

**UNIVERSIDAD DE CONCEPCIÓN
FACULTAD DE AGRONOMÍA**



ESTIMACIÓN DE LA PRODUCCIÓN DE FORRAJE DE ALFALFA (*MEDICAGO SATIVA L.*) MEDIANTE ESPECTRORRADIOMETRÍA VIS-NIR

POR

LUCIANO ALBERTO DOMÍNGUEZ NOVA

**MEMORIA PRESENTADA A LA
FACULTAD DE AGRONOMÍA DE LA
UNIVERSIDAD DE CONCEPCIÓN
PARA OPTAR AL TÍTULO DE
INGENIERO AGRÓNOMO.**

CHILLÁN – CHILE

2026

**UNIVERSIDAD DE CONCEPCIÓN
FACULTAD DE AGRONOMÍA**

**ESTIMACIÓN DE LA PRODUCCIÓN DE FORRAJE DE ALFALFA (*MEDICAGO
SATIVA L.*) MEDIANTE ESPECTRORRADIOMETRÍA VIS-NIR**

POR

LUCIANO ALBERTO DOMÍNGUEZ NOVA

**MEMORIA PRESENTADA A LA
FACULTAD DE AGRONOMÍA DE LA
UNIVERSIDAD DE CONCEPCIÓN
PARA OPTAR AL TÍTULO DE
INGENIERO AGRÓNOMO**

CHILLÁN – CHILE

2026

Aprobada por:

Profesor Asistente, Miguel Garriga C.
Lic. Biología, Dr. Cs.

Guía

Investigador, Luis Inostroza F.
Ing. Agrónomo, Dr. Cs.
INIA Quilamapu

Asesor

Profesor Asistente, Abdelhalim Khaled E.
Ingeniero Agrónomo, Dr. Cs.

Asesor

Profesor Asociado, Guillermo Wells M.
Ing. Agrónomo, Mg. Cs.

Decano

RECONOCIMIENTOS

Estudio realizado con el apoyo del proyecto FONDECYT N°1230399, ANID, Chile, orientado al estudio del rendimiento y la calidad del forraje de la alfalfa en entornos mediterráneos propensos a la sequía.

TABLA DE CONTENIDOS

	Página
Resumen	1
Summary	1
Introducción	2
Materiales y Métodos	5
Resultados y Discusión	7
Conclusiones	20
Referencias	21

ÍNDICE DE FIGURAS Y TABLAS

		Página
Figura 1	Distribución de los ensayos de alfalfa en la Estación Experimental de INIA en Cauquenes. (A) Condición de secano y (B) condición de riego suplementario. R1 y R2 representan las repeticiones 1 y 2, respectivamente	6
Figura 1	Rango de firmas espectrales y promedio de las firmas obtenidas en parcelas de alfalfa cultivadas bajo condiciones de riego y secano	8
Figura 2	Relación entre el rendimiento de forraje (RF) predicho y experimental para los mejores modelos de regresión obtenidos para A) secano, B) riego y C) secano y riego combinados, basados en la firma espectral (350-1.075 nm) y modelos multivariados	10
Figura 3	Relación entre el rendimiento de forraje (RF) predicho y experimental en modelos de regresión desarrollados para A) secano, B) riego y C) secano y riego combinados, con longitudes de onda seleccionadas.....	15
Tabla 1	Mejores modelos obtenidos mediante la firma espectral y diferentes métodos multivariados para la predicción del rendimiento de alfalfa en condiciones de secano, de riego y su combinación	9
Tabla 2	Parámetros de los modelos obtenidos mediante regresión lineal múltiple y selección de variables mediante algoritmo genético para la predicción del rendimiento de alfalfa en condiciones de secano, de riego y su combinación.....	14

ESTIMACIÓN DE LA PRODUCCIÓN DE FORRAJE DE ALFALFA (*MEDICAGO SATIVA* L.) MEDIANTE ESPECTRORRADIOMETRÍA VIS-NIR

ESTIMATION OF ALFALFA (*MEDICAGO SATIVA* L.) FORAGE PRODUCTION USING VIS-NIR SPECTRORADIOMETRY

Palabras índice adicionales: producción de biomasa, modelos multivariados, reflectancia espectral, PLS.

RESUMEN

La alfalfa es una leguminosa ampliamente cultivada en todo el mundo por su alto valor forrajero. El rendimiento de forraje constituye un rasgo fundamental tanto desde el punto de vista productivo como en los programas de mejoramiento genético de esta especie. Tradicionalmente, el rendimiento de forraje se mide manualmente, lo que requiere tiempo y mano de obra. Por ello, es necesario desarrollar métodos indirectos para su determinación. Esta investigación tiene como objetivo evaluar el potencial de métodos basados en reflectancia hiperespectral y modelos multivariados para predecir el rendimiento del forraje en alfalfa. Se midió la reflectancia espectral del dosel entre 350 y 1.075 nm y se construyeron modelos predictivos mediante regresión Ridge y regresión de mínimos cuadrados parciales (PLSR), así como modelos de regresión lineal múltiple (RLM) basados en longitudes de onda seleccionadas. En general, los modelos desarrollados alcanzaron un poder de predicción entre 57 % y 67 %, con la mayor precisión en condiciones de secano. Aunque es necesario mejorar la capacidad predictiva de los modelos, los resultados confirman la viabilidad del uso de la reflectancia Vis–NIR, combinada con modelos multivariados, como alternativa a los métodos tradicionales de medición del rendimiento de forraje.

SUMMARY

Alfalfa is a legume widely cultivated worldwide for its high forage value. Forage yield is a fundamental trait, both from a production standpoint and in breeding programs

for this species. Traditionally, forage yield is measured manually, which is time-consuming and labor-intensive. Therefore, it is necessary to develop indirect methods of determination. The objective of this research was to evaluate the potential of methods based on hyperspectral reflectance and multivariate models to predict alfalfa forage yield. The spectral reflectance of the canopy was measured between 350 and 1,075 nm, and predictive models were constructed using Ridge regression, partial least squares regression (PLSR), and multiple linear regression (MLR) based on selected wavelengths. Overall, the models developed achieved predictive accuracies of 57%–67%, with the highest accuracy under rainfed conditions. Although the predictive capacity of the models needs improvement, the results confirm the viability of using Vis–NIR reflectance combined with multivariate models as an alternative to traditional methods for measuring forage yield.

INTRODUCCIÓN

La alfalfa (*Medicago sativa* L.) es una leguminosa perenne ampliamente cultivada a nivel mundial por su alto valor forrajero; destaca por su contenido de proteína cruda, carbohidratos solubles, minerales esenciales y compuestos bioactivos que favorecen el rendimiento animal (Fan et al., 2018; Radović et al., 2009; Rafińska et al., 2017). Se caracteriza por desarrollar una raíz pivotante profunda, que puede alcanzar los dos metros de profundidad en condiciones favorables, lo que le permite acceder a capas de humedad profundas y tolerar períodos de sequía prolongados (Demagnet, 2019).

Su gran adaptabilidad a factores abióticos adversos, su alto valor nutricional y su excelente productividad le han valido a la alfalfa el título de “reina de las forrajeras”, una denominación ampliamente utilizada en la literatura agronómica (Russelle, 2001; Putnam., 2019). Esta leguminosa perenne tiene una amplia adaptabilidad a diferentes condiciones climáticas y de suelo y un alto potencial de rendimiento; es capaz de producir forraje verde durante gran parte del año, con una vida productiva de más de 5 años (Rashmi et al., 1997; Shi et al., 2017). Además de su alto contenido proteico, la alfalfa destaca por aportar una amplia variedad de compuestos bioactivos, incluidos carbohidratos, minerales, vitaminas y metabolitos

secundarios con propiedades beneficiosas para la salud animal (Radović et al., 2009; Rafińska et al., 2017). Desde una perspectiva ecológica, la alfalfa es valiosa por su raíz profunda, que mejora la estructura y la fertilidad del suelo, lo que contribuye a una producción ganadera sostenible (Radović et al., 2009; Sakiroglu et al., 2011). La capacidad de la alfalfa para producir una alta biomasa con bajos insumos agrícolas ha despertado interés en su uso como biocombustible (Bhattarai et al., 2013) e incluso como fuente de metabolitos secundarios para la industria (Rafińska et al., 2017).

En Chile, se estima que hay aproximadamente 75.000 hectáreas dedicadas al cultivo de alfalfa, con una producción anual de cerca de 1.350.000 toneladas (Valenzuela, 2017). El cultivo de alfalfa se extiende desde los valles transversales del desierto norte hasta la región de Magallanes. Se estima que cerca del 70% de la superficie nacional de alfalfa se concentra entre Valparaíso y Biobío (Troncoso, 2016).

En el contexto del cambio climático, diversos estudios han evidenciado que el aumento de las temperaturas y las alteraciones en los patrones de precipitación podrían afectar negativamente la producción forrajera, tanto en su rendimiento como en su calidad nutricional. Estas condiciones inciden directamente en el crecimiento vegetal, la eficiencia fotosintética y el metabolismo de las plantas forrajeras como la alfalfa, lo que puede traducirse en una disminución de la biomasa útil y en un deterioro de su valor nutricional (Garriga et al., 2020; del Pozo et al., 2017). Tales efectos resultan especialmente relevantes en zonas de secano, donde la disponibilidad hídrica es más limitada. Esta situación resalta la necesidad de desarrollar nuevas variedades forrajeras capaces de mantener altos niveles de producción incluso en condiciones adversas, como las sequías prolongadas, a fin de responder a los desafíos del cambio climático (Humphreys, 2005).

Los factores abióticos, como la sequía, representan limitantes clave para el crecimiento y desarrollo de la alfalfa, afectando tanto la producción de biomasa aérea como la subterránea, así como la distribución de recursos entre órganos, lo que condiciona su rendimiento en sistemas agrícolas bajo estrés hídrico (Luo et al., 2020). Además, la producción de biomasa en leguminosas perennes, como la

alfalfa, se ve significativamente afectada por la interacción genotipo \times ambiente y presenta una baja heredabilidad (Abberton y Marshall, 2005; Taylor, 2008). Por lo cual, la selección de genotipos con alto potencial de rendimiento y persistencia durante períodos prolongados de sequía constituye un objetivo crucial para los programas de mejoramiento de la alfalfa en ambientes mediterráneos (del Pozo et al., 2017).

Las mediciones manuales son fundamentales en la agricultura para evaluar parámetros como la altura de las plantas, el estado fenológico o el rendimiento, con un alto grado de precisión. Sin embargo, estos métodos presentan limitaciones importantes: son intensivos en mano de obra, demandan tiempo considerable y presentan baja escalabilidad, lo que reduce su eficiencia en sistemas productivos modernos (Araus y Cairns, 2014) y, más aún, en programas de mejoramiento genético de plantas, en los cuales se evalúan simultáneamente ciento o miles de genotipos, lo que limita su escalabilidad en programas de mejoramiento genético o en sistemas de producción de gran extensión (Gámez et al., 2024).

Frente a este desafío se han desarrollado tecnologías de fenotipado de alto rendimiento que permiten mediciones rápidas, no destructivas y en tiempo real, lo que representa una solución más efectiva para el monitoreo agronómico a gran escala. Estas pueden aplicarse al mejoramiento y a la selección de genotipos de alfalfa para determinar el estado de las plantas, la producción de biomasa y la calidad del forraje de manera más rápida y económica. Entre estas técnicas, destaca la espectroscopía hiperespectral, que permite medir la luz reflejada por la hoja o el dosel de cultivo. La luz reflejada en la región visible se asocia principalmente con la absorción de pigmentos fotosintéticos, como la clorofila, mientras que las regiones del infrarrojo cercano (NIR) y del infrarrojo de onda corta (SWIR) proporcionan información sobre el contenido hídrico, los compuestos estructurales y la concentración de nutrientes en los tejidos vegetales (Araus et al., 2022).

El uso de espectrorradiómetros portátiles ha demostrado ser una herramienta eficaz para la estimación no destructiva de parámetros fisiológicos y productivos en cultivos forrajeros como la alfalfa (Garriga et al., 2020; Gámez et al., 2024). Estos

dispositivos permiten medir la reflectancia en un amplio espectro (350–2,500 nm), capturando información tanto del dosel como de las hojas sin necesidad de procesamiento previo de las muestras, lo que optimiza su aplicabilidad en condiciones reales de campo (Gámez et al., 2024). Esta técnica se ha usado no solo para estimar variables productivas, como el rendimiento, sino también para evaluar rasgos fisiológicos asociados al estado hídrico, al índice de área foliar o a la composición isotópica, lo que permite una comprensión más integral del comportamiento del cultivo (Garriga et al., 2020; Feng et al., 2020; Cevoli et al., 2021).

Con base en estos antecedentes, la presente investigación tiene como objetivo evaluar el potencial de métodos basados en reflectancia hiperespectral y modelos multivariados para predecir el rendimiento del forraje en alfalfa. Esta aproximación busca contribuir al aumento de la eficiencia en la selección de genotipos en el proceso de mejoramiento genético de la alfalfa mediante la implementación de métodos más rápidos y económicos para determinar el rendimiento forrajero.

MATERIALES Y MÉTODOS

Material vegetal y condiciones de crecimiento

Se evaluaron 250 genotipos de alfalfa, que son progenies de medios hermanos y fueron obtenidos a partir de 70 accesiones tolerantes a la sequía y de diverso origen (Chile, Azerbaiyán, Kazajstán, Estados Unidos, Australia y España) por el Programa de Mejoramiento Genético (PMG) de alfalfa del Instituto de Investigaciones Agropecuarias (INIA). Las plantas se establecieron en la Estación experimental de INIA en Cauquenes (35°57'S y 72°19'O). Las parcelas experimentales constaron de 4 hileras, cada una de 1 metro de longitud y separadas entre sí por 20 cm. En cada hilera se establecieron plántulas a 10 cm de distancia entre sí (40 plantas por parcela).

Antes del trasplante, el suelo se preparó adecuadamente. Cada parcela fue suplementada con 200 kg ha⁻¹ de superfosfato triple (46% P₂O₅), 2000 kg ha⁻¹ de CaCO₃, 100 kg ha⁻¹ de sulfato de potasio (50% K₂O y 54% SO₄) y 20 kg ha⁻¹ de boronatrocalcita (11 % B). Se establecieron dos condiciones hídricas: una sin riego

y otra con riego (15 mm por semana). Ambas condiciones se organizaron en un diseño experimental α -lattice con dos repeticiones. Cada réplica estuvo compuesta por 10 bloques incompletos, cada uno con 25 progenies de medios hermanos (1.000 parcelas en total; Figura 1).

Figura 4. Distribución de los ensayos de alfalfa en la Estación Experimental de INIA en Cauquenes. (A) Condición de secano y (B) condición de riego suplementario. R1 y R2 representan las repeticiones 1 y 2, respectivamente.



Rendimiento de forraje

El rendimiento de forraje (RF) se evaluó en cada parcela (0,8 m²) cortando las plantas a 5 cm del suelo. Se determinó el peso fresco de las muestras cosechadas en campo y, posteriormente, se secaron a 65 °C en estufa con ventilación forzada hasta alcanzar un peso constante. Se realizó un total de 6 cortes durante la temporada.

Reflectancia espectral del dosel

La reflectancia del dosel se midió en cada parcela un día antes de la cosecha. Para ello, se utilizó un espectrorradiómetro portátil FieldSpec HandHeld 2 (ASD Inc., EE.UU.). El espectrorradiómetro se colocó sobre un trípode a 25 cm del dosel. El sensor del equipo cubrió un área circular de 12,5 cm de diámetro. Se tomaron tres espectros por parcela, que posteriormente se promediaron. Un espectro completo consta de 725 bandas con un intervalo de 1 nm entre 350 y 1.075 nm. Las

mediciones se realizaron en días despejados de 11:00 a 16:00 h. Se realizó una calibración radiométrica periódicamente mediante un panel blanco de referencia Spectralon (ASD Inc., EE.UU.).

Desarrollo de modelos predictivos

Se utilizaron datos de reflectancia espectral para desarrollar modelos multivariados que permitan estimar el rendimiento del forraje. Estos se obtuvieron para tres condiciones: seco, riego y una tercera que combina ambas (riego-seco).

Antes del modelado, los datos espectrales se preprocesaron para eliminar valores atípicos y reducir el ruido. Posteriormente, se construyeron modelos multivariados utilizando la firma espectral completa, es decir, la reflectancia en todas las longitudes de onda comprendidas entre 350 y 1.075 nm, y modelos con longitudes de onda previamente seleccionadas.

Los modelos con el uso de la firma espectral completa se obtuvieron mediante Regresión de Mínimos Cuadrados Parciales (PLSR), Regresión basada en Componentes Principales (PCR) y Regresión Ridge (RR). Estos fueron implementados en MATLAB, versión R2023a (The MathWorks Inc., 2023), mediante un "toolbox" de regresión (Consonni et al., 2021). Para la construcción de los modelos, el total de mediciones se dividió aleatoriamente en dos grupos: el 80 % de los datos se usó para la calibración del modelo y el 20 % restante para su validación.

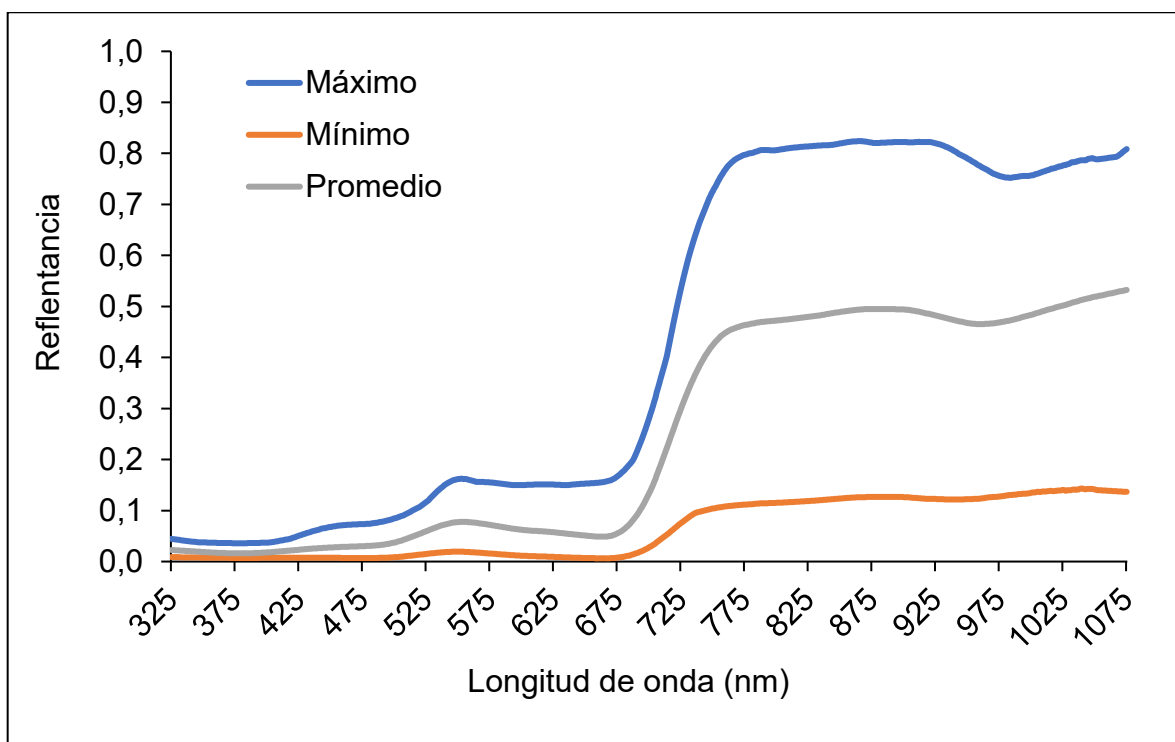
Los modelos con longitudes de onda específicas se desarrollaron utilizando el conjunto completo de datos. Estas bandas espectrales fueron seleccionadas mediante Algoritmo Genético (AG), en el cual diferentes combinaciones de variables (longitudes de onda) se "aparean" entre sí, mutan, se cruzan, se reproducen y luego evolucionan a través de generaciones sucesivas hacia una solución óptima (Reeves, 2010). Las condiciones de simulación de los AG fueron: número de población 100, porcentaje de mutación 35 % y número de generaciones 200. Los modelos obtenidos se validaron mediante el método "leave-one-out" (LOO). Todo ello se realizó mediante el programa BuildQSAR (de Oliveira y Gaudio, 2000).

En ambos casos, el desempeño predictivo de cada modelo se evaluó mediante el coeficiente de determinación (R^2) y el error, tanto en la calibración como en la validación.

RESULTADOS Y DISCUSIÓN

La Figura 2 muestra las firmas espectrales máxima, mínima y promedio de todas las mediciones realizadas en las parcelas de alfalfa. Estas representan el patrón de reflectancia espectral típico de una planta, en el que se observa una baja reflectancia en la región visible (~400–680 nm) debido a la alta absorción de luz por los pigmentos fotosintéticos. Específicamente, las clorofilas a y b absorben fuertemente en el azul (~430–460 nm) y en el rojo (~640–680 nm), y los carotenoides, principalmente, en el azul-verde. En la región del verde (~550 nm) se absorbe menos y se refleja más, lo que le confiere al verde su color característico.

Figura 5. Rango de firmas espectrales y promedio de las firmas obtenidas en parcelas de alfalfa cultivadas bajo condiciones de riego y seco.



Posteriormente se encuentra el borde del rojo (~680 a 750 nm), donde ocurre una transición abrupta entre la fuerte absorción de la clorofila en el rojo visible (~660–680 nm) y la alta reflectancia del infrarrojo cercano (NIR) (> 700 nm) debida a la estructura interna de las hojas (Ge et al., 2019). El punto de máxima pendiente suele ubicarse entre 700 y 730 nm, dependiendo de la especie vegetal, del estado

fisiológico, del contenido de clorofila y del estrés hídrico o nutricional (Su et al., 2025; Falcioni et al., 2023a).

En la zona del NIR (~700–1.300 nm), en este caso entre 700 y 1.075 nm, se produce una alta reflectancia foliar debido a que en este rango no existe absorción significativa por pigmentos fotosintéticos, predominando la interacción de la radiación con la estructura interna del mesófilo foliar, particularmente en las interfaces aire–agua–pared celular, lo que genera múltiples reflexiones y dispersión interna (Jacquemoud y Ustin, 2019). Esta elevada reflectancia contribuye al balance energético de la hoja y reduce la fracción de energía absorbida, lo que ayuda a evitar el sobrecalentamiento, dado que el NIR representa una porción importante de la radiación solar incidente.

Con la información contenida en toda la firma espectral se desarrollaron modelos multivariados basados en PLSR, PCR y regresión Ridge para las condiciones de riego y de seco y para la combinación de ambas. Los mejores resultados se obtuvieron con PLSR y Ridge (Tabla 1), empleando distintos métodos de preprocesamiento para optimizar el ajuste.

Tabla 3. Mejores modelos obtenidos mediante la firma espectral y diferentes métodos multivariados para la predicción del rendimiento de alfalfa en condiciones de seco, de riego y su combinación.

Condición	Modelo	Subgrupos	R ² cal	R ² val	REMC Validación (kg ha ⁻¹)
Secano	PLS	n _{cal} = 619 n _{val} = 154	0,623	0,629	958,9
Riego	Ridge	n _{cal} = 878 n _{val} = 220	0,744	0,566	1210,2
Combinado	Ridge	n _{cal} = 1496 n _{val} = 376	0,701	0,574	1164,7

Ridge: Regresión Ridge; PLS: Regresión de Mínimos Cuadrados Parciales; R²cal: coeficiente de determinación de la calibración; R²val: coeficiente de determinación de la validación; REMC: raíz del error medio cuadrático; n_{cal}: número de datos en el grupo de calibración; n_{val}: número de datos en el grupo de validación

Para la condición de seco (Tabla 1; Figura 3A), la mayor estimación del rendimiento de forraje se obtuvo con el método PLSR, tras preprocesar los datos

mediante corrección multiplicativa de la dispersión (MSC) y autoescalado. Este modelo mostró un poder predictivo (R^2_{val}) del 63 %. En la condición de riego (Tabla 1; Figura 3B), el mejor modelo se obtuvo con regresión Ridge y presentó un poder predictivo 6,3 % menor que el de Secano. Por último, en la condición combinada de riego y secano (Tabla 1; Figura 3C), el modelo Ridge fue el que presentó los mejores resultados, con un poder de predicción similar al obtenido en Riego. En las dos últimas condiciones, los mejores modelos se obtuvieron sin preprocesamiento de datos.

El uso de modelos multivariados aplicados a espectros completos ha demostrado ser una herramienta eficaz para estimar variables fisiológicas y productivas en alfalfa. A diferencia de estudios que se han centrado en índices de vegetación derivados de combinaciones específicas de bandas espectrales (Cevoli et al., 2021; Chandel et al., 2021; Feng et al., 2020), en el presente estudio se emplearon todas las longitudes de onda individuales como variables predictoras.

Figura 6. Relación entre el rendimiento de forraje (RF) predicho y experimental para los mejores modelos de regresión obtenidos para A) secano, B) riego y C) secano y riego combinados, basados en la firma espectral (350-1.075 nm) y modelos multivariados.

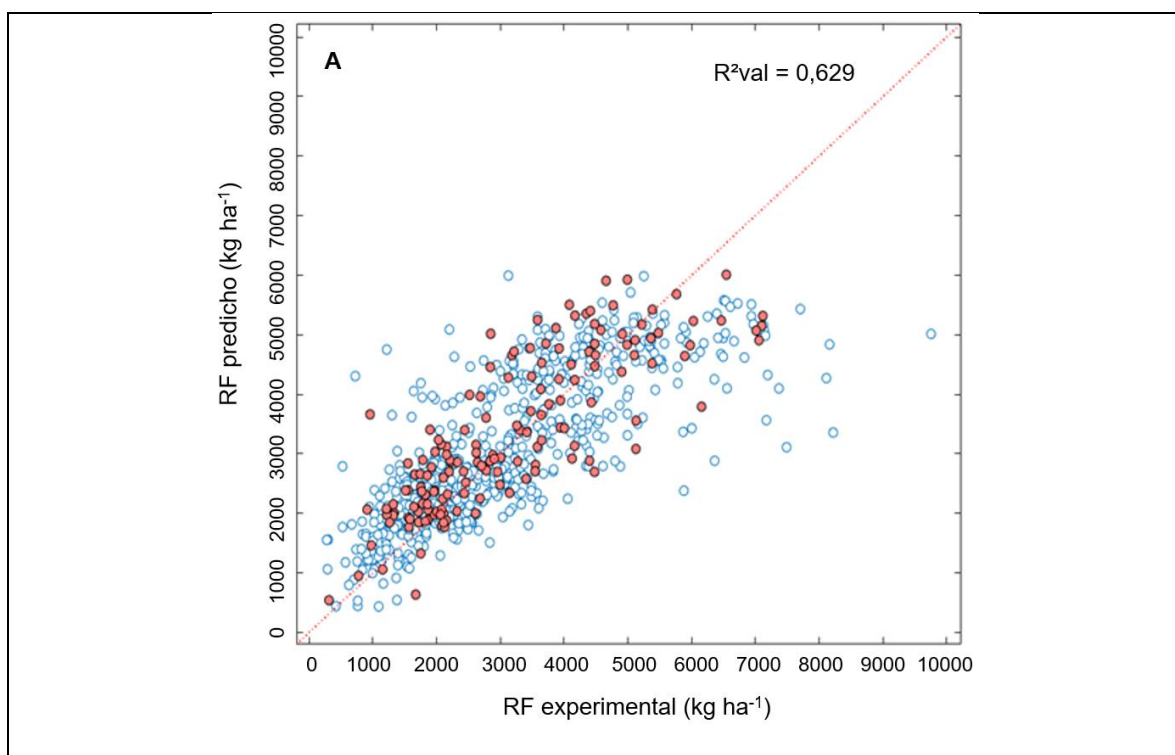
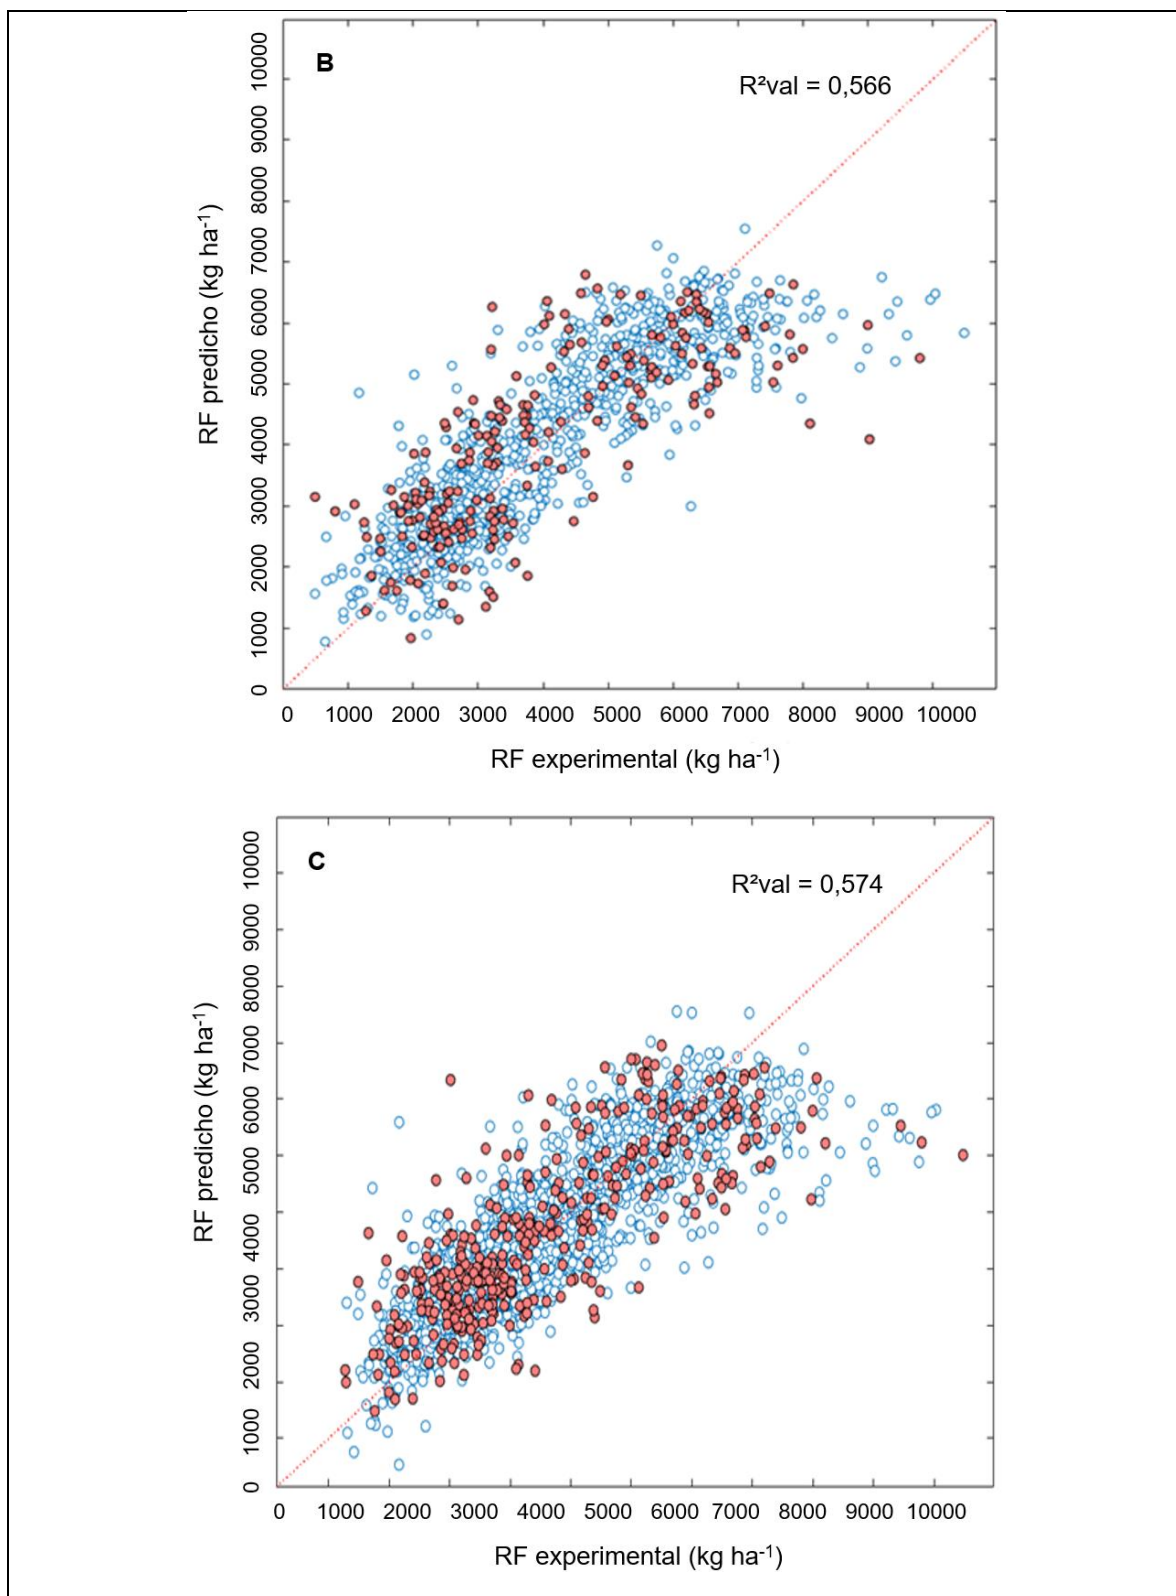


Figura 7. Continuación.



En azul, datos del conjunto de calibración; en rojo, datos del conjunto de validación. Línea diagonal recta 1:1.

Este enfoque permitió capturar la variabilidad espectral del cultivo, en particular bajo distintas condiciones hídricas y en diferentes etapas fenológicas. Además, esta estrategia contribuye a evitar la saturación de las bandas del infrarrojo cercano (NIR) en fases avanzadas del crecimiento, fenómeno que puede reducir la sensibilidad espectral y el desempeño de los modelos predictivos (Kayad et al., 2016; Garriga et al., 2020).

Los modelos desarrollados, en particular el PLSR bajo seco ($R^2_{\text{val}} = 0,629$), mostraron un rendimiento comparable al reportado por Garriga et al. (2020), quienes aplicaron regresión basada en máquina de soporte vectorial (SVR) y obtuvieron un R^2_{val} de 0,71 para el rendimiento de forraje en condiciones de estrés hídrico. A diferencia del trabajo de Garriga et al. (2020), en el que se evaluaron 9 cultivares en cuatro localidades, este estudio se basó en la medición de 250 progenies de medio hermanos en un único sitio, lo que destaca el potencial de su aplicación en etapas tempranas de la selección genotípica. Adicionalmente, el desempeño predictivo obtenido en este estudio se encuentra cercano al rango reportado por Noland et al. (2018), quienes obtuvieron R^2 de hasta 0,79 al usar imágenes multiespectrales junto con covariables meteorológicas tomadas en el momento de la cosecha.

Tedesco et al. (2022) ofrecen una revisión sistemática del uso de la teledetección para estimar la biomasa y la calidad de la alfalfa. Si bien enfatizan el potencial de las plataformas aéreas por su mayor cobertura espacial, también reconocen que los sensores portátiles, como los espectrorradiómetros de campo, ofrecen mayor precisión para validar modelos a escala local.

Feng et al. (2020) desarrollaron un modelo predictivo del rendimiento de alfalfa a partir de imágenes hiperespectrales tomadas con un dron y de algoritmos combinados, como Random Forest, SVR y KNN (k-Nearest Neighbors), alcanzando un R^2 de 0,874 y un RMSE de 221 kg ha⁻¹. Aunque este desempeño es superior, su enfoque requiere infraestructura y capacidades computacionales avanzadas. En contraste, el presente estudio demuestra que modelos como Ridge y PLSR, aplicados a datos de espectrorradiometría portátil, pueden ofrecer niveles de precisión aceptables con menor complejidad operativa. Asimismo, Chandel et al. (2021) utilizaron vehículos aéreos no tripulados con sensores multiespectrales y

térmicos para estimar el rendimiento de la alfalfa, aplicando índices como el MNLI (Modified Non-Linear Index) y el CWSI (Crop Water Stress Index). Su modelo MLR obtuvo un $R^2 = 0,64$, comparable al obtenido en este estudio para las tres condiciones evaluadas (R^2 val entre 0,57 y 0,63), lo que refuerza la relevancia de considerar indicadores de estrés y vigor en la predicción del rendimiento. Por otro lado, Cevoli et al. (2021) evaluaron el uso de imágenes hiperespectrales VIS–NIR (400–1.000 nm) para estimar el contenido de humedad en alfalfa, obteniendo un R^2 de 0,84 y un REMC de 2,05 %. Aunque su objetivo no fue estimar el rendimiento, el uso de modelos PLS refuerza la aplicabilidad de esta técnica para modelar variables fisiológicas.

Asimismo, Gámez et al. (2024) utilizaron información de reflectancia espectral en el rango de 350–2.500 nm y regresión PLS para estimar la calidad del forraje de alfalfa, logrando valores de R^2 elevados ($R^2 > 0,75$) para proteínas totales y FDN (fibra detergente neutra). En este estudio se mejoró la predicción al incorporar datos fenológicos y meteorológicos. El modelo más preciso para la predicción de la biomasa alcanzó un R^2 de 0,71. Los modelos para variables como nitrógeno total ($R^2 = 0,70$), sacarosa ($R^2 = 0,65$), flavonoides ($R^2 = 0,56$) y proteína soluble ($R^2 = 0,54$) mostraron desempeños inferiores, lo cual coincide con la tendencia observada en diversos estudios, en los que la biomasa suele estimarse mejor mediante modelos espectrales que los compuestos bioquímicos.

Además de los modelos basados en toda la firma espectral, se desarrollaron modelos para cada condición (secano, riego y riego + seco) mediante regresión lineal múltiple y reflectancia en longitudes de onda seleccionadas. Para la selección de variables se utilizó Algoritmo Genético (AG), un método de optimización inspirado en la evolución biológica, que se emplea en el modelamiento multivariado para seleccionar variables, optimizar parámetros de modelos o encontrar combinaciones de predictores que maximicen la precisión del modelo (Ge et al., 2019; Baranowski et al., 2023)

Los modelos desarrollados para los dos ambientes específicos y para su combinación mostraron poderes de predicción similares. El modelo desarrollado para la condición de seco (Tabla 2; Figura 4A) presentó un poder predictivo del

66 %. Este modelo incluyó reflectancia a 10 longitudes de onda, entre ellas dos en el visible (528 y 553 nm), dos en el borde del rojo (737 y 749 nm) y cinco en el NIR (786, 831, 886, 904 y 998 nm). Para la condición de riego (Tabla 2; Figura 4B), se obtuvo una predicción del 65 %. El modelo generado incluyó las bandas 342, 425, 461, 539, 569, 590, 649, 768, 807 y 988 nm. Finalmente, el modelo para ambos ambientes combinados (Figura 4C) obtuvo una precisión del 63 %. Las longitudes de onda seleccionadas fueron: 404, 416, 460, 535, 570, 659, 756, 788, 793 y 980 nm.

Tabla 4. Parámetros de los modelos obtenidos mediante regresión lineal múltiple (RLM) y selección de variables mediante algoritmo genético para la predicción del rendimiento de alfalfa en condiciones de secano, de riego y su combinación.

Condición	Número de muestra	R ² cal	R ² val	EXPRESS (kg ha ⁻¹)
Secano	619	0,669	0,665	930,7
Riego	878	0,651	0,650	1108,0
Combinado	1496	0,626	0,629	1099,1

R²cal: coeficiente de determinación de la calibración; R²val: coeficiente de determinación de la validación; EXPRESS: suma estandarizada de los errores de predicción.

Las bandas seleccionadas en los modelos se distribuyen principalmente entre los rangos de absorción de la clorofila (430–680 nm) y el plateau del NIR (750–900 nm), regiones espectrales comúnmente asociadas a parámetros fisiológicos como el contenido de pigmentos, el vigor del dosel y la acumulación de biomasa (Starks et al., 2016; Garriga et al., 2020).

La región visible del espectro electromagnético (VIS; 375–700 nm) constituye una ventana espectral clave para el diagnóstico del estado fisiológico y bioquímico de las plantas. En este rango, la reflectancia foliar está dominada por las absorciones electrónicas específicas de los pigmentos. Las bandas de absorción en el azul (~450 nm) y en el rojo (~670 nm), atribuibles a las clorofilas a y b, generan un máximo relativo de reflectancia en la región verde (~550 nm), donde la absorción es mínima (Ge et al., 2019; Falcioni et al., 2023a). Esta respuesta espectral permite no solo estimar la concentración absoluta de clorofila, sino también evaluar las

proporciones entre pigmentos, que sirven como indicadores indirectos del estado nutricional, la senescencia o el estrés abiótico (Ran et al., 2025).

Figura 8. Relación entre el rendimiento de forraje (RF) predicho y experimental en modelos de regresión desarrollados para A) seco, B) riego y C) seco y riego combinados, con longitudes de onda seleccionadas.


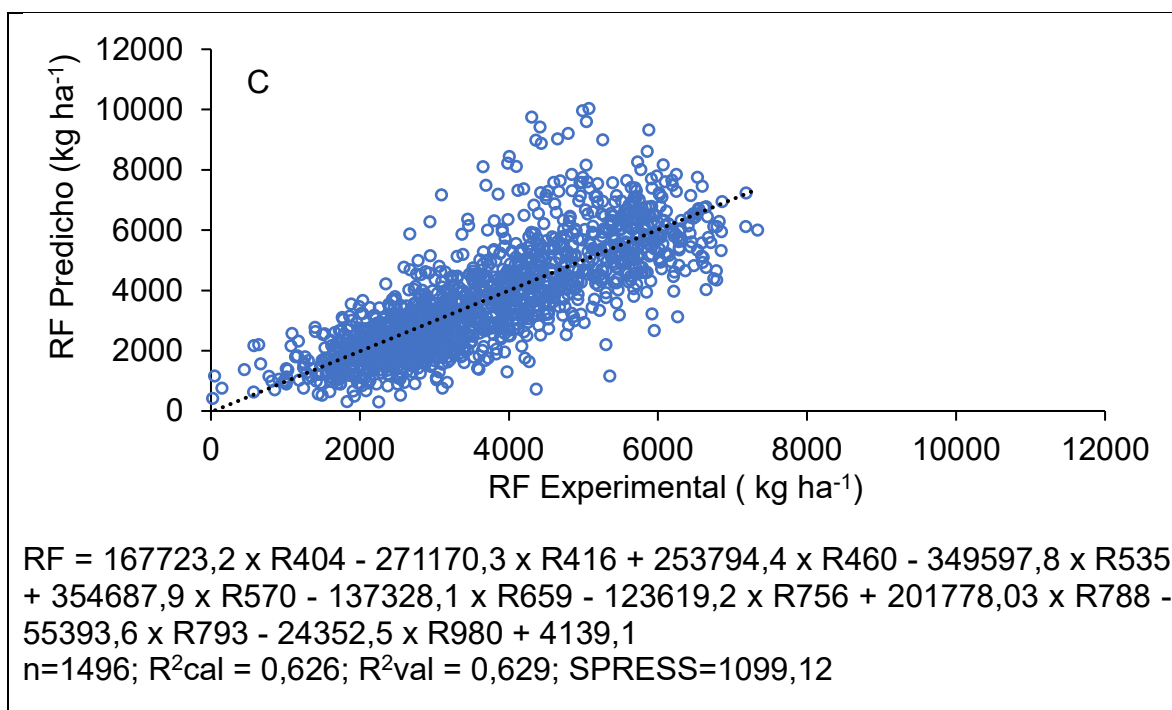


Figura 9. Continuación.



La línea diagonal representa la relación 1:1. n: número de datos. R²cal: coeficiente de determinación de la calibración; R²val: coeficiente de determinación de la validación; EXPRESS: suma estandarizada de los errores de predicción (kg ha⁻¹).

Estudios recientes han validado la capacidad del espectro visible para estimar parámetros bioquímicos, como el contenido de clorofila, mediante métodos multivariados como PLSR y SVR. En maíz, Ge et al. (2019) reportaron valores de R²val superiores a 0,9 con espectros completos VIS–NIR–SWIR (infrarrojo de onda corta), mientras que en cítricos, Li et al. (2023) demostraron que incluso algoritmos ligeros de aprendizaje automático aplicados a bandas del VIS (400–700 nm) lograron predicciones robustas del contenido de clorofila, con R²val entre 0,87 y 0,91. Esto coincide con los hallazgos de este estudio, en el que diversas bandas del rojo y del borde rojo (680–720 nm) fueron seleccionadas como determinantes del rendimiento del forraje de alfalfa.

Además de la clorofila, los carotenoides y las antocianinas pueden cuantificarse con buena precisión en el rango VIS (Falcioni et al., 2023a; 2023c), mediante sensores portátiles VIS–NIR y análisis multivariados. Adicionalmente, Ran et al. (2025) introdujeron índices espectrales escalables desde la hoja hasta el dosel, lo

cual se alinea directamente con la metodología empleada en este estudio para determinar el rendimiento de forraje de alfalfa a partir de mediciones del dosel.

Sin embargo, la aplicación del espectro VIS conlleva ciertas consideraciones prácticas. La geometría de iluminación afecta la señal, por lo que se requiere una calibración espectral con paneles de referencia, como se realizó en este estudio. Asimismo, la saturación en casos de alta concentración de pigmentos puede limitar la sensibilidad de los índices univariados; no obstante, el uso de modelos multivariados de espectro completo o basados en diversas bandas seleccionadas permite mitigar este problema y mejorar la estabilidad predictiva (Ge et al., 2019; Falcioni et al., 2023c)

Incluso sin considerar el NIR, las bandas del espectro visible permiten diferenciar el estado de nitrógeno foliar bajo diferentes disponibilidades hídricas en cultivos como el apio y la remolacha (Siłuch et al., 2023). Esta capacidad discriminativa también fue evidente en nuestros resultados, donde se observaron diferencias espectrales claras entre condiciones de riego y de seco, especialmente en el borde del rojo (680–710 nm) y en la región azul (430–480 nm), lo que refuerza la utilidad de esta región del espectro para estimar la productividad bajo estrés hídrico.

Aunque la banda SWIR no fue completamente cubierta en el presente estudio debido a las limitaciones del equipo (espectrómetro de 350–1.075 nm), antecedentes recientes destacan el alto valor diagnóstico de este rango para estimar no solo el rendimiento, sino también parámetros bioquímicos y estructurales en cultivos forrajeros, en particular en la alfalfa. En el estudio de Gámez et al. (2024), se utilizó un rango más amplio de longitudes de onda (350 – 2.500 nm), obteniendo 71 % de predicción de biomasa en alfalfa, así como 70 % para nitrógeno total, 65 % para contenido de sacarosa, 56 % para contenido de flavonoides y 54 % para proteína soluble.

Del mismo modo, la combinación de reflectancia, transmitancia y absorbancia en el rango SWIR ha mostrado mejoras significativas en la predicción de parámetros fotosintéticos, como la fluorescencia de clorofila a y la eficiencia cuántica (Falcioni et al., 2023b). Estas integraciones metodológicas permiten caracterizar con mayor precisión la calidad del tejido vegetal y el rendimiento fisiológico.

A pesar de sus ventajas, el uso de la región del infrarrojo de onda corta en condiciones de campo presenta limitaciones instrumentales relevantes, ya que los espectrómetros que operan en este rango requieren una alta relación señal–ruido (SNR, Signal-to-Noise Ratio). No obstante, avances recientes en espectrómetros portátiles y en técnicas de selección de variables, como el Muestreo Competitivo Adaptativo con Ponderación/reponderación (CARS), la Importancia de las Variables en la Proyección (VIP) y el Algoritmo Genético (GA), han mejorado la robustez de los modelos espectrales en condiciones de campo (Ge et al., 2019; Baranowski et al., 2023).

Desde una perspectiva aplicada, los resultados de estos estudios muestran el potencial de incluir bandas SWIR en futuras campañas espectrales sobre alfalfa, especialmente para capturar variables asociadas al contenido hídrico, la lignina, la celulosa y la calidad nutricional del forraje, aspectos directamente vinculados al objetivo productivo de este cultivo.

Los espectros utilizados abarcaron las regiones VIS y NIR (325–1.075 nm) y bandas seleccionadas para el desarrollo de los modelos lineales múltiples mediante algoritmo genético, las que coinciden en parte con la selección de bandas más informativas identificadas por Gámez et al. (2024), quienes demostraron que la región VIS y el plateau del NIR (700–1100 nm) aportan significativamente en la predicción de parámetros como biomasa, contenidos de azúcares y de nitrógeno. En este estudio, las bandas de mayor peso predictivo bajo secano se localizaron en los rangos de 381 a 998 nm, en riego entre 342 y 988 nm y en la combinación de ambos tratamientos entre 404 y 980 nm, lo que refleja un patrón similar.

Asimismo, se ha documentado que la fenología y las condiciones climáticas influyen de manera significativa en los rasgos bioquímicos del cultivo (Fan et al., 2018; Kume et al., 2001; Noland et al., 2018). En alfalfa, estas variables afectan tanto el rendimiento como el contenido de pigmentos y nutrientes, lo que respalda su inclusión como predictores auxiliares en los modelos desarrollados. La incorporación de variables agroclimáticas, como la temperatura y el GDD (grados-día de crecimiento), puede contribuir a mejorar la precisión de los modelos. En la presente investigación, si bien no se incorporaron directamente estos factores, la

evaluación según las condiciones de riego y seco permitió detectar diferencias relevantes en el comportamiento espectral del cultivo. En este sentido, se ha reportado un mejor desempeño de los modelos bajo estrés hídrico, ya que esta condición tiende a amplificar las diferencias en las firmas espectrales de las plantas (Tedesco et al., 2022). Lo cual se observó principalmente en este estudio en los modelos desarrollados con la firma espectral completa.

Aunque se requiere mejorar los niveles de predicción de rendimiento de forraje, este estudio evidencia que el uso de la espectrorradiometría VIS–NIR, en conjunto con métodos de modelamiento multivariado, tiene el potencial para predecir de manera rápida y eficiente el rendimiento de forraje de alfalfa y puede constituir una herramienta estratégica para el monitoreo agronómico y la selección genotípica temprana en programas de mejoramiento de esta especie. Además, aporta evidencia complementaria de la versatilidad de esta herramienta para abordar diversos objetivos fisiológicos y productivos.

CONCLUSIONES

1. La reflectancia del dosel en el rango de 350–1.075 nm, combinada con modelos multivariados, permite estimar el rendimiento de forraje de alfalfa con niveles de predicción moderados pero consistentes ($R^2_{val} \approx 0,57-0,67$), lo que confirma su potencial como alternativa a las mediciones tradicionales.
2. Las mejores estimaciones de rendimiento de forraje mediante el uso de la firma espectral se obtuvieron con regresión PLS en seco y, en riego y en condiciones combinadas, con regresión Ridge.
3. La selección de longitudes de onda mediante algoritmo genético permitió construir modelos con precisiones comparables a las basadas en el espectro completo, reduciendo la complejidad del modelado sin una pérdida significativa de información.
4. Aunque los resultados son consistentes, la capacidad predictiva del rendimiento sigue siendo moderada y podría mejorarse al incorporar información adicional para su uso en el fenotipado de alto rendimiento y en la selección temprana de genotipos de alfalfa.

REFERENCIAS

1. Abberton, M., R. MacDuff, M. Marshall, R. Collins, A. Hirata, Y. Takanashi y N. Yamada. 2005. Grassland genetic resources and genetic improvement: new challenges and technologies. *Grassl. Sci.* 51(3): 161–164.
2. Araus, J.L. y J.E. Cairns. 2014. Field high-throughput phenotyping: the new crop breeding frontier. *Nat. Rev. Genet.* 15(12): 847–857.
3. Araus, S. Carlisle, O. Vergara-Díaz, A. Gracia-Romero, F. Zahra, J. Segarra, M. Buchailot, M. Secret and J, Bort. 2022. Crop phenotyping in a context of global change: What to measure and how to do it. *J. Integr. Plant Biol.* 64(2): 592–618.
4. Bhattarai, K., E. Brummer y M. Monteros. 2013. Alfalfa as a bioenergy crop. pp: 207–231. In: M.C. Saha, H.S. Bhandari y J.H. Bouton (Eds.). *Bioenergy feedstocks. Breeding and genetics.* Wiley-Blackwell Publishing. Hoboken, NJ, USA.
5. Chandel, L. Khot and L. Yu. 2021. Alfalfa (*Medicago sativa* L.) crop vigor and yield characterization using high-resolution aerial multispectral and thermal infrared imaging technique. *Comput. Electron. Agric.* 182: 105999.
6. Cevoli, L. Di Cecilia, L. Ferrari, A. Fabbri and G. Molari. 2021. Potential of in-field Vis/NIR hyperspectral imaging to monitor quality parameters of alfalfa. En: *Proceedings of the 2021 IEEE International Workshop on Metrology for Agriculture and Forestry (MetroAgriFor)*, Noviembre 2021. IEEE. Trento, Italia. pp: 341–345.
7. Demanet R. 2019. *Manual de especies forrajeras 2019.* Watt's S.A., Universidad de La Frontera. Santiago, Chile.
8. De Oliveira, D. B., and A. C. Gaudio. 2000. BuildQSAR: a new computer program for QSAR analysis. *Quantitative Structure-Activity Relationships: Electroanalysis*, 19 (6): 599-601
9. del Pozo, A., J.I. Matus, M. Garriga, H. Meza, P. Ovalle, C. Barría, R. Teuber y M. Uribe. 2017. Variabilidad genética para tolerancia a la sequía en alfalfas chilenas. *Agro Sur.* 45(1): 29–38.
10. Falcioni, R., Antunes, W. C., Demattê, J. A. M., & Nanni, M. R. (2023a). Reflectance spectroscopy for the classification and prediction of pigments in agronomic crops. *Plants*, 12(12): 2347.
11. Falcioni, R., Antunes, W. C., Oliveira, R. B. d., Chicati, M. L., Demattê, J. A. M., & Nanni, M. R. (2023b). Assessment of combined reflectance, transmittance, and absorbance hyperspectral sensors for prediction of chlorophyll a fluorescence parameters. *Remote Sensing*, 15(20): 5067.

12. Falcioni, R., Gonçalves, J. V. F., de Oliveira, K. M., de Oliveira, C. A., Reis, A. S., Crusiol, L. G. T., Furlanetto, R. H., Antunes, W. C., Cezar, E., de Oliveira, R. B., Chicati, M. L., Demattê, J. A. M., & Nanni, M. R. (2023c). Chemometric analysis for the prediction of biochemical compounds in leaves using UV–VIS–NIR–SWIR hyperspectroscopy. *Plants*, 12(19): 3424.
13. Falcioni, R., Oliveira, R. B. d., Chicati, M. L., Antunes, W. C., Demattê, J. A. M., & Nanni, M. R. (2024). Estimation of biochemical compounds in *Tradescantia* leaves using VIS–NIR–SWIR hyperspectral and chlorophyll a fluorescence sensors. *Remote Sensing*, 16(11): 1910.
14. Fan, W., G. Ge, Y. Liu, W. Wang, Y. Jia. 2018. Proteomics integrated with Metabolomics. Analysis of the internal causes of nutrient changes in alfalfa at different growth stages. *BMC Plant Biol.* 18(1): 78.
15. Feng, Z. Zhang, Y. Ma, Q. Du, P. Williams, J. Drewry and B. Luck. 2020. Alfalfa yield prediction using UAV-based hyperspectral imagery and ensemble learning. *Remote Sens.* 12(12): 2028.
16. Gamez, A. T. Vatter, L. Santesteban. J. Araus and I. Aranjuelo. Onfield estimation of quality parameters in alfalfa through hyperspectral spectrometer data. *Remote Sens. Comput. Electron. Agric.* 216: 108463.
17. Ge, Y., Atefi, A., Zhang, H., Miao, C., Ramamurthy, RK, Sigmon, B., ... y Schnable, JC (2019). Análisis de alto rendimiento de las características fisiológicas y químicas de las hojas mediante espectroscopía VIS-NIR-SWIR: Un estudio de caso con un panel de diversidad de maíz. *Plant methods* , 15 (1): 66.
18. Humphreys, M.O. 2005. Genetic improvement of forage crops – past, present and future. *J. Agric. Sci.* 143(6): 441–448.
19. Jacquemoud, S., & Ustin, S. L. 2019. Leaf optical properties: A state of the art. *Remote Sens. Environ.*, 231, 111211.
20. Kayad, A. G., Al-Gaadi, K. A., Tola, E., Madugundu, R., Zeyada, A. M., & Kalaitzidis, C. (2016). Assessing the spatial variability of alfalfa yield using satellite imagery and ground-based data. *PLoS One*, 11(6): e0157166.
21. Kume, S., Toharmat, T., Nonaka, K., Oshita, T., Nakui, T. y Ternouth, JH (2001). Relación entre la proteína cruda y las concentraciones minerales en la alfalfa y el valor del ensilado de alfalfa como fuente mineral para vacas periparturientas. *Animal Feed Science and Technology* , 93 (3-4): 157-168.
22. Li, D., Hu, Q., Ruan, S., Liu, J., Zhang, J., Hu, C., Liu, Y., Dian, Y., & Zhou, J. 2023. Utilizing hyperspectral reflectance and machine learning algorithms for

- non-destructive estimation of chlorophyll content in citrus leaves. *Remote Sensing*, 15(20): 4934.
23. Luo, H., M. Chen, L. Liu, C. Shu, W. Song, L. Hu, Y. Wang, C. Xu y C. Zhang. 2020. Response strategies of alfalfa to drought stress. *Agronomy*. 10(3): 322.
 24. Noland, M. Scott, J. Coulter, T. Tiede, J. Baker, K. Martinson and C. Sheaffer. 2018. Estimating alfalfa yield and nutritive value using remote sensing and air temperature, *Field Crops Res.* 222: 189–196.
 25. Putnam, D.H. 2019. Ten reasons why alfalfa is highly suitable for the West [en línea]. Utah State University Extension. <https://extension.usu.edu/crops/research/ten-reasons-why-alfalfa-is-highly-suitable-for-the-west>. [Consulta: 3 junio 2025].
 26. Radović, J., D. Sokolović and J. Marković. 2009. Alfalfa – most important perennial forage legume in animal husbandry. *Biotechnol. Anim. Husb.* 25(5–6–1): 465–475.
 27. Rafińska, K., P. Pomastowski, O. Wrona, R. Górecki and B. Buszewski. 2017. *Medicago sativa* as a source of secondary metabolites for agriculture and pharmaceutical industry. *Phytochem. Lett.* 20: 520–539.
 28. Ran, D., Sun, Z., Lu, S., & Omasa, K. (2025). Dorsiventral and angular resistant spectral indices for estimating leaf biochemical traits: scaling from leaf to plant canopy levels. *New Phytologist*, 248(2): 1074-1093.
 29. Rashmi, R., M. Sarkar y V. Vikramaditya. 1997. Cultivation of alfalfa (*Medicago sativa* L.). *Anc. Sci. Life.* 17(2): 117–119.
 30. Reeves C.R. 2010. Genetic algorithms. In: Gendreau M, Potvin JY, (Eds.). *Handbook of Metaheuristics*. Springer, New York. 1: 109–139.
 31. Russelle, M. P. 2001. alfalfa: After an 8,000-year journey, the “Queen of Forages” stands poised to enjoy renewed popularity. *Am. Sci.* 89(3): 252-261.
 32. Sakiroglu, M., K.J. Moore y E.C. Brummer. 2011. Variation in biomass yield, cell wall components, and agronomic traits in a broad range of diploid alfalfa accessions. *Crop Sci.* 51(5): 1956–1964.
 33. Siłuch, M., Siedliska, A., Bartmiński, P., Kociuba, W., Baranowski, P., & Krzyszczak, J. 2023. The impact of water availability on the discriminative status of nitrogen (N) in sugar beet and celery using hyperspectral imaging methods. *Appl. Sci.*, 13(10): 6072.

34. Su, Q., Wang, J., Ling, H., Wang, Z., & Gai, J. 2025. Estimation of chlorophyll and water content in maize leaves under drought stress based on VIS/NIR spectroscopy. *Processes*, 13(10): 3087.
35. Shi, S., L. Nan y K.F. Smith. 2017. The current status, problems, and prospects of alfalfa (*Medicago sativa* L.) breeding in China. *Agronomy*. 7(1): 1.
36. Starks, M. Brown, K. Turner and B. Venuto. 2016. Canopy visible and near-infrared reflectance data to estimate alfalfa nutritive attributes before harvest. *Crop Sci.* 56(1): 484–496.
37. Taylor, N.L. 2008. A century of clover breeding developments in the United States. *Crop Sci.* 48(1): 1–13.
38. Tedesco, L. Nieto, C. Hernandez, J. Rybecky, D. Min, A. Sharda, K. Hamilton and I. Ciampitti. 2022. Remote Sensing on Alfalfa as an Approach to Optimize Production Outcomes: A Review of Evidence and Directions for Future Assessments. *Remote Sens.* 14(19): 4940.
39. The MathWorks Inc. 2023. MATLAB (vR2023a) [software de computación]. The MathWorks Inc.
40. Troncoso, D. 2016. Alfalfa: Factores claves a considerar en su producción. pp: 10–11. *Boletín Infocals N°22*. ANASAC. Chile.
41. Valenzuela, A., L. Andrés, A. Ortega, A. Rodríguez, J. Baeza, C. Barría, R. Leiva y A. Zúñiga. 2017. Simulación del crecimiento de praderas con el modelo BASGRA. *Agro Sur*. 45(1): 63–72.