ONLI1	Potencial	819;699;	0,6684	0,3631	24,2775
ONLI1	Potencial	811;699;	0,6537	0,3571	23,7453
ONLI1	Potencial	895;701;	0,6598	0,3558	23,9665
ONLI1	Potencial	839;700;	0,6419	0,3471	23,3153
ONLI1	Potencial	818;699;	0,6765	0,3467	24,5729
ONLI1	Lineal	899;698;	0,7728	0,2918	28,0719
ONLI1	Lineal	900;698;	0,7729	0,2918	28,0738
ONLI1	Lineal	898;698;	0,7729	0,2915	28,0765
ONLI1	Lineal	897;698;	0,7733	0,2910	28,0877
ONLI1	Lineal	871;698;	0,7730	0,2909	28,0773
ONLI1	Exponencial	866;698;	0,7944	0,2883	28,8557
ONLI1	Exponencial	871;698;	0,7944	0,2883	28,8576
ONLI1	Exponencial	865;698;	0,7945	0,2882	28,8577
ONLI1	Exponencial	867;698;	0,7944	0,2882	28,8558
ONLI1	Exponencial	868;698;	0,7944	0,2882	28,8573
ONLI1	Polinómica	871;712;	0,8026	0,2524	29,1552
ONLI1	Polinómica	871;713;	0,8026	0,2523	29,1529
ONLI1	Polinómica	870;712;	0,8028	0,2522	29,1604
ONLI1	Polinómica	872;712;	0,8027	0,2522	29,1586
ONLI1	Polinómica	872;713;	0,8027	0,2522	29,1564

**Tabla B4.** Primeros 5 modelos por tipo de regresión según su  $R^2$  para el subconjunto del índice OSAVI para el manejo de corte.

<b>IV</b>	<b>Regresión</b>	<b>Bandas (nm)</b>	<b>RMSE</b>	<b>R<sup>2</sup></b>	<b>RRMSE</b>
OSAVI	Potencial	870;650;	0,7792	0,3071	28,3050
OSAVI	Potencial	871;650;	0,7792	0,3071	28,3043
OSAVI	Potencial	872;650;	0,7793	0,3071	28,3059
OSAVI	Potencial	865;650;	0,7792	0,3070	28,3046
OSAVI	Potencial	866;650;	0,7792	0,3070	28,3043
OSAVI	Lineal	899;650;	0,7641	0,3067	27,7554
OSAVI	Lineal	900;650;	0,7641	0,3067	27,7566
OSAVI	Lineal	898;650;	0,7643	0,3065	27,7610
OSAVI	Lineal	899;651;	0,7644	0,3063	27,7658
OSAVI	Lineal	900;651;	0,7644	0,3063	27,7667
OSAVI	Exponencial	881;650;	0,7845	0,3017	28,4966
OSAVI	Exponencial	871;650;	0,7847	0,3014	28,5030
OSAVI	Exponencial	872;650;	0,7847	0,3014	28,5032
OSAVI	Exponencial	874;650;	0,7846	0,3014	28,4984
OSAVI	Exponencial	881;651;	0,7848	0,3013	28,5059
OSAVI	Polinómica	885;650;	0,8099	0,2494	29,4188
OSAVI	Polinómica	886;650;	0,8099	0,2494	29,4176
OSAVI	Polinómica	882;650;	0,8100	0,2493	29,4224
OSAVI	Polinómica	883;650;	0,8100	0,2493	29,4214
OSAVI	Polinómica	887;650;	0,8100	0,2493	29,4221



**Tabla B5.** Primeros 5 modelos por tipo de regresión según su  $R^2$  para el subconjunto del índice NDVI para el manejo de corte.

<b>IV</b>	<b>Regresión</b>	<b>Bandas (nm)</b>	<b>RMSE</b>	<b>R<sup>2</sup></b>	<b>RRMSE</b>
NDVI	Lineal	650;900;	0,6993	0,4077	25,4013
NDVI	Lineal	650;899;	0,6993	0,4076	25,4024
NDVI	Lineal	651;899;	0,6994	0,4076	25,4051
NDVI	Lineal	652;899;	0,6994	0,4076	25,4062
NDVI	Lineal	653;899;	0,6995	0,4076	25,4076
NDVI	Exponencial	680;897;	0,7183	0,3964	26,0930
NDVI	Potencial	680;899;	0,7185	0,3959	26,0992
NDVI	Potencial	680;900;	0,7185	0,3959	26,0983
NDVI	Potencial	680;898;	0,7186	0,3956	26,1041
NDVI	Potencial	680;897;	0,7189	0,3953	26,1117
NDVI	Potencial	679;900;	0,7191	0,3952	26,1195
NDVI	Exponencial	679;899;	0,7197	0,3949	26,1441
NDVI	Exponencial	679;897;	0,7197	0,3948	26,1438
NDVI	Exponencial	680;898;	0,7198	0,3945	26,1454
NDVI	Exponencial	678;899;	0,7204	0,3940	26,1672
NDVI	Polinómica	650;893;	0,7362	0,3557	26,7407
NDVI	Polinómica	650;886;	0,7365	0,3556	26,7529
NDVI	Polinómica	650;894;	0,7361	0,3556	26,7380
NDVI	Polinómica	650;885;	0,7366	0,3555	26,7563
NDVI	Polinómica	650;887;	0,7366	0,3555	26,7552

**Tabla B6.** Primeros 5 modelos por tipo de regresión según su  $R^2$  para el subconjunto del índice ONLI2 para el manejo de corte.

<b>IV</b>	<b>Regresión</b>	<b>Bandas (nm)</b>	<b>RMSE</b>	<b>R<sup>2</sup></b>	<b>RRMSE</b>
ONLI2	Lineal	865;733;	0,8241	0,2099	29,9347
ONLI2	Lineal	866;733;	0,8241	0,2099	29,9360
ONLI2	Lineal	867;733;	0,8242	0,2099	29,9369
ONLI2	Lineal	868;733;	0,8243	0,2096	29,9419
ONLI2	Lineal	870;733;	0,8245	0,2094	29,9475
ONLI2	Polinómica	828;733;	0,8351	0,2068	30,3329
ONLI2	Polinómica	823;733;	0,8346	0,2067	30,3174
ONLI2	Polinómica	827;733;	0,8354	0,2063	30,3466
ONLI2	Polinómica	816;733;	0,8344	0,2062	30,3082
ONLI2	Polinómica	829;733;	0,8355	0,2062	30,3488
ONLI2	Exponencial	866;733;	0,8611	0,2039	31,2801
ONLI2	Exponencial	865;733;	0,8612	0,2038	31,2816
ONLI2	Exponencial	867;733;	0,8613	0,2037	31,2849
ONLI2	Exponencial	861;733;	0,8611	0,2034	31,2774
ONLI2	Exponencial	862;733;	0,8612	0,2034	31,2804
ONLI2	Potencial	865;733;	0,8760	0,1880	31,8205
ONLI2	Potencial	866;733;	0,8761	0,1880	31,8223
ONLI2	Potencial	854;733;	0,8755	0,1879	31,8001
ONLI2	Potencial	855;733;	0,8754	0,1879	31,7990
ONLI2	Potencial	843;733;	0,8750	0,1878	31,7839

**Tabla B7.** Primeros 5 modelos por tipo de regresión según su  $R^2$  para el subconjunto del índice ONLI3 para el manejo de corte.

<b>IV</b>	<b>Regresión</b>	<b>Bandas (nm)</b>	<b>RMSE</b>	<b>R<sup>2</sup></b>	<b>RRMSE</b>
ONLI3	Polinómica	816;773;	0,9108	0,0988	33,0830
ONLI3	Polinómica	817;773;	0,9113	0,0982	33,1005
ONLI3	Polinómica	816;774;	0,9114	0,0979	33,1065
ONLI3	Polinómica	815;773;	0,9120	0,0975	33,1282
ONLI3	Polinómica	817;774;	0,9119	0,0973	33,1239
ONLI3	Exponencial	865;773;	0,9428	0,0876	34,2479
ONLI3	Exponencial	866;773;	0,9428	0,0876	34,2480
ONLI3	Exponencial	867;773;	0,9429	0,0875	34,2491
ONLI3	Exponencial	864;773;	0,9428	0,0873	34,2461
ONLI3	Exponencial	868;773;	0,9431	0,0873	34,2563
ONLI3	Potencial	865;773;	0,9435	0,0860	34,2706
ONLI3	Potencial	866;773;	0,9434	0,0860	34,2690
ONLI3	Potencial	867;773;	0,9434	0,0860	34,2687
ONLI3	Potencial	862;773;	0,9431	0,0858	34,2559
ONLI3	Potencial	868;773;	0,9436	0,0858	34,2738
ONLI3	Lineal	865;773;	0,9101	0,0848	33,0597
ONLI3	Lineal	866;773;	0,9102	0,0848	33,0623
ONLI3	Lineal	867;773;	0,9102	0,0847	33,0621
ONLI3	Lineal	868;773;	0,9103	0,0845	33,0653
ONLI3	Lineal	864;773;	0,9104	0,0843	33,0708

**Tabla B8.** Primeros 5 modelos por tipo de regresión según su  $R^2$  para el subconjunto del índice RSI para el manejo de corte.

<b>IV</b>	<b>Regresión</b>	<b>Bandas (nm)</b>	<b>RMSE</b>	<b><math>R^2</math></b>	<b>RRMSE</b>
RSI	Potencial	900;680;	0,7472	0,3627	27,1413
RSI	Potencial	899;680;	0,7473	0,3626	27,1453
RSI	Potencial	898;680;	0,7474	0,3623	27,1504
RSI	Potencial	897;680;	0,7475	0,3621	27,1539
RSI	Potencial	896;680;	0,7477	0,3617	27,1601
RSI	Lineal	899;680;	0,7335	0,3474	26,6447
RSI	Lineal	900;680;	0,7336	0,3473	26,6485
RSI	Lineal	898;680;	0,7337	0,3471	26,6505
RSI	Lineal	897;680;	0,7338	0,3469	26,6536
RSI	Lineal	896;680;	0,7342	0,3463	26,6687
RSI	Polinómica	870;680;	0,7531	0,3304	27,3540
RSI	Polinómica	884;680;	0,7533	0,3295	27,3639
RSI	Polinómica	859;680;	0,7539	0,3291	27,3834
RSI	Polinómica	850;680;	0,7541	0,3287	27,3923
RSI	Polinómica	873;680;	0,7540	0,3287	27,3871
RSI	Exponencial	900;680;	0,7816	0,3199	28,3892
RSI	Exponencial	899;680;	0,7816	0,3198	28,3892
RSI	Exponencial	896;680;	0,7812	0,3196	28,3766
RSI	Exponencial	898;680;	0,7817	0,3195	28,3943
RSI	Exponencial	895;680;	0,7813	0,3192	28,3816

**Tabla B9.** Primeros 5 modelos por tipo de regresión según su  $R^2$  para el subconjunto del índice NDRE1 para el manejo de corte.

<b>IV</b>	<b>Regresión</b>	<b>Bandas (nm)</b>	<b>RMSE</b>	<b><math>R^2</math></b>	<b>RRMSE</b>
NDRE1	Lineal	900;713;	0,6716	0,4468	24,3969
NDRE1	Lineal	899;713;	0,6717	0,4467	24,3992
NDRE1	Lineal	898;713;	0,6721	0,4460	24,4142
NDRE1	Polinómica	900;713;	0,6725	0,4452	24,4261
NDRE1	Lineal	897;713;	0,6727	0,4450	24,4366
NDRE1	Lineal	900;712;	0,6731	0,4447	24,4482
NDRE1	Polinómica	899;713;	0,6729	0,4446	24,4417
NDRE1	Polinómica	894;713;	0,6737	0,4440	24,4701
NDRE1	Polinómica	898;713;	0,6734	0,4440	24,4592
NDRE1	Polinómica	893;713;	0,6738	0,4439	24,4749
NDRE1	Potencial	900;713;	0,7034	0,4274	25,5516
NDRE1	Potencial	899;713;	0,7035	0,4273	25,5544
NDRE1	Potencial	898;713;	0,7037	0,4268	25,5627
NDRE1	Potencial	897;713;	0,7040	0,4261	25,5731
NDRE1	Potencial	900;712;	0,7044	0,4257	25,5872
NDRE1	Exponencial	900;713;	0,7158	0,4122	25,9998
NDRE1	Exponencial	899;713;	0,7160	0,4119	26,0087
NDRE1	Exponencial	898;713;	0,7160	0,4116	26,0072
NDRE1	Exponencial	899;712;	0,7162	0,4110	26,0152
NDRE1	Exponencial	900;712;	0,7164	0,4108	26,0235

**Tabla B10.** Primeros 5 modelos por tipo de regresión según su  $R^2$  para el subconjunto del índice NDRE2 para el manejo de corte.

<b>IV</b>	<b>Regresión</b>	<b>Bandas (nm)</b>	<b>RMSE</b>	<b>R<sup>2</sup></b>	<b>RRMSE</b>
NDRE2	Polinómica	833;742;	0,5089	0,6812	18,4859
NDRE2	Polinómica	831;741;	0,5088	0,6806	18,4809
NDRE2	Polinómica	832;741;	0,5088	0,6804	18,4807
NDRE2	Polinómica	832;742;	0,5104	0,6800	18,5415
NDRE2	Polinómica	834;742;	0,5096	0,6799	18,5112
NDRE2	Lineal	823;746;	0,5583	0,6170	20,2799
NDRE2	Lineal	823;747;	0,5591	0,6164	20,3077
NDRE2	Lineal	813;747;	0,5599	0,6160	20,3386
NDRE2	Lineal	823;745;	0,5591	0,6156	20,3072
NDRE2	Lineal	814;747;	0,5605	0,6148	20,3583
NDRE2	Potencial	815;748;	0,5996	0,5773	21,7792
NDRE2	Potencial	816;748;	0,5981	0,5771	21,7260
NDRE2	Potencial	816;747;	0,6010	0,5763	21,8297
NDRE2	Potencial	815;747;	0,6027	0,5761	21,8919
NDRE2	Potencial	817;748;	0,6014	0,5741	21,8463
NDRE2	Exponencial	789;746;	0,6840	0,4969	24,8461
NDRE2	Exponencial	789;745;	0,6804	0,4964	24,7158
NDRE2	Exponencial	789;747;	0,6886	0,4964	25,0129
NDRE2	Exponencial	790;746;	0,6856	0,4961	24,9030
NDRE2	Exponencial	789;744;	0,6774	0,4960	24,6060

**Tabla B11.** Primeros 5 modelos por tipo de regresión según su  $R^2$  para el subconjunto del índice NDRE3 para el manejo de corte.

<b>IV</b>	<b>Regresión</b>	<b>Bandas (nm)</b>	<b>RMSE</b>	<b>R<sup>2</sup></b>	<b>RRMSE</b>
NDRE3	Exponencial	895;784;	1,0153	0,4378	36,8780
NDRE3	Exponencial	895;785;	1,0081	0,4370	36,6182
NDRE3	Potencial	900;790;	1,0343	0,4337	37,5690
NDRE3	Potencial	900;789;	1,0361	0,4335	37,6351
NDRE3	Exponencial	896;786;	1,0147	0,4331	36,8596
NDRE3	Exponencial	896;785;	1,0226	0,4326	37,1452
NDRE3	Exponencial	900;789;	1,0279	0,4325	37,3378
NDRE3	Potencial	900;791;	1,0371	0,4314	37,6711
NDRE3	Potencial	895;784;	1,0186	0,4304	37,0013
NDRE3	Potencial	900;788;	1,0430	0,4295	37,8845
NDRE3	Lineal	900;788;	0,9970	0,4197	36,2146
NDRE3	Lineal	900;789;	0,9924	0,4183	36,0485
NDRE3	Lineal	900;787;	1,0032	0,4177	36,4410
NDRE3	Lineal	900;790;	0,9912	0,4177	36,0045
NDRE3	Lineal	900;793;	0,9989	0,4168	36,2848
NDRE3	Polinómica	832;783;	1,1308	0,3820	41,0764
NDRE3	Polinómica	831;784;	1,1333	0,3813	41,1643
NDRE3	Polinómica	831;785;	1,1122	0,3806	40,4010
NDRE3	Polinómica	832;784;	1,1164	0,3801	40,5530
NDRE3	Polinómica	832;782;	1,1322	0,3793	41,1272

**Tabla B12.** Primeros 5 modelos por tipo de regresión según su  $R^2$  para el subconjunto del índice ONLI2 para el manejo de pastoreo.

<b>IV</b>	<b>Regresión</b>	<b>Bandas (nm)</b>	<b>RMSE</b>	<b>R<sup>2</sup></b>	<b>RRMSE</b>
ONLI2	Exponencial	865;733;	1,0161	0,2039	32,4858
ONLI2	Exponencial	866;733;	1,0160	0,2038	32,4836
ONLI2	Exponencial	859;733;	1,0161	0,2036	32,4873
ONLI2	Exponencial	858;733;	1,0160	0,2027	32,4825
ONLI2	Exponencial	860;733;	1,0161	0,2023	32,4855
ONLI2	Potencial	865;733;	1,0174	0,2001	32,5288
ONLI2	Potencial	866;733;	1,0173	0,1999	32,5255
ONLI2	Potencial	859;733;	1,0175	0,1998	32,5302
ONLI2	Potencial	858;733;	1,0174	0,1989	32,5264
ONLI2	Potencial	860;733;	1,0174	0,1985	32,5290
ONLI2	Polinómica	859;733;	0,9942	0,1398	31,7870
ONLI2	Polinómica	865;733;	0,9942	0,1394	31,7848
ONLI2	Polinómica	866;733;	0,9941	0,1394	31,7821
ONLI2	Polinómica	858;733;	0,9941	0,1383	31,7824
ONLI2	Polinómica	860;733;	0,9941	0,1380	31,7821
ONLI2	Lineal	859;733;	0,9882	0,0787	31,5946
ONLI2	Lineal	865;733;	0,9881	0,0781	31,5926
ONLI2	Lineal	866;733;	0,9881	0,0780	31,5912
ONLI2	Lineal	858;733;	0,9881	0,0778	31,5905
ONLI2	Lineal	860;733;	0,9881	0,0776	31,5919



**Tabla B13.** Primeros 5 modelos por tipo de regresión según su  $R^2$  para el subconjunto del índice ONLI3 para el manejo de pastoreo.

<b>IV</b>	<b>Regresión</b>	<b>Bandas (nm)</b>	<b>RMSE</b>	<b>R<sup>2</sup></b>	<b>RRMSE</b>
ONLI3	Exponencial	807;789;	1,0041	0,1574	32,1019
ONLI3	Exponencial	806;789;	1,0040	0,1573	32,1010
ONLI3	Exponencial	806;790;	1,0040	0,1571	32,1001
ONLI3	Exponencial	807;790;	1,0040	0,1571	32,1007
ONLI3	Exponencial	807;788;	1,0040	0,1566	32,0991
ONLI3	Potencial	807;789;	1,0040	0,1534	32,0983
ONLI3	Potencial	806;789;	1,0039	0,1532	32,0969
ONLI3	Potencial	807;790;	1,0039	0,1531	32,0963
ONLI3	Potencial	806;790;	1,0039	0,1530	32,0964
ONLI3	Potencial	806;788;	1,0038	0,1524	32,0934
ONLI3	Lineal	859;789;	0,9784	0,0755	31,2814
ONLI3	Lineal	859;790;	0,9784	0,0750	31,2802
ONLI3	Lineal	858;789;	0,9784	0,0749	31,2807
ONLI3	Lineal	848;789;	0,9788	0,0748	31,2928
ONLI3	Lineal	849;789;	0,9787	0,0747	31,2911
ONLI3	Polinómica	865;790;	0,9877	0,0638	31,5795
ONLI3	Polinómica	865;789;	0,9879	0,0634	31,5841
ONLI3	Polinómica	849;790;	0,9867	0,0633	31,5479
ONLI3	Polinómica	858;790;	0,9874	0,0631	31,5673
ONLI3	Polinómica	849;789;	0,9869	0,0630	31,5519

**Tabla B14.** Primeros 5 modelos por tipo de regresión según su  $R^2$  para el subconjunto del índice OSAVI para el manejo de pastoreo.

<b>IV</b>	<b>Regresión</b>	<b>Bandas (nm)</b>	<b>RMSE</b>	<b>R<sup>2</sup></b>	<b>RRMSE</b>
OSAVI	Exponencial	865;656;	1,0186	0,1636	32,5669
OSAVI	Exponencial	866;656;	1,0186	0,1636	32,5658
OSAVI	Exponencial	859;656;	1,0186	0,1635	32,5670
OSAVI	Exponencial	867;656;	1,0186	0,1632	32,5659
OSAVI	Exponencial	858;656;	1,0185	0,1631	32,5643
OSAVI	Potencial	865;656;	1,0156	0,1483	32,4716
OSAVI	Potencial	866;656;	1,0156	0,1483	32,4709
OSAVI	Potencial	859;656;	1,0156	0,1481	32,4699
OSAVI	Potencial	867;656;	1,0156	0,1479	32,4705
OSAVI	Potencial	858;656;	1,0155	0,1477	32,4681
OSAVI	Lineal	859;656;	0,9916	0,0595	31,7018
OSAVI	Lineal	865;656;	0,9916	0,0593	31,7018
OSAVI	Lineal	866;656;	0,9916	0,0593	31,7017
OSAVI	Lineal	860;656;	0,9915	0,0592	31,7009
OSAVI	Lineal	858;656;	0,9915	0,0591	31,6991
OSAVI	Polinómica	869;650;	1,0349	0,0061	33,0883
OSAVI	Polinómica	870;650;	1,0350	0,0061	33,0907
OSAVI	Polinómica	871;650;	1,0350	0,0061	33,0910
OSAVI	Polinómica	872;650;	1,0350	0,0061	33,0906
OSAVI	Polinómica	875;650;	1,0350	0,0061	33,0920

**Tabla B15.** Primeros 5 modelos por tipo de regresión según su  $R^2$  para el subconjunto del índice RSI para el manejo de pastoreo.

<b>IV</b>	<b>Regresión</b>	<b>Bandas (nm)</b>	<b>RMSE</b>	<b>R<sup>2</sup></b>	<b>RRMSE</b>
RSI	Exponencial	890;655;	1,0978	0,2267	35,0972
RSI	Exponencial	880;655;	1,0970	0,2266	35,0729
RSI	Exponencial	885;655;	1,0974	0,2266	35,0855
RSI	Exponencial	879;655;	1,0970	0,2265	35,0721
RSI	Exponencial	881;655;	1,0969	0,2265	35,0685
RSI	Lineal	865;656;	1,0470	0,2220	33,4750
RSI	Lineal	866;656;	1,0470	0,2220	33,4744
RSI	Lineal	867;656;	1,0470	0,2220	33,4758
RSI	Lineal	871;656;	1,0472	0,2220	33,4802
RSI	Lineal	872;656;	1,0473	0,2220	33,4823
RSI	Potencial	886;656;	1,0638	0,2122	34,0109
RSI	Potencial	888;656;	1,0637	0,2122	34,0096
RSI	Potencial	883;656;	1,0637	0,2121	34,0092
RSI	Potencial	885;656;	1,0637	0,2121	34,0087
RSI	Potencial	887;656;	1,0637	0,2121	34,0069
RSI	Polinómica	833;679;	0,9157	0,0771	29,2769
RSI	Polinómica	835;679;	0,9157	0,0766	29,2776
RSI	Polinómica	831;679;	0,9162	0,0759	29,2929
RSI	Polinómica	833;669;	0,9172	0,0753	29,3231
RSI	Polinómica	829;679;	0,9173	0,0750	29,3279

**Tabla B16.** Primeros 5 modelos por tipo de regresión según su  $R^2$  para el subconjunto del índice EVI2 para el manejo de pastoreo.

<b>IV</b>	<b>Regresión</b>	<b>Bandas (nm)</b>	<b>RMSE</b>	<b><math>R^2</math></b>	<b>RRMSE</b>
EVI2	Exponencial	859;656;	1,0079	0,1755	32,2243
EVI2	Exponencial	865;656;	1,0079	0,1755	32,2232
EVI2	Exponencial	866;656;	1,0078	0,1754	32,2219
EVI2	Exponencial	858;656;	1,0078	0,1751	32,2220
EVI2	Exponencial	860;656;	1,0078	0,1748	32,2222
EVI2	Potencial	859;656;	1,0060	0,1616	32,1619
EVI2	Potencial	865;656;	1,0059	0,1616	32,1613
EVI2	Potencial	866;656;	1,0059	0,1616	32,1601
EVI2	Potencial	858;656;	1,0059	0,1612	32,1610
EVI2	Potencial	860;656;	1,0059	0,1610	32,1605
EVI2	Lineal	859;656;	0,9823	0,0520	31,4055
EVI2	Lineal	858;656;	0,9822	0,0517	31,4037
EVI2	Lineal	865;656;	0,9822	0,0516	31,4040
EVI2	Lineal	866;656;	0,9822	0,0516	31,4034
EVI2	Lineal	860;656;	0,9822	0,0515	31,4038
EVI2	Polinómica	876;655;	0,9961	0,0128	31,8482
EVI2	Polinómica	882;655;	0,9956	0,0128	31,8321
EVI2	Polinómica	859;655;	0,9974	0,0127	31,8896
EVI2	Polinómica	877;655;	0,9960	0,0127	31,8445
EVI2	Polinómica	881;655;	0,9957	0,0127	31,8349

**Tabla B17.** Primeros 5 modelos por tipo de regresión según su  $R^2$  para el subconjunto del índice NDVI para el manejo de pastoreo.

<b>IV</b>	<b>Regresión</b>	<b>Bandas (nm)</b>	<b>RMSE</b>	<b>R<sup>2</sup></b>	<b>RRMSE</b>
NDVI	Exponencial	656;886;	1,0426	0,1777	33,3343
NDVI	Exponencial	656;887;	1,0426	0,1777	33,3344
NDVI	Exponencial	656;888;	1,0426	0,1776	33,3342
NDVI	Exponencial	656;882;	1,0426	0,1775	33,3339
NDVI	Exponencial	656;883;	1,0426	0,1775	33,3350
NDVI	Potencial	656;886;	1,0385	0,1675	33,2024
NDVI	Potencial	656;887;	1,0385	0,1675	33,2018
NDVI	Potencial	656;888;	1,0385	0,1675	33,2023
NDVI	Potencial	656;882;	1,0385	0,1674	33,2013
NDVI	Potencial	656;883;	1,0385	0,1674	33,2024
NDVI	Lineal	656;876;	1,0098	0,1115	32,2843
NDVI	Lineal	656;865;	1,0097	0,1114	32,2805
NDVI	Lineal	656;866;	1,0097	0,1114	32,2809
NDVI	Lineal	656;871;	1,0097	0,1114	32,2831
NDVI	Lineal	656;872;	1,0097	0,1114	32,2825
NDVI	Polinómica	662;829;	0,9658	0,0207	30,8787
NDVI	Polinómica	662;832;	0,9658	0,0207	30,8796
NDVI	Polinómica	662;830;	0,9659	0,0206	30,8800
NDVI	Polinómica	662;831;	0,9659	0,0206	30,8810
NDVI	Polinómica	662;833;	0,9660	0,0206	30,8830

**Tabla B18.** Primeros 5 modelos por tipo de regresión según su  $R^2$  para el subconjunto del índice MTVI2 para el manejo de pastoreo.

<b>IV</b>	<b>Regresión</b>	<b>Bandas (nm)</b>	<b>RMSE</b>	<b><math>R^2</math></b>	<b>RRMSE</b>
MTVI2	Lineal	656;865;578;	0,9903	0,2210	31,6608
MTVI2	Lineal	656;867;578;	0,9903	0,2210	31,6606
MTVI2	Lineal	656;868;578;	0,9903	0,2210	31,6600
MTVI2	Lineal	656;871;578;	0,9902	0,2210	31,6595
MTVI2	Lineal	656;872;578;	0,9902	0,2210	31,6588
MTVI2	Exponencial	661;817;578;	1,0133	0,2123	32,3981
MTVI2	Exponencial	661;816;578;	1,0133	0,2121	32,3967
MTVI2	Exponencial	662;817;578;	1,0133	0,2120	32,3954
MTVI2	Exponencial	661;818;578;	1,0135	0,2120	32,4036
MTVI2	Exponencial	662;816;578;	1,0132	0,2119	32,3949
MTVI2	Potencial	661;790;578;	1,0110	0,2095	32,3225
MTVI2	Potencial	661;787;578;	1,0111	0,2094	32,3249
MTVI2	Potencial	661;788;578;	1,0110	0,2094	32,3222
MTVI2	Potencial	661;789;578;	1,0109	0,2094	32,3209
MTVI2	Potencial	661;791;578;	1,0111	0,2094	32,3251
MTVI2	Polinómica	656;866;554;	1,0797	0,0162	34,5208
MTVI2	Polinómica	656;866;553;	1,0793	0,0161	34,5072
MTVI2	Polinómica	656;865;554;	1,0798	0,0161	34,5239
MTVI2	Polinómica	656;867;554;	1,0799	0,0161	34,5252
MTVI2	Polinómica	656;872;554;	1,0799	0,0161	34,5257

**Tabla B19.** Primeros 5 modelos por tipo de regresión según su  $R^2$  para el subconjunto del índice ONLI1 para el manejo de pastoreo.

<b>IV</b>	<b>Regresión</b>	<b>Bandas (nm)</b>	<b>RMSE</b>	<b>R<sup>2</sup></b>	<b>RRMSE</b>
ONLI1	Potencial	805;712;	1,0542	0,1996	33,7056
ONLI1	Potencial	804;712;	1,0548	0,1995	33,7229
ONLI1	Potencial	803;712;	1,0557	0,1990	33,7518
ONLI1	Potencial	799;712;	1,0621	0,1989	33,9566
ONLI1	Potencial	800;712;	1,0606	0,1987	33,9102
ONLI1	Exponencial	865;701;	1,0297	0,1672	32,9213
ONLI1	Exponencial	859;701;	1,0297	0,1671	32,9207
ONLI1	Exponencial	866;701;	1,0296	0,1671	32,9195
ONLI1	Exponencial	860;701;	1,0297	0,1666	32,9199
ONLI1	Exponencial	858;701;	1,0296	0,1665	32,9171
ONLI1	Lineal	859;701;	0,9988	0,0709	31,9324
ONLI1	Lineal	865;701;	0,9988	0,0706	31,9323
ONLI1	Lineal	866;701;	0,9987	0,0705	31,9309
ONLI1	Lineal	858;701;	0,9987	0,0704	31,9292
ONLI1	Lineal	860;701;	0,9987	0,0704	31,9309
ONLI1	Polinómica	882;702;	1,0292	0,0285	32,9046
ONLI1	Polinómica	883;702;	1,0292	0,0284	32,9062
ONLI1	Polinómica	881;702;	1,0291	0,0283	32,9022
ONLI1	Polinómica	876;702;	1,0291	0,0281	32,9023
ONLI1	Polinómica	877;702;	1,0290	0,0281	32,8993

**Tabla B20.** Primeros 5 modelos por tipo de regresión según su  $R^2$  para el subconjunto del índice NDRE1 para el manejo de pastoreo.

<b>IV</b>	<b>Regresión</b>	<b>Bandas (nm)</b>	<b>RMSE</b>	<b>R<sup>2</sup></b>	<b>RRMSE</b>
NDRE1	Exponencial	876;701;	1,0633	0,2083	33,9954
NDRE1	Exponencial	886;701;	1,0637	0,2083	34,0089
NDRE1	Exponencial	865;701;	1,0631	0,2082	33,9891
NDRE1	Exponencial	866;701;	1,0631	0,2082	33,9888
NDRE1	Exponencial	871;701;	1,0632	0,2082	33,9921
NDRE1	Potencial	876;701;	1,0557	0,1903	33,7521
NDRE1	Potencial	882;701;	1,0560	0,1903	33,7611
NDRE1	Potencial	886;701;	1,0561	0,1903	33,7641
NDRE1	Potencial	887;701;	1,0561	0,1903	33,7638
NDRE1	Potencial	885;701;	1,0561	0,1902	33,7640
NDRE1	Lineal	876;701;	1,0249	0,1570	32,7669
NDRE1	Lineal	871;701;	1,0248	0,1568	32,7640
NDRE1	Lineal	865;701;	1,0247	0,1567	32,7620
NDRE1	Lineal	866;701;	1,0247	0,1567	32,7614
NDRE1	Lineal	872;701;	1,0248	0,1567	32,7638
NDRE1	Polinómica	882;701;	1,1047	0,0109	35,3190
NDRE1	Polinómica	883;701;	1,1050	0,0109	35,3292
NDRE1	Polinómica	884;701;	1,1051	0,0109	35,3304
NDRE1	Polinómica	881;701;	1,1041	0,0108	35,2985
NDRE1	Polinómica	885;701;	1,1051	0,0108	35,3320



**Tabla B21.** Primeros 5 modelos por tipo de regresión según su  $R^2$  para el subconjunto del índice NDRE2 para el manejo de pastoreo.

<b>IV</b>	<b>Regresión</b>	<b>Bandas (nm)</b>	<b>RMSE</b>	<b>R<sup>2</sup></b>	<b>RRMSE</b>
NDRE2	Lineal	874;736;	1,0634	0,3002	33,9981
NDRE2	Lineal	873;736;	1,0634	0,2993	33,9984
NDRE2	Lineal	869;736;	1,0633	0,2971	33,9966
NDRE2	Lineal	863;736;	1,0632	0,2930	33,9917
NDRE2	Lineal	862;736;	1,0634	0,2923	33,9994
NDRE2	Exponencial	785;733;	1,1109	0,2850	35,5160
NDRE2	Exponencial	786;733;	1,1123	0,2808	35,5636
NDRE2	Exponencial	876;735;	1,1159	0,2801	35,6777
NDRE2	Exponencial	872;735;	1,1164	0,2790	35,6926
NDRE2	Exponencial	875;735;	1,1158	0,2788	35,6735
NDRE2	Potencial	785;733;	1,0965	0,2588	35,0573
NDRE2	Potencial	786;733;	1,0977	0,2515	35,0959
NDRE2	Potencial	787;733;	1,0985	0,2475	35,1219
NDRE2	Potencial	788;733;	1,0989	0,2431	35,1322
NDRE2	Potencial	789;733;	1,0993	0,2400	35,1464
NDRE2	Polinómica	900;748;	0,8884	0,1221	28,4028
NDRE2	Polinómica	899;748;	0,8902	0,1191	28,4610
NDRE2	Polinómica	900;747;	0,8902	0,1182	28,4620
NDRE2	Polinómica	900;746;	0,8916	0,1156	28,5043
NDRE2	Polinómica	899;747;	0,8919	0,1154	28,5163

**Tabla B22.** Primeros 5 modelos por tipo de regresión según su  $R^2$  para el subconjunto del índice NDRE3 para el manejo de pastoreo.

<b>IV</b>	<b>Regresión</b>	<b>Bandas (nm)</b>	<b>RMSE</b>	<b>R<sup>2</sup></b>	<b>RRMSE</b>
NDRE3	Potencial	816;780;	0,8597	0,1914	27,4859
NDRE3	Polinómica	895;776;	0,8953	0,1877	28,6233
NDRE3	Polinómica	897;773;	0,8896	0,1875	28,4432
NDRE3	Polinómica	895;775;	0,8882	0,1861	28,3979
NDRE3	Polinómica	898;773;	0,8964	0,1851	28,6605
NDRE3	Polinómica	897;774;	0,9013	0,1850	28,8156
NDRE3	Lineal	807;784;	0,9813	0,1800	31,3747
NDRE3	Lineal	806;784;	0,9811	0,1727	31,3685
NDRE3	Lineal	888;783;	0,9931	0,1674	31,7496
NDRE3	Lineal	889;783;	0,9919	0,1673	31,7127
NDRE3	Lineal	887;783;	0,9943	0,1672	31,7888
NDRE3	Potencial	875;784;	1,0188	0,1668	32,5728
NDRE3	Potencial	879;784;	1,0185	0,1668	32,5632
NDRE3	Potencial	880;784;	1,0182	0,1666	32,5528
NDRE3	Potencial	874;784;	1,0189	0,1665	32,5749
NDRE3	Exponencial	879;784;	1,0143	0,1611	32,4274
NDRE3	Exponencial	880;784;	1,0140	0,1610	32,4180
NDRE3	Exponencial	875;784;	1,0144	0,1601	32,4310
NDRE3	Exponencial	793;788;	0,8926	0,1601	28,5366
NDRE3	Exponencial	788;793;	0,8926	0,1601	28,5366

**Tabla B23.** Primeros 10 modelos del subconjunto del índice EVI2 de acuerdo con su valor de suma de relativos para el manejo de corte.

<b>IV</b>	<b>Regresión</b>	<b>Bandas (nm)</b>	<b>RMSE</b>	<b>R<sup>2</sup></b>	<b>RRMSE</b>	<b>RMSE relativo</b>	<b>R<sup>2</sup> relativo</b>	<b>Suma de relativos</b>
EVI2	Potencial	865;650;	0,8447	0,2140	30,6819	0,0199	0,0000	0,0199
EVI2	Potencial	866;650;	0,8447	0,2140	30,6813	0,0199	0,0000	0,0199
EVI2	Potencial	867;650;	0,8447	0,2140	30,6826	0,0199	0,0000	0,0199
EVI2	Potencial	868;650;	0,8448	0,2139	30,6867	0,0200	0,0005	0,0205
EVI2	Potencial	870;650;	0,8449	0,2138	30,6901	0,0202	0,0009	0,0211
EVI2	Potencial	871;650;	0,8450	0,2138	30,6921	0,0203	0,0009	0,0212
EVI2	Potencial	864;650;	0,8449	0,2137	30,6887	0,0202	0,0014	0,0216
EVI2	Potencial	869;650;	0,8449	0,2137	30,6916	0,0202	0,0014	0,0216
EVI2	Potencial	866;651;	0,8449	0,2137	30,6894	0,0202	0,0014	0,0216
EVI2	Potencial	872;650;	0,8451	0,2137	30,6958	0,0204	0,0014	0,0218

**Tabla B24.** Primeros 10 modelos del subconjunto del índice MTVI2 de acuerdo con su valor de suma de relativos para el manejo de corte.

<b>IV</b>	<b>Regresión</b>	<b>Bandas (nm)</b>	<b>RMSE</b>	<b>R<sup>2</sup></b>	<b>RRMSE</b>	<b>RMSE relativo</b>	<b>R<sup>2</sup> relativo</b>	<b>Suma de relativos</b>
MTVI2	Potencial	650;871;578;	0,8050	0,2674	29,2418	0,0131	0,0015	0,0146
MTVI2	Potencial	651;871;578;	0,8050	0,2674	29,2415	0,0131	0,0015	0,0146
MTVI2	Potencial	650;872;578;	0,8050	0,2674	29,2421	0,0131	0,0015	0,0146
MTVI2	Potencial	650;873;578;	0,8050	0,2674	29,2418	0,0131	0,0015	0,0146
MTVI2	Potencial	650;870;578;	0,8051	0,2674	29,2427	0,0132	0,0015	0,0147
MTVI2	Potencial	650;880;578;	0,8051	0,2674	29,2460	0,0132	0,0015	0,0147
MTVI2	Potencial	651;873;578;	0,8050	0,2673	29,2415	0,0131	0,0019	0,0150
MTVI2	Potencial	651;872;578;	0,8050	0,2673	29,2426	0,0131	0,0019	0,0150
MTVI2	Potencial	651;870;578;	0,8050	0,2673	29,2422	0,0131	0,0019	0,0150
MTVI2	Potencial	650;867;578;	0,8050	0,2673	29,2421	0,0131	0,0019	0,0150

**Tabla B25.** Primeros 10 modelos del subconjunto del índice NDVI de acuerdo con su valor de suma de relativos para el manejo de corte.

<b>IV</b>	<b>Regresión</b>	<b>Bandas (nm)</b>	<b>RMSE</b>	<b>R<sup>2</sup></b>	<b>RRMSE</b>	<b>RMSE relativo</b>	<b>R<sup>2</sup> relativo</b>	<b>Suma de relativos</b>
NDVI	Lineal	650;900;	0,6993	0,4077	25,4013	0,0000	0,0000	0,0000
NDVI	Lineal	650;899;	0,6993	0,4076	25,4024	0,0000	0,0002	0,0002
NDVI	Lineal	651;899;	0,6994	0,4076	25,4051	0,0001	0,0002	0,0004
NDVI	Lineal	652;899;	0,6994	0,4076	25,4062	0,0001	0,0002	0,0004
NDVI	Lineal	651;900;	0,6994	0,4076	25,4042	0,0001	0,0002	0,0004
NDVI	Lineal	652;900;	0,6994	0,4076	25,4056	0,0001	0,0002	0,0004
NDVI	Lineal	653;900;	0,6994	0,4076	25,4062	0,0001	0,0002	0,0004
NDVI	Lineal	653;899;	0,6995	0,4076	25,4076	0,0003	0,0002	0,0005
NDVI	Lineal	656;900;	0,6996	0,4075	25,4124	0,0004	0,0005	0,0009
NDVI	Lineal	656;899;	0,6996	0,4075	25,4128	0,0004	0,0005	0,0009

**Tabla B26.** Primeros 10 modelos del subconjunto del índice ONLI1 de acuerdo con su valor de suma de relativos para el manejo de corte.

<b>IV</b>	<b>Regresión</b>	<b>Bandas (nm)</b>	<b>RMSE</b>	<b>R<sup>2</sup></b>	<b>RRMSE</b>	<b>RMSE relativo</b>	<b>R<sup>2</sup> relativo</b>	<b>Suma de relativos</b>
ONLI1	Potencial	873;701;	0,5961	0,3391	21,6513	0,0000	0,0661	0,0661
ONLI1	Potencial	811;699;	0,6537	0,3571	23,7453	0,0966	0,0165	0,1132
ONLI1	Potencial	839;700;	0,6419	0,3471	23,3153	0,0768	0,0441	0,1209
ONLI1	Potencial	819;699;	0,6684	0,3631	24,2775	0,1213	0,0000	0,1213
ONLI1	Potencial	872;701;	0,6321	0,3399	22,9621	0,0604	0,0639	0,1243
ONLI1	Potencial	895;701;	0,6598	0,3558	23,9665	0,1069	0,0201	0,1270
ONLI1	Potencial	804;699;	0,6534	0,3426	23,7326	0,0961	0,0565	0,1526
ONLI1	Potencial	871;701;	0,6426	0,3323	23,3408	0,0780	0,0848	0,1628
ONLI1	Potencial	812;699;	0,6665	0,3453	24,2102	0,1181	0,0490	0,1671
ONLI1	Potencial	838;700;	0,6542	0,3350	23,7614	0,0975	0,0774	0,1749

**Tabla B27.** Primeros 10 modelos del subconjunto del índice ONLI2 de acuerdo con su valor de suma de relativos para el manejo de corte.

<b>IV</b>	<b>Regresión</b>	<b>Bandas (nm)</b>	<b>RMSE</b>	<b>R<sup>2</sup></b>	<b>RRMSE</b>	<b>RMSE relativo</b>	<b>R<sup>2</sup> relativo</b>	<b>Suma de relativos</b>
ONLI2	Lineal	865;733;	0,8241	0,2099	29,9347	0,0000	0,0000	0,0000
ONLI2	Lineal	866;733;	0,8241	0,2099	29,9360	0,0000	0,0000	0,0000
ONLI2	Lineal	867;733;	0,8242	0,2099	29,9369	0,0001	0,0000	0,0001
ONLI2	Lineal	868;733;	0,8243	0,2096	29,9419	0,0002	0,0014	0,0017
ONLI2	Lineal	870;733;	0,8245	0,2094	29,9475	0,0005	0,0024	0,0029
ONLI2	Lineal	871;733;	0,8245	0,2094	29,9492	0,0005	0,0024	0,0029
ONLI2	Lineal	864;733;	0,8245	0,2092	29,9503	0,0005	0,0033	0,0038
ONLI2	Lineal	862;733;	0,8245	0,2092	29,9490	0,0005	0,0033	0,0038
ONLI2	Lineal	854;733;	0,8245	0,2092	29,9499	0,0005	0,0033	0,0038
ONLI2	Lineal	855;733;	0,8245	0,2092	29,9484	0,0005	0,0033	0,0038

**Tabla B28.** Primeros 10 modelos del subconjunto del índice ONLI3 de acuerdo con su valor de suma de relativos para el manejo de corte.

<b>IV</b>	<b>Regresión</b>	<b>Bandas (nm)</b>	<b>RMSE</b>	<b>R<sup>2</sup></b>	<b>RRMSE</b>	<b>RMSE relativo</b>	<b>R<sup>2</sup> relativo</b>	<b>Suma de relativos</b>
ONLI3	Polinómica	816;773;	0,9108	0,0988	33,0830	0,0008	0,0000	0,0008
ONLI3	Polinómica	817;773;	0,9113	0,0982	33,1005	0,0013	0,0061	0,0074
ONLI3	Polinómica	816;774;	0,9114	0,0979	33,1065	0,0014	0,0091	0,0105
ONLI3	Polinómica	815;773;	0,9120	0,0975	33,1282	0,0021	0,0132	0,0152
ONLI3	Polinómica	817;774;	0,9119	0,0973	33,1239	0,0020	0,0152	0,0172
ONLI3	Polinómica	816;775;	0,9122	0,0970	33,1333	0,0023	0,0182	0,0205
ONLI3	Polinómica	815;774;	0,9127	0,0967	33,1521	0,0029	0,0213	0,0241
ONLI3	Polinómica	818;773;	0,9127	0,0966	33,1535	0,0029	0,0223	0,0251
ONLI3	Polinómica	817;775;	0,9127	0,0964	33,1519	0,0029	0,0243	0,0271
ONLI3	Polinómica	816;776;	0,9129	0,0961	33,1607	0,0031	0,0273	0,0304

**Tabla B29.** Primeros 10 modelos del subconjunto del índice OSAVI de acuerdo con su valor de suma de relativos para el manejo de corte.

<b>IV</b>	<b>Regresión</b>	<b>Bandas (nm)</b>	<b>RMSE</b>	<b>R<sup>2</sup></b>	<b>RRMSE</b>	<b>RMSE relativo</b>	<b>R<sup>2</sup> relativo</b>	<b>Suma de relativos</b>
OSAVI	Lineal	900;650;	0,7641	0,3067	27,7566	0,0000	0,0013	0,0013
OSAVI	Lineal	899;650;	0,7641	0,3067	27,7554	0,0000	0,0013	0,0013
OSAVI	Lineal	898;650;	0,7643	0,3065	27,7610	0,0003	0,0020	0,0022
OSAVI	Lineal	900;651;	0,7644	0,3063	27,7667	0,0004	0,0026	0,0030
OSAVI	Lineal	899;651;	0,7644	0,3063	27,7658	0,0004	0,0026	0,0030
OSAVI	Lineal	898;651;	0,7646	0,3061	27,7716	0,0007	0,0033	0,0039
OSAVI	Lineal	897;650;	0,7646	0,3060	27,7725	0,0007	0,0036	0,0042
OSAVI	Lineal	899;652;	0,7647	0,3059	27,7762	0,0008	0,0039	0,0047
OSAVI	Lineal	900;652;	0,7647	0,3059	27,7780	0,0008	0,0039	0,0047
OSAVI	Lineal	898;652;	0,7648	0,3057	27,7822	0,0009	0,0046	0,0055

**Tabla B30.** Primeros 10 modelos del subconjunto del índice RSI de acuerdo con su valor de suma de relativos para el manejo de corte.

<b>IV</b>	<b>Regresión</b>	<b>Bandas (nm)</b>	<b>RMSE</b>	<b>R<sup>2</sup></b>	<b>RRMSE</b>	<b>RMSE relativo</b>	<b>R<sup>2</sup> relativo</b>	<b>Suma de relativos</b>
RSI	Potencial	900;680;	0,7472	0,3627	27,1413	0,0187	0,0000	0,0187
RSI	Potencial	899;680;	0,7473	0,3626	27,1453	0,0188	0,0003	0,0191
RSI	Potencial	898;680;	0,7474	0,3623	27,1504	0,0190	0,0011	0,0201
RSI	Potencial	897;680;	0,7475	0,3621	27,1539	0,0191	0,0017	0,0207
RSI	Potencial	896;680;	0,7477	0,3617	27,1601	0,0194	0,0028	0,0221
RSI	Potencial	894;680;	0,7478	0,3614	27,1628	0,0195	0,0036	0,0231
RSI	Potencial	895;680;	0,7479	0,3614	27,1654	0,0196	0,0036	0,0232
RSI	Potencial	899;679;	0,7485	0,3613	27,1886	0,0204	0,0039	0,0243
RSI	Potencial	900;679;	0,7485	0,3613	27,1895	0,0204	0,0039	0,0243
RSI	Potencial	898;679;	0,7485	0,3611	27,1900	0,0204	0,0044	0,0249

**Tabla B31.** Primeros 10 modelos del subconjunto del índice NDRE1 de acuerdo con su valor de suma de relativos para el manejo de corte.

<b>IV</b>	<b>Regresión</b>	<b>Bandas (nm)</b>	<b>RMSE</b>	<b>R<sup>2</sup></b>	<b>RRMSE</b>	<b>RMSE relativo</b>	<b>R<sup>2</sup> relativo</b>	<b>Suma de relativos</b>
NDRE1	Lineal	900;713;	0,6716	0,4468	24,3969	0,0000	0,0000	0,0000
NDRE1	Lineal	899;713;	0,6717	0,4467	24,3992	0,0001	0,0002	0,0004
NDRE1	Lineal	898;713;	0,6721	0,4460	24,4142	0,0007	0,0018	0,0025
NDRE1	Polinómica	900;713;	0,6725	0,4452	24,4261	0,0013	0,0036	0,0049
NDRE1	Lineal	897;713;	0,6727	0,4450	24,4366	0,0016	0,0040	0,0057
NDRE1	Polinómica	899;713;	0,6729	0,4446	24,4417	0,0019	0,0049	0,0069
NDRE1	Lineal	900;712;	0,6731	0,4447	24,4482	0,0022	0,0047	0,0069
NDRE1	Lineal	899;712;	0,6731	0,4445	24,4508	0,0022	0,0051	0,0074
NDRE1	Lineal	896;713;	0,6734	0,4440	24,4591	0,0027	0,0063	0,0089
NDRE1	Polinómica	898;713;	0,6734	0,4440	24,4592	0,0027	0,0063	0,0089

**Tabla B32.** Primeros 10 modelos del subconjunto del índice NDRE2 de acuerdo con su valor de suma de relativos para el manejo de corte.

<b>IV</b>	<b>Regresión</b>	<b>Bandas (nm)</b>	<b>RMSE</b>	<b>R<sup>2</sup></b>	<b>RRMSE</b>	<b>RMSE relativo</b>	<b>R<sup>2</sup> relativo</b>	<b>Suma de relativos</b>
NDRE2	Polinómica	833;742;	0,5089	0,6812	18,4859	0,0002	0,0000	0,0002
NDRE2	Polinómica	831;741;	0,5088	0,6806	18,4809	0,0000	0,0009	0,0009
NDRE2	Polinómica	832;741;	0,5088	0,6804	18,4807	0,0000	0,0012	0,0012
NDRE2	Polinómica	833;741;	0,5091	0,6798	18,4911	0,0006	0,0021	0,0026
NDRE2	Polinómica	834;742;	0,5096	0,6799	18,5112	0,0016	0,0019	0,0035
NDRE2	Polinómica	832;742;	0,5104	0,6800	18,5415	0,0031	0,0018	0,0049
NDRE2	Polinómica	830;741;	0,5102	0,6792	18,5343	0,0028	0,0029	0,0057
NDRE2	Polinómica	828;740;	0,5100	0,6785	18,5238	0,0024	0,0040	0,0063
NDRE2	Polinómica	827;741;	0,5104	0,6790	18,5413	0,0031	0,0032	0,0064
NDRE2	Polinómica	828;741;	0,5109	0,6789	18,5590	0,0041	0,0034	0,0075

**Tabla B33.** Primeros 10 modelos del subconjunto del índice NDRE3 de acuerdo con su valor de suma de relativos para el manejo de corte.

<b>IV</b>	<b>Regresión</b>	<b>Bandas (nm)</b>	<b>RMSE</b>	<b>R<sup>2</sup></b>	<b>RRMSE</b>	<b>RMSE relativo</b>	<b>R<sup>2</sup> relativo</b>	<b>Suma de relativos</b>
NDRE3	Polinómica	786;773;	0,7110	0,3756	25,8254	0,0000	0,1421	0,1421
NDRE3	Polinómica	786;774;	0,7161	0,3690	26,0133	0,0072	0,1571	0,1643
NDRE3	Polinómica	785;774;	0,7204	0,3576	26,1669	0,0132	0,1832	0,1964
NDRE3	Lineal	786;773;	0,7207	0,3577	26,1801	0,0136	0,1830	0,1966
NDRE3	Lineal	787;773;	0,7219	0,3549	26,2225	0,0153	0,1894	0,2047
NDRE3	Polinómica	785;773;	0,7223	0,3545	26,2362	0,0159	0,1903	0,2062
NDRE3	Polinómica	787;773;	0,7318	0,3582	26,5807	0,0293	0,1818	0,2111
NDRE3	Lineal	786;774;	0,7239	0,3518	26,2937	0,0181	0,1964	0,2146
NDRE3	Potencial	788;773;	0,7294	0,3522	26,4945	0,0259	0,1955	0,2214
NDRE3	Potencial	787;773;	0,7292	0,3520	26,4870	0,0256	0,1960	0,2216

**Tabla B34.** Primeros 10 modelos del subconjunto del índice EVI2 de acuerdo con su valor de suma de relativos para el manejo de pastoreo.

<b>IV</b>	<b>Regresión</b>	<b>Bandas (nm)</b>	<b>RMSE</b>	<b>R<sup>2</sup></b>	<b>RRMSE</b>	<b>RMSE relativo</b>	<b>R<sup>2</sup> relativo</b>	<b>Suma de relativos</b>
EVI2	Exponencial	859;656;	1,0079	0,1755	32,2243	0,0274	0,0000	0,0274
EVI2	Exponencial	865;656;	1,0079	0,1755	32,2232	0,0274	0,0000	0,0274
EVI2	Exponencial	866;656;	1,0078	0,1754	32,2219	0,0273	0,0006	0,0279
EVI2	Exponencial	858;656;	1,0078	0,1751	32,2220	0,0273	0,0023	0,0296
EVI2	Exponencial	860;656;	1,0078	0,1748	32,2222	0,0273	0,0040	0,0313
EVI2	Exponencial	867;656;	1,0078	0,1748	32,2206	0,0273	0,0040	0,0313
EVI2	Exponencial	849;656;	1,0077	0,1746	32,2177	0,0272	0,0051	0,0323
EVI2	Exponencial	848;656;	1,0077	0,1745	32,2189	0,0272	0,0057	0,0329
EVI2	Exponencial	854;656;	1,0078	0,1745	32,2202	0,0273	0,0057	0,0330
EVI2	Exponencial	864;656;	1,0078	0,1745	32,2196	0,0273	0,0057	0,0330



**Tabla B35.** Primeros 10 modelos del subconjunto del índice NDVI de acuerdo con su valor de suma de relativos para el manejo de pastoreo.

<b>IV</b>	<b>Regresión</b>	<b>Bandas (nm)</b>	<b>RMSE</b>	<b>R<sup>2</sup></b>	<b>RRMSE</b>	<b>RMSE relativo</b>	<b>R<sup>2</sup> relativo</b>	<b>Suma de relativos</b>
NDVI	Exponencial	656;886;	1,0426	0,1777	33,3343	0,0795	0,0000	0,0795
NDVI	Exponencial	656;887;	1,0426	0,1777	33,3344	0,0795	0,0000	0,0795
NDVI	Exponencial	656;888;	1,0426	0,1776	33,3342	0,0795	0,0006	0,0801
NDVI	Exponencial	656;882;	1,0426	0,1775	33,3339	0,0795	0,0011	0,0806
NDVI	Exponencial	656;883;	1,0426	0,1775	33,3350	0,0795	0,0011	0,0806
NDVI	Exponencial	656;885;	1,0426	0,1775	33,3349	0,0795	0,0011	0,0806
NDVI	Exponencial	656;889;	1,0426	0,1775	33,3328	0,0795	0,0011	0,0806
NDVI	Exponencial	656;866;	1,0423	0,1774	33,3232	0,0792	0,0017	0,0809
NDVI	Exponencial	656;876;	1,0424	0,1774	33,3283	0,0793	0,0017	0,0810
NDVI	Exponencial	656;877;	1,0424	0,1774	33,3274	0,0793	0,0017	0,0810

**Tabla B36.** Primeros 10 modelos del subconjunto del índice ONLI2 de acuerdo con su valor de suma de relativos para el manejo de pastoreo.

<b>IV</b>	<b>Regresión</b>	<b>Bandas (nm)</b>	<b>RMSE</b>	<b>R<sup>2</sup></b>	<b>RRMSE</b>	<b>RMSE relativo</b>	<b>R<sup>2</sup> relativo</b>	<b>Suma de relativos</b>
ONLI2	Exponencial	865;733;	1,0161	0,2039	32,4858	0,0348	0,0000	0,0348
ONLI2	Exponencial	866;733;	1,0160	0,2038	32,4836	0,0347	0,0005	0,0352
ONLI2	Exponencial	859;733;	1,0161	0,2036	32,4873	0,0348	0,0015	0,0363
ONLI2	Exponencial	858;733;	1,0160	0,2027	32,4825	0,0347	0,0059	0,0406
ONLI2	Exponencial	867;733;	1,0159	0,2023	32,4799	0,0346	0,0078	0,0425
ONLI2	Exponencial	860;733;	1,0161	0,2023	32,4855	0,0348	0,0078	0,0427
ONLI2	Exponencial	864;733;	1,0159	0,2015	32,4798	0,0346	0,0118	0,0464
ONLI2	Exponencial	862;733;	1,0160	0,2008	32,4818	0,0347	0,0152	0,0499
ONLI2	Exponencial	854;733;	1,0157	0,2007	32,4723	0,0344	0,0157	0,0501
ONLI2	Exponencial	871;733;	1,0157	0,2007	32,4745	0,0344	0,0157	0,0501

**Tabla B37.** Primeros 10 modelos del subconjunto del índice ONLI3 de acuerdo con su valor de suma de relativos para el manejo de pastoreo.

<b>IV</b>	<b>Regresión</b>	<b>Bandas (nm)</b>	<b>RMSE</b>	<b>R<sup>2</sup></b>	<b>RRMSE</b>	<b>RMSE relativo</b>	<b>R<sup>2</sup> relativo</b>	<b>Suma de relativos</b>
ONLI3	Exponencial	807;789;	1,0041	0,1574	32,1019	0,0267	0,0000	0,0267
ONLI3	Exponencial	806;789;	1,0040	0,1573	32,1010	0,0266	0,0006	0,0272
ONLI3	Exponencial	806;790;	1,0040	0,1571	32,1001	0,0266	0,0019	0,0285
ONLI3	Exponencial	807;790;	1,0040	0,1571	32,1007	0,0266	0,0019	0,0285
ONLI3	Exponencial	807;788;	1,0040	0,1566	32,0991	0,0266	0,0051	0,0317
ONLI3	Exponencial	806;788;	1,0039	0,1565	32,0976	0,0265	0,0057	0,0322
ONLI3	Exponencial	807;791;	1,0039	0,1558	32,0948	0,0265	0,0102	0,0366
ONLI3	Exponencial	806;791;	1,0038	0,1557	32,0945	0,0264	0,0108	0,0372
ONLI3	Exponencial	808;789;	1,0039	0,1555	32,0947	0,0265	0,0121	0,0386
ONLI3	Exponencial	805;789;	1,0038	0,1554	32,0940	0,0264	0,0127	0,0391

**Tabla B38.** Primeros 10 modelos del subconjunto del índice OSAVI de acuerdo con su valor de suma de relativos para el manejo de pastoreo.

<b>IV</b>	<b>Regresión</b>	<b>Bandas (nm)</b>	<b>RMSE</b>	<b>R<sup>2</sup></b>	<b>RRMSE</b>	<b>RMSE relativo</b>	<b>R<sup>2</sup> relativo</b>	<b>Suma de relativos</b>
OSAVI	Exponencial	865;656;	1,0186	0,1636	32,5669	0,0288	0,0000	0,0288
OSAVI	Exponencial	866;656;	1,0186	0,1636	32,5658	0,0288	0,0000	0,0288
OSAVI	Exponencial	859;656;	1,0186	0,1635	32,5670	0,0288	0,0006	0,0294
OSAVI	Exponencial	867;656;	1,0186	0,1632	32,5659	0,0288	0,0024	0,0312
OSAVI	Exponencial	858;656;	1,0185	0,1631	32,5643	0,0287	0,0031	0,0317
OSAVI	Exponencial	860;656;	1,0186	0,1631	32,5654	0,0288	0,0031	0,0318
OSAVI	Exponencial	864;656;	1,0185	0,1629	32,5633	0,0287	0,0043	0,0330
OSAVI	Exponencial	871;656;	1,0186	0,1629	32,5658	0,0288	0,0043	0,0331
OSAVI	Exponencial	870;656;	1,0185	0,1627	32,5641	0,0287	0,0055	0,0342
OSAVI	Exponencial	872;656;	1,0186	0,1627	32,5668	0,0288	0,0055	0,0343

**Tabla B39.** Primeros 10 modelos del subconjunto del índice MTVI2 de acuerdo con su valor de suma de relativos para el manejo de pastoreo.

IV	Regresión	Bandas (nm)	RMSE	R <sup>2</sup>	RRMSE	RMSE relativo	R <sup>2</sup> relativo	Suma de relativos
MTVI2	Lineal	656;877;578;	0,9901	0,2210	31,6566	0,0001	0,0000	0,0001
MTVI2	Lineal	656;871;578;	0,9902	0,2210	31,6595	0,0002	0,0000	0,0002
MTVI2	Lineal	656;872;578;	0,9902	0,2210	31,6588	0,0002	0,0000	0,0002
MTVI2	Lineal	656;882;578;	0,9902	0,2210	31,6567	0,0002	0,0000	0,0002
MTVI2	Lineal	656;865;578;	0,9903	0,2210	31,6608	0,0003	0,0000	0,0003
MTVI2	Lineal	656;867;578;	0,9903	0,2210	31,6606	0,0003	0,0000	0,0003
MTVI2	Lineal	656;868;578;	0,9903	0,2210	31,6600	0,0003	0,0000	0,0003
MTVI2	Lineal	656;879;578;	0,9901	0,2209	31,6564	0,0001	0,0005	0,0006
MTVI2	Lineal	656;878;578;	0,9901	0,2209	31,6565	0,0001	0,0005	0,0006
MTVI2	Lineal	656;874;578;	0,9901	0,2209	31,6566	0,0001	0,0005	0,0006

**Tabla B40.** Primeros 10 modelos del subconjunto del índice RSI de acuerdo con su valor de suma de relativos para el manejo de pastoreo.

IV	Regresión	Bandas (nm)	RMSE	R <sup>2</sup>	RRMSE	RMSE relativo	R <sup>2</sup> relativo	Suma de relativos
RSI	Lineal	866;656;	1,0470	0,2220	33,4744	0,1434	0,0207	0,1641
RSI	Lineal	865;656;	1,0470	0,2220	33,4750	0,1434	0,0207	0,1641
RSI	Lineal	867;656;	1,0470	0,2220	33,4758	0,1434	0,0207	0,1641
RSI	Lineal	871;656;	1,0472	0,2220	33,4802	0,1436	0,0207	0,1643
RSI	Lineal	872;656;	1,0473	0,2220	33,4823	0,1437	0,0207	0,1644
RSI	Lineal	859;656;	1,0471	0,2219	33,4762	0,1435	0,0212	0,1647
RSI	Lineal	870;656;	1,0472	0,2219	33,4795	0,1436	0,0212	0,1648
RSI	Lineal	877;656;	1,0472	0,2219	33,4804	0,1436	0,0212	0,1648
RSI	Lineal	860;656;	1,0470	0,2218	33,4731	0,1434	0,0216	0,1650
RSI	Lineal	876;656;	1,0470	0,2218	33,4746	0,1434	0,0216	0,1650

**Tabla B41.** Primeros 10 modelos del subconjunto del índice ONLI1 de acuerdo con su valor de suma de relativos para el manejo de pastoreo.

<b>IV</b>	<b>Regresión</b>	<b>Bandas (nm)</b>	<b>RMSE</b>	<b>R<sup>2</sup></b>	<b>RRMSE</b>	<b>RMSE relativo</b>	<b>R<sup>2</sup> relativo</b>	<b>Suma de relativos</b>
ONLI1	Potencial	805;712;	1,0542	0,1996	33,7056	0,0568	0,0000	0,0568
ONLI1	Potencial	804;712;	1,0548	0,1995	33,7229	0,0574	0,0005	0,0579
ONLI1	Potencial	803;712;	1,0557	0,1990	33,7518	0,0583	0,0030	0,0614
ONLI1	Potencial	806;712;	1,0526	0,1977	33,6530	0,0552	0,0095	0,0648
ONLI1	Potencial	802;712;	1,0569	0,1981	33,7912	0,0595	0,0075	0,0671
ONLI1	Potencial	800;712;	1,0606	0,1987	33,9102	0,0633	0,0045	0,0678
ONLI1	Potencial	801;712;	1,0587	0,1983	33,8480	0,0614	0,0065	0,0679
ONLI1	Potencial	799;712;	1,0621	0,1989	33,9566	0,0648	0,0035	0,0683
ONLI1	Potencial	798;712;	1,0626	0,1980	33,9740	0,0653	0,0080	0,0733
ONLI1	Potencial	840;713;	1,0470	0,1933	33,4743	0,0496	0,0316	0,0812

**Tabla B42.** Primeros 10 modelos del subconjunto del índice NDRE1 de acuerdo con su valor de suma de relativos para el manejo de pastoreo.

<b>IV</b>	<b>Regresión</b>	<b>Bandas (nm)</b>	<b>RMSE</b>	<b>R<sup>2</sup></b>	<b>RRMSE</b>	<b>RMSE relativo</b>	<b>R<sup>2</sup> relativo</b>	<b>Suma de relativos</b>
NDRE1	Exponencial	876;701;	1,0633	0,2083	33,9954	0,0393	0,0000	0,0393
NDRE1	Exponencial	865;701;	1,0631	0,2082	33,9891	0,0391	0,0005	0,0396
NDRE1	Exponencial	866;701;	1,0631	0,2082	33,9888	0,0391	0,0005	0,0396
NDRE1	Exponencial	871;701;	1,0632	0,2082	33,9921	0,0392	0,0005	0,0397
NDRE1	Exponencial	886;701;	1,0637	0,2083	34,0089	0,0397	0,0000	0,0397
NDRE1	Exponencial	877;701;	1,0633	0,2082	33,9955	0,0393	0,0005	0,0398
NDRE1	Exponencial	882;701;	1,0636	0,2082	34,0046	0,0396	0,0005	0,0401
NDRE1	Exponencial	872;701;	1,0632	0,2081	33,9920	0,0392	0,0010	0,0402
NDRE1	Exponencial	887;701;	1,0637	0,2082	34,0075	0,0397	0,0005	0,0402
NDRE1	Exponencial	875;701;	1,0633	0,2081	33,9940	0,0393	0,0010	0,0403

**Tabla B43.** Primeros 10 modelos del subconjunto del índice NDRE2 de acuerdo con su valor de suma de relativos para el manejo de pastoreo.

<b>IV</b>	<b>Regresión</b>	<b>Bandas (nm)</b>	<b>RMSE</b>	<b>R<sup>2</sup></b>	<b>RRMSE</b>	<b>RMSE relativo</b>	<b>R<sup>2</sup> relativo</b>	<b>Suma de relativos</b>
NDRE2	Potencial	882;733;	1,1094	0,3354	35,4709	0,2488	0,0006	0,2494
NDRE2	Potencial	886;733;	1,1104	0,3356	35,5025	0,2499	0,0000	0,2499
NDRE2	Potencial	883;733;	1,1098	0,3353	35,4812	0,2492	0,0009	0,2501
NDRE2	Potencial	885;733;	1,1102	0,3354	35,4955	0,2497	0,0006	0,2503
NDRE2	Potencial	881;733;	1,1090	0,3349	35,4552	0,2483	0,0021	0,2504
NDRE2	Potencial	884;733;	1,1098	0,3350	35,4819	0,2492	0,0018	0,2510
NDRE2	Potencial	887;733;	1,1106	0,3351	35,5073	0,2501	0,0015	0,2516
NDRE2	Potencial	876;733;	1,1082	0,3339	35,4318	0,2474	0,0051	0,2525
NDRE2	Potencial	880;733;	1,1088	0,3339	35,4492	0,2481	0,0051	0,2532
NDRE2	Potencial	877;733;	1,1081	0,3335	35,4265	0,2473	0,0063	0,2536

**Tabla B44.** Primeros 10 modelos del subconjunto del índice NDRE3 de acuerdo con su valor de suma de relativos para el manejo de pastoreo.

<b>IV</b>	<b>Regresión</b>	<b>Bandas (nm)</b>	<b>RMSE</b>	<b>R<sup>2</sup></b>	<b>RRMSE</b>	<b>RMSE relativo</b>	<b>R<sup>2</sup> relativo</b>	<b>Suma de relativos</b>
NDRE3	Potencial	816;780;	0,8597	0,1914	27,4859	0,0269	0,0000	0,0269
NDRE3	Polinómica	897;773;	0,8896	0,1875	28,4432	0,0626	0,0204	0,0830
NDRE3	Polinómica	895;775;	0,8882	0,1861	28,3979	0,0609	0,0277	0,0886
NDRE3	Polinómica	895;776;	0,8953	0,1877	28,6233	0,0694	0,0193	0,0887
NDRE3	Polinómica	896;773;	0,8860	0,1841	28,3271	0,0583	0,0381	0,0964
NDRE3	Polinómica	895;774;	0,8827	0,1831	28,2221	0,0543	0,0434	0,0977
NDRE3	Polinómica	896;774;	0,8941	0,1847	28,5861	0,0680	0,0350	0,1030
NDRE3	Polinómica	898;773;	0,8964	0,1851	28,6605	0,0707	0,0329	0,1036
NDRE3	Polinómica	897;774;	0,9013	0,1850	28,8156	0,0766	0,0334	0,1100
NDRE3	Polinómica	894;777;	0,8981	0,1829	28,7143	0,0727	0,0444	0,1172

**Tabla B45.** Resultados de los modelos PLSR generados con el conjunto de datos sin tratamiento para el manejo de corte.

<b>Pretratamiento</b>	<b>Variables latentes</b>	<b>RMSE</b>	<b>R<sup>2</sup></b>	<b>RMSE relativo</b>	<b>R<sup>2</sup> relativo</b>	<b>Suma relativa</b>
RAW	2	0,7551	0,3373	0,0000	0,0000	0,0000
RAW	3	0,9406	0,1214	0,2457	0,6401	0,8857
RAW	4	0,9906	0,1082	0,3119	0,6792	0,9911
RAW	5	1,2189	0,0636	0,6142	0,8114	1,4257

**Tabla B46.** Resultados de los modelos PLSR generados con el conjunto de datos SMT para el manejo de corte.

<b>Pretratamiento</b>	<b>Variables latentes</b>	<b>RMSE</b>	<b>R<sup>2</sup></b>	<b>RMSE relativo</b>	<b>R<sup>2</sup> relativo</b>	<b>Suma relativa</b>
SMT	2	0,7550	0,3373	0,0000	0,0000	0,0000
SMT	3	0,9406	0,1213	0,2458	0,6404	0,8862
SMT	4	0,9919	0,1073	0,3138	0,6819	0,9957
SMT	5	1,2196	0,0627	0,6154	0,8141	1,4295

**Tabla B47.** Resultados de los modelos PLSR generados con el conjunto de datos SNV para el manejo de corte.

<b>Pretratamiento</b>	<b>Variables latentes</b>	<b>RMSE</b>	<b>R<sup>2</sup></b>	<b>RMSE relativo</b>	<b>R<sup>2</sup> relativo</b>	<b>Suma relativa</b>
SNV	3	0,7045	0,4147	0,0000	0,0000	0,0000
SNV	4	0,7735	0,3200	0,0979	0,2284	0,3263
SNV	2	0,7761	0,2838	0,1016	0,3156	0,4173
SNV	5	0,8501	0,2444	0,2067	0,4107	0,6173

**Tabla B48.** Resultados de los modelos PLSR generados con el conjunto de datos SNV+SMT para el manejo de corte.

<b>Pretratamiento</b>	<b>Variables latentes</b>	<b>RMSE</b>	<b>R<sup>2</sup></b>	<b>RMSE relativo</b>	<b>R<sup>2</sup> relativo</b>	<b>Suma relativa</b>
SNV+SMT	3	0,7049	0,4141	0,0000	0,0000	0,0000
SNV+SMT	4	0,7727	0,3211	0,0962	0,2246	0,3208
SNV+SMT	2	0,7761	0,2836	0,1010	0,3151	0,4161
SNV+SMT	5	0,8500	0,2440	0,2058	0,4108	0,6166

**Tabla B49.** Resultados de los modelos PLSR generados con el conjunto de datos SMT+SNV para el manejo de corte.

<b>Pretratamiento</b>	<b>Variables latentes</b>	<b>RMSE</b>	<b>R<sup>2</sup></b>	<b>RMSE relativo</b>	<b>R<sup>2</sup> relativo</b>	<b>Suma relativa</b>
SMT+SNV	3	0,7052	0,4136	0,0000	0,0000	0,0000
SMT+SNV	4	0,7734	0,3202	0,0967	0,2258	0,3225
SMT+SNV	2	0,7761	0,2837	0,1005	0,3141	0,4146
SMT+SNV	5	0,8499	0,2445	0,2052	0,4088	0,6140

**Tabla B50.** Resultados de los modelos PLSR generados con el conjunto de datos sin tratamiento para el manejo de pastoreo.

<b>Pretratamiento</b>	<b>Variables latentes</b>	<b>RMSE</b>	<b>R<sup>2</sup></b>	<b>RMSE relativo</b>	<b>R<sup>2</sup> relativo</b>	<b>Suma relativa</b>
RAW	3	0,8772	0,1769	0,0000	0,0000	0,0000
RAW	2	0,9399	0,0600	0,0715	0,6608	0,7323
RAW	4	1,0264	0,0621	0,1701	0,6490	0,8190
RAW	5	1,0837	0,0697	0,2354	0,6060	0,8414

**Tabla B51.** Resultados de los modelos PLSR generados con el conjunto de datos SMT para el manejo de pastoreo.

<b>Pretratamiento</b>	<b>Variables latentes</b>	<b>RMSE</b>	<b>R<sup>2</sup></b>	<b>RMSE relativo</b>	<b>R<sup>2</sup> relativo</b>	<b>Suma relativa</b>
SMT	3	0,8775	0,1764	0,0000	0,0000	0,0000
SMT	2	0,9394	0,0603	0,0705	0,6582	0,7287
SMT	4	1,0267	0,0616	0,1700	0,6508	0,8208
SMT	5	1,0844	0,0692	0,2358	0,6077	0,8435

**Tabla B52.** Resultados de los modelos PLSR generados con el conjunto de datos SNV para el manejo de pastoreo.

<b>Pretratamiento</b>	<b>Variables latentes</b>	<b>RMSE</b>	<b>R<sup>2</sup></b>	<b>RMSE relativo</b>	<b>R<sup>2</sup> relativo</b>	<b>Suma relativa</b>
SNV	2	0,9191	0,0908	0,0000	0,1019	0,1019
SNV	5	1,0282	0,1011	0,1187	0,0000	0,1187
SNV	3	1,0648	0,0676	0,1585	0,3314	0,4899
SNV	4	1,0313	0,0639	0,1221	0,3680	0,4900

**Tabla B53.** Resultados de los modelos PLSR generados con el conjunto de datos SMT+SNV para el manejo de pastoreo.

<b>Pretratamiento</b>	<b>Variables latentes</b>	<b>RMSE</b>	<b>R<sup>2</sup></b>	<b>RMSE relativo</b>	<b>R<sup>2</sup> relativo</b>	<b>Suma relativa</b>
SMT+SNV	2	0,9192	0,0905	0,0000	0,1048	0,1048
SMT+SNV	5	1,0247	0,1011	0,1148	0,0000	0,1148
SMT+SNV	3	1,0631	0,0673	0,1565	0,3343	0,4909
SMT+SNV	4	1,0297	0,0633	0,1202	0,3739	0,4941

**Tabla B54.** Resultados de los modelos PLSR generados con el conjunto de datos SNV+SMT para el manejo de pastoreo.

<b>Pretratamiento</b>	<b>Variables latentes</b>	<b>RMSE</b>	<b>R<sup>2</sup></b>	<b>RMSE relativo</b>	<b>R<sup>2</sup> relativo</b>	<b>Suma relativa</b>
SNV+SMT	2	0,9194	0,0904	0,0000	0,1041	0,1041
SNV+SMT	5	1,0250	0,1009	0,1149	0,0000	0,1149
SNV+SMT	4	1,0298	0,0635	0,1201	0,3707	0,4907
SNV+SMT	3	1,0636	0,0671	0,1568	0,3350	0,4918



**11. APÉNDICE C: CÓDIGOS UTILIZADOS PARA EL DESARROLLO DE LOS  
MODELOS**

```

from sklearn.decomposition import PCA
import pandas as pd
import numpy as np

path = r"C:\users\juan_\Desktop\datos TFG\ARTMO\IAF_C_VS2.csv"
data = pd.read_csv(path)

ds = data[data.columns[1:-2]]

y = data[data.columns[0]]
x = ds

# Determinación de los 10 primeros componentes principales
pca = PCA(n_components=10).fit(x)
# Obtención de las puntuaciones de cada uno de los 10 componentes principales
x_reduced = pca.transform(x)
# Varianza de cada uno de los 10 componentes principales
total_var = pca.explained_variance_ratio_
# Varianza acumulada de los dos primeros componentes principales
actual_var = total_var[0] + total_var[1]
i = 1
# Ciclo para determinar cuántos componentes principales se necesitan para
alcanzar una varianza explicada mayor o igual a 0.95
while actual_var<=0.95:
    next_var = total_var[(i+1)]
    actual_var += next_var
    i += 1

# Varianza y puntuaciones de los componentes principales que alcanzan una
varianza explicada mayor o igual a 0.95
var = total_var[:(i+1)]
scores = x_reduced[:,:(i+1)]

# Creación de un data frame con las puntuaciones y varianza de cada espectro
data_frame = pd.concat([y, pd.DataFrame(scores)],axis=1)
export_df = pd.concat([data_frame,pd.DataFrame([var])],axis=1)
export_df.columns=["id","PC1","PC2","var PC1","var PC2"]

```

```
# Exportación del data frame
name = r"C:\users\juan_\Desktop\data_PCA_Pastoreo_antes.csv"
export_df.to_csv(name)
```

```
import numpy as np
import pandas as pd
from sklearn.preprocessing import StandardScaler
from scipy.signal import savgol_filter

path = r"C:\users\juan_\Desktop\datos TFG\ARTMO\IAF_C_VS.csv"
data = pd.read_csv(path,index_col=0)

# Separación de IDs y espectros
X = data[data.columns[0:-2]].values
y = data[data.columns[-2]].values

# Pretratamiento snv
Scaler = StandardScaler()
snv_data = Scaler.fit_transform(X.transpose())
snv_data = snv_data.transpose()

#Suavizado
smt_data = savgol_filter(X, window_length=17, deriv=0, polyorder=2)

# SNV con suavizado
snv_smt_data = savgol_filter(snv_data, window_length=17, deriv=0, polyorder=2)

# Suavizado con SNV
smt_snv_data = Scaler.fit_transform(smt_data.transpose())
smt_snv_data = smt_snv_data.transpose()

#creación de dataframes para cada pretratamiento
snv = pd.DataFrame(snv_data)
smt = pd.DataFrame(smt_data)
smt_snv = pd.DataFrame(smt_snv_data)
snv_smt = pd.DataFrame(snv_smt_data)
Y = pd.DataFrame(y)

snv_values = snv.transpose()
```

```

labels = Y.transpose()
snv_frame = [labels,snv_values]

smt_values = smt.transpose()
smt_frame = [labels,smt_values]

smt_snv_values = smt_snv.transpose()
smt_snv_frame = [labels,smt_snv_values]

snv_smt_values = snv_smt.transpose()
snv_smt_frame = [labels,snv_smt_values]
# Exportación de los dataframes
export = pd.concat(snv_frame)
name = "F:\Desktop\datos TFG\ARTMO\plsr\preprocesado\data_snv_corte.csv"
export.to_csv(name)

export = pd.concat(smt_frame)
name = "F:\Desktop\datos TFG\ARTMO\plsr\preprocesado\data_smt_corte.csv"
export.to_csv(name)

export = pd.concat(snv_smt_frame)
name = "F:\Desktop\datos TFG\ARTMO\plsr\preprocesado\data_snv+smt_corte.csv"
export.to_csv(name)

export = pd.concat(smt_snv_frame)
name = "F:\Desktop\datos TFG\ARTMO\plsr\preprocesado\data_smt+snv_corte.csv"
export.to_csv(name)

```

```

import numpy as np
import pandas as pd
path = [r"C:\Users\juan_\Desktop\iv_corte.csv",
        r"C:\Users\juan_\Desktop\iv_corte.csv",
        r"C:\Users\juan_\Desktop\iv_corte.csv"]
dataframe_final = {}
dataframe_rel_final = {}
dataframe_reference = {}

```

```

for reg,ruta in enumerate(path):
    data = pd.read_csv(ruta)

    manejo = path[0].split("\\")[4].split("_")[1].split(".")[0]

    #Filtrado por IV

    # Diccionario en el que se guardan todos los modelos por indice
    indices = {
        "EVI2": ["", "", "", "", "", ""],
        "NDVI": ["", "", "", "", "", ""],
        "MTVI2": ["", "", "", "", "", ""],
        "ONLI1": ["", "", "", "", "", ""],
        "ONLI2": ["", "", "", "", "", ""],
        "ONLI3": ["", "", "", "", "", ""],
        "OSAVI": ["", "", "", "", "", ""],
        "RSI": ["", "", "", "", "", ""],
    }

    models = data.to_numpy()

    f = models.shape[0]
    IV = ["EVI2", "NDVI", "MTVI2", "ONLI1", "ONLI2", "ONLI3", "OSAVI", "RSI"]

    # Ciclo para guardar los modelos bajo la llave correcta en el diccionario
    "indices"
    for key in IV:
        for i in range(f):
            if models[i,0] == key:
                indices[key] = np.vstack([indices[key],models[i,:]])

    #Filtrado por R2 y RMSE

    best_model = {} #Diccionario donde se guarda el mejor modelo de cada indice

    # Diccionario en el que se guardan los modelos con sus respectivos alores
    relativos de R2 y RMSE
    iv_final = {

```

```

}

# Diccionario en el que se guarda el R2 mas alto y el RMSE mas bajo para cada
uno de los indices
abs_metrics = { #Estaria bueno incluirlo en la tesis como los valores de
referencia
    "EVI2": ["" , ""],
    "NDVI": ["" , ""],
    "MTVI2": ["" , ""],
    "ONLI1": ["" , ""],
    "ONLI2": ["" , ""],
    "ONLI3": ["" , ""],
    "OSAVI": ["" , ""],
    "RSI": ["" , ""]
}

top_rel = {
    "EVI2": ["" , "" , "" , "" , "" , ""],
    "NDVI": ["" , "" , "" , "" , ""],
    "MTVI2": ["" , "" , "" , "" , ""],
    "ONLI1": ["" , "" , "" , "" , ""],
    "ONLI2": ["" , "" , "" , "" , ""],
    "ONLI3": ["" , "" , "" , "" , ""],
    "OSAVI": ["" , "" , "" , "" , ""],
    "RSI": ["" , "" , "" , "" , ""],
}

for iv,metric in enumerate(IV):

    # Determinacion de valores de referencia
    r2_max = np.max(indices[metric][1:,4])
    rmse_min = np.min(indices[metric][1:,3])
    abs_metrics[metric][0] = r2_max
    abs_metrics[metric][1] = rmse_min

    s = indices[metric].shape[0]
    for model in range(1,s):

```

```

# Calculo de valores relativos
rel_r2 = 1-((indices[metric][model][4])/r2_max)
rel_rmse = ((indices[metric][model][3])/rmse_min)-1
if model == 1:
    iv_final[metric] =
np.hstack([indices[metric][model],rel_rmse,rel_r2])
    elif model > 1:
        iv_final[metric] =
np.vstack([iv_final[metric],np.hstack([indices[metric][model],rel_rmse,rel_r2])])

rel_sum = iv_final[metric][:,7] + iv_final[metric][:,6] # Calculo de suma
de valores relativos
rel_res = np.abs(iv_final[metric][:,7] - iv_final[metric][:,6]) # Calculo
de resta de valores relativos

ds = np.hstack((iv_final[metric],rel_sum.reshape(-1,1),rel_res.reshape(-
1,1)))

ds = ds[ds[:,8].argsort()] # Ordenamiento ascendente del arreglo que
contiene todos los modelos de por indice con base en la suma de valores relativos

ds_final = ds[:10,:] # Seleccione de los 10 modelos con la suma de valores
relativos mas pequeña

#ds_final = ds_final[ds_final[:,9].argsort()] # Ordenamiento ascendente
del arreglo que contiene todos los modelos de por indice con base en la resta de
valores relativos

best_model[metric] = ds_final[0]

top_rel[metric] = ds_final

name =
rf"C:\Users\juan\Desktop\{manejo}_mejores_modelos_filtro2_top10_{metric}.csv"
dataframe_rel_final =
pd.DataFrame(ds_final,columns=["index", "reg_type", "bands", "rmse", "r2", "RRMSE", "re
l_rmse", "rel_r2", "rel_sum", "rel_res"])
dataframe_rel_final.to_csv(name)

```

```

    key = "REG"+str(reg+1)
    dataframe_final[key] =
pd.DataFrame.from_dict(best_model,orient='index',columns=["index","reg_type","bands","rmse","r2","RRMSE","rel_rmse","rel_r2","rel_sum","rel_res"])
    dataframe_reference[key] =
pd.DataFrame.from_dict(abs_metrics,orient='index',columns=["R2","RMSE"])

export_dataframe = dataframe_final["REG1"]
export_dataframe_reference =dataframe_reference["REG1"]
#export_dataframe =
pd.concat([dataframe_final["REG1"],dataframe_final["REG2"],dataframe_final["REG3"]],axis=0)

export_dataframe.to_csv(rf"C:\Users\juan_\Desktop\{manejo}_mejores_modelos_filtro2_v2.csv")
#export_rel_dataframe.to_csv(rf"C:\Users\juan_\Desktop\{manejo}_mejores_modelos_filtro2_top10.csv")
export_dataframe_reference.to_csv(rf"C:\Users\juan_\Desktop\{manejo}_mejores_modelos_filtro2_metrics.csv")

```

```

import numpy as np
import pandas as pd
path = [r"C:\Users\juan_\Desktop\PLSR_C.csv",
        r"C:\Users\juan_\Desktop\PLSR_C.csv",
        r"C:\Users\juan_\Desktop\PLSR_C.csv"]
dataframe_final = {}
dataframe_rel_final = {}
dataframe_reference = {}
for reg,ruta in enumerate(path):
    data = pd.read_csv(ruta)

    manejo = path[0].split("\\")[4].split("_")[1].split(".")[0]

    #Filtrado por IV

    # Diccionario en el que se guardan todos los modelos por indice

```



```

indices = {
    "SNV": [ "", "", "", "", "", "" ],
    "SMT": [ "", "", "", "", "", "" ],
    "SNV+SMT": [ "", "", "", "", "", "" ],
    "SMT+SNV": [ "", "", "", "", "", "" ],
    "RAW": [ "", "", "", "", "", "" ]
}

models = data.to_numpy()

f = models.shape[0]
IV = ["SNV", "SMT", "SMT+SNV", "SNV+SMT", "RAW"]

# Ciclo para guardar los modelos bajo la llave corrcta en el diccioinario
"indices"
for key in IV:
    for i in range(f):
        if models[i,0] == key:
            indices[key] = np.vstack([indices[key], models[i,:]])

#Filtrado por R2 y RMSE

best_model = {} #Diccionario donde se guarda el mejor modelo de cada indice

# Diccionario en el que se guardan los modelos con sus respectivos alores
relativos de R2 y RMSE
iv_final = {

}

# Diccionario en el que se guarda el R2 mas alto y el RMSE mas bajo para cada
uno de los indices
abs_metrics = { #Estaria bueno incluirlo en la tesis como los valores de
referencia
    "SNV": [ "", "" ],
    "SMT": [ "", "" ],
    "SNV+SMT": [ "", "" ],
    "SMT+SNV": [ "", "" ],
    "RAW": [ "", "" ],
}

```

```

}

top_rel = {
    "SNV": [ "", "", "", "", "", "" ],
    "SMT": [ "", "", "", "", "" ],
    "SNV+SMT": [ "", "", "", "", "" ],
    "SMT+SNV": [ "", "", "", "", "" ],
    "RAW": [ "", "", "", "", "" ],
}

for iv,metric in enumerate(IV):

    # Determinacion de valores de referencia
    r2_max = np.max(indices[metric][1:,4])
    rmse_min = np.min(indices[metric][1:,3])
    abs_metrics[metric][0] = r2_max
    abs_metrics[metric][1] = rmse_min

    s = indices[metric].shape[0]
    for model in range(1,s):

        # Calculo de valores relativos
        rel_r2 = 1-((indices[metric][model][4])/r2_max)
        rel_rmse = ((indices[metric][model][3])/rmse_min)-1
        if model == 1:
            iv_final[metric] =
np.hstack([indices[metric][model],rel_rmse,rel_r2])
        elif model > 1:
            iv_final[metric] =
np.vstack([iv_final[metric],np.hstack([indices[metric][model],rel_rmse,rel_r2])])

        rel_sum = iv_final[metric][:,7] + iv_final[metric][:,6] # Calculo de suma
de valores relativos
        rel_res = np.abs(iv_final[metric][:,7] - iv_final[metric][:,6]) # Calculo
de resta de valores relativos

        ds = np.hstack((iv_final[metric],rel_sum.reshape(-1,1),rel_res.reshape(-
1,1)))

```

```

    ds = ds[ds[:,8].argsort()] # Ordenamiento ascendente del arreglo que
contiene todos los modelos de por indice con base en la suma de valores relativos

    ds_final = ds[:10,:] # Seleccione los 10 modelos con la suma de valores
relativos mas pequeña

    #ds_final = ds_final[ds_final[:,9].argsort()] # Ordenamiento ascendente
del arreglo que contiene todos los modelos de por indice con base en la resta de
valores relativos

    best_model[metric] = ds_final[0]

    top_rel[metric] = ds_final

    name =
rf"C:\Users\juan\Desktop\{manejo}_mejores_modelos_plsr_top10_{metric}.csv"
    dataframe_rel_final =
pd.DataFrame(ds_final,columns=["index","reg_type","bands","rmse","r2","RRMSE","rel_rmse","rel_r2","rel_sum","rel_res"])
    dataframe_rel_final.to_csv(name)

    key = "REG"+str(reg+1)
    dataframe_final[key] =
pd.DataFrame.from_dict(best_model,orient='index',columns=["index","reg_type","bands","rmse","r2","RRMSE","rel_rmse","rel_r2","rel_sum","rel_res"])
    dataframe_reference[key] =
pd.DataFrame.from_dict(abs_metrics,orient='index',columns=["R2","RMSE"])

export_dataframe = dataframe_final["REG1"]
export_dataframe_reference =dataframe_reference["REG1"]
#export_dataframe =
pd.concat([dataframe_final["REG1"],dataframe_final["REG2"],dataframe_final["REG3"]],axis=0)

export_dataframe.to_csv(rf"C:\Users\juan\Desktop\{manejo}_mejores_modelos_plsr_v
2.csv")

```

```
#export_rel_dataframe.to_csv(rf"C:\Users\juan_\Desktop\{manejo}_mejores_modelos_f  
iltro2_top10.csv")  
export_dataframe_reference.to_csv(rf"C:\Users\juan_\Desktop\{manejo}_mejores_mode  
los_plsr_metrics.csv")
```