



**2025 | 16-20**  
**GIJÓN | JUNIO**

**9º CONGRESO FORESTAL ESPAÑOL**

**9CFE-1673**

Actas del Noveno Congreso Forestal Español  
Edita: **Sociedad Española de Ciencias Forestales. 2025.**  
ISBN: **978-84-941695-7-1**

Organiza





## Estimación de calidad forrajera de pastos mediterráneos con reflectancia hiperespectral: desentramando el efecto de la fenología y la transferibilidad de los modelos.

JESÚS FERNÁNDEZ-HABAS\*, ÓSCAR PÉREZ-PRIEGO, PILAR FERNÁNDEZ-REBOLLO

Departamento de Ingeniería Forestal, ETSIAM, Universidad de Córdoba, Ctra. Madrid, Km 396. 14071 Córdoba, España.

\*Autor de correspondencia: [jesus.fdezha@gmail.com](mailto:jesus.fdezha@gmail.com)

### Resumen

Los avances en teledetección de características de la vegetación ofrecen la posibilidad de proporcionar información en tiempo real sobre la calidad de los pastos. Esta información podría ser de utilidad para la gestión de sistemas agrosilvopastorales. Sin embargo, sigue habiendo incertidumbres asociadas a los modelos que limitan su fiabilidad. En este trabajo se estudia el efecto de la fenología en la precisión y utilidad de los modelos, así como su transferibilidad. Se calibraron modelos *Partial Least Squares Regression* con reflectancia hiperespectral medida mediante un espectroradiómetro en pastos de 5 explotaciones en distintas fechas para estimar concentración de proteína bruta (CP%). Los modelos multitemporales, que incluyeron muestras de distintos estadios fenológicos mostraron mejores ajustes ( $R^2_{cv}=0.81$ ) que los modelos calibrados para estados fenológicos específicos ( $R^2_{cv}=0.60$  Verde,  $R^2_{cv}=0.70$  Verde-senescente y  $R^2_{cv}<0$  Senescente). No obstante, la utilidad de estos modelos depende no solo de las características del pasto, sino también del contexto. La transferibilidad entre explotaciones fue baja ( $R^2_{test}$  0-0.60), lo que indica la necesidad de calibrar modelos con conjuntos de datos extensos y diversos, representativos de las distintas condiciones sobre las que se vaya a predecir.

**Palabras clave:** sistemas agrosilvopastorales, proteína bruta, teledetección, *Partial Least Squares Regression*.

### 1. Introducción

La calidad del pasto es uno de los principales determinantes de la capacidad de carga de los pastizales y, por ende, del rendimiento del ganado en pastoreo (COLLINS & NEWMAN, 2018). La calidad de los pastizales está determinada por tres propiedades principales: i) la concentración de nutrientes, ii) la digestibilidad de estos y iii) el consumo voluntario (COLLINS & NEWMAN, 2018). Desde una perspectiva cuantitativa, la calidad de los pastos y forrajes se estima en función de la concentración de principios nutritivos como la proteína cruda, la fibra ácido detergente, la fibra neutro detergente, la energía metabolizable o la digestibilidad de la materia orgánica (DUMONT et al., 2015; PULLANAGARI et al., 2013). Esta información es crucial para tomar decisiones de manejo en sistemas ganaderos extensivos basados en pastizales (SERRANO et al., 2021, 2023).

En comparación con los métodos tradicionales de muestreo y análisis, el desarrollo de la teledetección ha brindado nuevas oportunidades para proporcionar información espacialmente detallada sobre las variables biofísicas y bioquímicas de los pastizales casi en tiempo real y a un coste bajo (ver revisión de ALI et al., 2016). La próxima generación de satélites hiperespectrales, como CHIME y EnMAP fomentará estas aplicaciones al proporcionar información espectral más precisa y completa que los satélites multispectrales (HANK et al., 2019; PULLANAGARI et al., 2013; RASTt et al., 2019). Estudios previos han demostrado el potencial de la teledetección para estimar los parámetros de calidad del pasto, en especial la



concentración o el contenido en proteína bruta (por ejemplo, LUGASSI et al., 2019; MORAIS et al., 2023; SERRANO et al., 2018, 2020), aunque las incertidumbres asociadas a los modelos siguen aún siendo altas (DARVISHZADEH et al., 2008; FERNÁNDEZ-HABAS et al., 2021; LONGMIRE et al., 2023; MORAIS et al., 2023). Por ello, resulta adecuado desentrañar los diversos factores que pueden afectar a la precisión de las predicciones.

Se sabe que fenología estacional de los pastizales está relacionada con la calidad, pero también con algunas propiedades que sustentan la relación entre la calidad y la respuesta espectral del pasto (FÉRET et al., 2017; LU et al., 2021; PACHECO-LABRADOR et al., 2021; VERRELST et al., 2023). En este sentido, se ha argumentado que los modelos que estiman la calidad de los pastizales a partir de su respuesta espectral en diferentes etapas fenológicas, modelos multitemporales, superan a los modelos desarrollados para fases fenológicas específicas (FERNÁNDEZ-HABAS et al., 2022; PULLANAGARI et al., 2021; ZHOU et al., 2019). Sin embargo, en estos modelos multitemporales otros factores, como por ejemplo la diferente estructura del dosel herbáceo, pueden enturbiar la relación entre la reflectividad y los parámetros de calidad del pasto. La calibración de modelos específicos para distintas fases fenológicas podría matizar la relación entre la reflectividad espectral y la calidad, particularmente en pastizales heterogéneos, y permitiría reducir las fuentes de incertidumbre.

Por otro lado, la utilidad de los modelos basados en teledetección para la evaluación de la calidad de los pastizales depende de su capacidad de generalización. Aunque los modelos calibrados en pastizales concretos puedan presentar buenos ajustes, su capacidad para proporcionar estimaciones fiables en otras zonas puede ser baja (MURO et al., 2022; WANG et al., 2019, 2020). Por lo tanto, es esencial probar la generalización de los modelos para facilitar su implementación y evitar inexactitudes desproporcionadas en las estimaciones (MORAIS et al., 2021).

## 2. Objetivos

El objetivo de este estudio fue avanzar en la implementación de modelos basados en teledetección hiperespectral para la evaluación de la proteína bruta de los pastizales investigando (i) la precisión de modelos multitemporales en comparación con modelos específicos para fases fenológicas concretas, y (ii) la capacidad de generalización de los modelos.

## 3. Material y método

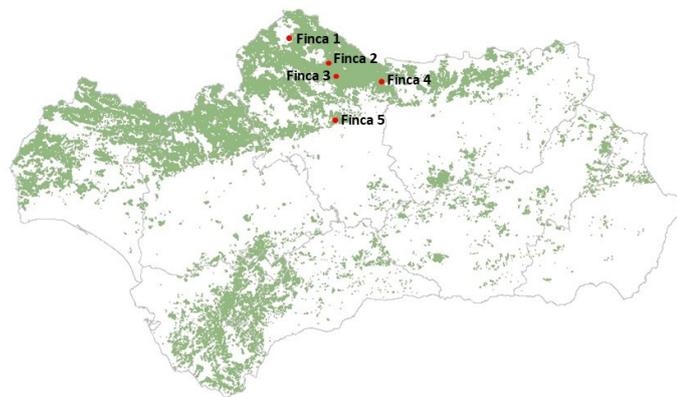
### 3.1. Zona de trabajo, muestreos de pastizales y análisis de calidad

El trabajo se realizó en el norte de la provincia de Córdoba (España), donde se muestrearon pastizales de cinco fincas de dehesa (figura 1). Las fincas están dedicadas a la producción ganadera extensiva (bovino, ovino y porcino) y se sitúan en un gradiente de precipitación anual que va desde los 487 mm hasta los 956 mm, y una altitud que oscila entre los 542 y los 780 m sobre el nivel del mar. Los pastizales permanentes y temporales presentes en estas fincas pertenecen a las alianzas *Helianthemetalia guttati*, *Malcomietalia* y *Poetalia bulbosae*. Algunos de ellos habían sido mejorados en años previos mediante fertilización y siembra de mezclas de leguminosas pratenses.

En cuatro de las fincas (1, 2, 3 y 4), el muestreo se llevó a cabo durante la temporada de crecimiento 2012/2013. Para ello, se instaló en cada finca una parcela de exclusión al pastoreo de 8 m × 4 m. En los meses de enero/febrero, marzo, abril, mayo y junio se cortó el pasto a ras del suelo en cuatro cuadrantes de muestreo de 0.4 m × 0.4 m dentro y fuera de la parcela de exclusión, sin repetir la

misma posición de los cuadrantes de muestreo a lo largo del tiempo. Se obtuvieron 116 muestras útiles en esta campaña de muestreo, dado que en algunas fechas y parcelas la producción en pie del pasto fue demasiado baja y no permitió realizar análisis de laboratorio o tomar medidas de reflectividad.

En la finca 5 el muestreo se realizó en mayo de 2019. Se establecieron de manera aleatoria cuatro cuadrantes de muestreo de 0.4 m × 0.4 m dentro de parcelas amplias (10 m × 10 m) en diferentes zonas de la finca: pastizales mejorados con mezclas de semillas pratenses (6 parcelas), pastizales regados en verano (3 parcelas) y pastizales naturales permanentes (3 parcelas). El pasto dentro de los cuadrantes de muestreo se cortó a ras del suelo. En esta campaña se recogieron 48 muestras de pastos.



*Figura 1. Localización de las fincas en las que muestrearon los pastos. En el fondo, en verde, se muestra la superficie ocupada por formaciones adehesadas en Andalucía (Censo de dehesas, Junta de Andalucía).*

Las muestras de pastos se clasificaron en función de su estado en:

- i) Verde, indicando que el pastizal fue muestreado durante el período de crecimiento vegetativo y floración hasta el inicio de la senescencia en el que comienzan a amarillear.
- ii) Verde-senescente, cuando el pasto fue recolectado después del pico de producción y antes de la senescencia completa.
- iii) Senescente, cuando fue muestreado en plena senescencia.

Las muestras de pastos se secaron en estufa de aire forzado a 60 °C durante 48 h y se molieron hasta pasar por un tamiz de 1 mm. En el laboratorio de Nutrición Animal del SERIDA se determinó, entre otros parámetros, la concentración de proteína bruta (CP%).

### **3.2. Medidas espectrales y preprocesado de los espectros**

Antes de cortar el pasto se tomaron medidas de su reflectividad utilizando un espectroradiómetro ASD FieldSpec (ASD Inc, Boulder, Colorado, EE.UU.). Las mediciones espectrales se realizaron entre las 10:00 y las 15:00 bajo cielo despejado. El espectroradiómetro está equipado con una sonda de fibra óptica montada en una empuñadura que se mantuvo a 1.20 m de altura para permitir



que las mediciones cubrieran un área aproximada de 0.22 m<sup>2</sup>. Se tomaron cuatro medidas de reflectividad por parcela que se promediaron para obtener un único espectro representativo del pasto que se cortaba. El espectroradiómetro se calibró después de cada cuatro mediciones consecutivas utilizando un panel de referencia estándar (Spectralon, Labsphere, NorthSutton, NH). Los espectros se suavizaron utilizando un filtro Savitzky-Golay (SAVITZKY & GOLAY, 1964) de primer orden polinómico con un tamaño de ventana de 15 nm y se eliminaron las regiones que mostraban ruido debido a la absorción de agua (1350-1420 nm y 1800-1950 nm), al propio instrumento (350-399 nm y 2300-2500 nm) o al cambio del detector (999-1003 nm). Por último, se identificaron valores atípicos espectrales mediante un análisis de componentes principales y el estadístico Hotelling T<sup>2</sup> con un umbral del 95% (XU et al., 2018). Este análisis reveló nueve valores atípicos espectrales que se eliminaron del conjunto de datos (N=155).

### 3.3. Modelos y análisis estadísticos

Para cada conjunto de datos (Verde, Verde-senescente y Senescente) y para el total se calibraron modelos PLSR (BURNETT et al., 2021; VERRELST et al., 2015) mediante validaciones cruzadas Leave-One-Out (LOOCV). La fiabilidad de los modelos se evaluó en función de tres métricas: R<sup>2</sup>, la relación entre rendimiento y la desviación (RPD) y el error medio cuadrático (RMSE). RPD se calcula mediante el cociente de la desviación estándar de la variable dependiente y el error estándar de la predicción de dicha variable. Un valor de RPD de 1 significa que el error estándar es igual a la desviación estándar de los datos de referencia, lo que indica que el modelo no tiene utilidad para las predicciones. Para facilitar la comparación el RMSE se normalizó (NRMSE) utilizando el rango de la variable dependiente. Basándose en los valores de RPD y R<sup>2</sup>, se considera que los modelos con RPD>2 y R<sup>2</sup>>0,7 tienen una buena capacidad de hacer estimaciones cuantitativas (ASKARI et al., 2019). Para evaluar la capacidad de generalización de los modelos, se calibraron modelos PLSR con datos de cuatro explotaciones, dejando los de la quinta explotación como conjunto de validación externa. El proceso se realizó de forma iterada cinco veces, para que cada vez una de las explotaciones proporcionara los datos para la validación externa. Adicionalmente y para comparar, se calibró un sexto modelo utilizando el 80% del total de los datos elegidos aleatoriamente (datos de todas las fincas formaban parte del conjunto de calibración), que se validó con el 20% de los datos restantes, considerados datos externos (modelo denominado 80/20). Se calcularon los valores de R<sup>2</sup>, RPD, RMSE y NRMSE de la validación cruzada y externa.

Los análisis espectrales y la calibración de los modelos se realizaron utilizando funciones del paquete *mdatools* (KUCHERYAVSKIY, 2019, 2020) de R v. 4.2 (R DEVELOPMENT CORE TEAM, 2023).

## 4. Resultados

La tabla 1 muestra los valores medios por finca de la concentración de proteína bruta de los pastos muestreados. Globalmente, el valor medio de CP% se situó en 12.8%, con un rango de los datos de 25.9 unidades. A nivel de finca, el valor medio más bajo se obtuvo en la finca 2, localizada en la zona de menor precipitación, mientras que en la finca 1 con mayor precipitación se alcanzó el valor medio más alto. CP% de los pastos de la finca 5 mostró la mayor variabilidad, con un CV de 65.9%. La distribución de muestras recogidas en los estados fenológicos verde, verde-senescente y senescente fue de 60, 60 y 35 respectivamente, aunque la proporción varió entre fincas con el mayor número de muestras senescentes en la

finca 2. La concentración media de proteína bruta para los pastos Verdes fue de 17.1% mientras que para los Verdes-senescentes fue de 11.0% y 8.34% para los Senescentes. El rango de los datos fue de 23.2, 16.3 y 8.69 para las muestras Verdes, Verdes-senescentes y Senescentes respectivamente.

*Tabla 1. Estadísticas descriptivas de la variable proteína bruta del pasto (CP%) en cada una de las fincas y en el total de las muestras y el número de muestras recogidas en cada estado fenológico por finca y en total. CV: coeficiente de variación.*

		Fincas					Total n=155
		1 n=25	2 n=24	3 n=31	4 n=27	5 n=48	
CP%	Media	15.3	10.5	14.2	11.4	12.5	12.8
	Rango	16.8	16.9	12.1	13.0	25.9	25.9
	CV (%)	36.9	37.1	22.5	28.7	65.9	45.8
Estados fenológicos (n)	Verde	11	10	8	8	23	60
	Verde- senescente	7	-	16	12	25	60
	Senescente	7	14	7	7	-	35

El análisis de componentes principales (PCA) explicó el 96.6 % de la varianza de los datos espectrales del 96.6%, (60.7% el eje primer eje principal y 35.9% el segundo) (figura 2). El primer eje contribuyó en gran medida a explicar las diferencias espectrales entre las distintas etapas fenológicas, mostrando una clara separación de la etapa de Senescencia de las otras dos, las cuales mostraron una mayor superposición (figura 2 A). En cuanto a la ubicación de las muestras de pastos procedentes de cada finca en el espacio espectral, algunas de ellas presentaron diferencias constatables mientras que el solape de las muestras de pastos de otras fincas fue importante (figura 2 B).

La firma espectral media de las muestras de pastos según etapa fenológica se presenta en la figura 3. Las muestras Senescentes presentaron una reflectancia media más alta que las de las de las otras dos etapas en la región visible (Vis, 400-700 nm), en la región del infrarrojo cercano (NIR, 700-1300 nm) a partir de 1100 nm, y en toda la región del infrarrojo de onda corta (SWIR, 1300-2350 nm). La reflectancia de la etapa Verde-senescente también mostró una mayor reflectancia en la región verde-roja del visible y, además, fue más baja en la región NIR y más alta en la SWIR en comparación con las muestras de pasto Verde.

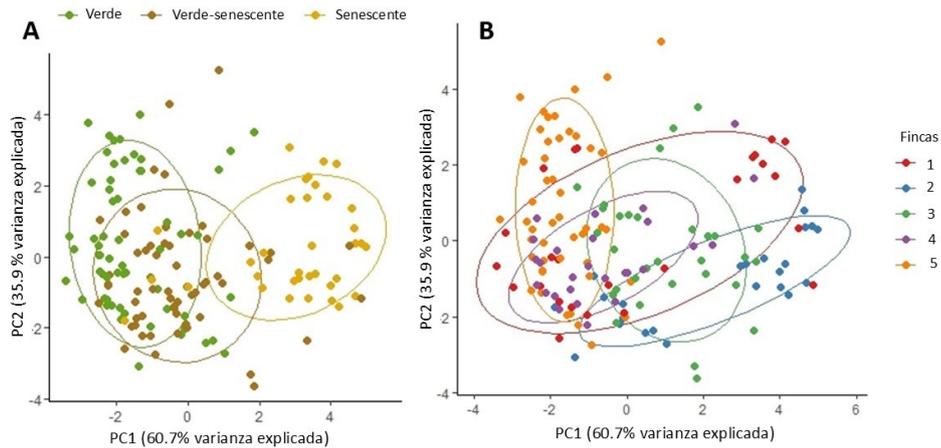


Figura 2. Posición de los datos espectrales en los dos primeros ejes del análisis de componentes principales (PCA) y elipses (95% probabilidad) coloreados según etapa fenológica (A) y finca (B). N=155.

El ajuste del modelo de predicción de proteína bruta (CP%) considerando todos los datos (modelo multitemporal) fue bueno, al igual que su capacidad predictiva, con un  $R^2 = 0.81$ , NRMSE = 9.78% y RPD = 2.31 (figura 3 A). Comparado con el modelo multitemporal, los calibrados para cada fase fenológica mostraron peores ajustes, especialmente el correspondiente a la fase senescente (figura 4 D). La concentración de proteína fue predicha con una precisión moderada en los modelos Verde y Verde-senescente (figura 4 B y C).

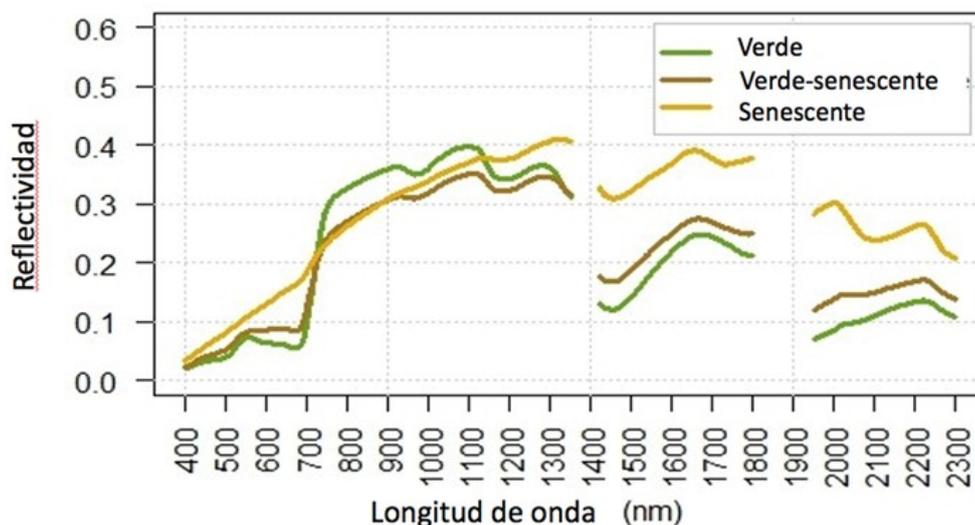


Figura 3. Reflectividad media del pasto en los tres estados fenológicos considerados: Verde (n=60), Verde-senescente (n=60) y Senescente (n=35).

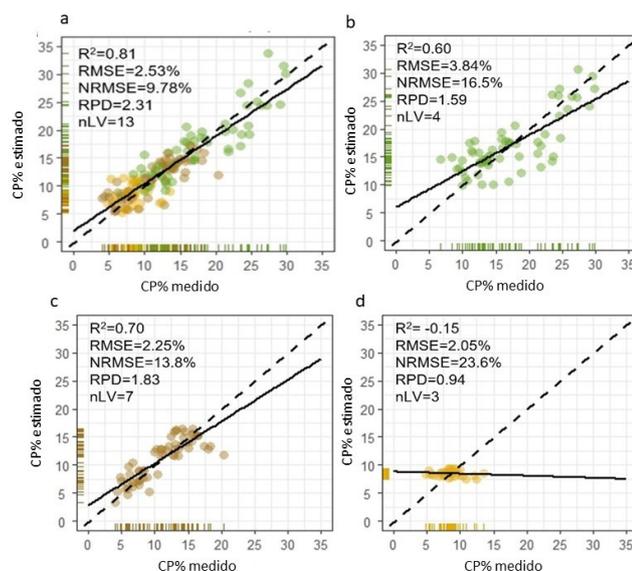


Figura 4. Valores medidos de proteína bruta (CP%) y predichos mediante validación cruzada (Leave-one-out cross-validation, LOOCV) para el modelo multitemporal (a) ( $n=155$ ) y los distintos estados fenológicos considerados: Verde ( $n=60$ ) (b), Verde-senescente ( $n=60$ ) (c) y Senescente ( $n=35$ ) (d).

En general, los modelos demostraron una baja capacidad de generalización, aunque los resultados variaron entre las fincas (tabla 2). A pesar de los valores relativamente altos de  $R^2_{cv}$  y  $RPD_{cv}$  para todas las fincas, los estadísticos mostraron una pobre capacidad predictiva sobre las fincas de validación, que habían sido excluidas del colectivo de calibración de los modelos, con un  $R^2_{test}$  que varió entre -0.06 y 0.60. El estadístico  $NRMSE_{test}$  fue superior al 19% para todas las fincas. Las fincas 2 y 3 mostraron el menor ajuste, con  $R^2_{test} < 0$ , lo que indica una capacidad predictiva inferior al valor medio del colectivo de calibración. La predicción de CP% para las fincas 1 y 5 mostraron valores de  $R^2_{test}$  y  $RPD_{test}$  que indican una capacidad predictiva moderada, aunque con errores de predicción elevados (tabla 2). El modelo construido con el 80% de los datos y validado en el 20% restante (seleccioandos aleatoriamente) arrojó mejores estadísticos, con valores altos de  $R^2_{test}$  y  $RPD_{test}$ , así como un  $NRMSE_{test}$  bajo (tabla 2), muy cercanos al modelo calibrado con todos los datos.

Tabla 2. Estadísticos de la predicción de proteína bruta (CP%) utilizando distintos conjuntos de datos para validación externa (fincas individuales y el 20% de los datos elegidos aleatoriamente). Se muestran los valores de  $R^2$ , RMSE y RPD tanto de la validación cruzada (Leave-one-out, cv) como los de la validación externa (test). nLV= número de variables latentes del modelo.

	Fincas					
	1	2	3	4	5	80/20
N	25	25	31	27	48	28
nLV	14	14	14	13	10	8
$R^2_{cv}$	0.83	0.81	0.82	0.84	0.67	0.74
$R^2_{test}$	0.48	-0.01	-0.06	0.36	0.60	0.72
$RMSE_{cv}$	2.38	2.63	2.64	2.51	2.55	3.00

RMSE <sub>test</sub>	3.97	3.85	3.23	2.57	5.16	2.99
NRMSE <sub>cv</sub>	9.18	10.16	10.19	9.69	12.85	11.60
NRMSE <sub>test</sub>	23.57	22.78	26.65	19.77	19.95	13.86
RPD <sub>cv</sub>	2.44	2.31	2.39	2.49	1.74	1.96
RPD <sub>test</sub>	1.59	1.64	1.17	1.28	1.94	1.98

## 5. Discusión

### 5.1. Modelos multitemporales vs modelos específicos para fenofases

El mejor desempeño de los modelos multitemporales en comparación con los calibrados para fases específicas se explica en gran medida por la mayor variabilidad y rango del conjunto de datos (PULLANAGARI et al., 2021). Esto concuerda con estudios previos que también han documentado mejores estadísticas para modelos multitemporales en comparación con modelos específicos de fenofases (ver ejemplos en PULLANAGARI et al., 2021; ZENG y CHEN, 2018; ZHOU et al., 2019). Los modelos multitemporales podrían presentar una mayor capacidad de generalización a diferentes condiciones fenológicas, lo cual es de crucial importancia en los pastizales mediterráneos que muestran una elevada diversidad; sin embargo, su precisión debe interpretarse con cautela. El rango de CP% en las muestras senescentes es relativamente pequeño (8.7) en comparación con el RMSE del modelo multitemporal (2.53%), lo que significa que la capacidad de estos modelos para discriminar áreas del pasto con calidad diferenciada cuando éste está agostado puede ser baja. Por el contrario, en momentos como el inicio de la senescencia, con grandes diferencias fenológicas a escala de parcela, las predicciones de proteína bruta podrían ayudar a identificar áreas con mejor calidad en el pasto con una mayor precisión. Las estadísticas de los modelos basados en teledetección parecen depender principalmente de las relaciones entre la fenología y la concentración de clorofila en la planta con el contenido en proteína bruta (MUTANGA y SKIDMORE, 2007). A medida que la fenología avanza, el contenido de clorofila disminuye y comienza a descomponerse en favor de otros pigmentos (VERRELST et al., 2023). Además, durante las fases de floración y formación de frutos y semillas, el N se redistribuye en la planta dirigiéndose hacia estos nuevos órganos (flor, fruto, semilla), donde la penetración de luz es más débil (BERGER et al., 2020a, 2020b). Estos procesos, junto con la menor variabilidad mencionada, pueden explicar por qué la estimación de proteína bruta es menos precisa en pastizales senescentes.

No obstante, más allá de los parámetros estadísticos que evalúan los modelos, su utilidad depende del contexto. Así, a lo largo de la fase de crecimiento vegetativo y hasta plena floración, tanto los modelos multitemporales como específicos pueden discriminar zonas o periodos con diferente concentración de proteína bruta, ayudando en la toma de decisiones. Sin embargo, el uso de los modelos pierde interés en escenarios diferentes, como pueden ser pastizales muy uniformes o durante la senescencia, debido tanto a la baja variabilidad espacial en la concentración de proteína, como a la pobre precisión de los modelos.

### 5.2 Generalización de los modelos

Los resultados muestran claramente que los modelos calibrados carecen de capacidad de generalización. Esto constituye la principal limitación de los modelos empíricos que predicen propiedades biofísicas de la vegetación (ver MURO et al., 2022; VERRELST et al., 2015). En el caso de los pastizales mediterráneos, esta debilidad podría ser aún más elevada debido a su alta variabilidad y diversidad. MURO et al. (2022) identificaron la falta de generalización como una de las



principales deficiencias de los modelos empíricos (en su caso calibrados mediante técnicas como Random Forest y Redes Neuronales Profundas) en la estimación de la biomasa vegetal y la riqueza de especies en pastizales templados. El ajuste de los modelos demostró depender de las características y la representatividad de las muestras. Por ejemplo, las fincas con una mayor proporción de muestras de pastos senescentes mostraron peores ajustes (como por ejemplo la finca 2 con  $R^2_{\text{test}} = -0.01$ ), mientras que aquellas con predominancia de muestras Verdes y Verde-senescente (la finca 5 con  $R^2_{\text{test}} = 0.60$ ) obtuvieron mejores resultados. Además, las fincas con mayor cobertura del espacio espectral, como la finca 1, mostraron un ajuste superior ( $R^2_{\text{test}} = 0.48$ ), a pesar de que el  $\text{NRMSE}_{\text{test}}$  exhibió una considerable variabilidad en todos los casos ( $>19\%$ ). Esto sugiere que los modelos PLSR calibrados con pocas muestras (menos de 200) son inadecuados para extrapolarse a condiciones que difieren bastantes de las de calibración (PULLANAGARI et al., 2021). Algoritmos no lineales más complejos como las Redes Neuronales Convolucionales (CNN), precisan de mayor número de muestras en la fase de calibración, alrededor de 1500 (MORAIS et al., 2021; PULLANAGARI et al., 2021). Aun así, en nuestro estudio, los modelos PLSR mostraron un buen ajuste cuando se aplicaron a condiciones similares a las del colectivo de calibración, como muestran los resultados del modelo general, denominado 80/20, con RMSE y  $R^2$  alrededor de 3 y 0.73.

Otro aspecto importante destacado por PATEL et al. (2023), es la correlación cruzada entre variables biofísicas y bioquímicas del dosel vegetal en ciertos momentos (por ejemplo, una gestión particular, etapa fenológica o composición botánica), que puede llevar a que los modelos aprendan patrones y atributos (por ejemplo, fenología o LAI) más dominantes que la variable objetivo, enmascarando la verdadera sensibilidad del modelo hacia la variable objetivo (por ejemplo, CP%) (PATEL et al., 2023). Parece que esto toma mayor importancia cuando el colectivo de calibración es reducido.

A partir de los resultados, se puede concluir que el uso de modelos empíricos para predecir la calidad del pasto con un colectivo de calibración limitado solo puede proporcionar estimaciones realistas y útiles si se aplican a condiciones similares a la de calibración. Por lo tanto, para avanzar hacia la implementación práctica de los modelos empíricos de estimación de la calidad de los pastos basados en datos hiperespectrales, los esfuerzos deben dirigirse a seleccionar colectivos de calibración representativos de las distintas condiciones ambientales y manejos de los pastizales mediterráneos (SCHWEIGNER, 2020). Por otro lado, la combinación de técnicas de aprendizaje activo con métodos híbridos (ver BERGER et al., 2021) es un enfoque interesante para enfrentar las limitaciones de los métodos empíricos (como PLSR), aprovechando las ventajas de ambos (BERGER et al., 2020; DARVISHZADEH et al., 2008; VERRELST et al., 2015).

## 6. Conclusiones

El modelo multitemporal mostró mejores ajustes que los modelos calibrados para fases fenológicas específicas. No obstante, la capacidad para estimar la concentración de proteína bruta en pastizales senescentes es limitada. Es necesario tener en cuenta que la utilidad de los modelos depende del contexto, y su aplicación requiere conocer sus limitaciones más allá de la evaluación de las estadísticas de precisión.

La capacidad de generalización de los modelos empíricos en los pastizales mediterráneos es baja, por lo que no son útiles para la predicción en condiciones



diferentes a las de calibración.

Los esfuerzos deben dirigirse a la ampliación del colectivo de calibración con muestras representativas de las distintas estructuras del dosel herbáceo, condiciones ambientales y de manejo. Esto junto al uso de modelos híbridos puede ser el camino que seguir para resolver las limitaciones que presentan los modelos empíricos y aprovechar el potencial que ofrecen los datos hiperespectrales de los satélites actuales y futuros. No obstante, se requiere más investigación para confirmar la utilidad de los modelos híbridos en pastizales mediterráneos.

### 7. Agradecimientos

Agradecemos a los ganaderos de las fincas el haber permitido que hayamos trabajado en sus propiedades. Este trabajo ha sido financiado por los proyectos (1) GRASSEN: Plataforma de apoyo a la gestión de pastos mediterráneos mediante sensores próximos y remotos ID: G14814354 y (2) Nuevos pastos de leguminosas perennes para la dehesa: Provisión de Servicios Ecosistémicos en condiciones de mayor aridez (Pastos-SEcos) ID: ProyExcel\_00465.

### 8. Bibliografía

- ALI, I., CAWKWELL, F., DWYER, E., BARRETT, B., GREEN, S. 2016. Satellite remote sensing of grasslands: From observation to management. *J. Plant Ecol.*, 9, 649–671.
- ASKARI, M.S., MCCARTHY, T., MAGEE, A., MURPHY, D.J. 2019. Evaluation of grass quality under different soil management scenarios using remote sensing techniques. *Remote Sens.* 11, 1–23.
- BERGER, K., RIVERA CAICEDO, J. P., MARTINO, L., WOCHER, M., HANK, T., VERRELST, J. 2021. A survey of active learning for quantifying vegetation traits from terrestrial earth observation data. *Remote Sens.*, 13, 1–23.
- BERGER, K., VERRELST, J., FÉRET, J. B., HANK, T., WOCHER, M., MAUSER, W., CAMPS-VALLS, G. 2020. Retrieval of aboveground crop nitrogen content with a hybrid machine learning method. *Int. J. Appl. Earth Obs. Geoinf.*, 92, 102174.
- BERGER, K., VERRELST, J., FÉRET, J. B., WANG, Z., WOCHER, M., STRATHMANN, M., ... HANK, T. 2020. Crop nitrogen monitoring: Recent progress and principal developments in the context of imaging spectroscopy missions. *Remote Sens. Environ.*, 242.
- BURNETT, A. C., ANDERSON, J., DAVIDSON, K. J., ELY, K. S., LAMOUR, J., LI, Q., ... SERBIN, S. P. 2021. A best-practice guide to predicting plant traits from leaf-level hyperspectral data using partial least squares regression. *J. Exp. Bot.*, 72, 6175–6189.
- COLLINS, MICHAEL, NEWMAN, Y. C. 2018. Forage Quality. In Micahel Collins, C. J. Nelson, K. J. Moore, R. F. Barnes (Eds.), *Forages, Volume 1: An Introduction to Grassland Agriculture* (John Wiley, pp. 363–390). Hoboken, USA: John Wiley Sons, Inc.
- DARVISHZADEH, R., SKIDMORE, A., SCHLERF, M., ATZBERGER, C. 2008. Inversion of a radiative transfer model for estimating vegetation LAI and chlorophyll in a heterogeneous grassland. *Remote Sens. Environ.*, 112, 2592–2604.
- DUMONT, B., ANDUEZA, D., NIDERKORN, V., LÜSCHER, A., PORQUEDDU, C., PICON-COCHARD, C. 2015. A meta-analysis of climate change effects on forage quality in grasslands: specificities of mountain and mediterranean areas. *Grass Forage Sci.*, 70, 239–254.
- FÉRET, J. B., GITELSON, A. A., NOBLE, S. D., JACQUEMOUD, S. 2017. PROSPECT-D: Towards modeling leaf optical properties through a complete lifecycle. *Remote Sens. Environ.*, 193, 204–215.
- FERNÁNDEZ-HABAS, J., CARRIERE CAÑADA, M., GARCÍA MORENO, A. M., LEAL-



- MURILLO, J. R., GONZÁLEZ-DUGO, M. P., ABELLANAS OAR, B., FERNÁNDEZ-REBOLLO, P. 2022. Estimating pasture quality of Mediterranean grasslands using hyperspectral narrow bands from field spectroscopy by Random Forest and PLS regressions. *Comput. Electron. Agric.*, 192.
- FERNÁNDEZ-HABAS, J., GARCÍA MORENO, A. M., HIDALGO-FERNÁNDEZ, M. T., LEAL-MURILLO, J. R., ABELLANAS OAR, B., GÓMEZ-GIRÁLDEZ, P. J., FERNÁNDEZ-REBOLLO, P. 2021. Investigating the potential of Sentinel-2 configuration to predict the quality of Mediterranean permanent grasslands in open woodlands. *Sci. Total Environ.*, 791, 148101.
- HANK, T. B., BERGER, K., BACH, H., CLEVERS, J. G. P. W., GITELSON, A., ZARCO-TEJADA, P., MAUSER, W. 2019. Spaceborne Imaging Spectroscopy for Sustainable Agriculture: Contributions and Challenges. *Surveys in Geophysics (Vol. 40)*. Springer Netherlands.
- KUCHERYAVSKIY, S., 2019. Package ‘mdatools’.
- KUCHERYAVSKIY, S., 2020. mdatools – R package for chemometrics. *Chemom. Intell. Lab. Syst.* 198, 103937.
- LONGMIRE, A., POBLETE, T., HORNERO, A., CHEN, D., ZARCO-TEJADA, P. J. 2023. Estimation of grain protein content in commercial bread and durum wheat fields via traits inverted by radiative transfer modelling from Sentinel-2 timeseries. *ISPRS J. Photogramm. Remote Sens.*, 206, 49–62.
- LU, B., PROCTOR, C., HE, Y. 2021. Investigating different versions of PROSPECT and PROSAIL for estimating spectral and biophysical properties of photosynthetic and non-photosynthetic vegetation in mixed grasslands. *GIScience Remote Sens.*, 58, 354–371.
- LUGASSI, R., ZAADY, E., GOLDSHLEGER, N., SHOSHANY, M., CHUDNOVSKY, A. 2019. Spatial and temporal monitoring of pasture ecological quality: Sentinel-2-based estimation of crude protein and neutral detergent fiber contents. *Remote Sens.*, 11.
- MORAIS, T. G., JONGEN, M., TUFIK, C., RODRIGUES, N. R., GAMA, I., FANGUEIRO, D., TEIXEIRA, R. F. M. 2023. Characterization of portuguese sown rainfed grasslands using Remote Sens. and machine learning. *Precis. Agric.*, 24, 161–186.
- MORAIS, T. G., TEIXEIRA, R. F. M., FIGUEIREDO, M., DOMINGOS, T. 2021. The use of machine learning methods to estimate aboveground biomass of grasslands: A review. *Ecol. Indic.*, 130, 108081.
- MURO, J., LINSTÄDTER, A., MAGDON, P., WÖLLAUER, S., MÄNNER, F. A., SCHWARZ, L. M., DUBOVYK, O. 2022. Predicting plant biomass and species richness in temperate grasslands across regions, time, and land management with Remote Sens. and deep learning. *Remote Sens. Environ.*, 282.
- MUTANGA, O., SKIDMORE, A. K. 2007. Red edge shift and biochemical content in grass canopies. *ISPRS J. Photogramm. Remote Sens.*, 62, 34–42.
- PACHECO-LABRADOR, J., EL-MADANY, T. S., VAN DER TOL, C., MARTIN, M. P., GONZALEZ-CASCON, R., PEREZ-PRIEGO, O., MIGLIAVACCA, M. 2021. senSCOPE: Modeling mixed canopies combining green and brown senesced leaves. Evaluation in a Mediterranean Grassland. *Remote Sens. Environ.*, 257, 112352.
- PATEL, M. K., PADARIAN, J., WESTERN, A. W., FITZGERALD, G. J., MCBRATNEY, A. B., PERRY, E. M., RYU, D. 2023. Retrieving canopy nitrogen concentration and aboveground biomass with deep learning for ryegrass and barley: Comparing models and determining waveband contribution. *Field Crops Res.*, 294, 108859.
- PULLANAGARI, R. R., DEGHAN-SHOAR, M., YULE, I. J., BHATIA, N. 2021. Field spectroscopy of canopy nitrogen concentration in temperate grasslands using a convolutional neural network. *Remote Sens. Environ.*, 257.



- PULLANAGARI, REDDY R, KING, W. M., YULE, I. J., THULIN, S., KNOX, N. M., RAMOELO, A. 2013. Remote sensing of Pasture Quality. In D. L. Michalk, G. D. Millar, W. B. Badgery, K. M. Broadfoot (Eds.), Proc. 22nd International Grasslands Congress (pp. 15–19). Sydney, Australia: New South Wales Department of Primary Industry, Kite St., Orange New South Wales, Australia.
- RAST, M., ANANASSO, C., BACH, H., DOR, E., CHABRILLAT, S., COLOMBO, R., STROBL, P. 2019. Copernicus Hyperspectral Imaging Mission for the Environment-Mission Requirements Document. European Space Agency, ESA-EOPSM-CHIM-MRD-3216.
- SAVITZKY, A., GOLAY, M.J.E.. 1964. Smoothing and differentiation. *Anal. Chem.* 36,1627–1639.
- SCHWEIGER, A. K. 2020. Spectral Field Campaigns: Planning and Data Collection. In J. Cavender-Bares, J. A. Gamon, P. A. Townsend (Eds.), Remote Sens. of Plant Biodiversity (Springer N, pp. 385–425). Saint Paul, MN, USA: Springer Open.
- SERRANO, J., MENDES, S., SHAHIDIAN, S., MARQUES DA SILVA, J. 2023. Pasture Quality Monitoring Based on Proximal and Remote Optical Sensors: A Case Study in the Montado Mediterranean Ecosystem. *AgriEngineering*, 5, 380–394.
- SERRANO, J., SHAHIDIAN, S., DA SILVA, J. M. 2018. Monitoring seasonal Pasture Quality Degradation in the Mediterranean montado ecosystem: Proximal versus Remote Sensing. *Water*, 10.
- SERRANO, J., SHAHIDIAN, S., DA SILVA, J. M., PAIXÃO, L., CARREIRA, E., CARMONA-CABEZAS, R., RATO, A. E. 2020. Evaluation of near infrared spectroscopy (NIRS) and Remote Sensing (RS) for estimating pasture quality in Mediterranean montado ecosystem. *Appl. Sci.*, 10.
- SERRANO, J., SHAHIDIAN, S., PAIXÃO, L., MARQUES DA SILVA, J., MORAIS, T., TEIXEIRA, R., DOMINGOS, T. 2021. Spatiotemporal patterns of pasture quality based on ndvi time-series in mediterranean montado ecosystem. *Remote Sens.*, 13.
- VERRELST, J., CAMPS-VALLS, G., MUÑOZ-MARÍ, J., RIVERA, J. P., VEROUSTRAETE, F., CLEVERS, J. G. P. W., MORENO, J. 2015. Optical remote sensing and the retrieval of terrestrial vegetation bio-geophysical properties - A review. *ISPRS J. Photogramm. Remote Sens.*, 108, 273–290.
- VERRELST, J., HALABUK, A., ATZBERGER, C., HANK, T., STEINHAUSER, S., BERGER, K. 2023. A comprehensive survey on quantifying non-photosynthetic vegetation cover and biomass from imaging spectroscopy. *Ecol. Indic.*, 155, 110911.
- WANG, Z., CHLUS, A., GEYGAN, R., YE, Z., ZHENG, T., SINGH, A., TOWNSEND, P. A. 2020. Foliar functional traits from imaging spectroscopy across biomes in eastern North America. *New Phytol.*, 228, 494–511.
- WANG, Z., TOWNSEND, P. A., SCHWEIGER, A. K., COUTURE, J. J., SINGH, A., HOBBIE, S. E., CAVENDER-BARES, J. 2019. Mapping foliar functional traits and their uncertainties across three years in a grassland experiment. *Remote Sens. Environ.*, 221, 405–416.
- XU, S., ZHAO, Y., WANG, M., SHI, X. 2018. Comparison of multivariate methods forestimating selected soil properties from intact soil cores of paddy fields by Vis-NIR spectroscopy. *Geoderma* 310, 29–43.
- ZENG, L., CHEN, C. 2018. Using remote sensing to estimate forage biomass and nutrient contents at different growth stages. *Biomass and Bioenergy*, 115, 74–81.
- ZHOU, Z., MOREL, J., PARSONS, D., KUCHERYAVSKIY, S. V., GUSTAVSSON, A. M. 2019. Estimation of yield and quality of legume and grass mixtures using partial least squares and support vector machine analysis of spectral data. *Comput. Electron. Agric.*, 162, 246–253.